# UVOD U METODOLOGIJU DRUŠTVENIH ZNANOSTI

Željko Pavić
Antun Šundalić

*Za nakladnika:*
Izv. prof. dr. sc. Leonard Pon

*Recenzenti:*
Prof. dr. sc. Branko Matić
Prof. dr. sc. Josip Mesarić

*Lektura i korektura:*
Ivana Žužul

*Grafičko oblikovanje i tisak:*
Krešendo, Osijek

ISBN 978-953-314-144-2

CIP zapis dostupan u računalnom katalogu
Gradske i sveučilišne knjižnice Osijek pod brojem 150326096.

Objavljivanje ovoga udžbenika odobrio je Senat Sveučilišta Josipa Jurja Strossmayera u Osijeku na svojoj 5. sjednici u akademskoj godini 2020./21. održanoj 24. veljače 2021. godine (broj suglasnosti 2/21).

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FILOZOFSKI FAKULTET OSIJEK

# UVOD U METODOLOGIJU DRUŠTVENIH ZNANOSTI

Drugo, dopunjeno izdanje

Željko Pavić

Antun Šundalić

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FILOZOFSKI FAKULTET

Osijek, 2021.

# SADRŽAJ

**PREDGOVOR** ... 9

**PREDGOVOR DRUGOM, DOPUNJENOM IZDANJU** ... 11

**1. O ZNANJU KAO TEORIJI I PRAKSI – RAZLIČITI PRISTUPI** ... 13

**2. ZNANOST I DRUŠTVENI RAZVOJ** ... 19
2.1. Kratki povijesni ekskurs ... 21
2.2. Put do autonomije sveučilišta ... 27
2.3. Znanstvena revolucija ... 30
2.4. Zadatci znanosti i obrazovanja u suvremenosti ... 34
2.5. Vrijeme znanosti i inovacija – tehnoznanost ... 36
2.6. Etička dimenzija razvoja i upotrebe znanosti ... 41
2.7. O pozivu znanstvenika u društvu znanja ... 44

**3. ODREĐENJE ZNANOSTI I ZNANSTVENE TEORIJE** ... 51
3.1. Klasifikacija znanosti ... 62
3.2. Zadatci i obilježja znanosti ... 65

**4. ZNANSTVENO ISTRAŽIVANJE** ... 71
4.1. Klasifikacija znanstvenih istraživanja ... 71
4.1.1. Podjela prema stupnju znanstvenosti ... 72
4.1.2. Podjela prema stupnju uopćavanja ... 73
4.1.3. Kvantitativna i kvalitativna istraživanja ... 73
4.1.4. Prethodna i konačna istraživanja ... 77
4.1.5. Povremena i stalna istraživanja ... 77
4.1.6. Istraživanja prema nositelju istraživanja ... 78
4.1.7. Istraživanja prema disciplinarnosti ... 78
4.1.8. Istraživanja prema razini obuhvata ... 79
4.1.9. Istraživanja prema razini znanstvene spoznaje ... 79
4.2. Komponente znanstveno-istraživačkog procesa ... 85
4.3. Istraživačka etika ... 94

**5. MJERENJE I MJERNI INSTRUMENTI** ... 105
5.1. Razine mjerenja ... 105
5.2. Mjerne skale ... 108
5.2.1. Definicija i osnovne vrste mjernih skala ... 108

5.2.2. Skale rangiranja ... 109
5.2.3. Skale uspoređivanja u parovima ... 110
5.2.4. Skale konstantne sume ... 111
5.2.5. Kontinuirana ljestvica procjene ... 112
5.2.6. Stapelova skala ... 112
5.2.7. Semantički diferencijal ... 113
5.2.8. Likertova skala ... 115
5.2.9. Thurstoneova skala ... 117
5.2.10. Guttmanova skala ... 120
5.3. Mjerni instrumenti ... 122
5.3.1. Mjerne karakteristike instrumenata ... 124
5.3.2. Baždarenje mjernih instrumenta ... 135

**6. UZORKOVANJE** ... 137
6.1. Temeljni pojmovi uzorkovanja ... 137
6.2. Osnovne vrste uzoraka ... 145

**7. ISTRAŽIVAČKI NACRTI** ... 157
7.1. Tipovi istraživačkih nacrta ... 157
7.2. Korelacijski nacrt ... 158
7.3. Longitudinalni nacrt ... 162
7.4. Eksperimentalni nacrt ... 169
7.4.1. Osnovna obilježja eksperimentalnih istraživanja ... 169
7.4.2. Eksperimentalna kontrola ... 174
7.4.3. Valjanost eksperimentalnih istraživanja ... 183
7.4.4. Kvazieksperimentalna istraživanja ... 187
7.5. Nedostatci eksperimentalnih istraživanja ... 189

**8. ANKETNA ISTRAŽIVANJA** ... 193
8.1. Definicija anketnih istraživanja ... 193
8.2. Vrste anketnih pitanja ... 196
8.3. Postavljanje socijalno osjetljivih pitanja o ponašanju ... 198
8.4. Postavljanje „neprijetećih“ pitanja o ponašanju ... 204
8.5. Najčešće pogreške u formulaciji anketnih pitanja ... 207
8.5.1. Pogreške koje uključuju pristranost u mjerenju konstrukta ... 207
8.5.2. Pogreške koje proizlaze iz nekonzistentnog razumijevanja pitanja ... 208
8.5.3. Pogreške koje su rezultat nepostojanja odgovarajućih informacija ... 211

8.5.4. Pogreške koje su rezultat neodgovarajuće forme odgovora ..... 212
8.6. Redoslijed pitanja u upitniku ..... 214
8.7. Demografska pitanja ..... 218
8.7.1. Pitanja o dohotku ..... 218
8.7.2. Pitanja o dobi ..... 2220
8.7.3. Pitanja o zanimanju ..... 221
8.8. Načini prikupljanja podataka pomoću upitnika ..... 221
8.9. Izvori pogreške u anketnom istraživanju ..... 226
8.10. Upotreba upitnika u međukulturnim istraživanjima ..... 229
8.11. Predtestiranje upitnika ..... 230

**9. KVALITATIVNE METODE** ..... 235
9.1. Osnovna obilježja kvalitativnih metoda ..... 235
9.2. Opažanje ..... 240
9.3. Intervju ..... 211
9.4. Studija slučaja ..... 252
9.5. Fokus grupe ..... 257
9.5.1. Osnovna obilježja, svrhe i organizacija fokus grupa ..... 257
9.5.2. *Online* fokus grupe ..... 268
9.6. Delfi metoda ..... 273
9.7. Analiza sadržaja ..... 274
9.7.1. Definicija i vrste analize sadržaja ..... 274
9.7.2. Osnovni elementi analize sadržaja ..... 276
9.7.3. Mjerna obilježja analize sadržaja ..... 283
9.8. Analiza diskursa i analiza konverzacije ..... 294
9.9. Projektivne tehnike ..... 304

**10. PRIMIJENJENA ISTRAŽIVANJA** ..... 309
10.1. Medijska istraživanja – istraživanja medijske publike ..... 309
10.1.1. Čitanost tiskanih medija ..... 310
10.1.2. Posjećenost interneta ..... 313
10.1.3. Televizijska gledanost ..... 315
10.1.4. Radijska slušanost ..... 317
10.1.5. Marketinški medijski indikatori ..... 319
10.2. Istraživanja tržišta ..... 320

**11. KLASIFIKACIJA ZNANSTVENIH RADOVA** ..... 325
11.1. Znanstvene knjige ..... 325
11.2. Znanstveni članci ..... 326
11.3. Znanstveni i stručni priručnici ..... 328
11.4. Znanstveni i stručni radovi prema sadržaju ..... 330
11.5. Znanstveni i stručni radovi kao publikacije ..... 332

**12. STRUKTURA ZNANSTVENOG I STRUČNOG DJELA** ..... 335
12.1. Glavni dijelovi ..... 335
12.2. Orijentacijski dijelovi ..... 337
12.3. Pomoćni dijelovi ..... 339

**13. PISANJE ZNANSTVENOG I STRUČNOG DJELA** ..... 343
13.1. Citiranje, parafraziranje, interpretiranje ..... 343
13.2. Pozivna bilješka ..... 349
13.3. Ilustracije ..... 350
13.4. Literatura ..... 357

**14. OBJAVLJIVANJE ZNANSTVENOG I STRUČNOG DJELA** ..... 361
14.1. Forma ili oblik pisanja ..... 361
14.2. Stil pisanja ..... 362
14.3. Znanstvena i stručna kritika rada ..... 365
14.4. Uvjeti objavljivanja rukopisa ..... 366
14.5. Kako pisati? ..... 368
14.5.1. Seminarski rad ..... 368
14.5.2. Završni rad ..... 368
14.5.3. Diplomski rad ..... 369
14.5.4. Doktorska disertacija ..... 369
**LITERATURA** ..... 371
**KAZALO IMENA** ..... 381
**KAZALO TEMELJNIH POJMOVA** ..... 384
**BILJEŠKE O AUTORIMA** ..... 388

# PREDGOVOR

Obrazovanje već više od dva stoljeća čini važno razdoblje svačijeg života. Dok se nekada obrazovanje smatralo statusnim simbolom, ono je danas postalo egzistencijalnom potrebom. Nekada je ono trajalo nekoliko godina, a danas smo skloni govoriti o cjeloživotnom obrazovanju. No, ne samo da se produljilo trajanje obrazovanja, promijenio se i njegov sadržaj. Stalno umnožavanje novih i novih znanja uzrokovalo je nužnu selekciju obrazovnih sadržaja za različite profesije, za različita usmjerenja i specijalnosti. Otuda je obrazovni proces dobio i svojevrsnu zadaću selekcije prema sposobnostima i željama za dulje ili kraće obrazovne procese u institucionalnom okviru. Različita ponuda – od gimnazija i različitih strukovnih škola do visokih stručnih i znanstvenih programa – diferencira društvo prema postignutom obrazovnom stupnju/programu. Obrazovanje je u socioprofesionalnom pogledu postalo vrlo moćna pokretačka poluga promjene socijalnoga statusa pojedinca, pa je zato i postalo jedno od neotuđivih prava građana u demokratskom svijetu.

Obrazovanje pruža uvid u dosege znanosti. Što je viša razina obrazovanja, to je znanstvenost razumijevanja i objašnjavanja činjenica i zakonitosti prirode i društva veća a programi sve složeniji i zahtjevniji. Fakultetsko obrazovanje, posebice diplomska i poslijediplomska razina, trebaju studentima otvoriti vrata prema znanosti. Vođenje na putu prema znanosti na sebe preuzimaju znanstvenici, profesori na fakultetima.

Od nedovoljno upućenih može se čuti kako je vrijeme profesora i nastave „ex cathedra“ prošlost jer ih sve više u prenošenju informacija i sadržaja obrazovnih procesa zamjenjuje računalna tehnologija, tzv. internetizacija društva. Često je iskazana veća vjera u dostupnost računalnih internetskih baza, negoli znanstvenost bogate knjiške građe na koju se oslanja višegodišnje fakultetsko obrazovanje. Unatoč tome što je informatizacija postala globalnim procesom koji povezuje društva i kulture, znanstvenike i studente, ona ne predstavlja put do znanstvene spoznaje kakav predstavlja ukupno obrazovanje, posebice fakultetsko i ne može ga zamijeniti. Upravo suprotno, nužno je njihovo spajanje, dopunjavanje i oživljavanje potrebe za novim modusima akumuliranja i širenja znanja obrazovanjem. To, pak, stavlja pred nastavnike posebno važnu zadaću posredovanja između studenata i znanstvenih sadržaja u obrazovnom procesu koji se produljuje.

Znanstvena teorija, kao i znanstvena praksa, moraju postati jednako bitne pri ulasku u znanost, bilo da se služimo primarnim, sekundarnim ili tercijarnim izvorima informacija. Studente treba uvesti u znanost pomoću jasnih odred-

nica same znanosti, faza znanstveno-istraživačkog procesa, vrsta znanstvenih istraživanja, odrednica znanstvenog i stručnog rada i ostalog potrebnog za što potpunije doživljavanje znanosti. Time će i znanstveni sadržaji biti metodološki prepoznati kao sastavnice života prirode i društva, kao zakonitosti koje znanost otkriva, njima prilagođava čovjekove aktivnosti, ili ih pomoću njih mijenja.

Upravo na tragu takvog prilaženja znanosti, ovaj udžbenik ima četverostruku zadaću: 1. pružiti studentima osnovni *uvid u društvenu uvjetovanost proizvodnje znanja i povijesni razvoj znanosti*; 2. osposobiti studente za *upotrebu znanstvene literature* s kojom se susreću tijekom studija i sve prisutnijeg cjeloživotnog učenja; 3. osposobiti studente da *društvenim pojavama pristupaju na znanstveni način;* 4. osposobiti studente za *provođenje samostalnih znanstvenih i stručnih istraživanja* usvajanjem temeljnih istraživačkih metoda i tehnika. Rezultat toga trebao bi biti i osposobljenost studenata za kvalitetno pisanje seminarskih i završnih radova na svim razinama obrazovnog procesa.

Te se zadaće ogledaju i u strukturi udžbenika. Nakon povijesnog prikaza razvoja znanosti, slijede njezino određenje i klasifikacija. Metode i tehnike istraživanja obrađene su s minimalnim pozivom na statističku analizu podataka, samo tamo gdje je to bilo nužno jer studenti statistiku slušaju u sklopu posebnih kolegija. Završni dijelovi udžbenika posvećeni su pisanju i objavljivanju znanstvenog rada.

Udžbenik je nastao za potrebe izvođenja metodoloških kolegija na Sveučilištu Josipa Jurja Strossmayera u Osijeku, no nadamo se da će biti koristan i svima onima koji se žele upoznati s osnovama istraživačke metodologije u društvenim znanostima.

*Autori*

# PREDGOVOR DRUGOM, DOPUNJENOM IZDANJU

Imajući u vidu da je od prvog izdanja udžbenika proteklo osam godina, ukazala se potreba da se udžbenik dopuni u skladu s novim spoznajama i istraživanjima u području metoda istraživanja u društvenim znanostima. Stoga ovo izdanje udžbenika sadrži oko 40% više materijala u odnosu na ono prvo. Jedan su od razloga proširenja i dopuna i nova nastavna iskustva autora udžbenika koja su pokazala koji su dijelovi udžbenika manje jasno predstavljeni te na koji ih način treba razraditi. Isto tako, novo izdanje udžbenika metodički je razrađenije te je dopunjeno dijelovima teksta u kojima se ističu ključne točke potrebne za razumijevanje materijala kao i literatura koja se predlaže za dodatno učenje. U novom izdanju udžbenika također je i ponešto više tehničkih detalja koji objašnjavaju pozadinu zakonitosti koje su u prvom izdanju iskazane isključivo verbalno. Međutim, matematička pozadina istraživačkih metoda detaljnije je iznesena samo u slučaju poglavlja u istraživačkim uzorcima, s obzirom na to da su iznošenje i objašnjavanje formula za procjenu populacijskih parametara i izračun standardnih pogrešaka znatno ekonomičniji i jasniji od pokušaja da se te ideje iznesu samo u verbalnom obliku. Nadamo se da su navedene promjene olakšale čitanje i razumijevanje materijala iznesenih u udžbeniku te da će novim generacijama studenata omogućiti još bolje usvajanje osnova metodologije društvenih znanosti.

*Autori*

# 1. O ZNANJU KAO TEORIJI I PRAKSI – RAZLIČITI PRISTUPI

Pribavljanje hrane u počecima stvaranja ljudskih zajednica bio je način života i jedini put preživljavanja. Prepoznavanje prirodnog okruženja kao svog životnog prostora unutar kojeg je trebao zadovoljiti sve potrebe preživljavanja, čovjeku je u počecima civilizacijskog uređivanja života u zajedništvu s drugima bio iskustveni pothvat na kojemu su učile nove generacije. Prvobitna *orijentacija na iskustvo*, vlastito i drugih, posebice starijih, dovela je čovjeka do potrebe za organiziranjem života prema određenim konstantama, svojevrsnim obrascima koji se razlikuju u prostoru i vremenu različitih skupina. Te su se razlike poslije prepoznavale kao kulture prvobitnih društava, kulture plemena i naroda, kulture podneblja i povijesnih razdoblja. Na tom dugotrajnom povijesnom putu stvaranja kulture, čovjek je postupno preuzimao inicijativu uređivanja životnog prostora i životnih uvjeta na određenom prostoru. Prelazio je iz trpnog stanja (*natura naturata*) u aktivno, stvaralačko djelovanje (*natura naturans*).[1] Time ne samo da je čovjek promijenio svoju ulogu i mjesto u prirodi, već je promijenio i prirodu sâmu, pretvorivši je u njemu dane resurse koje može i smije trošiti.

Postajanje „gospodarom svijeta" nije bio odraz spontanosti suživota čovjeka s prirodom, nego prije svega rezultat čovjekove *spoznajne prirode*. Otkrivanje zakonitosti prirodnih procesa, životnih ciklusa, odnosa među živim i neživim tvarima i sličnim pojavama potaknule su čovjeka na stvaralačke pothvate koji su ga u konačnici doveli do posebne, organizirane djelatnosti nazvane *znanošću*.

Aristotelova rečenica na početku prve knjige *Metafizike* – *Ljudski je težiti znanju!* – dobra je interpretacija čovjekova hoda tijekom povijesti na putu prema znanosti. U znanju se može tražiti teorijska i praktična primjena. Znanjem obogatiti život pojedinaca i kolektiva, ponuditi im rješenja starih i novih nepoznanica, učiniti ih otvorenijim za nova znanja – sve se to zahtijeva od *teorijskog znanja* koje se od vremena grčke filozofije, preko vremena rimske dominacije te posebno skolastičke dominacije, nalazilo u okvirima koje je pokrivala filozofija. Kada je riječ o *praksi znanja*, ona se, među ostalim, potvrđuje u primjeni znanja na praktična rješenja u proizvodnji, prometu, komunikaciji i svuda gdje čovjek nastoji održati ili promijeniti dotadašnje praktično djelovanje.

---

[1] U skolastičkom značenju *natura naturans* (stvaralačka priroda) označavala je Božju aktivnost, za razliku od *natura naturata* (stvorena priroda) koju predstavlja postojeći svijet u odnosu prema Bogu. (Bošnjak, 1977: 197)

*Teorija* se uvijek gradi na nizu definicija i ustanovljenih veza među pojmovima kojima razumijevamo i objašnjavamo iskustvene činjenice, ili, pak, kojima stvaramo temelje i polazišta za neke druge teorije. *Praksa* kao „praktična primjena" znanja u svakodnevnim situacijama u čovjeka je uvijek svjesna aktivnost kojom povezuje teorijsko s empirijskim. Pri tome se uvijek može očekivati da empirijska provjera teorijskog znanja može potvrditi postojeće znanje ili ga djelomično ili u potpunosti izmijeniti. Praksa se uzima i kao provjera, *kriterij istinitosti* određene teorije.

U **filozofiji** je odnos teorije i prakse kao odnos razuma i empirije shvaćan kao suodnos koji potvrđuje istinu.[2] Aristotel je odnos pojavnog i mišljenog sveo na *kategorije* kao opće pojmove preko kojih je moguća spoznaja pojavnoga. Poslije ćemo naći stavove poput empirističkog: *Nihil est in intellectu quod non prius in sensu fuerit*, ili Spinozina racionalističkog uvjerenja– *Veritas norma sui et falsi est,* ili a mišljenja – *Veritas est adaequatio intellectus et rei*.[3] Filozofska opterećenost istinom u istraživanju bitka nije filozofiju učinila znanošću, ali ju je kao *ljubav prema mudrosti* učinila važnom potporom razvoja i osamostaljivanja znanosti koja će se početi događati tek u drugoj polovini 17. stoljeća. Filozofija je također budućem razvoju znanosti dala svojevrsnu obvezu kada je riječ o istraživanju istine – istina je cjelina.

**Teologija** se često smatra neznanstvenim, čak antiznanstvenim pristupom životu i svijetu. Teologijska istina time se uzima kao neargumentirana empirijom, dogmatski utemeljena. Takav se stav danas vezuje uz razdoblje skolastike (skolastičke filozofije od 9. do 14. st.), koja je filozofsko mišljenje uzimala kao predvorje istine do koje je jedino dolazila teologija, pa je filozofija postala *ancilla theologiae* (sluškinja teologije). Suvremena je teologija okrenula novu stranicu u odnosu na znanost i istraživanje istine. Odnos sučeljavanja ne uzima se kao odnos sukoba i nepriznavanja znanstvenih dostignuća, nego kao odnos provjere i poticaja daljnjem istraživanju. Tako je teologija spremna prihvatiti znanstvene istine ako one ne dovode u pitanje čovjeka samog i teološku istinu o čovjeku (Lambert, 2003: 7-12). U enciklici *Fides et ratio* papa Ivan Pavao II. od znanstvenog pristupa ipak traži uključivanje metafizičke i moralne dimenzije svijesti, kako se ne bi izgubila istina osobe i života pred opijenosti tehničkim mogućnostima u znanstvenom gospodarenju prirodom (Ivan Pavao II., 1999: 68).

---

[2] Opširan prikaz povijesti filozofije u: Bošnjak, B. (1993). *Povijest filozofije* I, II, III, Zagreb, Nakladni zavod Matice hrvatske.

[3] „Ništa nije u razumu što prethodno nije bilo u osjetilima." „Istina je kriterij sebe i lažnosti." „Istina je adekvatnost mišljenja i predmeta."

**Znanstveni** pristup istraživanju prirode i društva ne postavlja nikakve polazišne ograde i uvjete, što, pak, neznanstveni pristupi čine. *Otvorenost* znanstvenog istraživanja dobro opisuju ove teze: „Oni kojima treba izvjesnost, neka se niti ne prihvaćaju znanosti. Nek se mole u svom odabranom ideološkom svetištu, a svoj izbor riješe s vlastitom savješću." Znanstvenik ne smije nuditi izvjesnost „proročanske istine" ni neoborive hipoteze. To je njegova moralna i intelektualna obveza (Berger, 1995: 53). Znanost mora biti otvorena promjeni zbog toga što „znanstvenici ne izmišljaju istinu; oni je otkrivaju." (Horgan, 2001: 11). U tablici 1 istaknute su ključne razlike između znanstvenog i neznanstvenog pristupa u spoznaji stvarnosti.

*Tablica 1. Odlike znanstvenog i neznanstvenog pristupa u spoznaji*

| **Radnje** | **Neznanstveni pristup** | **Znanstveni pristup** |
|---|---|---|
| Opći pristup | Intuitivan, zdravorazumski | Empirijski |
| Opažanje | Prigodno, nesustavno, bez kontrole | Sustavno, kontrolirano |
| Izvještavanje | Subjektivno | Objektivno |
| Definicije pojmova | Dvosmislene, nejasne | Jasne, operacijske |
| Instrumenti | Netočni, neprecizni | Točni, precizni |
| Mjerenje | Nevaljano i nepouzdano | Valjano i pouzdano |
| Pretpostavke | Neprovjerljive | Provjerljive |
| Zaključci | Subjektivni, osobni, nadilaze objektivne podatke | Utemeljeni na podatcima |
| Stav | Nekritičan | Kritički, skeptičan |

Izvor: Milas, 2009: 11

Kada je riječ o *neznanstvenom* pristupu stvarnosti, tada se uglavnom vraćamo predrenesansnom vremenu u kojemu su dominirala skolastička gledišta, kako u istraživanju istine, tako i u njezinu tumačenju. Osim što je za sva pitanja koja su zadirala u vjersko područje važio dogmatski pristup (neupitnost vjerskih istina koje su otkrivene na natprirodan način), svakodnevica se tumačila metodama (1) *autoriteta* (npr. nepogrešivost učenja velikog Tome Akvinskog), (2) *intuicije* (koja je počivala na „očevidnoj istini") i (3) *metode ustrajnosti, inercije* (riječ je o navici da se vjeruje u neke tvrdnje bez njihova provjeravanja).

***Znanstveni se pristup stvarnosti prije svega odlikuje kritičnošću, provjerljivošću, sustavnošću i jasnoćom.***

Descartesova je *metodička sumnja* prekinula dominaciju navedenih metoda i uvela razum kao kriterij istine. Njegovo *Cogito, ergo ego sum!*[4] postavlja novu analitičku metodu mišljenja koja postaje put spoznavanja stvarnosti posredstvom razumskih argumenata objektivnosti i realnosti. To postaje ujedno temelj buduće znanstvene metode. Kako se znanstvenim počelo smatrati samo ono što je moguće kvantificirati i empirijski potvrditi, prirodne su znanosti bile u prednosti. Ponesena tim duhom empirizma i racionalizma, čak se je i filozofija zanijela matematičkim pristupom. Tako Spinoza svoju *Etiku* pokušava pretvoriti u definicije, aksiome, postavke i dokaze te joj u podnaslovu naglašava: *Ordine geometrico demonstrata*.[5] To, međutim, nije novost u filozofiji ako se zna da je već Pitagora (oko 580. – 500. p. n. e.) matematikom pokušavao odgovoriti na veze i odnose u pojavnom svijetu. Zastupao je stav da se brojevima mogu izraziti zakonitosti objektivnog postojanja. Platon (427. – 347. p. n. e.) na ulazu je u svoju *Akademiju* naglašavao važnost matematike za ulaženje u filozofiju (matematička pojmovna određenja i misaona istraživanja priprema su za dijalektičko razumijevanje ideja). No, sve do druge polovine 17. stoljeća nije se moglo govoriti o znanstvenom istraživanju kao prihvaćenom pristupu spoznavanja prirode i društva, kao ni o znanosti kao zasebnoj djelatnosti.

## DODATNA LITERATURA UZ PRVO POGLAVLJE

Cowles, Henry M. (2009). *The Scientific Method: An Evolution of Thinking from Darwin to Dewey*. Harvard: Harvard University Press.

U knjizi se prikazuje mnogostrukost načina spoznaje svijeta tijekom povijesti te razvoj znanstvene eksperimentalne metode koja s vremenom postaje specifičan način mišljenja koji odlikuju kritičnost i empirijski pristup stvarnosti.

[4] „Mislim (sumnjam), dakle ja jesam!“

[5] „Geometrijskim redom izložena.“

## PITANJA UZ PRVO POGLAVLJE

1. Što je određivalo prvobitni čovjekov odnos prema životnoj sredini?
2. U čemu se već u početku potvrđivala čovjekova spoznajna priroda?
3. Što se traži od teorijskog, a što od praktičnog znanja?
4. Kakav je odnos teorije i prakse u filozofiji?
5. Kakav je odnos skolastičke teologije, a kakav suvremene teologije prema znanosti?
6. Koje su osnovne razlike između znanstvenog i neznanstvenog pristupa istraživanju prirode i društva?
7. Koje metode određuju dogmatski pristup istraživanju prirode i društva?
8. Što u mišljenje donosi Descartesova metodička sumnja?
9. Otkada se može govoriti o znanstvenom pristupu proučavanju prirode i društva?

# 2. ZNANOST I DRUŠTVENI RAZVOJ

Suvremeni je čovjek sve manje fasciniran otkrićima, posebice znanstvenim jer su ona postala njegovom svakodnevicom. Znanstvena su otkrića također sve rjeđe nazivana epohalnima jer su unaprijed anticipirana nova na koja se neće dugo čekati. Pri tome im se uglavnom pridaje važnost u pragmatičnoj primjeni, a sve rjeđe u ontološkom značenju. Koga, uopće, danas opterećuje pitanje apsolutne istine, tko još ustrajava na pitanju smisla postojanja osim vrlo malobrojnih ljubitelja mudrosti, filozofa koji su upravo tim pitanjima zaokupljeni. Ostali su uglavnom zaokupljeni utilitarnom svrhom određenog otkrića, materijalnom koristi koja iz njega može proizići, zaštitom autorskog prava i slično. Tako je značenje pojma istine evoluiralo od filozofskog poimanja, koje joj je pristupalo holistički i u značenju apsolutnog, do *znanstvenog, koje je sve manje fundamentalno, a sve više primijenjeno i razvojno*.

***Današnja se znanost sve više sastoji od primijenjenih i razvojnih istraživanja čiji je cilj proizvesti upotrebljive i komercijalne spoznaje.***

Ako se u fundamentalnom smislu znanstveno sve manje može otkrivati, primijenjena će znanost trajati još dugo, tvrdi John Horgan. Znanstveno razvijanje novih materijala, brža i sofisticiranija računala, tehnike genetskog inženjeringa koje će nas učiniti zdravijima, proizvodnja jeftinije i ekološki prihvatljive energije i slično, područja su na kojima će znanost ostvarivati daljnji napredak (Horgan, 2001: 28). Ta su područja ujedno snažan kohezivni činitelj današnjeg globalnog svijeta, koji je sve opterećeniji pitanjima održivog razvoja kao jedinog puta koji daje izglede budućem životu na zemlji. Postojeća je stvarnost često nazivana katastrofičnom. Njezina se istina stavlja na dušu, između ostalih, i znanosti koja je „otkrivala" nove i nove mogućnosti napretka, a koje su, pokazalo se, više razarale negoli stvarale povoljne okolnosti razvoja života, dakako s aspekta bioetike i ekologije.

Čini se da je zauvijek prošlo vrijeme u kojemu je čovjek kao nepoznanice odgonetavao sebe, vlastiti rod, kulturu i civilizaciju koju je zatekao i u kojoj živi, mjesto u svijetu i mjesto u svemiru. Sve je postalo poznato i spoznatljivo. Tajnovitost se izgubila iz ljudske svijesti, nestalo je nedodirljivih tema.

Suvremeni je svijet otvoren svim temama, bilo da je riječ o ratu, gladi, bolesti, siromaštvu ili bogaćenju, bilo da su teme bog, kraj povijesti, smisao egzistencije,

kloniranje čovjeka ili bilo što drugo.[6] Mnoštvo je tema zapljusnulo čovjeka današnjice, te je teško očekivati hoće li svaka od njih jednako opteretiti svakog pojedinca, svaku socijalnu skupinu, svako društvo. Premda je problematika suvremenog svijeta univerzalne naravi, ona je ipak selektivno prihvaćana na različitim meridijanima svijeta. Kao takav, svijet je čovjeku zadana, a ne dana stvarnost. Stoga je briga o svijetu u biti briga čovjeka o životu, tj. o sebi i svojoj sutrašnjici. U kojem će smjeru ići ta briga, često se razlikuje od društva do društva. Tako će *razvijena i bogata društva* zagovarati demokratizaciju, čija je važna sastavnica pravo na *obrazovanje* stanovništva. Zagovarat će i stalno ulaganje u *znanstveno-istraživački razvoj*, koji je pretpostavka razvoja i usavršavanja današnje tehnologije. U tim će društvima, dakle, *obrazovanje, znanost i visoka tehnologija* biti ključni pokazatelji standarda, kako društvenog, tako i individualnog. *Siromašna društva*, tzv. zemlje Trećeg svijeta, ovim će temama nadrediti primarno egzistencijalne sadržaje, poput rješavanja pitanja gladi, bolesti i minimuma zdravstvene zaštite, dok će obrazovanje, posebice visoko, i znanost ostati privilegij uskog sloja društva. Tako će i današnja priča o demokratskom kapitalizmu i globalnoj umreženosti svijeta dobiti svoju svijetlu i tamnu stranu prema kojima je evidentno da su znanje i visoka tehnologija vlasništvo jednog dijela svijeta, dok je onaj preostali dio usmjeren na kupovanje tuđeg znanja uz visoku cijenu, te se time učinio ovisnim i neperspektivnim društvom.

Takvo je stanje u svijetu ipak rezultat jedne druge istine, one na koju upozorava F. J. Radermacher. Bogati i moćni Sjever, tvrdi on, svoje bogatstvo i moć ostvaruje kroz „skrivenu, krupnu pljačku Juga" privlačenjem najobrazovanijeg dijela tih društava. Taj tzv. *odljev mozgova* najprivlačniji je kapital Juga koji se besplatno stavlja u funkciju bogaćenja i širenja moći Sjevera (Radermacher, 2003: 50).

Danas se, dakle, potvrđuje, više no ikada prije, da su obrazovanje i znanost posebno pozicionirani glede uloge koju imaju kako za *globalni, svjetski razvoj*, tako i za pojedinačni razvoj svakog društva, a koja je najuočljivija u promjenama koje svijetu i društvima donose sofisticirane tehnologije. Njihova je uloga nezaobilazna kada je riječ o bilo kojem segmentu razvitka društva. Implementiranost znanosti u sve socijalne procese suvremenih tehnologija čini znanost primarnom ljudskom djelatnošću, no put do tog njezina položaja nije bio nimalo lak. Njezine su *Scile i Haribde* započele s čovjekovom potrebom tumačenja sebe i svojeg položaja u svijetu te traženja što boljeg načina života u zajednici. Govoreći u

[6] Npr. vezano uz društveni problem održavanja reda; pomoću znanstvenih otkrića i njihove primjene patentiran je uređaj za proizvodnju zvuka čovjeku nepodnošljive frekvencije kojim policija rastjeruje skupine demonstranata.

europskom povijesnom kontekstu, grčka je filozofija najbolje mjesto u kojemu se može govoriti o rađanju znanstvene misli.

## 2.1. KRATKI POVIJESNI EKSKURS

Premda je razdoblje koje prethodi grčkoj filozofiji „neznanstveno" – to je vrijeme Homera, Hesioda te orfika – u kojem dominiraju teme o zagrobnom životu i odnosu čovjeka i bogova, treba ga spomenuti jer su tu začeti pokušaji traženja odgovora na vječna pitanja smisla života i uloge čovjeka u svijetu.[7] Svojevrsno spuštanje s neba na zemlju djelomično je ostvarila grčka filozofija, a ovdje ćemo spomenuti samo njezine najveće predstavnike.

**Sokrat** (469. – 399. p. n. e.) je, kao najspominjaniji grčki mudrac i trajno nadahnuće brojnim filozofima i književnicima tijekom cijele povijesti, potrebu za znanjem spustio među obične ljude, na ulice i trgove Atene. U središtu je njegova učenja čovjek, odnosno ljudski razum koji treba istražiti. Svojom „rodiljskom vještinom" dolaženja do istine on uvodi *induktivni postupak* koji se očituje u suprotstavljanju različitih stavova (teze i antiteze) kako bi se došlo do opće definicije. Prema spoznatoj istini tada je trebalo djelovati. Na taj je način Sokrat pokazao *jedinstvo teorijskog i praktičnog djelovanja*.[8]

**Platon** (427. – 347. p. n. e.), kao najpoznatiji Sokratov učenik i, prema mnogim autorima, najveći grčki filozof, antropološki period sofista i Sokrata zamjenjuje sistemom objektivnog idealizma. Svoj put spoznaje Platon gradi na dualizmu pojavnog svijeta i svijeta ideja. Prava je spoznaja istine spoznaja svijeta ideja, a nju daju znanosti koje se bave pojmovnim – *dijalektika* koja jedina dopire do ideja, i *matematika* koja pruža razumsku spoznaju. Treće od istine je spoznaja pojavnog svijeta koju Platon naziva *mnijenje*. Prema sposobnostima dosezanja određenog stupnja znanja, Platon je razvrstao ljude na proizvoditelje (oni su najbrojniji, a njihova je najviša vrlina umjerenost), čuvare/vojnike (njihova je vrlina hrabrost) i filozofe (oni su vrlo malobrojni, njihova je vrlina umnost te su oni

---

7 Sažeti prikaz učenja Homera, Hesioda i orfika dan je u B. Bošnjak (1978). *Grčka filozofija*, Zagreb, NZMH. U kratkom prikazu Sokrata, Platona i Aristotela koristit ćemo se, pored spomenute, i knjigama: B. Bošnjak (1993). *Povijest filozofije*, Zagreb, NZMH; W. Windelband (1988). *Povijest filozofije*, Zagreb, Naprijed; D. Laertije (1979). *O životu i mišljenju istaknutih filozofa*, Beograd, BIGZ.

8 Sokrat nije pisao te o njemu i njegovu učenju doznajemo iz knjiga njegovih učenika Platona i Ksenofonta.

jedini pozvani upravljati državom). Svoj nacrt pravedne države Platon gradi na tezi da svatko treba raditi ono za što je sposoban. Istina je dohvatljiva malobrojnima – filozofima – stoga se svi ostali trebaju prepustiti njihovu vodstvu.[9] Svoje je učenje Platon razvijao u Akademiji, školi u kojoj su sve tadašnje znanosti bile zastupljene, posebice matematika.

**Aristotel** (384. – 322. p. n. e.), iako je Platonov učenik, nije vjerovao da će filozofijom utjecati na tadašnje političke poretke, što je bez uspjeha pokušavao Platon. Platonov idealizam Aristotel zamjenjuje materijalizmom. Spoznaja počiva na opažanju svijeta stvari. Dok su predmeti dani pojedinačno, spoznaja se zasniva na pojmovima koji odražavaju *općost*. Deset najopćenitijih pojmova Aristotel je izdvojio kao *kategorije*: supstancija, kvantitet, kvalitet, relacija, mjesto, vrijeme, položaj, imanje, činjenje, trpljenje. Iz općih se pojmova do pojedinačnog može doći *dedukcijom*. Aristotelova deduktivna metoda poznata je kao *silogizam*. Posebno mjesto u Aristotelovu učenju zauzima logika, odnosno proučavanje zakonitosti ljudskog mišljenja. Tri su opća principa koja vrijede za svako mišljenje: *princip identiteta* (sve što je istinito mora se samo sa sobom podudarati), *princip kontradikcije* (nemoguće je da se jednom i istom na isti način jedno i isto određenje dodaje i ne dodaje) i *princip isključenja trećeg* (između kontradiktornih stavova ne može biti ništa trećeg). Oruđe mišljenja („organon") služi radi spoznavanja predmetnog svijeta, ali i onoga „iza". Tu nastupa *metafizika*, ili prva filozofija, koja se bavi onim najapstraktnijim i najopćenitijim – *materijom, oblikom, uzrokom kretanja i svrhom*. U svojem je filozofskom sustavu Aristotel obuhvatio proučavanje prirode i svemira, anatomije i psihologije, ali također i društva posredstvom etike, politike i poetike.[10]

Osim razvoja filozofije, antička je Grčka donijela i prve početke mnogih prirodnih te društvenih i humanističkih znanosti. Tako dolazi do prvih razrađenih pokušaja tumačenja gibanja nebeskih tijela. Shvaćajući nebesku sferu kao područje savršenosti, Grci su smatrali da se nebeska tijela moraju gibati po kružnici kao najsimetričnijem obliku. Pokušavajući protumačiti kružno gibanje zvijezda tijekom noći te nepravilnije putanje planeta, grčki matematičar Eudoks smatra da se svemir sastoji od niza prozirnih kugli na koje su pričvršćene zvijezde i planeti, a ovaj se model dobro slagao s poznatim kretanjima nebeskih tijela. Aristotel je

---

9 Mnoštvo je Platonovih djela. Navedimo neka od njih: *Protagora* (protiv sofista), *Država* (o pravednosti), *Menon* (o sjećanju), *Fedon* (o besmrtnosti duše), *Sofist* (o znanju), *Zakoni* (druga najbolja država) i druga.

10 Iz brojnih Aristotelovih djela spomenimo najpoznatija: *Metafizika*, *Organon*, *Politika*, *Nikomahova etika*, *Poetika* i druga.

također prihvatio ovaj model kretanja nebeskih tijela, no njihovo kružno kretanje kod njega proizlazi iz postavke po kojoj su nebeska tijela, za razliku od zemaljskih koja su građena od poznata četiri elementa, građena od petog elementa – etera. Ta tijela su zbog toga nepromjenjiva i mogu se kretati samo po savršenim kružnim putanjama. Posljednju kuglu u tom nizu, prema Aristotelu, pokreće tzv. nepokretni pokretač, tj. neko vrhovno biće.

U razdoblju antičke Grčke došlo je i do pojave *historiografije* kao znanosti. **Herodot** (484. – 425. p. n. e.) u svojemu djelu *Povijest* donio je pregled razvoja Perzijskog carstva, grčko-perzijskih ratova,[11] kao i etnografske i geografske zapise o tadašnjim civilizacijama (Egiptu, Babilonu...). Za razliku od dotadašnjeg prenošenja povijesnog znanja preko predaja i mitova, Herodot pokušava racionalno, nepristrano i sustavno ispitati događaje oslanjajući se na analizu dokumenata i svjedočenja očevidaca. Zbog toga ga se obično i naziva „ocem povijesti". Unatoč tome, još uvijek povijesne događaje dijelom objašnjava sudbinom i božanskom intervencijom uzrokovanom nemoralnim ponašanjem ljudi. Za razliku od njega, **Tukidid** (460. – 395. p. n. e.) u svojemu djelu *Povijest Peloponeskog rata* napušta ideju božanske intervencije i događaje tumači uzročno-posljedičnim odnosima. Tako Peloponeski rat tumači ekspanzivnom politikom Atene koja je dovela do reakcije Sparte i njezinih saveznika, pri čemu još pažljivije od Herodota analizira podatke na kojima temelji svoje zaključke. Stoga ga se često naziva i „ocem znanstvene povijesti".

Razdoblje *helenizma* (širenja grčke kulture nakon osvajanja Aleksandra Makedonskog) označavalo je nešto jači razvoj znanstvenih istraživanja. Tako je **Eratosten** iz Aleksandrije (276. – 195. p. n. e) empirijskim putem došao do procjene Zemljina polumjera. **Aristarh** iz Samosa (310. – 230. p. n. e.) kombinacijom empirijske metode i geometrijskog znanja došao je do procjene udaljenosti između Zemlje i Sunca te Zemlje i Mjeseca, a smatrao je i da je *heliocentrični* sustav točan. Međutim, kako nije bilo moguće primijetiti pomicanje (paralaksu) zvijezda, a što bi se moralo dogoditi ako je heliocentrični sustav točan,[12] tadašnji su astronomi odbacili Aristarhov heliocentrizam koji će ponovno oživjeti tek Kopernik. Umjesto heliocentrizma, bio je prihvaćen **Ptolomejev**[13] (83. – 161.) geocentrični su-

[11] Ponajviše zahvaljujući Herodotu poznati su detalji velikih povijesnih bitaka između Grka i Perzijanaca – Maratonsko polje, Termopilski klanac, Salamina – čiji je ishod znatno utjecao na odnos Istoka i Zapada i nastanak zapadne civilizacije.

[12] Današnjim astronomskim instrumentima paralaksu je moguće primijetiti, dok to u Aristarhovo doba nije bilo moguće pa se činilo kao da zvijezde miruju. Naime, zbog velike udaljenosti nije bilo moguće primijetiti njihovo kretanje.

[13] Ptolomej je bio astronom koji je živio u Egiptu pod rimskom vladavinom, a pisao je na grčkom jeziku.

stav. Ptolomej je svoj sustav opisao u djelu *Synthaxis Mathematice* (poznatije pod arapskim nazivom *Almagest*).[14] Prema njemu gibanje planeta oko Zemlje može se opisati jednom većom kružnicom, nazvanom deferenta, dok se na deferenti nalazi središte manje kružnice ili epicikle po kojoj se gibaju planeti. Takav model dobro se slagao s gibanjima planeta i služio je kao jedini i vladajući astronomski model sve do Kopernika i naknadnog prihvaćanja njegova učenja.

Posebno važna institucija za razvoj znanosti u helenističkom razdoblju bila je *Aleksandrijska biblioteka*. Osnovana je vjerojatno u 3. stoljeću p. n. e. pod ptolomejskom dinastijom, a cilj joj je bio skupljanje svih dotadašnjih znanstvenih spoznaja. Nije točno poznato koliko je knjiga (svitaka papirusa) imala, ali prema legendi svaki brod koji je uplovljavao u aleksandrijsku luku morao je predati sve knjige, koje su zatim kopirane i ostavljane u knjižnici. Aleksandrijska je biblioteka bila dio muzeja koji je predstavljao i središte znanstvenog rada jer su se unutar nje nalazile predavaonice, čitaonice i neke vrste laboratorija. Mnogi poznati znanstvenici tog doba, poput Euklida i Arhimeda, dolazili su raditi u Aleksandriju, a neki od njih, poput Aristarha i Eratostena, bili su i glavni knjižničari Aleksandrijske biblioteke.

Poslije Aristotela Grčka je prestala biti glavnim rasadnikom filozofije i znanja uopće. Rim preuzima tu ulogu, premda je ne obnaša tako dobro kao njegova prethodnica. Konstantinovim ediktom (313. godine) kršćanstvo je postalo državnom religijom Rimskog carstva, a Justinijanovim ukidanjem filozofskih škola (529. godine) nastupilo je vrijeme u kojemu je sve znanje trebalo služiti potvrđivanju kršćanskog dogmatskog sustava. Filozofija tako dobiva mjesto *ancillae theologiae* u dugom razdoblju skolastike (9. – 14. st.) koje je obilježeno autoritetom velikog **Tome Akvinskog**. Toma Akvinski u skolastiku uvodi Aristotelovu filozofiju, ali ne da bi je dalje razvijao, nego da bi njome branio i potvrđivao dogme kršćanstva. „To znači da teologija daje filozofiji i predmet i kriterij mišljenja. Zbog tog ograničenja filozofija je nužno morala ostati samo u *predvorju istine* i nije se mogla samostalno razvijati, ...“ (Bošnjak, 1977: 215).

Unatoč takvom stanju neslobode istraživanja, ljudski um nije mirovao. Na tragu spomenute Aristotelove misli – *Ljudski je težiti znanju!* – ljudski je duh širio horizonte znanja bez obzira na teološke zabrane. Prve kritike srednjovjekovne začahurenosti nalazimo u ranoj renesansi talijanske književnosti **Dantea Ali-**

[14] U značenju „velika rasprava“. Arapski naziv Ptolomejeva djela poznatiji je od grčkog ili latinskog zbog toga što su, kao i kad su u pitanju drugi klasični mislioci, Europljani upoznali njegovo djelo posredstvom Arapa.

**ghierija** (1265. – 1321.), **Francesca Petrarce** (1304. – 1374.) i **Giovannija Boccaccia** (1313. – 1365.). Još jača kritika skolastičke slike svijeta vidljiva je u buđenju *filozofije prirode i prirodnih znanosti* uopće. Tako već **Roger Bacon** (1214. – 1294.) odvaja teologiju od ostalih „profanih" znanosti. Znanstveno je mišljenje, prema njemu, utemeljeno na iskustvu, eksperimentu i matematici. Još dalje je otišao **Nikola Kuzanski** (1401. – 1464.) uvodeći kvantitavni princip (broj) kao put u izvjesnost znanosti. No, znanstvenici moraju shvatiti koliko je njihovo znanje ograničeno, koliko je ono *učeno neznanje* (*docta ignorantia*), smatra Kuzanski, te tu oživljava neoplatonistički pristup uvodeći stupnjeve znanja: (1) *osjetilna* spoznaja (*sensus*) je najniža, na višoj razini je (2) *razumska* spoznaja (*ratio*), još je viša (3) *intelektualna* spoznaja koja sintetizira (*intelectus*), a vrhunac je (4) *intuitivna*, mistična spoznaja (*visio intellectualis*).

Europska je filozofija u postrenesansnom razdoblju doživjela *buđenje iz dogmatskog drijemeža* (I. Kant) koje se potvrđuje u potrebi novog pristupa čovjeku i svijetu. Počevši s **Descartesovom** metodičkom sumnjom, racionalistička se filozofija gradi na gledištu da se objektivna stvarnost može spoznati jedino *razumom*. Za njezino ispravno spoznavanje nužna je upotreba *znanstvene metode*, a što je za Descartesa jedini put u pravilno upravljanje umom i traženje istine u znanostima. Matematika (geometrija) postaje u društvenim znanostima uzor primjene znanstvene metode. Tako **Spinoza** svoju *Etiku* izlaže geometrijskom metodom (*ordine geometrico demonstrata*).[15]

Dok je racionalizam jačao u Francuskoj i Njemačkoj, u Engleskoj, tada gospodarski i tehnološki najrazvijenijoj, najizraženiji je **empirizam**. Engleska se empiristička filozofija[16] okrenula proučavanju prirode i društva neposrednošću dodira u empiriji. Bolje spoznati prirodu, ali i društvo, zadatak je koji je brzo rastući kapitalizam stavio pred znanost.[17] To je vrijeme kada u Francuskoj cvijeta **pro-**

---

15 Najveći su umovi filozofije racionalizma R. Descartes (1596. – 1650.), B. De Spinoza (1632. – 1677.), G. W. Leibniz (1646. – 1716.). Opširnije o racionalizmu u knjizi M. Kangrga (1979). *Racionalistička filozofija*, Zagreb, NZMH te u spomenutim povijestima filozofije W. Windelbanda i B. Bošnjaka.

16 Glavni su predstavnici engleskog empirizma F. Bacon (1561. – 1626.), T. Hobbes (1588. – 1679), J. Locke (1632. – 1704.) i D. Hume (1711. – 1776.), o čijoj filozofiji opširnije u G. Petrović (1979). *Engleska empiristička filozofija*, Zagreb, NZMH.

17 O znanosti toga vremena F. Capra piše: „Znanost sedamnaestog stoljeća zasnivala se na novoj metodi istraživanja, koju je gorljivo zastupao Francis Bacon, a uključivala je *matematički opis prirode* i *analitičku metodu mišljenja*, koju je iznašao Descartesov genij. Priznavajući znanosti presudnu ulogu u izazivanju ovih dalekosežnih posljedica, povjesničari su nazvali šesnaesto i sedamnaesto stoljeće *doba znanstvene revolucije*." (istaknuo A. Š.) / Capra, 1986: 56/

**svjetiteljska misao,** koja preko brojnih predstavnika uzdiže ljudski um kao jedini autoritet u spoznavanju svijeta. Prosvjetiteljska misao slavi trijumf uma nad dogmatskim autoritetom nepokretnosti srednjeg vijeka. Um je shvaćen kao nositelj progresa koji se treba dogoditi svim slojevima društva. Prema tome je prosvjetiteljstvo bilo pokret koji je dobio široku podršku u građanstvu, a koja se manifestirala i u velikoj revoluciji 1789. godine.[18]

Posebno je obilježje europskom ukupnom znanju dala **filozofija njemačkog klasičnog idealizma** koja predstavlja sumu europskog mišljenja tijekom povijesti, te je ona svojevrstan pokušaj „završetka" filozofije. Postrenesansna je misao tražila uporište novonastajućem građanskom poretku koji je trebao drukčije odgovore na pitanja o svijetu od onih koji su vrijedili u starom staleškom društvu. **Immanuel Kant** (1724. – 1804.) svojim je trima kritikama[19] tražio odgovore na ključna četiri pitanja: *Što mi je znati?*; *Što mi je činiti?*; *Čemu se mogu nadati?*; te konačno: *Što je čovjek?* Kant je tek u prosvjetiteljstvu i Francuskoj revoluciji vidio spremnost čovjeka da iziđe iz doba svoje maloljetnosti te se počne služiti vlastitim umom. Vrhunac umnosti tadašnje filozofije predstavlja **Georg Wilhelm Friedrich Hegel** (1770. – 1831.), prema mnogima najveće ime u povijesti europske filozofije. Put do istine jedino je otvoren za *znanost*, stoga Hegel želi filozofiji dati formu znanosti. U njegovu filozofskom sustavu svjetskog duha važne su kategorije povijesnosti, objektivne stvarnosti i prirode. Čovjek se kao prirodno biće uzdiže iz stanja *subjektivnog duha* (tu Hegel smješta antropologiju i psihologiju) u stanje *objektivnog duha* (koje se iskazuje u pravu, moralitetu, te obitelji, građanskom društvu i državi) i konačno doseže *apsolutni duh* (posredstvom umjetnosti, objavljenom religijom i filozofijom). Hegel je dao veliki doprinos i modernoj historiografiji. Ističući da je povijest *napredovanje u svijesti o slobodi*, dao je mnogim budućim misliocima oslonac u razmišljanju gdje tražiti motiv čovjekova povijesnog razvoja i napretka.[20]

---

18 Glavni su predstavnici francuskoga prosvjetiteljstva: Montesquieu (1689. – 1755.), Voltaire (1694. – 1778.), Rousseau (1712. – 1778.), Diderot (1713. – 1783.), Helvetius (1715. – 1771.), Holbach (1723. – 1789.). O francuskom prosvjetiteljstvu u knjizi D. Pejović (1978). *Francuska prosvjetiteljska filozofija*, Zagreb, NZMH.

19 Riječ je o Kantovim djelima *Kritika čistog uma, Kritika praktičnog uma, Kritika moći suđenja*, u kojima postavlja temelje modernoj spoznajnoj teoriji, etici i estetici.

20 Velika je ostavština Hegelovih djela, navedimo glavna: *Fenomenologija duha*, *Filozofija prava*, *Filozofija povijesti*, *Povijest filozofije*, *Logika*, *Enciklopedija filozofijskih znanosti*.
Opširniji prikaz filozofije Kanta, Hegela i cijelog njemačkog klasičnog idealizma daje V. Filipović (1982). *Klasični njemački idealizam*, Zagreb, NZMH, kao i spomenute povijesti filozofije.

## 2.2. PUT DO AUTONOMIJE SVEUČILIŠTA

Premda je znanost razvijana u okviru filozofije i filozofskih škola još u vremenu rane grčke filozofije, ona nije postojala u suvremenom smislu. Kao filozofske discipline postoje metafizika i dijalektika, fizika i astronomija, antropologija i astrologija, logika i retorika, psihologija i teologija, etika i estetika. Iako je srednji vijek u razdoblju skolastičke dogmatske konstrukcije znanja o prirodi i društvu sve te discipline podredio teologiji, ipak je došlo do institucionalizacije znanosti u vidu prvih sveučilišta. Prvo je europsko sveučilište osnovano u *Bologni* 1088. (ili 1119.), drugo u *Parizu* 1231. godine. Prva su sveučilišta u Engleskoj osnovana u *Oxfordu* 1167. (ili 1209.) i *Cambridgeu* 1209. (ili 1214.) godine. Širom Europe otada niču brojna nova sveučilišta: u *Pragu* (1347.), *Beču* (1365.), *Krakowu* (1364. ili 1384.) te mnoga sveučilišta u njemačkim gradovima. Podaci kazuju da je u Europi *između 12. i 15. stoljeća postojalo 75 sveučilišta s oko 10 do 15 tisuća studenata*.[21] Znanosti koje su se razvijale na tim sveučilištima bile su *pravo, medicina, teologija i filozofija*. Prve su znanstvene zajednice, a činili su ih učitelji i studenti, često bile izložene pritisku, kako Crkve, tako i građana, te su se posebnim ugovorima regulirali odnosi sveučilišta prema društvu.[22]

Iako se tradicionalno kršćansko europsko feudalno društvo opiralo prodoru i zaživljavanju znanstvenog tumačenja društva, a posebice prirodnih fenomena, pokrenuti proces institucionalizacije znanosti nije više bilo moguće zaustaviti. Učvršćenju znanosti u društvu u 18. stoljeću i početkom 19. stoljeća mnogo je pridonio *scijentistički pokret* u Engleskoj i Francuskoj, koji je od znanosti učinio središnji simbol otvorenog i naprednog društva (Ben-David, 1986:104).[23] Nositelji scijentističkog pokreta nisu izvorno bili znanstvenici, nego ljudi političkih i ekonomskih interesa čiji je cilj pomoću znanosti ukazati na ispravnost svojih ideja o promjeni sustava vrijednosti tradicionalnog društva. Otuda se, upozorava Ben-David, pred znanost i stavljaju praktični zadatci. Na taj je način *scijentizam pomogao društvenom lociranju znanosti kao samostalne institucije*. Institucionalizacija je značila troje:

---

21 Opširnije o tome u: Ivan Cifrić (1990.) *Ogledi iz sociologije obrazovanja*, Zagreb, Školske novine (str. 115-123).

22 Prikaz te problematike daje knjiga J. Ben-Davida (1986.) Uloga znanstvenika u društvu, Zagreb, Školska knjiga (str. 67-100).

23 „Scijentistički pokret čini grupa ljudi koji vjeruju da je znanost (iako možda za njih nerazumljiva) pravi put do istine, da se pomoću nje može ovladati prirodom i riješiti probleme pojedinca i društva. Empirička i matematička znanost je prema tome model za rješavanje problema općenito i simbol beskonačne usavršivosti svijeta." (Ben-David, 1986: 104)

*1. da društvo prihvaća neku djelatnost* (znanost, A. Š.) *kao važnu društvenu funkciju vrijednu samu po sebi,*

*2. da postoje norme kojima se određuje ponašanje na nekom području djelatnosti pomoću modela koji je u skladu s ostvarenjem ciljeva i autonomijom te djelatnosti i, na kraju,*

*3. da su društvene norme na drugim poljima djelatnosti donekle prilagođene njihovim normama* i *da se time znanost oslobađa pritiska tradicije* (Ben-David, 1986:101).

Prva su sveučilišta bila organizirana kao korporacije, tj. organizacije s vlastitom pravnom osobnošću koju su svjetovne i crkvene vlasti poštovale, što je stvorilo određeni prostor slobode u kojemu se moglo relativno neometano raspravljati o znanosti. Sveučilišta su, čak i kada određena pitanja nisu empirijski istraživala, postavljala znanstveno relevantna pitanja koja će odgovore dobiti poslije. Osim toga, sveučilišta su stvorila određenu vrstu „institucionalne memorije", tj. omogućila su prenošenje znanja stvarajući znanstvenike, ali i knjige, knjižnice i slično (Bekar i Lipsey, 2002.). Znanost, naime, za vlastito prenošenje treba posebne institucije, tj. ne može se prenositi prešutno, s generacije na generaciju, kao npr. praktične vještine.

U prvoj fazi razvoja sveučilišta latinska riječ za sveučilište – *universitas* – označavala je samo cehovsku zajednicu nastavnika i/ili studenata (npr. *Universitas magistrorum et scholarium*), dok u drugoj fazi počinje označavati sveučilište kao korporaciju. U prvoj se fazi sveučilište često označavalo izrazom *studium generale*, a taj izraz predstavlja osnovicu hrvatske riječi „sveučilište". Ovim se izrazom naglašavalo da sveučilište treba imati sve tada uobičajene fakultete, a to je bio i jedan od osnovnih uvjeta za formalno stjecanje statusa i naziva sveučilišta. Nastanak sveučilišta i njihovo masovno širenje upravo u 12. i 13. stoljeću može se povezati s jačim gospodarskim razvojem, koji dovodi do potrebe većeg broja obrazovanijih (pismenih) ljudi za obavljanje administrativnih poslova. K tome, *gregorijanska reforma* unutar Crkve veći je naglasak stavila na poznavanje kanonskog prava i bolje obrazovanje sâmih svećenika i redovnika. Ta su sveučilišta činila jedinstveni akademski sustav u Europi, jer je akademski stupanj stečen na jednom sveučilištu označavao mogućnost poučavanja na svim drugim sveučilištima (tzv. *ius ubique docendi*), iako su to pravo u početku imala samo sveučilišta u Bologni, Parizu i Salernu.

Korijeni sveučilišne akademske slobode mogu se naći u dokumentu *Authentica Habita* (1155.), kojim je car Fridrich I. Barbarossa sveučilištima dao neke povlastice, poput slobodnog putovanja u svrhu poučavanja i učenja, izuzeća od

gradskih sudova i drugih povlastica, a koje su obično imali klerici (svećenstvo). Osim careva, takve povlastice davali su i pape, te su često dovodile do sukoba s gradskim vlastima jer su sveučilištarci zloupotrebljavali imunitet i kršili lokalne zakone. Često se događalo i da zbog sukoba sveučilištarci prekinu nastavu na nekoliko godina ili presele u drugi grad. Međutim, takva akademska sloboda nije u potpunosti uključivala pravo samostalnog određivanja onoga što će se učiti i poučavati, unatoč tome što je sloboda određivanja nastavnog programa bila različita u različitim područjima znanosti. Tako su područja geometrije, algebre i empirijske astronomije bila relativno neproblematična jer nisu bila u suprotnosti s crkvenim dogmama, pa ih Crkva nije niti pokušala regulirati i nadzirati. S druge strane, pitanja prirode svemira bila su vrlo osjetljiva jer su mogla doći u koliziju s crkvenim učenjem (Bekar i Lipsey, 2002: 13).

Studij je bio strukturiran tako da se prvih šest godina na Filozofskom fakultetu proučavalo tzv. sedam slobodnih vještina[24] (*septem artes liberales*) – trivij[25] (gramatika, retorika i dijalektika) i kvadrivij (aritmetika, geometrija, astronomija i glazba). Nakon toga se školovanje moglo nastaviti na medicinskom, pravnom ili teološkom fakultetu. Učenje nije bilo istraživačkoga tipa, nego je korištena tzv. *skolastička metoda*. Naime, uglavnom se učilo iz knjiga koje su smatrane vrhuncem spoznaje na nekom području (npr. Aristotelova *Fizika* ili *Summa theologica* Tome Akvinskoga). Drugim riječima, istina nije bila nešto što je trebalo pronaći metodama empirijskog istraživanja, nego nešto što je već poznato i zapisano u knjigama velikih učitelja. Upućenost na autoritete vidljiva je i u činjenici da se sveučilišni kolegiji nisu organizirali prema temama (sadržajno), nego su okosnicu činile pojedine knjige. Stoga se o srednjovjekovnim sveučilištima i ne može govoriti kao o tvorcima znanosti i znanstvenog istraživanja, iako su prvi moderni znanstvenici obrazovani na sveučilištu i na njima su uglavnom i predavali (Galileo, Newton, Kopernik itd.). To znači da je svrha srednjovjekovnih sveučilišta bila obrazovati svećenike, pravnike, državne službenike i liječnike, a ne proizvoditi znanost i znanstvenike. Stoga su se najvažnija znanja odnosila na filozofiju, teologiju, klasičnu filologiju i teorijske aspekte medicine. Znanost je nalazila svoje mjesto na sveučilištima, no to je mjesto bilo drugorazredno jer je znanost bila integrirana u druge discipline. Npr. kemija je bila dio medicine, a fizika dio filozofije, pa je iz tih razloga bavljenje znanošću bilo stvar individualnih sklonosti pojedinih znanstvenika, a ne dio sustava.

---

[24] Te su se vještine nazivale slobodnim jer nisu uključivale znanje koje je bilo neposredno i praktično primjenjivo.

[25] Trivij je bio nešto jednostavniji od kvadrivija, iz čega proizlazi i etimologija riječi „trivijalan".

## 2.3. ZNANSTVENA REVOLUCIJA

Znanstvena revolucija pripremljena je pojavom *heliocentričnog sustava* koji je izložio **Nikola Kopernik** (1473. – 1543.), a u kojemu se se svi planeti (uključujući i Zemlju) gibali oko Sunca. Taj je sustav unio znatne promjene u pogledu na svijet, pa se obično i naziva *kopernikanskim obratom*. Naime, heliocentrični sustav značio je da Zemlja i ljudi nemaju povlašteni položaj u svemiru, što je početak osporavanja religijskog svjetonazora. Pri tome valja spomenuti da Kopernik ipak nije mogao dati eksperimentalne dokaze u prilog svoje teorije, unatoč njezinoj matematičkoj jednostavnosti. Naime, kao i u slučaju Aristarha stoljećima ranije, nepostojanje zvjezdane paralakse korišteno je kao dokaz heliocentrizma. Osim toga, kretanje Zemlje nije moguće primijetiti u svakodnevici; dapače, svakodnevno iskustvo govori u prilog tome da je Zemlja nepomična, zbog čega je heliocentrizam odbacio i tadašnji poznati astronom Tycho Brahe. Nakon Galileovih dokaza u prilog heliocentričnog sustava, Kopernikovo glavno djelo *O kretanju nebeskih sfera* (*De revolutionibus orbium coelestium*) stavljeno je na tzv. *indeks zabranjenih knjiga* (*Index librorum prohibitorum*), a tu je zabranu Katolička crkva u potpunosti skinula tek u 19. stoljeću. Koliko su izložene ideje bile opasne, pokazuje i činjenica da je Kopernik oklijevao s objavljivanjem knjige i da ju je objavio tek neposredno prije vlastite smrti.

**Johannes Kepler** (1571. – 1630.) u svojoj je najvažnijoj knjizi *Nova astronomija* (*Astronomia nova,* 1609.) dalje razvio heliocentrični sustav, matematički opisavši kretanje planeta oko Sunca po elipsama (tzv. tri Keplerova zakona). Kepler je jedan od prvih znanstvenika koji je, iako nije uspio pronaći fizikalne uzroke gibanja nebeskih tijela, pošao od ideje da Aristotelovo razdvajanje savršenih nebeskih tijela i nesavršenih zemaljskih objekata nije opravdano, tj. pretpostavio je da i jednima i drugima vladaju iste zakonitosti i da su građeni od istih tvari. Ideju o istim zakonitostima poslije će potvrditi Newton, koji je teorijom gravitacije objasnio i Keplerove zakone, a Galileo će teleskopskim promatranjima pokazati da su i nebeska tijela nesavršene građe.

Potvrdu valjanosti heliocentričnog sustava dao je **Galileo Galilei** (1564. – 1642.) razvojem *teleskopa* i preciznijim astronomskim promatranjima. Galileo je, utvrdivši postojanje sunčevih pjega, uzdrmao dotadašnju vjeru u savršenost nebeskih tijela. Osobito je važno i njegovo otkriće Venerinih faza, koje predstavlja prvi djelomični dokaz točnosti heliocentričnog nasuprot geocentričnom (ptolomejskom) sustavu. Eksperimentalnim dokazivanjem da tijela različite mase imaju istu akceleraciju slobodnog pada, dokazao je netočnost Aristotelove fizike. Naime, Aristotelova je fizika smatrala da kretanje pojedinih tijela ovisi o njihovoj posebnoj građi,

kao i da su nebeska tijela drukčije građe od zemaljskih, a Galileo je opovrgnuo obje te postavke. Zbog svih svojih pogleda iznesenih u knjizi *Dijalog o dva glavna sustava svijeta* (1632.), Crkva ga je u inkvizicijskom postupku prisilila da se javno odrekne heliocentričnog sustava te je zadnje godine života proveo u kućnom pritvoru.[26]

Znanstvenu revoluciju na području *fizike* dovršio je **Isaac Newton** (1642. – 1727.). Jedinstvenom teorijom gravitacije (tzv. Newtonovi zakoni) u djelu *Philosophiae Naturalis Principia Mathematica* (1687.) objasnio je planetarna i zemaljska gibanja pri čemu su svi objekti podložni istim zakonima gravitacije. Newtonov rad predstavlja krunu znanstvene revolucije jer je u njemu na precizan, matematički način postavljena teorija koja je imala vrlo širok doseg, tj. bila je vrlo općenita. Newtonovo će djelo u 18. i 19. stoljeću predstavljati model znanstvenog načina razmišljanja, a znatno će utjecati i na razvoj tehnologije, tj. na pojavu industrijske revolucije.

***Znanstvena revolucija označava niz međusobno povezanih spoznaja i pokreta koji su stvorili temelje za razvoj suvremene znanosti.***

U okviru ovog prikaza dotaknimo se i dvojbe oko *razvitka i napretka* u znanosti. Uobičajeno je mišljenje među laicima, ali i među brojnim znanstvenicima, da se znanost razvija *kumulativno*, nastavljajući se na otkrića koja su joj prethodila. Dakle, sadašnji je stadij znanosti posljedica postupnog gomilanja znanja koje se dalje nastavlja. Takvoj se koncepciji razvoja znanosti priklonio još početkom 18. stoljeća Isaac Newton tvrdeći: „Ako vidim dalje od vas, to je zato što stojim na ramenima divova." No, tijekom 19., a posebice 20. stoljeća, znanstveni je razvoj bio vrlo intenzivan te je bilo nepraktično, pa i pogrešno svaku novu spoznaju temeljiti na znanstvenim postavkama davnih prethodnika. Razvoj znanosti značio je otkrivanje novih znanja o zakonitostima prirode i društva te je često tražio zamjenu starog novim.

Znanstvene revolucije predstavljaju rezultate znanstvenog razvoja i donose objašnjenja i razumijevanja problema bitno drukčija od dotadašnjih (bilo da ih dopunjuju ili potpuno negiraju). Takav odnos prema razvoju znanosti zastupa **Thomas S. Kuhn**, filozof znanosti iz druge polovine 20. stoljeća. On smatra da kumulacija znanja ima određenu ulogu u razvoju znanosti, no ne i presudnu. „Ako

[26] Treba, ipak, spomenuti da Galileo nije imao definitivne dokaze o točnosti heliocentričnog sustava, kao i da je vlastiti pristup znanosti pokušao teološki opravdati na način koji nije bio u skladu s tadašnjim službenim teološkim pristupom (doslovno tumačenje *Biblije*).

je znanost," reći će Kuhn, „skup činjenica, teorija i metoda skupljenih u određenim tekstovima, tada su znanstvenici ljudi koji se – uspješno ili bezuspješno – bore da tom skupu dodaju još koji element. Znanstveni razvoj postaje postupni proces tijekom kojeg se ti elementi, pojedinačno ili u kombinaciji, dodaju stalno rastućem skladištu koje čini znanstvenu tehniku i znanje." Ipak, presudnu ulogu u znanosti on pridaje znanstvenim revolucijama kojima se mijenjaju prevladane paradigme. *Znanstvene revolucije* su uzete kao nekumulativne razvojne epizode u kojima je starija paradigma u potpunosti ili djelomično zamijenjena jednom novom koja je nespojiva s tom starom. (Kuhn, 2002: 16,103)

*Paradigmom* Kuhn smatra univerzalno prihvaćeno znanstveno dostignuće koje nekoj zajednici praktičara za određeno vrijeme pruža model-probleme i rješenja. Kada je paradigma zaživjela, nastupa razdoblje *normalne znanosti* u kojemu se svi problemi nastoje riješiti po naputcima koje nudi paradigma, čime se učvršćuje vjerodostojnost same paradigme. Kada se u tom nastojanju pojave *anomalije* kojima se ne potvrđuje paradigma, tj. kada se u okviru mišljenja i puteva znanstvene spoznaje koje zastupa paradigma ne mogu naći rješenja istraživanih problema, stvaraju se pretpostavke za *krizu* koja se očituje zamagljivanjem same paradigme, labavljenjem pravila za normalno istraživanje i stvaranjem pred-paradigmatskog razdoblja. Kriza prethodi znanstvenoj revoluciji, nakon koje zaživljava nova paradigma (Kuhn, 2002: 10, 96).

Jasnoće radi, prikažimo Kuhnovu teoriju izmjene paradigmi jednim primjerom iz ekonomske povijesti:

*Tablica 2. Koncepcija izmjene paradigmi*

| | |
|---|---|
| PARADIGMA I | *Primjer merkantilista* (15. – 18. st.): trgovina je jedini stvaratelj vrijednosti i bogatstva |
| Normalna znanost | Napori merkantilista oko učvršćivanja i širenja postojeće paradigme – tumačenje uloge vanjske politike, uloge države u povećavanju nacionalnog bogatstva i sl. |
| Anomalije | Nemogućnost objašnjavanja stvaranja viška vrijednosti; preveliko fokusiranje na bogatstvo kao posjedovanje plemenitih metala; monopol kao izvor ekonomskog gubitka; prevelika orijentacija na državu i zanemarivanje važnosti slobodnog tržišta |
| Kriza | Brojnost anomalija dovodi u pitanje paradigmu te proizvodi krizu paradigme |
| Revolucija | Rušenje vladajuće paradigme i stvaranje nove |
| PARADIGMA II | *Primjer fiziokrata* (18. st.): poljoprivreda je jedini izvor nove vrijednosti i bogatstva, važnost uloge slobodnog tržišta |

Kuhnova ideja o znanstvenim revolucijama dovela je u pitanje niz dotad uobičajenih mišljenja o znanosti (prema Sardaru i Van Loonu, 2005: 54):

*1. Realizam* – znanstvene teorije na objektivan način objašnjavaju realnost. Kuhnova ideja promjena paradigme u znanost unosi određenu dozu subjektivnosti.

*2. Razgraničenje* – postoji jasna razlika između znanosti i drugih sustava vjerovanja (religije, umjetnosti, političkih ideologija...). Kako promjena paradigme djelomično ovisi i o subjektivnoj odluci, time se znanost približava spomenutim sustavima vjerovanja.

*3. Kumulativnost* – znanstvene se teorije nadograđuju jedna na drugu. Prema Kuhnu, to se zbiva naglo, revolucionarnim putem.

*4. Razlika između promatrača i teorije* – opažanje i teorija međusobno su odvojivi, opažanja su neovisna o teoriji koju se zastupa. Prema Kuhnu paradigme definiraju koji su podatci vrijedni proučavanja, a podatci se tumače ovisno o paradigmi.

*5. Temelji znanosti zasnivaju se na opažanjima i eksperimentima.* Prema Kuhnu temelj znanosti nalazi se u promjenama paradigmi.

*6. Deduktivna struktura teorije* – teorije se provjeravaju na temelju opažanja koja se deduktivno izvode iz teorije. Kako je ranije navedeno, svaka paradigma definira činjenice, odnosno činjenice se ne izvode deduktivnim, logičkim putem iz teorije.

*7. Preciznost* – znanstveni termini imaju jasno određena značenja. Prema Kuhnu termini su donekle subjektivni jer ovise o paradigmi unutar koje se definiraju.

*8. Otkriće i opravdavanje teorija može se odvojiti* – psihološke i sociološke okolnosti nastanka teorije nisu važne kao razlozi prihvaćanja neke teorije. Prema Kuhnu paradigma je i sociološki fenomen. Odluka koju paradigmu prihvatiti ne donosi se uvijek samo iz znanstvenih razloga.

*9. Jedinstvo znanosti* – sve se znanosti, možda, u konačnici mogu svesti na jednu temeljnu znanost. Prema Kuhnu, u različitim znanostima postoje različite paradigme, a često unutar iste znanosti istovremeno postoje različite paradigme.

Zaključujući ovaj segment rasprave o tumačenju razvoja znanosti, korisno je navesti jednu kompleksniju i slojevitiju *definiciju paradigme* koju daje američki sociolog **Georg Ritzer (**1997: 412): *Paradigma je fundamentalna slika predmeta unutar znanosti. Ona služi da se definira što treba proučavati, određuje koja pitanja treba postavljati, na koji ih način treba postavljati, te koja se pravila u interpretiranju rezultata istraživanja moraju slijediti. Paradigma je najšira jedinica konsenzusa unutar znanosti i služi za diferenciranje jedne znanstvene zajednice (ili podzajednice) od druge. Ona supsumira, definira i međusobno povezuje primjere, teorije, metode i instrumente koji unutar nje postoje.*

## 2.4. ZADATCI ZNANOSTI I OBRAZOVANJA U SUVREMENOSTI

Već od svoje pojave, sveučilišta dobivaju višestruku ulogu: proizvodnja znanja, posredovanje znanja, dodjeljivanje titula kao društvene legitimacije socijalnog prestiža, uloga završetka obrazovanja, posebnost u odnosu na druge organizacije (ceremonije pri upisu, diplomiranju i sl.) (Cifrić, 1990: 96). Sveučilišta, međutim, ne ostaju sama u razvoju i širenju znanosti. Njima se u suvremenom društvu pridružuju instituti, bilo samostalni, bilo u okviru različitih industrija. Znanost tako, kao posebna djelatnost u okviru nacionalnih djelatnosti, dijeli sudbinu s ostalima. Svaki nacionalni znanstveno-istraživački sustav sastoji se od četiri tipa aktera (Prpić i Brajdić Vuković, 2005: 30):

1. Proizvođači znanja (znanstvene ustanove),
2. Financijeri znanstvene proizvodnje (javni i privatni),
3. Korisnici znanstvene proizvodnje,
4. Donositelji odluka o znanstvenoj politici.

Znanstvene se ustanove mogu podijeliti na tri osnovna tipa:

1. Javni instituti,
2. Ustanove visokog obrazovanja,
3. Ostale ustanove (industrijski instituti, bolnice i sl.).

Ove se ustanove znatno razlikuju prema tipu znanstvenih istraživanja koja rade te prema komercijalnoj orijentaciji. Tako javni instituti rade najviše fundamentalnih istraživanja, „ostale ustanove" najmanje, dok su ustanove visokog obrazovanja negdje u sredini. Javni instituti rade i najviše komercijalnih istraživanja, potom slijede visokoškolske ustanove te ostale ustanove. Podatci za Hrvatsku navedeni su u donjoj tablici.

*Tablica 3. Udio vrsta istraživanja u pojedinim ustanovama*

| | **Javni institut** | **Visokoškolska ustanova** | **Ostale ustanove** |
|---|---|---|---|
| **Fundamentalna** | 39,9% | 22,3% | 7,1% |
| **Primijenjena i razvojna** | 27,0% | 40,0% | 57,1% |
| **Mješovita** | 33,1% | 37,8% | 35,9% |
| **Ukupno** | 100,0% | 100,0% | 100,0% |

Izvor: Prpić i Brajdić Vuković, 2005: 58.

Osim tri temeljna tipa znanstvenih ustanova, u većini zemalja postoje i tzv. akademije. Naziv „akademija" vuče korijen iz Platonove škole istoga naziva. Akade-

mije su obnovljene tijekom renesanse, gdje su označavale skupine ljudi koji su se okupljali zbog proučavanja znanosti, književnosti, prava i drugih područja. Neke od tih akademija stavljale su jači naglasak na *znanstvena istraživanja*, neke na proučavanje *nacionalne kulture* (osobito jezika), a neke su bile *statusni klubovi* u koje su mogli ući samo istaknuti znanstvenici ili drugi istaknuti članovi društva. Tu mnogostrukost ciljeva i obilježja moguće je naći i u današnjim akademijama koje uglavnom imaju sljedeće ciljeve: istraživačka uloga i uloga nadgledanja i usmjeravanja cijelog sustava znanosti, uloga financiranja znanosti i znanstvenika, savjetodavna uloga, počasna uloga (članstvom se odaje priznanje najzaslužnijim znanstvenicima).

Danas se može ustvrditi da je znanost, svojim institucionalnim ustrojem i društvenom ulogom koju je preuzela, postala ne samo priznata i od društva prihvaćena djelatnost, već je postala i važan mehanizam *socijalne kontrole*. To se posebice pokazalo ustanovljenjem obrazovnog sustava za šire društvene slojeve, čime obrazovanje dobiva prinudnu moć nad pojedincem, nudeći mu *objektivnu istinu* kao *subjektivnu zbilju*. Zatečeni korpus znanja institucije socijalizacijskim procesom nameću pojedincu te ga oblikuju prema važećim društvenim obrascima, normama i vrijednostima određene kulture društva u kojemu živi (Berger, Luckmann, 1992: 81-88). Također se može ustvrditi da su *stručnost* i *obrazovanost radne snage* postali glavno konkurencijsko oružje na svjetskom tržištu. Znanje i vještine postali su jedini izvor komparativne prednosti i ujedno glavne odrednice raspoređivanja gospodarskih aktivnosti u svijetu krajem 20. stoljeća. Dominira *simbolički kapital* (znanje, informacija i komunikacija) koji za svoje održavanje traži *cjeloživotno učenje*. Taj je zahtjev novoga vremena stalno razvijajuće tehnologije postavljen jednako pred (1) društva (države), u borbi za što bolju poziciju na ljestvici konkurentnosti, bogatstva i razvijenosti, ali i pred (2) pojedince u građenju karijere i osiguranju stalnoga zaposlenja radi stvaranja sredstava potrebnih za što kvalitetniji život.

Već na početku 20. stoljeća E. Durkheim (1996.) zadaću škole vidi u funkciji uklapanja pojedinca u društvo. Poštujući školska pravila, pojedinac uči poštivati i društvena pravila. Time škola pridonosi visokom stupnju *homogenizacije društva*. Škola je u socijalizaciji nositelj *univerzalnih* vrijednosti društva, dok je obitelj nositelj *partikularnih* vrijednosti društva. Može se ustvrditi da su glavni zadatci škole: usađivanje svjetonazora, legitimiranje postojećeg političkog poretka, prenošenje znanja tehničke naravi. Dakle, odgoj koji nudi škola višeslojan je: (1) usvajanje duhovnih vrijednosti, (2) elementarna politička naobrazba (ideologija) i (3) odgoj za stvaranje materijalnih dobara.

Suvremeno je društvo pred školu stavilo potrebu brzog reagiranja na promjene koje je društvu donijela i donosi znanost i na njoj temeljena nova tehnologija. Škola mora dvostruko reagirati: (1) osuvremenjivati sebe kako bi bila dorasla tehnologiji vremena i (2) obrazovati mlade naraštaje za potrebe nove tehnologije. To je izazvalo određene promjene u shvaćanju uloge škole, posebice osnovne i srednje. Osnovna škola, umjesto da ostane okrenuta djetetu i pučanstvu, postala je pripremni stupanj za srednju školu. Srednja je škola postala jedna od poluga društvene selekcije, te je jednima postala stepenica za visoku naobrazbu, drugima završetak obrazovanja. Time je škola preuzela i ulogu socijalne selekcije.

Analizirajući stanje francuskoga obrazovnog sustava, J. Lesourne (1993.) ukazao je na dva ključna pitanja koja se stavljaju pred školu: 1. na koji način upravljati ekspanzijom spoznaja (posebice u srednjem i visokom obrazovanju)?; 2. na koji način odgajati znanstveno i tehničko osoblje nacije? Ta pitanja postaju tim aktualnija što je prisutnija svijest o potrebi „cjeloživotnog obrazovanja" i o poduzećima kao „učećim organizacijama".

Društveni interesi određuju kakav će se odgojno-obrazovni sustav razvijati u nekom društvu. Pri tome se svako društvo susreće s nizom pitanja vezanih uz očekivanja od obrazovanja, npr: koja je *svrha odgojno-obrazovnog sustava*? (učiti kako se uči; omogućiti razvoj pojedinca; izobrazba i selekcija elite; zajedničko dobro društva...); gdje je mogućnost *demokratizacije* društva? (glede jednakosti mogućnosti svih u obrazovanju, bez obzira na socijalno porijeklo); u kojoj se mjeri postavljaju pitanja *djelotvornosti „utrke za diplomom"*, pitanja načina *selekcije* u školama; pitanja *sadržaja i vrsnoće* nastave; pitanja *financiranja* odgojno-obrazovnog sustava; pitanja *položaja nastavnika*; pitanja sposobnosti *upravljanja* složenim odgojno-obrazovnim sustavom; pitanja *krize povjerenja* javnosti prema školi? i slično. Danas, u uvjetima tehničke racionalnosti, ključni je interes društva da škola mora ostvarivati dvije bitne funkcije: 1. neposredno *prenijeti dovoljno znanja* za radno-profesionalnu komunikaciju; 2. posredovati dovoljno *funkcionalnih vrednota* koje će pripremiti potrošača za konzumiranje i prihvaćanje postojećega (svjetskog) poretka.

## 2.5. VRIJEME ZNANOSTI I INOVACIJA – TEHNOZNANOST

Od 19. stoljeća postalo je sve naglašenije isticanje čovjekove moći u ovladavanju prirodom. Tome je veliki, čak najveći doprinos davala znanost. Spoznavanjem

prirodnih zakonitosti fizičari su kapitalističkom konceptu privređivanja pružili nove mogućnosti korištenja energije. Otkrića na području anatomije i biologije, te populariziranje Darwinove teorije vrsta, čovjeka su potpuno spustila na zemlju. Dotadašnja dominacija *teocentrične* koncepcije svijeta (Bog je u središtu, on je osnova svega), potpuno je potisnuta novom *antropocentričnom* i *tehnocentričnom* koncepcijom (čovjek i tehnika su pokretači svega razvoja i napretka). Primjena otkrića egzaktnih znanosti (fizike, biologije, kemije) u svakodnevici proizvodnje doživljavana je kao veliki napredak (npr. pomak od razdoblja rane mehanizacije, preko uporabe parnog stroja u proizvodnji i transportu do konstruiranja stroja s unutrašnjim sagorijevanjem). Razvijala se svijest o čovjeku kao stvaraocu i gospodaru svijeta.

Ubrzana industrijalizacija i urbanizacija razvijenog dijela europskog kontinenta pretvorili su to područje iz pretežito poljoprivrednog u industrijsko društvo. Novo je društvo tražilo novu sliku o sebi. Nju je dobivalo od znanosti, kako prirodnih tako i društvenih. Tako krajem 19. stoljeća *obrazovanje i znanost* postaju nezamjenjive *sastavnice ekonomskog i ukupnog društvenog razvitka*. Put do takvog položaja znanosti i obrazovanja na prijelazu stoljeća, te poslije njihovo još dublje implementiranje u sve promjene koje znače razvoj i napredak, ne samo u nacionalnim gospodarstvima, već u svjetskom gospodarskom sustavu, možemo vidjeti na primjeru *Freeman-Perezove tehno-ekonomske paradigme*. Autori aktualiziraju teoriju dugih valova ekonomskog razvitka Nikolaja Kondratieva prikazujući ključna obilježja i promjene u svakom razdoblju. Nama je ovdje važno uvidjeti promjene u organizaciji obrazovanja i položaju znanstvenika i znanosti (vidi Tablicu 4.). Taj proces *uprezanja znanosti i stručnog obrazovanja* u kola društvenog razvitka zorno predočuju stupci 5 i 6 Tablice 4.

*Tablica 4. Freeman-Perezova tehno-ekonomska paradigma*

| **Val/ Razdoblje** | **Naziv vala prema Kondratievu** | **Glavne industrije i sektori rasta** | **Osnovni oblici poslovne organizacije** | **Organizacija R&D tehnološkog transfera** | **Organizacija obrazovanja** |
|---|---|---|---|---|---|
| 1 | 2 | 3 | 4 | 5 | 6 |
| 1. od 1770./80. do 1830./40. | Rana mehanizacija | Tekstilna i kemijska ind., postrojenja, čeličane itd. | Individualne tvrtke, mala poduzeća | Individualni inovatori, početak suradnje industrija – sveučilište, migracije | Obrazovanje uz rad, parcijalno obrazovanje |

| | | | | | |
|---|---|---|---|---|---|
| 2. od 1830./40. do 1880./90. | Parni pogon i željeznica | Parni strojevi, parni brodovi i željeznica | Veća poduzeća, trgovačka društva (d.o.o i d.d.) | Početak integracije istraživačke funkcije u sveučilišni rad, formalni tehnološki transfer, zaštita intelektualnog vlasništva | Profesionalno obrazovanje i usavršavanje inženjera, specijalizacija, učenje putem djelovanja i interakcije |
| 3. od 1880./90. do 1930./40. | Električna i teška industrija | Električno inženjerstvo i strojarstvo, teška industrija | Gigantske firme, monopoli, oligopoli, bankovni sustavi | Tehnološka infrastruktura, R&D kao poslovna funkcija poduzeća (*in-house* R&D) | Industrija upošljava znanstvenike i inženjere s akademskim stupnjem |
| 4. od 1930./40. do 1980./90. | Fordistička masovna proizvodnja, nafta osnovni energent | Automobili, zrakoplovi, petrokemija, potrošačka roba, sintetika | Oligopoli, multinacionalne korporacije | Specijalizacija R&D, nacionalni laboratoriji, ugovorna istraživanja za industriju, licencni transfer, *know-how* ugovori | Nagli rast sekundarnog i visokog obrazovanja i industrijskog osposobljavanja |
| 5. od 1980./90. | Informacije i komunikacije | Računala, elektronika, *software*, telekomunikacije, optička vlakna, robotika, informacijske usluge | Transnacionalne kompanije i financiranje, rizični (*venture*) kapital | Kooperativna istraživanja, državna potpora generičkim tehnologijama, 'tvornica kao laboratorij' | Suradnja sveučilište-industrija, početak integracije tehnološke funkcije u rad sveučilišta |
| 5. a | Znanje i inovacije | Visoke tehnologije, 'pametni proizvodi', novi materijali, genetičko inženjerstvo | Mrežna poduzeća, sistematizacija | Daljnji razvoj kooperativnih istraživanja na međunarodnoj razini, strateške alijanse | *Hibridno sveučilište*, mrežno sveučilište |

Izvor: Švarc, 1998: 186.

Tih pet valova gospodarskog razvoja koje nam prikazuje prethodna tablica pokrivaju razdoblje od gotovo dva i pol stoljeća. Na prethodnim stranicama pokazali smo da je tomu prethodilo mnogo dulje razdoblje borbe znanosti, bolje reći pojedinaca znanstvenika-istraživača za autonomiju i društveno priznanje znanosti. Put je od *mitske slike* svijeta do znanstvene bio dug i prepun zapreka. Predznanstveno je vrijeme pokrivala mitska interpretacija povijesnih događaja,

prirodnih fenomena, zajedničkoga ljudskog iskustva i tradicionalnih vrijednosti društvenog nasljeđa. Mit[27] nije bio potpuna izmišljotina kao ni čista istina. On je, može se reći, predstavljao poželjnu hipotezu. Nasuprot zajednici mita, *zajednica znanosti* predstavljala je posebnu kulturu koja počiva na autoritetu eksperimenta i promatranja. Znanstvenom je revolucijom potisnut autoritet srednjovjekovne tradicije koji se širio poput mita. Sada je znanost željela sve promatrati i predstavljati matematičkom tehnikom i matematičkim (egzaktnim) jezikom. (Back, 1997: 40-41)

Danas znanost nije za javnost izdvojena djelatnost koja je dostupna samo malobrojnima, ona je na ulici, u svakom domu, na radnim mjestima, ona je u *tehnici* pa je dobila i „upotrebni naziv" – *tehnoznanost*. Naviknuti smo da je znanost posvuda, bilo da je riječ o proizvodnji hrane ili gradnji stambenih objekata, cesta, mostova, proizvodnji automobila, aviona, brodova, ... ili o sofisticiranoj visokoj tehnologiji komunikacije i automatizacije. Naviknuti smo na korištenje visoke tehnologije, ali i na neznanje kako ta tehnologija stvarno djeluje.

Naše je vrijeme, dakle, obilježeno dvostrukim odnosom prema tehnologiji: s jedne strane prevladava *masovno znanje* korištenja tehnologije; s druge, pak, *usko specijalizirano znanje* proizvođenja tehnologije. Zbog toga je ispravna tvrdnja **C. Freemana** da je naše vrijeme obilježeno *tehničkim novinama*. On ih dijeli u četiri kategorije: 1. *rubne novine* (stalna poboljšanja proizvodnih procesa), 2. *korjenite novine* (dovode do prijeloma, tj. korjenitog inoviranja u proizvodnim procesima), 3. *tehničke revolucije* (potiču nastanak novih djelatnih grana), 4. *tehničke mutacije* (unose duboke promjene u sustav odnosa između društvenog, gospodarskog i tehničkog područja). Informacijska je tehnologija dovela do tehničkih mutacija koje su „informatizirale" društvo u svim njegovim segmentima te danas, prema mnogim teoretičarima, živimo u informacijskom društvu. Njega obilježavaju posebice dva procesa: 1. proces stvaranja svjetske kulture, te 2. proces mondijalizacije gospodarstva (J. Lesourne, 1993: 134, 145-149). Navedeni procesi, dakako, postoje zahvaljujući visokoj tehnologiji brze komunikacije.

Takva je tehnologija stvorila *umreženo društvo*, reći će **Manuel Castells**, koje se okreće paradigmi informatičke tehnologije. Pet je značajki nove tehnološke paradigme: 1. informacija je glavna tehnološka sirovina; 2. učinci novih tehno-

---

[27] *Mit* je sakralna ili religijska priča čiji se sadržaj bavi porijeklom ili kreacijom prirodnih, nadnaravnih ili kulturnih fenomena. Antropološko tumačenje mita razlikuje se stoga što implicira neistinu. Mitovi su bili proučavani kao djelomični izvori oralne povijesti, kao indikacije o društveno dominantnim vrijednostima, kao „socijalni dokument" i zbog njihove univerzalne strukture. (Marshall, 1998: 437)

logija proširuju se na područje individualnog i kolektivnog postojanja; 3. ona počiva na logici umrežavanja; 4. važno joj je svojstvo fleksibilnost, tj. sposobnost preslagivanja i 5. sposobnost povezivanja specifičnih tehnologija kao što su mikroelektronika, telekomunikacija, optoelektronika, računala u visoko povezani sustav. Nova ekonomija koja se razvija prema toj paradigmi doživljava se kao *informacijska globalna ekonomija* (Castells, 2000: 94-5, 99).

Da je nova paradigma – paradigma informatičke tehnologije – ključno uporište gospodarskog razvoja, pa onda i ocjenjivanja razvijenosti pojedinog društva prema njezinoj zaživljenosti, vidljivo je iz Tablice 5. U njoj se prepoznaju razvijeni, kod kojih je broj korisnika interneta iznad 70% ili se tome postotku približava, oni u razvoju i nerazvijeni kreću se u znatno manjoj zastupljenosti korisnika interneta. Prema podatcima *Svjetske banke* vidljivo je da se uporaba interneta intenzivira tek iza 1997. godine, a posebno je veliki skok u svim zemljama između 2005. i 2007. godine. Ovdje donosimo podatke iz jednog desetljeća (2001. – 2010.) u šest godišta za odabrane 22 države. Prvih deset zemalja u tablici danas se smatra razvijenim i bogatim društvima. Pogledamo li stanje 2009. i 2010. godine, uočit ćemo da neke tranzicijske zemlje – Slovačka, Estonija pa i Slovenija – brojem korisnika interneta dostižu najrazvijenije, čak su prestigle Francusku. Hrvatska je prema broju korisnika interneta u gornjoj polovini tranzicijskih zemalja, pa je za očekivati da će se vrlo skoro podići iznad 70% korisnika.

*Tablica 5. Broj korisnika interneta (na 100 stanovnika)*

| **Zemlja** | **2001.** | **2003.** | **2005.** | **2007.** | **2009.** | **2010.** |
|---|---|---|---|---|---|---|
| 1. Island | 9,66 | 14,66 | 26,29 | 88,9 | 92,1 | 95,6 |
| 2. Švedska | 6,60 | 12,22 | 27,93 | 82,1 | 91,1 | 90,0 |
| 3. SAD | 4,49 | 9,56 | 17,31 | 75,3 | 71,2 | 74,2 |
| 4. Kanada | 9,12 | 14,25 | 21,68 | 73,3 | 80,2 | 81,3 |
| 5. Finska | 2,58 | 9,42 | 22,38 | 80,8 | 82,5 | 86,9 |
| 6. Norveška | 1,96 | 8,74 | 21,44 | 87,2 | 92,2 | 93,3 |
| 7. Velika Britanija | 0,56 | 5,23 | 16,44 | 75,0 | 83,3 | 84,7 |
| 8. Njemačka | 2,55 | 5,42 | 13,08 | 75,4 | 79,5 | 82,5 |
| 9. Austrija | 3,99 | 7,40 | 14,27 | 69,4 | 73,5 | 72,7 |
| 10. Francuska | 0,98 | 5,75 | 15,03 | 63,9 | 69,3 | 77,5 |
| 11. Slovenija | 0,28 | 2,91 | 9,83 | 56,61 | 63,5 | 69,3 |
| 12. Estonija | 1,28 | 6,67 | 13,31 | 66,2 | 72,6 | 74,2 |
| 13. Češka | 0,06 | 0,34 | 6,93 | 51,8 | 64,1 | 68,6 |
| 14. Poljska | 0,03 | 0,51 | 2,48 | 48,7 | 59,1 | 62,5 |
| 15. Hrvatska | 0,00 | 0,08 | 2,62 | 41,3 | 56,0 | 60,1 |
| 16. Slovačka | 0,00 | 0,42 | 3,37 | 62,2 | 75,6 | 79,9 |

| | | | | | | |
|---|---|---|---|---|---|---|
| 17. Mađarska | 0,31 | 2,61 | 6,46 | 53,2 | 61,7 | 65,2 |
| 18. Bugarska | 0,00 | 0,00 | 2,14 | 33,6 | 44,7 | 46,0 |
| 19. Makedonija | 0,00 | 0,00 | 0,61 | 36,3 | 51,8 | 51,9 |
| 20. Ruska Federacija | 0,00 | 0,24 | 1,11 | 24,9 | 29,2 | 43,4 |
| 21. Bosna i Hercegovina | 0,00 | 0,04 | 0,36 | 27,9 | 37,7 | 52,0 |
| 22. Albanija | 0,00 | 0,00 | 0,01 | 0,32 | 2,88 | 3,29 |

Izvor: www.data.worldbank.org/indicator

## 2.6. ETIČKA DIMENZIJA RAZVOJA I UPOTREBE ZNANOSTI

U drugoj polovini 20. st. hladnoratovski odnosi između Istoka i Zapada donijeli su veliku promjenu glede svrhe znanosti, načina na koji se provode znanstvena istraživanja, kao i porasta financijskih sredstava dostupnih znanstvenicima. Razvoj nuklearnog oružja i poslijeratna utrka u naoružanju između SAD-a i Sovjetskog Saveza uvjetovali su znatan porast državnih financijskih ulaganja u znanost, što je dovelo do važnih znanstvenih i tehnoloških otkrića. Ta se promjena obično označava kao pomak od „male znanosti" (*small science*), u kojoj je znanost oslonjena na individualni rad pojedinačnih znanstvenika, prema „velikoj znanosti" (*big science*) koju karakteriziraju: a) veliki proračuni, b) veliki broj znanstvenika koji zajednički rade i c) velike istraživačke institucije.

Krajem 20. stoljeća velike korporacije (industrija) postaju najveći ulagači u znanstvena istraživanja, što dovodi u pitanje objektivnost znanstvenih istraživanja i njihovu općedruštvenu korist. Znanstvenici prestaju biti „gospodari" znanstvenih dostignuća, njihova otkrića prisvajaju naručitelji istraživanja, uglavnom velike međunarodne korporacije. Kako je sve manje posrijedi uporaba znanstvenika, znanosti i znanstvenih dostignuća za opću korist čovječanstva, a sve više za privatne i partikularne interese pojedinaca i korporacija, pred znanost i znanstvenike postavilo se pitanje *etičke odgovornosti*.

Današnja znanost obilježena je kombinacijom neizvjesnosti oko *rizičnosti primjene* znanstvenih otkrića te *komercijalizacijom znanosti* koja može utjecati na objektivnost znanstvenika, tj. na to koja će se pitanja više a koja manje istraživati. Niz je primjena znanstvenih otkrića u praksi svoju opasnost pokazalo godinama poslije. Npr. bolest nazvana „kravlje ludilo" pojavila se godinama nakon što su bjelančevine životinjskog porijekla počele biti korištene u prehrani goveda. Genetski modificirane žitarice u nekim su slučajevima dovele do pojave alergena kod drugih biljaka, pa opasnost od genetski modificiranih organizama još nije

posve poznata.[28] Imajući u vidu da samim znanstvenicima, koje financiraju korporacije, često nije u interesu upozoriti na opasnosti i rizike vlastitih otkrića, danas se sve više govori da se znanost u društvenom smislu nalazi u tzv. *postnormalnoj fazi*. Nju, za razliku od tzv. *normalne faze* znanosti koja je završena i koju je karakteriziralo bezgranično povjerenje u znanost i njezina predviđanja, karakteriziraju neizvjesnost znanja i veliki potencijalni rizici. Stoga, postnormalnu znanost obilježavaju sljedeća društvena obilježja (Sardar, Van Loon, 2005: 157):

1. Umjesto znanstvene sigurnosti postoji dijalog šireg kruga zainteresiranih (građani, političari, lokalna zajednica, mediji, poduzetnici i sl.).
2. Umjesto znanstvenih „čvrstih" činjenica u obzir se uzimaju i osobna iskustva, medijski izvještaji i druge informacije.
3. Umjesto znanstvene istine u prvi plan dolazi kvaliteta života građana – ako građani smatraju da im primjena znanosti smanjuje kvalitetu života, njihovo mišljenje je važnije od mišljenja znanstvenika.
4. Umjesto znanstvenog fundamentalizma sve perspektive postaju jednakovrijedne.

Sažeto rečeno, osnovna su načela postnormalne znanosti sljedeća: (1) *demokratizacija znanosti* (uključenost svih u raspravu o štetnosti znanosti) i (2) zagovaranje tzv. *načela preventive*, koje je prvi put definirano na Konferenciji o klimatskim promjenama u Rio de Janeiru 1992. godine. Prema tom načelu, primjenu znanosti mora voditi opreznost, mora postojati vrlo visok stupanj sigurnosti da određena tehnologija nije opasna. Postoji li i najmanja sumnja, tehnologiju ne treba primijeniti. Osnovna je ideja načela preventive da će neoprezna i brzopleta primjena novih tehnologija dovesti do toga da će znanstvenici i korporacije ići za profitom te štetiti sadašnjim i budućim generacijama.

Etička pitanja i dileme vezane uz *biomedicinska (genetička) istraživanja* danas su pod posebnim povećalom. U tom se području, naime, otvaraju mogućnosti genetskog manipuliranja ljudskim bićima s ciljem popravljanja genskih pogrešaka i sprječavanja pojave bolesti, ali i mogućnost „popravljanja" ljudskih bića pomoću genetske manipulacije. Genetskim manipulacijama moguće je modificirati i postojeće biljne i životinjske vrste ili stvoriti nove. Međutim, takve vrste ljudske intervencije u genetski kôd otvaraju niz etičkih pitanja (Huff, 1996.):

[28] O toj problematici krajem 20. st. vrlo argumentirano piše W. Engdahl u bestseleru *Sjeme uništenja* (hrvatsko izdanje 2005., Zagreb, Detecta).

1. Rizici koji nastupaju nisu posve predvidivi – npr. modificiranje biljnih i životinjskih vrsta može dovesti do prirodne neravnoteže.
2. Upitnost prava čovjeka na stvaranje života umjetnim putem – npr. većina velikih religija smatra da se čovjek ne bi smio „igrati Boga" stvaranjem života na taj način.
3. Posljedice na individualni identitet – stvaranje čovjeka genetskom manipulacijom znači da se biranjem budućih karakteristika još nerođenog ljudskog bića sužava njegova sloboda. Ljudski identitet, naime, postaje unaprijed određen nečijom odlukom (unaprijed se određuju tjelesna i psihološka obilježja nerođenog djeteta).
4. Društvena nejednakost – bogatiji pojedinci mogli bi genetskom manipulacijom kreirati „superiornije" potomstvo, što bi bilo uskraćeno onima koji nemaju potrebna financijska sredstva.

Mnogi smatraju da genetske manipulacije donose nastanak „postljudskog" društva u kojemu će osobine budućih ljudi, a time i njihov identitet, biti unaprijed određene tehnologijom i izborom njihovih roditelja ili društva.[29] Na taj bi način bila ugrožena dosadašnja poimanja ljudske slobode i moralnog izbora.

Etička pitanja vezana uz *patentiranje znanja* postala su također važna pitanja današnje znanosti. Taj je problem vrlo prisutan u iskorištavanju tradicionalnih znanja u zemljama Trećeg svijeta i njihova komercijalnog iskorištavanja preko patenata. Komercijalno iskorištavanje bioraznolikosti ili tradicionalnog znanja, uglavnom multinacionalnih (farmaceutskih) korporacija iz razvijenih zemalja, obično se naziva *biopiratstvom*. Takve korporacije tradicionalno znanje koriste kao osnovicu za poboljšanje ili umjetno sintetiziranje kemijskih spojeva (najčešće lijekova) koje zatim patentiraju. Na taj način, bez naknade, iskoriste znanje koje se u nerazvijenim zemljama stjecalo generacijama ili koriste bioraznolikost, koja bi prema nekim etičkim postavkama trebala biti vlasništvo zemalja u kojima se nalazi. Prema patentnom pravu većine zemalja tradicionalno znanje ne može onemogućiti prijavu patenta budući da takvo znanje nije javno objavljeno[30] ili njegova učinkovitost nije dokazana. Zbog toga neke zemlje, poput npr. Indije, stvaraju baze tradicionalnih znanja te ih javno (elektronički) objavljuju kako bi spriječile da ih znanstvenici i korporacije patentiraju. *Konvencija o biološkoj ra-*

[29] Tu je ideju, unutar žanra znanstvene fantastike, prvi iznio Aldous Huxley u knjizi *Vrli novi svijet* (*Brave New World*). U tom romanu, objavljenom 1932. godine, prikazan je dehumanizirani svijet budućnosti u kojemu je prirodna reprodukcija nestala, a položaj pojedinaca unutar društva i njegove osobine unaprijed su određeni pomoću kemijskih procesa.

[30] Javna objava nekog izuma onemogućava drugu osobu da ga patentira.

*znolikosti* iz 1993. od korisnika biološke raznolikosti neke zemlje zahtijeva da dobije pristanak te zemlje ili da plati odgovarajuću nadoknadu.

Drugi aspekt patentiranja znanja odnosi se na patentnu zaštitu lijekova. Naime, patentiranje lijekova dovodi do toga da je njihova cijena višestruko veća od tzv. generičkih lijekova, tj. lijekova nad kojima ne postoji patentna zaštita. Patentiranjem lijekova farmaceutske korporacije štite vlastita ulaganja u istraživanje i razvoj, no lijekovi tako postaju nedostupni siromašnim zemljama koje bi ga mogle jeftino proizvesti i tako spasiti mnoge ljudske živote. To ne mogu učiniti zbog patentne zaštite tih lijekova.

Dakle, vlasnici znanstvenih otkrića, a to danas uglavnom nisu znanstvenici već međunarodne korporacije, u znanosti nalaze sredstvo širenja moći i ostvarenja velike zarade. Patentiranjem znanstvenih otkrića dehumaniziraju ulogu znanosti jer je čine sve manje općim dobrom i polugom općeg razvitka, a sve više sredstvom polarizacije čovječanstva na „prvi" i „treći" svijet. Otuda je etička dimenzija uporabe znanosti postala globalnom temom.

## 2.7. O POZIVU ZNANSTVENIKA U DRUŠTVU ZNANJA

Suvremeno je društvo sve sklonije kao glavnu zadaću znanstvenicima dodjeljivati rješavanje problema, bilo da je riječ o područjima medicine, geologije, astronomije i drugih znanosti ili o područjima političke svakodnevice globalnog društva. Svjedoci smo da su mnogi problemi posljedica lošeg gospodarenja prirodnim resursima ili lošeg političkog upravljanja i odlučivanja o socijalnim pitanjima. Znanstvenici stoga imaju argumente za prebacivanje odgovornosti na političare kada je riječ o uporabi znanosti i neželjenim posljedicama. No njihova je moralna odgovornost da svoje spoznaje stave na raspolaganje javnosti kako bi u *postnormalnoj fazi* znanosti smanjili neizvjesnost znanja i veličinu potencijalnih rizika. Tako npr. Al Gore, spoznavši zabrinjavajuće stanje prirodnog okoliša, otkriva javnosti *Marshallov plan* za spašavanje globalnog okoliša. Valja poduzeti sljedeće korake: (1) stabilizacija svjetskog stanovništva; (2) stvaranje i razvoj ekološki prihvatljivih tehnologija; (3) potpuna promjena ekonomskih pravila kojima se mjeri utjecaj ekonomskih odluka na okoliš; (4) usvajanje nove generacije međunarodnih ugovora; (5) uspostavljanje globalnog plana za izobrazbu svjetskog stanovništva o zaštiti globalnog okoliša (Gore, 1994: 235-6).

*Poziv znanstvenika*, dakle, nalaže svakome znanstveniku djelovanje u općem interesu, za opće dobro, u korist života. A prema mišljenju pojedinih znanstve-

nika-intelektualaca to znači zastupati najviše vrijednosti: individualnu slobodu, pravdu i istinu. Znanstvenik-intelektualac ne smije sve navedeno staviti u primjenu praktične politike, on ne smije na taj način biti angažiran, nego mora štititi statičnost, neutilitarnost i racionalnost najviših duhovnih vrijednosti – pravde, istine i razuma (Benda, 1997: 43-56). [31] Na tragu takvog razmišljanja i pola stoljeća poslije **K. P. Liessmann** kritizira promijenjenu ulogu znanja i obrazovanja pa i samih znanstvenika. Reforme obrazovanja vode industrijalizaciji i ekonomizaciji znanja, te su čovjekove kognitivne sposobnosti stavljene na raspolaganje tržištu. Zadaće obrazovanja postaju *partikularizacija, fragmentacija i istodobna univerzalna raspoloživost znanja*. Događa se degradacija obrazovanja na „izobrazbu," a znanja na „humani kapital" kojim se može računovodstveno raspolagati. Također na djelu je „preusmjeravanje obrazovnih ciljeva na sposobnosti i kompetencije". Promašaj je, tvrdi Liessmann, ako se kao obrazovni ciljevi postave „sposobnost za timski rad, fleksibilnost i komunikacijska spremnost". Na škole i sveučilišta prebacuje se paradigma poslovno-ekonomskog mišljenja, od njih se želi napraviti poduzeća (sve su prisutniji pojmovi efikasnost, konkurentnost, prilagodljivost, promjenljivost). Danas se može razlikovati *znanstvenik* od *znanstvenog menadžera*; prvom je cilj *istina*, drugom *efikasnost*. Menadžeri znanja vjeruju da je znanje resurs koji se u okviru poduzeća može optimirati, raspodijeliti, gomilati, uvoziti, izvoziti i dijeliti poput ostalih sirovina i postupaka. Znanje se prihvaća ako se može unovčiti. Danas se „društvo znanja" predstavlja procesom zamjene „materijalne ekonomije" „simboličkom ekonomijom" (Liessmann, 2008.).

Ta se zamjena može uzeti kao prijelaznica iz društva rada u društvo znanja. Nova društvena elita postaje nova srednja klasa koju će **P. Drucker** nazvati *radnicima znanja*.[32] Riječ je o pojedincima koji trebaju zadovoljiti dva osnovna zahtjeva: da imaju formalno obrazovanje, koje im omogućuje da uđu u svijet radnika znanja, te da budu spremni nastaviti obrazovanje tijekom radnog vijeka kako bi unaprijedili to znanje. Radnici znanja postali su novi kapitalisti, a njihovo znanje ključni i jedini nedostajući resurs. Radnici znanja kao novi kapitalisti profesionalno

---

31 Benda je svoju knjigu *Izdaja intelektualaca* prvi put objavio 1946. godine.

32 P. Drucker tvrdi: „Pojmovi *ekonomija znanja, posao znanja* i *radnik znanja*, stari su samo četrdeset godina. Nastali su oko 1960., istodobno, ali nezavisno; prvi je pojam skovao ekonomist s Princetona, Fritz Machlup. Danas ih svi koriste, ali još malo tko razumije njihovo djelovanje na ljudske vrijednosti i ljudsko ponašanje, na upravljanje ljudima i produktivnost, na ekonomiju i politiku. Međutim, već je sada jasno da će društvo znanja i ekonomija znanja, koji su na pomolu, biti radikalno drukčiji od društva i ekonomije posljednjih godina 20. stoljeća." (2007: 179).

se organiziraju i kao takvi jednaki su onima koji naručuju njihovu uslugu. Time se društvo znanja treba gledati kao društvo „seniora" i „juniora", a ne kao društvo poslodavaca (kapitalista) i zaposlenih (najamnih radnika) (Drucker, 2007: 181-182). Zaživljavanje društva znanja najavio je Drucker već 1989. godine poglavljem *Društvo znanja* u knjizi *Nova zbilja*. On će vrijeme 21. stoljeća – a ono je već nastupilo svojim problemima krajem 20. stoljeća – nazvati *postposlovno* društvo. Takvo društvo obilježavaju tri komponente: *informacija, menadžment i umni radnik*. Imperativ umnosti radnika postavila je suvremena tehnologija koja traži sposobnost pretvaranja informacije u znanje. Stoga, kada se govori o perspektivi razvoja društva, govori se o ulaganju u obrazovanje. Ono je najisplativije ulaganje za samo gospodarstvo i predstavlja njegovo „pogonsko gorivo". Školovana, pak, osoba nositelj je gospodarskih procesa i oblikovatelj društvenih odnosa (Drucker, 1992: 217). Iz toga je vidljivo da se od znanosti i znanstvenika traži neposredno angažiranje, posebice u razvoju tehnologije. Znanost „zarobljena" u tehnologiji više je nego ikada odgovorna društvu, ne samo za svoje epohalne iskorake (npr. u genetici ili istraživanju svemira), nego i za „normalni" tijek svakodnevice. Svakodnevica traži intervenciju znanstvenih rješenja na gotovo svim područjima. Uzmemo li kao primjer danas dominirajuću sferu menadžmenta, vidjet ćemo kako se od znanosti traži proučavanje posljedica koje je suvremena organizacija društva učinila na području morala. Očekuje se ne znanstveno popravljanje nemoralnih, nego znanstveno poticanje inicijative za kontrolu sustava, nadzor nestašice, poboljšanje kanala informiranja kao i kulture organiziranja (Maclagan, 1998: 2).

*Društvo znanja* moguće je odrediti kao ono u kojemu je znanje njegov ključni resurs, a radnici znanja dominantna skupina unutar radne snage. Znanje, kao osnovni resurs, obilježava troje: mogućnost njegova nekontroliranog širenja; vertikalna pokretljivost znanja u sustavu obrazovanja (od nižih prema višim razinama); znanje nije jamstvo uspjeha, ono je sredstvo koje se koristi u proizvodnji (Drucker, 2007: 166). Koliko je znanje važno sredstvo u proizvodnji, kazuju rasprave o *kognitivnom kapitalizmu* današnjice u kojemu se glavni izvor vrijednosti nalazi u *znanjima* koja utjelovljuju i mobiliziraju živi rad a ne u kapitalu i materijalnom radu. Otuda se i izvor bogatstva nacija treba tražiti u sustavu obrazovanja i istraživanja. To je ona radikalna promjena kojom se kapitalizam transformira u kognitivni kapitalizam. Naime, kapitalizam i dalje zadržava ključna obilježja poput profita i najamnine, ali njegova kognitivna dimenzija ističe novu prirodu rada, izvora vrednovanja i strukturu rada koju određuje znanje. Znanje se inkorporira u rad i u kapital, ono stvara pravo intelektualnog vlasništva te postaje ključna kompetitivna varijabla. Nastajanje kognitivnog kapitalizma

zbiva se posredstvom triju procesa: 1. rastuće potrebe za autonomijom radnika i odbijanja parceliziranog rada svojstvenog fordizmu; 2. intenziviranja proizvodnje znanja u djelatnostima koje primarno služe čovjeku (zdravstvo, obrazovanje, istraživanje i sl.); 3. demokratizacije obrazovanja i porasta opće razine izobrazbe (Lebert, Vercellone, 2007: 22-23).

U promijenjenim okolnostima nova organizacija poduzeća zamjenjuje *parcelizirane i repetitivne zadaće* radnika *timskom organizacijom rada*. Radnik prestaje biti usko specijaliziran, lako zamjenjiv kotačić u proizvodnji (standardiziranog tipa i ekonomiji razmjera fordističkog vremena) i sve više postaje *polivalentan radnik*, fleksibilno specijaliziran (prema zahtjevima promjena vanjskog okruženja). Njegova učinkovitost u mrežnoj organizaciji i vertikalnoj dezintegraciji potvrđuje važnost učenja i podjele znanja koja osobito dolazi do izražaja u podjeli rada među poduzećima (Schmeder, 2007: 61-63). Poduzeća su, pak, u toj promjeni prisiljena postati *učeće organizacije* koje statičko upravljanje resursima zamjenjuju *dinamičkim upravljanjem znanjem*, a što postaje osnova komunikacije među poduzećima, bilo da je riječ o kooperaciji ili konkurenciji. Takva su poduzeća osnova *gospodarstva znanja* u kojima se događa zaokret: nematerijalni proizvodni faktori (a to su obrazovanje, razvoj i istraživanje, ljudski kapital) prestaju biti čimbenici potrošnje i postaju oni koji proizvodima dodaju novu vrijednost. Nastaje novi tip gospodarstva koji ima postindustrijski karakter, a što znači da se težište prenosi s materijalnih čimbenika proizvodnje na nematerijalne, neopipljive čimbenike poput intelektualnih prava, obrazovanja, marketinga i medija, informacijsko-komunikacijskih i drugih usluga. Glavna imovina takvih poduzeća nisu zgrade i strojevi već kreativnost, znanje, intelektualna prava i slično (Švarc, 2011: 922-927). Dakle, znanstvenik i znanost u cijelosti su stavljeni u *utilitarnu* i *pragmatičku* funkciju društvenog razvoja. Njihove su zadaće time prioritetnije što smo ovisniji o znanstvenim otkrićima, posebice danas, kada je riječ o *društvu znanja*, kako se suvremeni svijet kvalificira.

## DODATNA LITERATURA UZ DRUGO POGLAVLJE

Kuhn, Thomas (2009). *Struktura znanstvenih revolucija*. Zagreb: Jesenski i Turk.

Pomoću pojma paradigme Kuhn pokazuje razvoj znanosti kao niz smjena razdoblja „normalne znanosti“ i „znanstvenih revolucija“ u kojima dolazi do iznenadne promjene slike određenog područja uslijed nakupljenih anomalija koje stara paradigma ne može objasniti.

Horgan, John (2009). *Kraj znanosti. Suočavanje s granicama znanosti u sumrak znanstvene ere*. Zagreb: Jesenski i Turk.

John Horgan u ovoj knjizi propituje granice fundamentalnih znanosti, odnosno pita se jesu li velike spoznaje i promjene paradigmi uopće više moguće, ili će se budućnost znanosti svesti na niz sve preciznijih primjena postojećih paradigmi.

## PITANJA UZ DRUGO POGLAVLJE

1. Koja će vrsta znanstvenog istraživanja, prema J. Horganu, dominirati?
2. Zašto su znanje i obrazovanje važne poluge održanja moći u svijetu?
3. Koje teme dominiraju u ljudskom mišljenju iz vremena prije grčke filozofije?
4. Koju metodu (postupak) uvodi Sokrat u filozofiju?
5. Koje dvije znanosti razvija Platon u svojoj filozofiji?
6. Na čemu Aristotel temelji spoznaju i koju metodu (postupak) uvodi u filozofiju?
7. Koja su tri opća principa mišljenja za Aristotela?
8. Što su „znanstveno" Hipokrat i Galen unijeli u medicinu?
9. Koje su znanstvene teme bile vrlo prisutne u doba helenizma?
10. Gdje je bilo sakupljeno sve znanje helenističkoga vremena?
11. Čime N. Kuzanski i R. Bacon dovode u pitanje skolastički dogmatski sustav mišljenja?
12. Koji su još znanstvenici i kojim spoznajama pridonijeli razvoju znanosti u vremenu renesanse?
13. Po čemu je važan R. Descartes za razvoj znanstvenog mišljenja?
14. Koja je središnja preokupacija empirizma, a koja prosvjetiteljstva?
15. Koju formu Hegel želi dati filozofiji?
16. Kada i gdje je osnovano prvo europsko sveučilište?
17. Što je predstavljao scijentistički pokret?
18. Kada se dogodila i što je donijela institucionalizacija znanosti?
19. Na koja su tri načina u početku osnivana sveučilišta?
20. Koja su dva autoriteta dominirala na prvim sveučilištima, na kojima se uglavnom učilo skolastičkom metodom?
21. Što je značio „kopernikanski obrat" za razvoj znanosti?
22. Koji su glavni predstavnici znanstvene revolucije na području fizike i astronomije, a koji u medicini i kemiji?
23. Što znači da se znanost razvija „kumulativno" a što putem „znanstvenih revolucija"?
24. Što su znanstvene revolucije, prema T. Kuhnu, i kako se one događaju?

25. Što je znanstvena paradigma prema T. Kuhnu i prema G. Ritzeru?
26. Od koja se četiri tipa aktera sastoji svaki nacionalni znanstveno-istraživački sustav?
27. Koja su tri osnovna tipa znanstvenih ustanova?
28. Što znači da je danas znanost svojim institucionalnim ustrojem postala važnim mehanizmom socijalne kontrole?
29. Koja se dva ključna pitanja prema J. Lesourneu stavljaju pred suvremenu školu?
30. Što je u središtu teocentrične a što u središtu antropocentrične koncepcije svijeta?
31. Za razliku od „zajednice mita," na čemu počiva „zajednica znanosti"?
32. Koje značenje ima pojam „tehnoznanost"?
33. Koje četiri vrste „tehničkih novina" postoje prema C. Freemanu?
34. Kojih je pet značajki paradigme informatičke tehnologije prema M. Castellsu?
35. Što je značio pomak od „male znanosti" prema „velikoj znanosti" u drugoj polovini 20. stoljeća?
36. Što otkrivaju rasprave o etičnosti uporabe znanosti?
37. Što sa sobom donosi „postnormalna faza" znanosti?
38. Što sa sobom donosi „patentiranje znanja"?
39. Što svakom znanstveniku nalaže „poziv zananstvenika"?
40. Po čemu se danas može razlikovati „znanstvenik" od „znanstvenog menadžera"?
41. Tko su „radnici znanja" i što određuje „društvo znanja"?
42. Na što ukazuju suvremene rasprave o „kognitivnom kapitalizmu"?

# 3. ODREĐENJE ZNANOSTI I ZNANSTVENE TEORIJE

Neizvjesnost izazvana čovjekovim nepoznavanjem prirodnog životnog okruženja poticala ga je na *istraživanje* prirodne, potom i društvene stvarnosti radi sigurnije egzistencije. Postupno, uslijed akumulacije znanja („otkrivene istine"), čovjek je, spoznavši zakone i zakonitosti prirodnog svijeta, počeo njime gospodariti. Isto tako i u društvu, uslijed povijesno akumuliranog znanja, čovjek je došao do spoznaje bîti društvenog života – život u zajedništvu koji mora jamčiti slobodu i dostojanstvo svakom čovjeku. Otuda je razvidno da je povijesni razvoj zapravo *razvoj čovjekove spoznajne mogućnosti*, naknadno izdvojene kao zasebne djelatnosti – *znanosti*.

Znanost kao zasebna djelatnost nije rezultat slučajnih otkrića ni spontanosti suživota čovjeka s prirodom, već je ona svjesno artikulirana suma znanja bitnih za život u prirodi, do kojih se došlo u dugom povijesnom hodu civilizacije. Za **M. Foucaulta** znanost je *cjelina veza* koje ujedinjuju u određenom razdoblju različito djelovanje, a što u konačnici rezultira rastom znanosti i oblikovanjem znanstvenih sustava. Znanost je, prema **T. Luckmannu**, postala svojevrstan *komunikativni medij*, baš kao što je i novac komunikativni medij u ekonomiji (Price, 1997: 5-6). Da je znanost prepoznatljiva kao ustustavljena *suma znanja*, kao cjelina veza i kao komunikativni medij u suvremenom svijetu, može se, manje ili više, iščitati iz gotovo svake definicije znanosti.

Za početak uzmimo najuopćeniju enciklopedijsku definiciju znanosti. **Encyclopedia Britannica** znanost određuje kao bilo koji *sustav znanja koji se tiče fizičkog svijeta i njegovih fenomena te sadrži nepristrana (objektivna) opažanja i sistematsko eksperimentiranje. Općenito, znanost uključuje traganje za znanjem koje donosi opće istine ili funkcioniranje osnovnih pravila*. (www.britannica.com, pristup 18. 4. 2012.)

Predmet kojim se bavi u osnovi je razlikovanja vrsta znanosti. Tako u *Britannici* nalazimo mnoštvo nabrojanih predmeta prema kojima se znanosti razlikuju. Neki od predmeta su: priroda, društvo, politika, historija, zemlja, poljoprivreda, klima, materijali, mistika, religija, umjetnost, informacija i drugo. Za svaki od tih predmeta u okviru znanstvenog ustustavljivanja znanost daje sva potrebna znanja koja daju *istinu* predmeta i *zakonitosti* njegova postojanja.

Kako bismo izbjegli nepotrebno nabrajanje mnoštva definicija znanosti prema predmetima bavljenja, prihvatimo jednu uopćenu definiciju koja sadrži sve bitne sastavnice za razumijevanje toga što je znanost:

„Znanost je skup sistematiziranih i argumentiranih znanja, odnosno skup spoznajnih činjenica, pojmova, načela, podataka, informacija, teorija, zakona i zakonitosti u određenom povijesnom razdoblju o objektivnoj stvarnosti (tj. prirodi i društvu) do kojega se došlo primjenom objektivnih znanstvenih metoda, a kojima je temeljna svrha i cilj spoznaja zakona i zakonitosti o prošlosti, sadašnjosti i budućnosti prirodnih i društvenih pojava i maksimizacija učinkovitosti ljudske prakse." (Zelenika, 1998: 45)

Dakle, za znanost je iz ove definicije uočljivo sljedeće:

1. čine je sistematizirana i argumentirana znanja o prirodi i društvu,
2. temelji se na primjeni objektivnih znanstvenih metoda,
3. cilj i svrha su joj (a) spoznaja zakona i zakonitosti o prirodi i društvu i (b) maksimizacija učinkovitosti ljudske prakse.

Vidljivo je da se specifičnost znanstvenog načina spoznaje svijeta očituje u formaliziranoj *istraživačkoj metodologiji* koja nam govori kako se dolazi do znanstvenih tvrdnji, te kako se određuje koja je od njih točna a koja netočna. Pojam znanstvene metodologije treba razlikovati od pojmova znanstvenih *metoda i tehnika* (Milas, 2005.). Naime, znanstvene metode odnose se na opće pristupe u istraživačkom radu, dok se tehnike odnose na specifične postupke u okvirima pojedinih metoda. Tako npr. metoda anketnog ispitivanja u sebi uključuje tehnike terenskog, telefonskog, poštanskog i *online* anketiranja. Metodologija određene znanosti, znanstvenog područja ili znanosti općenito obuhvaća pojedinačne metode i tehnike, no predstavlja i nešto više od toga. U njoj se, naime, pokušava analizirati opravdanost, dobre i loše strane i spoznajna vrijednost upotrebe određenih metoda i tehnika. Drukčije rečeno, metodologija je disciplina u kojoj se procjenjuje na osnovi kojih se kriterija u konkretnim situacijama znanstvene spoznaje upotrebljavaju određene metode i tehnike te jesu li ti kriteriji opravdani. Stoga se metodologija, za razliku od primjene pojedinih metoda i tehnika, nužno bavi i metaznanstvenim pitanjima poput objektivnosti znanstvene spoznaje, kriterijima utvrđivanja uzročnosti, logičkim osnovama znanosti (indukcija, dedukcija i sl.), prirodom društvenog svijeta, istraživačkom etikom, itd.

Proučavanje metodologije može se svesti na tri temeljna cilja:

1. Razumijevanje znanstvene literature (rezultata tuđih istraživanja),
2. Osposobljavanje za znanstveno razmišljanje,
3. Provođenje vlastitih znanstvenih i stručnih istraživanja.

Dakle, bez razumijevanja metodologije nije moguće ne samo provoditi vlastita istraživanja, nego ni razumjeti i valorizirati tuđa istraživanja i teorije u određe-

nom području znanosti. Budući da su temelji istraživačke metodologije slični u gotovo svim znanostima, poznavanje metodologije omogućava čak i razumijevanje onih područja znanosti s kojima nismo dobro upoznati i koja su udaljena od onoga čime se primarno bavimo (istražujemo, studiramo i sl.).

Znanstvena istraživanja rezultiraju spoznajama koje se vremenom oblikuju u *znanstvenu teoriju*. U najširem smislu, prema G. Milasu (2005.), *teorija je skup zamisli o tome što je priroda i prema kojim načelima funkcionira*. Uglavnom sve definicije teorije svode se na tezu da je teorija pojmovna organizacija – „pojmovna prerada zbilje" – čija je svrha objašnjenje zbilje. Kao takva, teorija se pojavljuje kao *cilj znanosti*. No, teorija je i *sredstvo znanosti* jer se prema njoj dalje usmjeravaju znanstvena istraživanja. Znanstveno objašnjenje unosi u teoriju elemente nagađanja zbog njegova tri temeljna obilježja: 1. *djelomičnost* (jer uzima u obzir tek neke činitelje važne za istraživanu pojavu); 2. *uvjetnost* (jer vrijede samo pod određenim okolnostima); 3. *približnost* (jer su objašnjenja redovito manje ili više neprecizna u odnosu na opažanje i ne omogućuju posve točno predviđanje. (Milas, 2005: 23-32)

***Znanstvena teorija predstavlja pokušaj objašnjenja stvarnosti pomoću općih pojmova.***

Teorijsko promišljanje simbiotski je vezano za empirijsko-istraživački dio znanosti, stoga se i može reći da bez dobre teorije nema ni dobrih istraživanja, odnosno kvalitetne znanosti. Kako kaže sociolog Robert Merton (1957), teorija više važnih funkcija, a Mertonov se primjer odnosi na Durkheimovu teoriju suicida. Naime, prema ovoj teoriji, socijalna kohezija u određenoj društvenoj grupi negativno je korelirana sa stopom suicida pripadnika grupe (viša kohezija, manja stopa suicida). Prema Mertonu teorija prije svega omogućuje da se određena empirijska pravilnost promotri kao specifičan slučaj pravilnosti višega reda, odnosno postavke više razine apstrakcije. Na taj se način mnoge empirijske pravilnosti mogu objasniti jednom postavkom (teorijom). U Durkheimovu slučaju, empirijska pravilnost koja se odnosi na religijske skupine (npr. katolici imaju niže stope suicida od protestanata) može se protumačiti kao dio teorije prema kojoj je kohezija bilo koje društvene grupe povezana sa stopom suicida unutar nje. Dakle, religijske su grupe samo poseban slučaj povezanosti koja postoji u svim društvenim skupinama. Kao drugo, teorija ima funkciju sistematizacije različitih spoznaja, odnosno akumulacije empirijskih spoznaja koje omogućuju procjenu valjanosti same teorije. Na taj se način postiže integracija naizgled raznolikih empirijskih

pravilnosti. Primjerice, stope suicida u različitim grupama mogu biti protumačene jednom teorijom. Nadalje, dobra je teorija plodna u smislu donošenja novih spoznaja. Naime, formuliranje teorije omogućava da se dođe do prognoza novih fenomena koji su na prvi pogled, bez teorije, bili nepovezani s izvornom empirijskom pravilnošću. Kad je riječ o Durkheimovoj teoriji, to bi moglo biti, kako kaže Merton, testiranje povezanosti kohezije unutar grupe s drugim psihopatološkim fenomenima. Kao četvrto, teorija omogućuje stabilniju predikciju. Primjerice, Merton navodi mogućnost da se socijalna kohezija katolika smanji. Teorija bi tada mogla predvidjeti i povećanje stope suicida, što zadržavanje na empirijskoj pravilnosti ne bi moglo. Naime, iz postojećih pravilnosti mogu se ekstrapolirati samo iste pravilnosti. I na kraju, funkcija je teorije i preciznost predviđanja koja omogućuje bolju provjeru teorije. Naime, pri testiranju teorije uvijek postoji mogućnost počinjenja logičke pogreške koja se naziva afirmacija konsekvencija. Naime, iz propozicija (1) Ako A, onda B i (2) B, nikako ne možemo sigurno utvrditi da je A istinito. Drukčije rečeno, teorija može istinito predvidjeti neke fenomene, no isti se fenomeni možda mogu objasniti nekom drugom teorijom. Što je predviđanje preciznije, odnosno što je teorija formulirana s većom matematičkom preciznošću, to je i vjerojatnost njezine ispravnosti veća. Drugim riječima, nije vjerojatno da je teorija koja određeni fenomen predviđa s preciznošću na šestu decimalu slučajno prediktivno dobra, odnosno da je došlo do slučajno točne predikcije, iako je neka druga teorija zapravo ispravna. Spomenuta Durkheimova teorija tako bi bila još pouzdanija ako bi odnos između kohezije i stope suicida uspjela izraziti u matematičkom obliku. Nadalje, kako kaže Merton, teorija upravo svojom mogućnošću integracije različitih područja, odnosno objašnjenja različitih empirijskih pravilnosti, povećava i vlastitu plauzibilnost.

Sastavni su elementi teorije konstrukti, hipoteze, znanstveni zakoni i znanstvena objašnjenja (Milas, 2005: 24).

*Konstrukti* se odnose na pojmove visoke razine općenitosti koji služe za objašnjenje niza drugih pojava. Dakle, konstrukti predstavljaju hipotetičke pojave koje se mogu operacionalizirati (mjeriti) na različite načine i objektivno ne postoje u vanjskom svijetu. Prednost konstrukata njihova je općenitost, tj. mogućnost da objasne vrlo širok spektar različitih pojava. Primjerice, osobine ličnosti i inteligencija psihološki su konstrukti kojima se može objasniti ponašanje pojedinca u različitim situacijama (npr. spremnost na pomaganje drugim ljudima, uspješnost u poslu i sl.). Slično tome, socijalni status ili životni stil pojedinca sociološki su konstrukti kojima se također može objasniti ponašanje pojedinca u nizu situacija (npr. političko ponašanje, vrijednosti i stavovi, kulturne preferencije i

sl.). Arbitrarnost u definiranju konstrukata odraz je tzv. metodološkog nominalizma kao dominantnog pristupa u definiranju pojmova u suvremenoj znanosti (Popper, 2003: 30-32). Nasuprot metodološkom esencijalizmu koji prema definiciji traži istinsku bît neke stvari, u metodološkom se nominalizmu definicijom pokušava utvrditi kako se neka stvar ponaša, tj. kako je povezana s drugim stvarima. Dobra je definicija ona koja omogućava dolaženje do plodnih znanstvenih spoznaja, a ne ona koja otkriva što stvar „doista jest". Primjerice, metodološki esencijalizam pokušavao bi doći do „istinske" definicije religije, dok bi metodološki nominalizam religiju definirao na određeni način (npr. kao pohađanje religijskih obreda) te bi pokušao utvrditi na koji je način ovaj fenomen povezan s drugim fenomenima (npr. socijalnim statusom, političkim stavovima i sl.).

S obzirom na to da su konstrukti općeniti pojmovi, u istraživanjima ih je potrebno operacionalizirati, odnosno precizno definirati na koje će se sve načine ti konstrukti specificirati u istraživanju. Takve definicije obično nazivamo operacionalnim definicijama, a mogu se podijeliti na mjerene i eksperimentalne.[33] U mjerenim operacionalnim definicijama definiramo način na koji će se varijabla mjeriti. Primjerice, kažemo da će konstrukt inteligencije biti operacionaliziran pomoću nekog određenog testa inteligencije. Eksperimentalna operacionalna definicija odnosi se na specificiranje konstrukta pomoću eksperimentalne manipulacije. Primjerice, istraživač može odrediti da se u nekom eksperimentu izloženost nasilju operacionalizirano definira prikazivanjem nekog nasilnog filma, dok se neizloženost nasilju definira prikazivanjem nekog neutralnog filma. Dakle, u ovom slučaju nije riječ o mjerenju, nego o odluci da se varijabla definira njezinom eksperimentalnom manipulacijom.

Način na koji se operacionaliziraju konstrukti ponekad može imati i veliko praktično značenje, odnosno utjecati na javne politike (Neuman, 2004: 106). Primjerice, siromaštvo je moguće operacionalizirati na nekoliko načina. Možemo ga operacionalizirati neposjedovanjem dobara koja se smatraju nužnim za život ili ga možemo operacionalizirati nekom količinom dohotka i usporediti s dohotkom koji primaju pojedinci u tom društvu (npr. polovina medijanskog dohotka). U ova dva slučaja različite će definicije dovesti do različitih mjera socijalne politike. Slično tome, inteligencija se može operacionalizirati tako da uključi samo analitičku inteligenciju ili socijalnu, emotivnu i druge vrste inteligencije, što može imati znatne posljedice na selekcioniranje pojedinaca u obrazovnom sustavu ili na radnim mjestima.

---

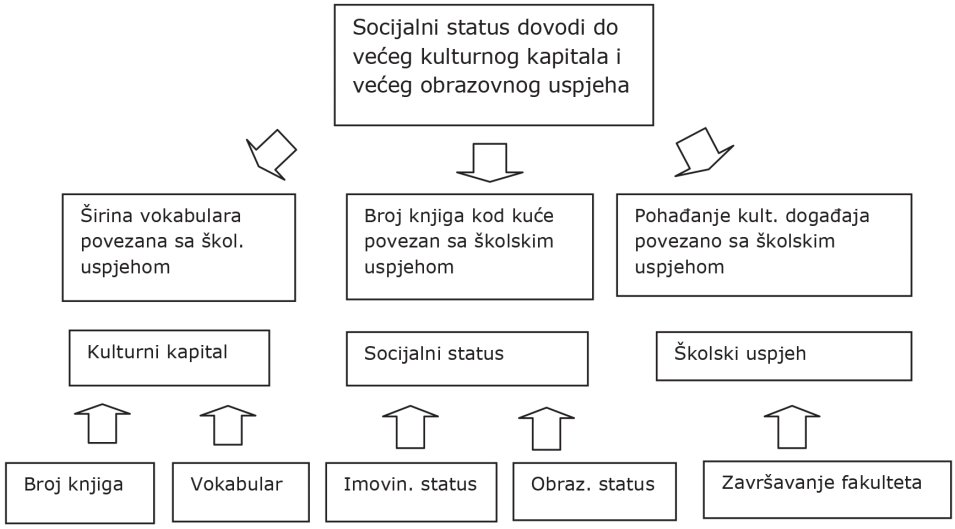
[33] Kerlinger, 1988; na temelju Wimmer i Dominick, 1994: 45.

Pojam *hipoteze* najčešće se shvaća na dva načina, a u skladu s tim shvaćanjima hipoteze je moguće podijeliti na *teorijske i empirijske* (*statističke*). Teorijske hipoteze odnose se na predviđanje odnosa među konstruktima, tj. označavaju odnos među konstruktima koji još nije doživio dovoljan stupanj empirijske provjere da bi bio pouzdano utvrđen i postao teorija. Statističke hipoteze predstavljaju predviđanje odnosa između empirijskih fenomena, a izvode se iz neke teorije. Statističke su hipoteze znatno specifičnije od teorije, pa se iz jedne teorije izvodi niz specifičnih hipoteza. Na primjer, postavimo li teoriju kako su stariji ljudi društveno konzervativniji zbog toga što stavovi s dobi postaju sve manje promjenjivi i zbog toga što stariji ljudi imaju izgrađene društvene pozicije te ne žele društvene promjene (nisu im u interesu). Iz ovakve teorije zatim izvodimo hipoteze prema kojima će stariji ljudi češće glasati za stranke desnice i bit će skloniji tradicionalnim obiteljskim odnosima. Ovdje se, dakle, iz jedne općenitije teorije izvode znatno specifičnije hipoteze.

*Znanstveni zakoni* predstavljaju čvrsto potvrđene opće empirijske pravilnosti. Drukčije rečeno, znanstvenim se zakonom utvrđuje povezanost između dviju pojava, ali ta povezanost nije nužno teorijski jednoznačno objašnjena. Primjerice, utvrdimo li u više istraživanja da obrazovaniji ljudi češće konzumiraju proizvode visoke kulture, možemo reći da smo utvrdili znanstveni zakon. Međutim, ta povezanost može biti objašnjena na različite teorijske načine (novac, ukus stečen obrazovanjem, ukus stečen višim socijalnim podrijetlom i sl.).

*Znanstveno objašnjenje* označava pronalaženje uzročno-posljedičnih odnosa između pojava. Iz tih uzročno-posljedičnih odnosa trebaju proizlaziti hipoteze koje se slažu s utvrđenim znanstvenim zakonitostima. Znanstveno objašnjenje predstavlja krunu znanstvene teorije, a upravo znanstveno objašnjenje često se i naziva teorijom. Kao što bi se u gore navedenom primjeru znanstveno objašnjenje za društveno konzervativnije različite starije ljude manifestiralo težim usvajanjem novih spoznaja (stavova, vrijednosti) te željom da sačuvaju stečene društvene pozicije.

Hijerarhijsku strukturu teorije ilustrirat ćemo na primjeru teorije kulturnog kapitala kojom se pokušava objasniti nejednaki obrazovni uspjeh među djecom iz različitih društvenih slojeva.




*Slika 1. Fiktivni primjer hijerarhijske strukture teorije (prema Milasu, 2009)*

*Empirijski podatci* – školske ocjene, završavanje fakulteta, imovinski status roditelja, stupanj obrazovanja roditelja, širina vokabulara djece, broj knjiga kod kuće, učestalost pohađanja kulturnih događaja i sl.

*Konstrukti* – kulturni kapital (obuhvaća širinu vokabulara, broj knjiga, učestalost pohađanja kulturnih događaja i sl.), društveni status (obuhvaća imovinski status, stupanj obrazovanja roditelja i sl.), obrazovni uspjeh (obuhvaća ocjene, završavanje fakulteta i sl.).

*Znanstveni zakon* – društveni status roditelja povezan je sa školskim uspjehom djece (viši status – bolji uspjeh).

*Hipoteze* – širina vokabulara, broj knjiga, posjećivanje kulturnih događaja i sl. bit će pozitivno povezani sa školskim uspjehom; socijalni status roditelja bit će pozitivno povezan i s kulturnim kapitalom djece i sa školskim uspjehom.

*Objašnjenje* – viši društveni status dovodi do veće razine kulturnog kapitala, a time i do većeg školskog uspjeha. Drukčije rečeno, bolji školski uspjeh djece iz viših socijalnih slojeva može se objasniti većom količinom kulturnog kapitala.

***Tipična se znanstvena teorija u društvenim znanostima sastoji od podataka, konstrukata, znanstvenih zakona i hipoteza, povezanih u koherentno objašnjenje nekoga dijela stvarnosti.***

Vrlo je važno da se prilikom testiranja teorije ne miješaju različite razine analize. Naime, istraživač ne bi trebao na temelju podataka prikupljenih na jednoj razini donositi zaključke na drugoj razini analize. U tom smislu moguće je počiniti dvije pogreške – ekološku pogrešku i pogrešku redukcionizma (Neuman, 2004: 96-97). Prva se pogreška odnosi na situaciju u kojoj istraživač podatke prikuplja na grupnoj razini, a zatim zaključke izvodi na individualnoj razini. Durkheimova studija suicida predstavlja primjer takve pogreške. Durkheim je testirao hipotezu o različitosti stopa samoubojstava između protestanata i katolika, a koja je proizlazila iz njegove teorije u odnosu društvene integracije i suicida. Utvrdivši da su stope suicida veće u područjima u kojima živi protestantska većina, zaključio je da su protestanti skloniji samoubojstvima. Međutim, Durkheim je počinio ekološku pogrešku jer je iz podataka o stopama samoubojstva u regijama zaključivao o pojedincima. Primjerice, moguće je da su protestantske regije ekonomski razvijenije, a da s ekonomskim razvojem imamo veće stope samoubojstva. Teorijski je moguće da su katolici u svim područjima koje je proučavao Durkheim imali veću stopu samoubojstava od protestanata kada se promotre podatci **unutar** regija, u najmanju ruku Durkheimovi podatci ne mogu isključiti takvu mogućnost. Uzmimo kao drugi primjer ekološke pogreške situaciju u kojoj istraživač na temelju činjenice da se gradovima u kojima u prosjeku žive obrazovaniji pojedinci imaju višu razinu kulturalne participacije (npr. odlasci u muzeje, koncerte, kazališta i sl.), zaključuje da obrazovaniji pojedinci imaju višu razinu kulturalne participacije. Sasvim je moguće, naime, da su gradovi u kojima žive obrazovaniji pojedinci u prosjeku bogatiji i da svojim građanima mogu pružiti subvencioniranu kulturnu potrošnju. Još jedan primjer ekološke pogreške predstavlja krivo zaključivanje o povezanosti između zarade pojedinca i političke orijentacije, odnosno glasačkog ponašanja. Naime, postoji povezanost između razine prosječne zarade u američkim okruzima i stope glasovanja za Demokratsku stranku u tim okruzima (Bickel, 2007). Drukčije rečeno, što je prosječna zarada u okruzima veća, to je i postotak koji na izborima dobiva Demokratska stranka veći. Ovaj je podatak pomalo „čudan" imajući u vidu da konvencionalno znanje o američkom političkom sustavu kaže da Republikanska stranka štiti interese imućnijih, a Demokratska stranka interese manje imućnih slojeva populacije. No kada se izradi analiza o povezanosti glasovanja unutar okruga, dobije se jasna povezanost između visine zarade i glasovanja za Republikansku stranku. Dakle, povezanost ove dvije varijable unutar okruga posve je drukčija od povezanosti između okruga. Vjerojatno je objašnjenje svjetonazorska liberalizacija do koje dolazi s porastom zarade (dohotka, stupnja ekonomskog blagostanja) u nekom području. Ilustrirajmo ovaj koncept jednim numeričkim primjerom. U tablici 6

prikazana je povezanost između količine vremena provedenog u učenju (mjerenog u satima tjedno) i ocjene koju su učenici dobili iz nekog školskog predmeta na kraju godine. Iz nje je vidljivo da su u razredima u kojima učenici provedu više vremena u učenju prosječne ocjene niže, iz čega bi se moglo zaključiti da učenje smanjuje ocjene. Međutim, promotrimo li povezanost unutar razreda, vidimo da učenici koji provedu više vremena u učenju postižu veće ocjene. Jedno je moguće objašnjenje ove povezanosti strogost nastavnika koji predaje navedeni predmet. Naime, moguće je da strogost dovodi do davanja više zadataka, a time i više vremena provedenog u učenju. Isto tako, strogi nastavnici možda daju niže ocjene. Stoga bi ispravna analiza ovakvih podataka morala uključiti više razina analize, odnosno u analizu se mora uključiti podatak o tome koji razred pohađa učenik. Samo na taj način može se vidjeti kakva je stvarna povezanost količine učenja i ocjena na individualnoj razini analize.[34] Primjerice, u slučaju donje tablice Pearsonova korelacija između vremena provedenog u učenju i ocjene bila bi negativna i iznosila bi - 0,14, što bi nas navelo na krivi trag jer bismo zaključili da se smanjenjem vremena provedenog u učenju mogu dobiti bolje ocjene.

*Tablica 6. Primjer ekološke pogreške*

| | **Razred 1** | | **Razred 2** | | **Razred 3** | |
|---|---|---|---|---|---|---|
| **Redni broj učenika** | **Vrijeme** | **Ocjena** | **Vrijeme** | **Ocjena** | **Vrijeme** | **Ocjena** |
| 1 | 10 | 1 | 5 | 3 | 0 | 3 |
| 2 | 11 | 2 | 6 | 3 | 1 | 4 |
| 3 | 12 | 3 | 7 | 4 | 2 | 4 |
| 4 | 13 | 4 | 8 | 4 | 3 | 5 |
| 5 | 14 | 5 | 9 | 5 | 4 | 5 |
| Prosjeci | $\bar{x}$ = 12,0 | $\bar{x}$ = 3,0 | $\bar{x}$ = 7,0 | $\bar{x}$ = 3,8 | $\bar{x}$ = 2,0 | $\bar{x}$ = 4,2 |

Pogreška redukcionizma odnosi se na situaciju u kojoj istraživač na temelju podataka prikupljenih na razini pojedinaca (ili općenito na nižoj razini) donosi zaključke na grupnoj (višoj) razini. Primjer ovakve pogreške bila bi situacija u kojoj istraživač na temelju činjenice da obrazovaniji pojedinci u prosjeku zarađuju više od manje obrazovanih pojedinaca, zaključuje da će se države koje više ulažu u obrazovanje jače ekonomski razvijati od država koje manje ulažu u obrazovanje. Naime, moguće je da obrazovaniji pojedinci zarađuju više zbog toga što popunja-

[34] U analizi podataka u ovakvim istraživačkim situacijama najčešće se upotrebljava tzv. višerazinska (multilevel) analiza u koju se uključuju varijable s različitih (najčešće dvije ili tri) razina analize. Dopuštanjem varijacija koeficijenata, kao i interakcije između varijabli s različitih razina, može se odgovoriti na različita istraživačka pitanja na koja nije moguće odgovoriti jednorazinskom analizom.

vaju postojeća radna mjesta, tj. zbog diplome imaju prednost prilikom zapošljavanja. Dakle, ideja prema kojoj obrazovanje povećava ekonomsku produktivnost pojedinaca, a time i društava, ne mora biti točna. U svakom slučaju, o njezinoj točnosti ne može se zaključivati na temelju podataka koji su mjereni na razini pojedinaca. I ovdje ćemo navesti numerički primjer gore navedene povezanosti između stupnja obrazovanja i dohotka, pri čemu je obrazovanje mjereno u završnim godinama školovanja, a dohodak u eurima mjesečno. Iz tablice 7 može se zaključiti da unutar država postoji jasna pozitivna povezanost između stupnja obrazovanja i dohotka, a da među državama jasna (izrazita) povezanost ne postoji. Naime, najveći prosječni dohodak ima država sa srednjom prosječnom razinom obrazovanja.

*Tablica 7. Primjer pogreške redukcionizma*

| | **Država 1** | | **Država 2** | | **Država 3** | |
|---|---|---|---|---|---|---|
| **Redni broj osobe** | **Obrazovanje** | **Dohodak** | **Obrazovanje** | **Dohodak** | **Obrazovanje** | **Dohodak** |
| 1 | 8 | 600 | 11 | 1000 | 15 | 300 |
| 2 | 9 | 700 | 12 | 1100 | 16 | 400 |
| 3 | 9 | 800 | 12 | 1100 | 17 | 500 |
| 4 | 10 | 900 | 13 | 1200 | 18 | 600 |
| 5 | 11 | 1000 | 14 | 1300 | 19 | 700 |
| Prosjeci | $\bar{x}$ = 9,4 | $\bar{x}$ = 800,0 | $\bar{x}$ = 12,4 | $\bar{x}$ = 1140,0 | $\bar{x}$ = 17,0 | $\bar{x}$ = 500,0 |

Kako je vidljivo iz navedenih primjera, ponekad se različite pravilnosti na različitim razinama analize mogu pojaviti zato što je na nekoj višoj, grupnoj razini analize varijabla povezana s nekom trećom varijablom koja „kvari“ vezu koja postoji na individualnoj razini. Primjer takve situacije je veza između prosječnog stupnja obrazovanja u nekom gradu i kulturne participacije koja se pojavljuje samo zato što su gradovi s većim prosječnim stupnjem obrazovanja istovremeno i bogatiji. S druge strane, nekada postoje pravi grupni efekti koji se ne mogu povezati s utjecajem trećih varijabli, odnosno koji nastaju kao rezultat grupne dinamike. Primjer predstavlja utjecaj socioekonomskog statusa na školska postignuća. Naime, osim što je socioekonomski status važan kao prediktor školskih postignuća na indvidualnoj razini, važan je i prosječni socioekonomski status razreda ili škole koju učenik pohađa. Naime, može se pretpostaviti da koncentracija većeg broja učenika boljeg socioekonomskog statusa u jednom razredu ili školi dovodi do dodatnog povećanja školskih postignuća učenika koji se nalaze u takvoj okolini. Osim ovakvih učinaka koji se istražuju analiziranjem prosječne razine neke indvidualne varijable u nekoj grupi (npr. prosječni socioekonomski

status učenika u razredu), postoje i utjecaji koji su čisto grupne naravi (npr. disciplinsko ozračje u nekoj školi). Stoga je prilikom svih situacija u kojima se mogu pretpostaviti učinci koji se događaju na različitim razinama potrebno i analizu izraditi na taj način, prema mogućnosti pomoću tzv. višerazinskih (multilevel) statističkih modela (vidjeti npr. Bickel, 2007). Svakako treba voditi računa i o tome da na različitim razinama povezanost između varijabli može ići u istom smjeru, no da u pozadini mogu biti posve drukčiji procesi. Primjerice, možemo utvrditi pozitivnu povezanost između stupnja obrazovanja i dohotka i na individualnoj i na grupnoj (državnoj) razini analize, no procesi koji objašnjavaju ove povezanosti mogu biti različiti. Povezanost na individualnoj razini može biti rezultat toga da poslodavci smatraju da će obrazovaniji pojedinci imati poželjnije osobine ličnosti (npr. radne navike), a na razini države može biri rezultat činjenice da bogatije države više ulažu u obrazovanje te je u njima zbog toga stupanj obrazovanja veći (obrnuta kauzalnost). Drugim riječima, objašnjenje nekog fenomena na jednoj razini nikako ne omogućuje jednostavno preslikavanje objašnjenja na drugu razinu.

***Pri planiranju istraživanja valja voditi računa o postojanju različitih razina analize i grupnim efektima koji mogu utjecati na individualnu razinu analize. Samo na taj način moguće je izbjeći ekološku pogrešku i pogrešku redukcionizma, odnosno izvlačenje krivih zaključaka iz prikupljenih podataka.***

Navedena tipična struktura teorije u društvenim i humanističkim znanostima upućuje na izraženi značaj subjektivnosti i kreativnosti istraživača prilikom postavljanja i testiranja teorija. U prethodnom smo poglavlju objasnili Kuhnov pojam *paradigme* kojim je obuhvaćena upravo ta osnovna zamisao. Naime, tijekom procesa postavljanja teorije, njezine operacionalizacije i testiranja istraživač donosi niz odluka koje predstavljaju tek djelomičnu, odnosno tek jednu od mogućih konceptualizacija termina koji se koriste unutar teorije. Poslužimo se primjerom koji kao ilustraciju te ideje navode Faber i Sheper (2003: 140-143), tj. pretpostavimo da istraživač iznese postavku po kojoj „ljude višeg statusa drugi ljudi tretiraju na bolji način". Iako naizgled samorazumljiva, ta postavka uključuje termine čije je značenje izrazito ovisno o kontekstu. Primjerice, u nekoj tvrtki osoba višeg statusa bit će definirana položajem u hijerarhiji, a tretman može biti definiran ozbiljnošću kojom će prijedlozi te osobe biti razmotreni unutar tvrtke. U kontekstu situacije prodavanja automobila u izložbenom salonu, status osobe bit će definiran prodavačevom percepcijom kupovne moći kupca, a tretman prosječnim vremenom čekanja na uslugu. Iz tog je primjera vidljivo da konceptualizacije ter-

mina unutar jedne postavke u određenoj mjeri uvjetuju jedna drugu, no skupine konceptualizacija mogu biti posve različite i neovisne jedne od drugih. Dodatnu dimenziju subjektivnosti testiranja teorije daje i činjenica da se čak i empirijski podatci mogu mjeriti na različite načine. Primjerice, položaj unutar hijerarhije može se mjeriti kao formalan ili neformalan, percepcija kupovne moći također je mjerljiva na razne načine, i slično. Iz navedenih razloga testiranje teorija unutar društvenih i humanističkih znanosti, a često i u unutar prirodnih znanosti, obavlja se pomoću statistike, odnosno ne predstavlja logičku dedukciju. Naime, subjektivnost u shvaćanju termina i njihovoj operacionalizaciji neizbježno dovodi do toga da povezanost između pojava („ako – onda" propozicije) postaje labavija i može se utvrditi tek kao statistička pravilnost. Drukčije rečeno, ispostavlja se da uzrok dovodi do posljedice u određenom broju slučajeva, ali ne i uvijek.

Sve navedeno ne implicira da je postavljanje i testiranje teorije sasvim proizvoljan proces. Međutim, istraživač bi trebao biti svjestan vlastite definicije određenih termina, držati se njihovih značenja, uspoređivati vlastite nalaze s drugim teorijama koje imaju sličnu definiciju te smanjiti subjektivnost prilikom prikupljanja podataka i testiranja teorije. Različiti načini kojima je to moguće postići bit će navedeni u poglavljima koja slijede.

## 3.1. KLASIFIKACIJA ZNANOSTI

Europski znanstveni proboj u 17. i 18. stoljeću, nazvan *znanstvena revolucija*, početak je moderne znanosti za koji je Europa najzaslužnija (Landes, 2003: 442). Doživjevši svoju institucionalnu preobrazbu, znanost se oslobađa tradicionalizma i neznanstvenih predrasuda te otpočinje svoj sve samostalniji razvoj uvažavajući, dakako, znanstvene iskorake mislilaca rane renesanse. Neprestano povećavanje broja sveučilišta, znanstvenika i studenata bilo je jasan znak da više nema barijera glede njezina širenja, kao i društvene potrebe za prihvaćanjem znanosti. Tako od znanstvenih početaka u Italiji, put širenja znanosti ide dalje preko Engleske, Francuske, Njemačke do Sjedinjenih Američkih Država. Međutim, znanost se širila i u spoznajnom smislu a ne samo zemljopisno.

U drugom poglavlju pokazali smo da je znanost bila jedinstvena s filozofijom sve do kasne renesanse. Potom slijede stoljeća razdvajanja znanstvenog i filozofskog pristupa, te se izdvajaju matematika, fizika, biologija (fiziologija), medicina, ali i pravo kao posebne znanosti. Potreba za jasnoćom i snalaženjem u sve opsežnijem korpusu znanosti donijela je prvo odvajanje *prirodnih* od *duhovnih* (*društvenih*) znanosti.

Dvadeseto je stoljeće obogaćeno s više klasifikacija znanosti kojima je osnovna svrha bila pojednostaviti snalaženje u znanstvenim dostignućima njihovim grupiranjem u znanstvena područja. Posebice su se ubrzano razvijale prirodne znanosti.

U Republici Hrvatskoj izmijenile su se (tj. dopunjavale i širile) *četiri klasifikacije*. *Prva* iz 1979. dijeli znanost na 5 *oblasti* (društvenohumanističke znanosti, prirodne znanosti, medicinske znanosti, tehničke znanosti i biotehničke znanosti) i 36 znanstvenih *područja*. *Druga* klasifikacija iz 1989. zadržala je istih 5 *oblasti*, ali je *područja* proširila na 48 u okviru kojih je bilo razvrstano 345 znanstvenih disciplina. *Treća* klasifikacija je donesena 1994. (dopunjena 1997.) i sadržavala je 6 znanstvenih *područja ili oblasti* (prirodne znanosti, tehničke znanosti, medicinske znanosti, biotehničke znanosti, društvene znanosti i humanističke znanosti) i 57 znanstvenih *polja* (1997. smanjeno na 45 znanstvenih polja) u okviru kojih su znanstvene grane (prema Zeleniki, 1998: 85).

Danas je važeća *četvrta* klasifikacija iz 2009. (dopunjena klasifikacija iz 2008.) prema kojoj su znanstvenim područjima, poljima i granama dodana i umjetnička područja, polja i grane. Postoji devet *znanstvenih i umjetničkih područja* u okviru kojih su *znanstvena polja, znanstvene grane i znanstveni ogranci*. Dakle, važeća je klasifikacija znanosti i umjetnosti sljedeća:

Znanstvena i umjetnička *područja* su:

1. Prirodne znanosti,
2. Tehničke znanosti,
3. Biomedicina i zdravstvo,
4. Biotehničke znanosti,
5. Društvene znanosti,
6. Humanističke znanosti,
7. Umjetničko područje,
8. Interdisciplinarna područja znanosti,
9. Interdisciplinarna područja umjetnosti.

Područja se dijele na *polja*, npr.:

Područje *Društvenih znanosti* sadrži sljedeća *polja*:

1. Ekonomija,
2. Pravo,
3. Politologija,

4. Informacijske i komunikacijske znanosti,
5. Sociologija,
6. Psihologija,
7. Pedagogija,
8. Edukacijsko-rehabilitacijske znanosti,
9. Logopedija,
10. Kineziologija,
11. Demografija,
12. Socijalne djelatnosti,
13. Sigurnosne i obrambene znanosti,
14. Interdisciplinarne društvene znanosti.

Unutar pojedinih znanstvenih područja i polja utvrđuju se znanstvene *grane*, npr.:

Područje *Društvenih znanosti,* polja *Ekonomija*, *grane* su:

1. Ekonomika poduzetništva,
2. Financije,
3. Kvantitativna ekonomija,
4. Organizacija i menadžment,
5. Međunarodna ekonomija,
6. Opća ekonomija,
7. Trgovina i turizam,
8. Poslovna informatika,
9. Makroekonomija,
10. Mikroekonomija,
11. Ekonomska matematika i statistika,
12. Marketing,
13. Računovodstvo.[35]

Osim ove, službene, klasifikacije pojedinih znanosti i dijelova znanosti, postoje i druge koje imaju vlastite ciljeve i namjene. Tako je u knjižničarstvu uobičajena tzv. univerzalna decimalna klasifikacija (UDK) koja predstavlja sustavni prikaz područja cjelokupnog ljudskog znanja, s mogućnostima stalnog razvoja i dodavanja novih područja. Za održavanje ove klasifikacije zadužen je poseban nepro-

[35] Cjelovit prikaz znanstvenih i umjetničkih područja, polja i grana vidi u: *Pravilnik o znanstvenim i umjetničkim područjima, poljima i granama*, Narodne novine, broj 118 (2009.).

fitni konzorcij sa sjedištem u Haagu (Nizozemska). UDK se sastoji od glavnih i pomoćnih tablica koja znanje dijele na 10 glavnih skupina (označenih brojevima od 0 do 10, a glavne se skupine dalje dijele na podksupine koje se dalje mogu dijeliti *ad infinitum*. Pomoćne tablice sadrže elemente koje su zajednički skupinama navedenim u glavnim tablicama (opće pomoćne tablice), odnosno vezane su za neku od tih skupina (specijalne pomoćne tablice). Pomoćne tablice, primjerice, sadrže oznake za neki jezik, mjesto izdavanja publikacije i sl. Tako ova knjiga ima UDK 303.01(075.8), što znači da je u pitanju visokoškolski udžbenik – oznaka (075.8) koji se teorijski bavi metodologijom društvenih znanosti – oznaka 303.01.

## 3.2. ZADATCI I OBILJEŽJA ZNANOSTI

Treba reći da je danas društvena uloga znanosti određena i zadatcima koji u svojoj konačnoj izvedbi često i ne ostavljaju dojam znanstvenosti. M. Žugaj (1997: 2) navodi više zadataka i očekivanja stavljenih pred znanost, a koji se potvrđuju kao *praktički doprinosi znanstvenih istraživanja* u proizvodnoj i drugoj praksi. Nabrojimo neke:

- povećanje opsega proizvodnje,
- poboljšanje kakvoće novostvorenih vrijednosti,
- stvaranje novih ideja, spoznaja, proizvoda,
- bolja raspodjela stvorenih vrijednosti,
- bolja organizacija rada, racionalnost i uspješnost,
- racionalizacija prostornih kapaciteta,
- bolji raspored i uporaba ljudskih potencijala,
- racionalnije opremanje i bolja uporaba postojeće opreme,
- poticanje i prihvaćanje novatorstva,
- skraćivanje vremena od otkrića do njegove primjene,
- izvoz znanja,
- stvaranje uvjeta za širenje znanja,
- stvaranje uvjeta za bolji opći i osobni standard, ...

Iz same definicije znanosti jasno je da, kao i svaka druga djelatnost, i znanost ima određenu zadaću u društvu, bilo u neposrednoj praktičnoj primjeni, ili odgođenoj primjeni u rezultatima nekih drugih istraživanja. Od znanosti se traži 1. da je *univerzalna* (glede predmeta istraživanja) i svojim zahtjevima dostupna

svima, i 2. da je *praktički upotrebljiva* (na opće dobro) (Ben-David, 1986: 12). To, drugim riječima, znači da se od znanstvene spoznaje očekuje ne samo teorijsko predviđanje, nego i praktičko ovladavanje prirodnim i društvenim procesima s osnovnom svrhom da koristi ljudskim potrebama (Ivanović, 1996: 83).

Zadatke znanosti, kao svojevrsne ciljeve znanstvenog istraživanja, možemo svesti na nekoliko ključnih: prvi je zadatak *otkrivanje novih znanja* o istraživanom predmetu; drugi je *argumentiranje* novih spoznaja mogućnošću primjene (teorijske ili praktične) koja daje bolje rezultate od starog znanja, a treći je *nedogmatski pristup* novoj spoznaji, što je u duhu znanosti kao otvorene i nezavršene, što potvrđuje i dinamički karakter sâme znanosti.

Iz tih polazišnih zadataka mogu se odrediti i za znanost prepoznatljiva obilježja. Ovdje ćemo navesti osam ključnih:[36]

1. *Jedinstvenost* znanosti potvrđuje se u znanstvenom pristupu koji čine sistematizirana i argumentirana znanja o prirodi i društvu, a temelji se na primjeni objektivnih znanstvenih metoda s ciljem spoznaje zakona i zakonitosti o prirodi i društvu.
2. *Upotreba znanstvenih metoda* osnova je svakog znanstvenog istraživanja, znanstvene metode glavno su oruđe znanosti prema kojemu se znanost izdvaja od drugih djelatnosti.
3. *Objektivnost* u znanosti jedan je od stupova na kojima se gradi povjerenje u znanost. Objektivnost se postiže transparentnošću istraživačkog postupka i mogućnošću provjere postignutih spoznaja. Iako se zna da apsolutne objektivnosti nema čak ni u prirodnim znanostima, ona je ipak važna značajka znanstvenog pristupa.
4. *Pouzdanost* znanstvene spoznaje gradi se na poštivanju znanstvene procedure. To znači da odnos polazišne hipoteze i dobivenih rezultata nije stvar „dogovora" ili „uštimavanja" potrebama istraživača, već je rezultat primjene znanstvenih metoda i tehnika pomoću objektivnih instrumenata na istraživanom uzorku.

---

[36] U svom udžbeniku R. Zelenika navodi 14 značajki znanosti: 1. Jedinstvenost znanosti, 2. Jedinstvo znanstvene teorije i prakse, 3. Znanstveno istraživanje i znanstvene metode, 4. Kreativnost u znanosti (stvaralaštvo), 5. Svjesno organizirani timski rad znanstvenika, 6. Zakon ubrzanog razvoja znanosti, 7. Dinamički razvoj znanosti, 8. Sličnost u fazama razvoja znanosti, 9. Objektivnost i znanost, 10. Preciznost, studioznost i znanost, 11. Pouzdanost i znanost, 12. Sustavnost i znanost, 13. Analitičko-sintetički postupak i znanost, 14. Racionalnost i znanost (Zelenika, 1998: 60-65).

5. *Preciznost* u znanosti ne smije biti upitna. Ona se mora potvrđivati u svim koracima znanstvenog istraživanja: od definiranja problema, predmeta i cilja istraživanja, preko hipotetskih polazišta, do odabira metoda i tehnika, uzorka istraživanja, a posebno analize dobivenih rezultata. Preciznost se posebno traži pri upotrebi znanstvenih pojmova, definicija i klasifikacija kako se ne bi višeznačno koristili.
6. *Analitičko-sintetički postupak* neophodan je u svakom znanstvenom pristupu određenoj pojavi. Taj se postupak temelji na primjeni logike metoda analize i sinteze, i to tako da se istraživana pojava analitički rastvori na jednostavnije, razumljivije dijelove iz kojih se, pak, sintezom izvode zaključci o zajedničkim obilježjima, poveznicama, uzrocima i slično.
7. *Sustavnost* je posebno uočljivo obilježje zbog svoje prisutnosti u svakoj fazi znanstvenog istraživanja. Ako pođemo od teze da se sustav potvrđuje u samodovoljnosti cjeline i svih njezinih dijelova za njihovo postojanje, tada se i sustavnost treba shvatiti kao potpunost i cjelovitost u znanosti, posebice u njezinim istraživačkim fazama. Svaka znanstvena aktivnost mora imati cilj i plan, sredstva izvršenja i izvršitelje, redoslijed izvršenja zadataka, završetak i provjeru izvršenja zadatka. Istraživačke faze međusobno se dopunjuju a ne isključuju, pa se upravo u tome treba potvrđivati sustavnost. Svaka od faza znanstvenog istraživanja može se shvatiti kao podsustav koji zajedno s ostalima čini cjelinu, tj. potvrđuje sustavnost znanosti.
8. *Racionalnost* u znanosti obilježje je kojim se znanost uvijek potvrđuje kao potrebna aktivnost. To znači da se pri započinjanju bilo koje znanstvene aktivnosti uvijek treba voditi računa o ekonomičnosti trošenja vremena rada, energije i materijala u istraživanju. No, ne samo da je potrebno „uštedjeti" u svakoj fazi znanstvenog istraživanja, nego se treba opravdati zašto je određeno istraživanje potrebno provesti. Racionalnost se potvrđuje i u načinu objavljivanja rezultata, kada se postavlja pitanje treba li umnožavati debele cjelovite studije za javnost ili sve svesti na tanke brošure prikazivanja samih rezultata. Danas se informatizacija pokazuje kao velika ušteda vremena, energije i materijala u znanosti.

Na tragu navedenih zadataka i obilježja znanosti i znanstvenog pristupa predmetima istraživanja navedimo distinkciju **Edgara Morina** (2008: 61-63) između znanstvenog mišljenja („dobro misliti") i neznanstvenog („loše misliti").

Neznanstveno, *loše misliti* znači:

- Komadati naše znanje i spremati ga u zasebne pretince,

- Težiti ignoriranju konteksta,
- Stvarati *black-out* o kompleksnosti,
- Vidjeti samo jedinstvo ili različitost, a ne i jedinstvo različitosti i različitost jedinstva,
- Vidjeti samo ono neposredno, zaboravljati prošlost i vidjeti samo kratkoročnu budućnost,
- Ispuštati bitno zbog hitnog, i zaboravljati hitnost bitnog,
- Privilegirati mjerljivo i uklanjati ono što računica ne poznaje,
- Širiti deterministička i mehanička logiku umjetnog stroja na društveni život,
- Uklanjati ono što izmiče zatvorenoj racionalnosti,
- Odbacivati dvosmislenost i kontradikcije kao pogreške mišljenja,
- Poštivati paradigmu pojednostavljivanja koju nameće načelo disjunkcije ili/i načelo redukcije za spoznaju koje sprečava da se shvate veze jedne spoznaje s njezinim kontekstom i s cjelinom čiji je ona sastavni dio,
- Slabiti razumijevanje i štetiti dijagnozi.

Znanstveno, *dobro misliti* znači:

- Povezivati,
- Uklanjati pretince u koje je zatvoreno naše mišljenje,
- Odbacivati krnja gledišta razdvojenih disciplina i tražiti pluridisciplinarnu ili transdisciplinarnu spoznaju,
- Prihvaćati metodu za obradu kompleksnosti,
- Poštovati načelo koje u isto vrijeme navodi i na razlikovanje i na povezivanje,
- Prepoznavati složenost u jedinstvu i jedinstvo u složenosti,
- Ne zaboravljati hitnost bitnog,
- Integrirati računicu i kvantifikaciju u svoja sredstva spoznaje,
- Graditi otvorenu racionalnost,
- Prepoznavati i hvatati se ukoštac s neizvjesnostima i kontradikcijama,
- Graditi dijalogiku koja integrira i nadilazi klasičnu logiku,
- Nastojati graditi solidarnost između elemenata cjeline,
- Boriti se protiv deformacija pamćenja, selektivnog zaboravljanja, samoopravdavanja i samozasljepljivanja.

Znanstveno misliti znači u procesu znanstvenoistraživačkih aktivnosti ostati otvoren očekivanom i predviđenom, kao i neočekivanom i nepredviđenom. Ono

također znači da se i u konačnim rezultatima osjeti ta dinamičnost i nezavršenost, a što je rečeno u određenju zadataka znanosti. Sve to treba biti dovoljna argumentacija u razlikovanju znanosti od pseudoznanosti.

Iako mnogi kritičari „znanstvene svemoći" povjerenje u znanost nazivaju svojevrsnom religijom, to im ne daje argumente da izbrišu jasne granice između znanstvenog pristupa i pseudoznanstvenog. *Pseudoznanost*, za razliku od praznovjerja, tvrdi da se temelji na znanstvenim argumentima, no ti argumenti uglavnom ne zadovoljavaju uobičajene znanstvene kanone. Kao najvažnije sastavnice pseudoznanosti mogu se izdvojiti sljedeća obilježja (Pavić, 2012):

1. *Neprovjerljive i nejasne tvrdnje* – npr. astrološka predviđanja, kao jedna od najzastupljenijih formi pseudoznanosti današnjice, najčešće su vrlo nejasna i ne mogu se pouzdano testirati.
2. *Tvrdnje i teorije koje su višestruko opovrgnute* pomoću rigoroznih testova utemeljenih na strogim metodološkim načelima – npr. mnoge grane alternativne medicine u većini eksperimenata ne pokazuju učinak koji se ne bi mogao objasniti placebo-efektom.
3. *Nemogućnost drugih promatrača da testiraju teorije* – npr. praktikanti alternativne medicine svojim klijentima nude individualizirane terapije koje nitko drugi ne može ponoviti.
4. *Ignoriranje protivnih dokaza* – pseudoznanost bira samo one empirijske dokaze koji potvrđuju njezine tvrdnje.
5. *Oslanjanje na anegdotalne dokaze* – nepouzdani dokazi često se uzimaju kao pouzdani, npr. Dan Brown u *Da Vincijevu kodu* nepouzdane legende o dolasku Marije Magdalene u Francusku proglašava povijesnom činjenicom.
6. *Teret je dokazivanja na onome tko opovrgava pseudoznanost* (*argumentum ad ignorantiam*) – npr. „teoretičari zavjera" obično zahtijevaju da se njihove, uglavnom neprovjerljive teorije, u potpunosti opovrgnu. Ako se to ne može učiniti, smatraju ih dokazanim.

***Pseudoznanost se od legitimne znanosti razlikuje se po postavljanju nejasnih i neopovrgljivih tvrdnji koje ne mogu testirati nezavisni promatrači, ili po tvrdnjama koje su višestruko opovrgnute u istraživanjima.***

Najčešće su forme u kojima se danas javlja pseudoznanost *astrologija* (temelji se na vjerovanju u božansku narav planeta, tj. mogućnost da se poruke bogova pročitaju iz njihova kretanja), *alternativna medicina* (metode liječenja koje nisu

znanstveno utemeljene i uglavnom se sastoje od placebo efekta) i *kreacionizam* (teološko-znanstveno protivljenje teoriji evolucije).

## DODATNA LITERATURA UZ TREĆE POGLAVLJE

Shoemaker, Pamela J.; Tankard, James W.; Lasorsa, Dominic L. (2004). *How to Build Social Science Theories.* London: Sage Publications.

Autori objašnjavaju osnovne građevne elemente teorija u društvenim znanostima te pokazuju kako od njih izgrađivati multivarijatne modele utemeljene na operacionalnim definicijama varijabli. U knjizi se također elaboriraju načini evaluacije i upotrebe teorija.

## PITANJA UZ TREĆE POGLAVLJE

1. Uslijed čega se tijekom povijesti dogodio razvoj posebne čovjekove djelatnosti nazvane znanost?
2. Što je znanost?
3. Što je znanstvena teorija?
4. Koji su sastavni elementi teorije?
5. Što su znanstveni konstrukti, znanstvene hipoteze, znanstveni zakoni i znanstvena objašnjenja?
6. Koja su tri temeljna obilježja znanstvenog objašnjenja?
7. Što su to ekološka pogreška i pogreška redukcionizma?
8. Koje su se dvije skupine znanosti prve odijelile?
9. Koja su znanstvena i umjetnička područja utvrđena prema važećoj klasifikaciji u RH?
10. Na što se dijele znanstvena i umjetnička područja?
11. U čemu se danas mogu vidjeti praktički doprinosi znanstvenih istraživanja?
12. Što se danas, prema Ben-Davidu, traži od znanosti?
13. Koja tri ključna zadatka znanosti možemo izdvojiti?
14. Kojih je osam prepoznatljivih obilježja znanosti?
15. Što znači, prema E. Morinu, „loše misliti“, a što „dobro misliti“?
16. Koja su obilježja pseudoznanosti?
17. U koje se tri forme najčešće javlja pseudoznanost?

# 4. ZNANSTVENO ISTRAŽIVANJE

Iz određenja znanosti u prethodnom poglavlju razvidno je da se znanost kao posebna ljudska aktivnost potvrđuje u istraživanju. Da bi neko istraživanje bilo znanstveno, ono mora podržavati sve one kriterije znanstvenosti koji vrijede za znanost. Prije svega, neko će istraživanje biti znanstveno ako se oslanja na *znanstvene metode* i ako *rezultate* dobivene uporabom tih metoda koristi isključivo u *znanstvene svrhe*. Još treba dodati da znanstveno istraživanje poduzima i provodi *znanstvenik*, bilo sâm ili u timu znanstvenika sa sveučilišta, pojedinih fakulteta ili instituta. „*Znanstveno istraživanje* skup je svjesnih, sistematiziranih i metodološki organiziranih aktivnosti pomoću kojih dolazimo do objektivnog znanja o predmetu, odnosno pojavi koju istražujemo." (Baban i dr., 2000: 34)

Znanstvena se istraživanja uvijek poduzimaju kada za njima postoji potreba. To nisu ishitrene, dokoličarske aktivnosti znanstvenika i stručnjaka koji radi sebe žele nešto istražiti pa se time bave „rekreativno". Naprotiv, znanstvena su istraživanja uglavnom naručena s jasnim zadatkom, predmetom i ciljem istraživanja. Njih mogu provoditi samo znanstvenici i stručnjaci osposobljeni za područja u okviru kojih se istraživani problem nalazi. Za svako istraživanje moraju se osigurati *resursi*, kako oni *materijalni* (novac, prostor i oprema) tako i *znanstveni/stručni* (provjereni znanstvenici za određena područja istraživanja, pristup informacijama o istraživanom problemu).

Također treba još dodati, kako navode Kukić i Markić (2006: 48-49), da svako znanstveno istraživanje treba udovoljiti trima zahtjevima:

1. Zahtjev za *izvornošću* koji se ne odnosi samo na istraživanje neistraženog, nego i na spoznavanje i otkrivanje novih znanja već istraživanih predmeta. Prema tom zahtjevu svako znanstveno istraživanje mora u konačnici imati znanstveni doprinos.
2. Zahtjev za *pouzdanošću i provjerljivošću* činjenica i ideja na kojima se znanstveno istraživanje temelji.
3. Zahtjev za *korištenjem najprimjerenijih metoda* u znanstvenom istraživanju kako bi se izbjeglo nekorisno gomilanje različitih metoda koje ne daju rezultate ubrojive u znanstveni doprinos istraživanja.

## 4.1. KLASIFIKACIJA ZNANSTVENIH ISTRAŽIVANJA

Brojne su klasifikacije znanstvenih istraživanja što nam kazuje kako ih je moguće klasificirati prema različitim kriterijima. Kriteriji se mogu temeljiti na znan-

stvenosti i stručnosti, primjenjivosti, različitosti predmeta istraživanja, načina provođenja, vremena provođenja, znanstvene disciplinarnosti i slično.[37] Za naše smo se potrebe odlučili prikazati sljedeće klasifikacije.

### 4.1.1. Podjela prema stupnju znanstvenosti

Najraširenija je UNESCO-va klasifikacija koja znanstvena istraživanja dijeli na fundamentalna, primijenjena i razvojna.

*Fundamentalna* znanstvena istraživanja imaju kao osnovni zadatak proširiti postojeće znanje. Neovisno o predmetu istraživanja i znanstvenom području, sva su fundamentalna istraživanja slična u jednom – njihov je rezultat uvijek *nova spoznaja* o istraživanom predmetu kojom se proširuje postojeće znanje, ili mijenja na temelju novih otkrića. Zbog svoje prirode ta se istraživanja još nazivaju temeljna, bazna, polazišna, osnovna, a pojedini ih autori još nazivaju *čistom znanošću*. Fundamentalna su istraživanja uglavnom (1) skupa i zahtijevaju (2) angažiranje većeg broja znanstvenika i znanstvenih timova, a vrlo često su (3) dugotrajna, pa iza njih uglavnom stoje nacionalne države. Također, ona (4) ne nude praktična rješenja već su polazišta drugim istraživanjima.

Fundamentalna istraživanja dijelimo na: 1. *slobodna* (*neusmjerena*) *istraživanja*: ona u kojima znanstvenici sami slobodno biraju predmet istraživanja. Poticaj im je najčešće znanstvena radoznalost vezana uz određene nejasnoće koje se odnose na postojeća znanja. Cilj im nije unaprijed određen, niti se očekuje konkretna primjena njihovih rezultata. Takva istraživanja vrlo često donose neočekivane spoznaje. i 2. *usmjerena fundamentalna*: ta su istraživanja uvijek vođena unaprijed određenim ciljem, ali i svrhom primjene. Unaprijed je razrađena strategija njihove provedbe, pa se još nazivaju i strategijskim. Uglavnom su angažirani timovi znanstvenih istraživača).

*Primijenjena* znanstvena istraživanja još se nazivaju i *aplikativna* jer im je središnje obilježje otkrivanje novih znanja i njihova praktična primjena. Primijenjena istraživanja mogu postojeća fundamentalna otkrića primjenjivati na konkretne slučajeve, ali mogu i sama dolaziti do novih spoznaja koje će primijeniti. Pre-

[37] Postoje brojne podjele znanstvenih istraživanja kojima se želi jasno naglasiti kriterije distinkcije. Npr. Lj. Baban klasificira znanstvena istraživanja prema: vremenu istraživanja (prošlosti, sadašnjosti i budućnosti), učestalosti (povremena i stalna), kvantitetu (statička i dinamička) i kvaliteti (motivacijska i tehnološka), završenosti, načinu provođenja, disciplinarnosti, predmetu istraživanja u širem i užem smislu i druga (Baban, 2000: 37-60).

ma tome, primijenjena istraživanja kao i fundamentalna pridonose proširenju postojećeg znanja, samo se od fundamentalnih istraživanja razlikuju prema primjeni.

*Razvojna* istraživanja predstavljaju svojevrsni produžetak primijenjenih istraživanja.[38] Razvojna istraživanja idu korak dalje od primijenjenih, no ne u znanstvenom smislu već u smislu primjene i razvojnih poboljšanja u primjeni određenih znanja. Razvojna istraživanja su na neki način završetak ciklusa od znanstvenog otkrića do njegove primjene i razvoja u svakodnevnoj praksi. Za razliku od fundamentalnih istraživanja primijenjena i razvojna još se nazivaju *čistom tehnikom* ili akcijom (Baban, 2000:40).

### 4.1.2. Podjela prema stupnju uopćavanja

Prema stupnju uopćavanja istraživanja se mogu podijeliti na nomotetska i idiografska.

*Nomotetsko* istraživanje u osnovi predstavlja široko uopćavanje. Ono ima za cilj prikupiti zajednička obilježja ispitivane populacije. Iako pokazatelji nomotetskog istraživanja relativno dobro prikazuju populaciju, među članovima ispitivane populacije mogu postojati brojne razlike pa se nomotetskim istraživanjem među njima traži *sličnost*.

*Idiografski* pristup počiva na izučavanju pojedinca i naglašavanju njegove *jedinstvenosti*. Iako većinu istraživanja karakterizira nomotetski pristup, idiografska istraživanja služe im kao dopuna u spoznavanju pojedinca. Temeljna je metoda idiografskog pristupa *studija slučaja* (Milas, 2009: 46-47).

### 4.1.3. Kvantitativna i kvalitativna istraživanja

*Kvantitativna* istraživanja pružaju brojčani opis istraživane pojave pomoću statističke analize i sažimanja izvornih podataka. Sažeto rečeno, kvantitativna metodologija nastoji korištenjem formalnih metoda mjerenja i statističkog zaključivanja pronaći općenite zaključke o uzročno-posljedičnim odnosima (generalizacija). Kvantitativna istraživanja mogu biti *statička* (izražavaju trenutni odnos među pojavama ili opis pojave, npr. aritmetičku sredinu, mod, medijan, postotak

[38] R. Zelenika razvojna istraživanja naziva *stručnim* istraživanjima, jer polaze od znanja stečenih fundamentalnim i primijenjenim istraživanjima (Zelenika, 1998: 145).

i dr.) i *dinamička* (izražavaju odnose među pojavama u kraćim ili dužim razdobljima, npr. stopa rasta i dr.). Kvantitativna istraživanja mogu se prepoznati, posebice u društvenim znanostima, u različitim pristupima. Navedimo neke:

a) *pozitivistički pristup* (stvarnosti prilazi kao činjenicama koje je moguće klasificirati, brojčano izraziti njihove odnose poput korelacije i kauzalnosti), b) *funkcionalistički pristup* (na tragu pozitivizma, pristup je stvarnosti kao pozitivnim činjenicama koje promatra kroz odnos uzrok – posljedica. To je metodološki postupak kojim se određuje *funkcija* pojave, institucije, djelatnosti ili pojedinca u odnosu na društvo kao cjelinu), c) *eksperiment* (u prirodnim znanostima raširenији i egzaktniji, u društvenim se koristi s manjom uspješnošću zbog prirode uzorka istraživanja, tj. teško je kontrolirati uvjete u eksperimentalnoj skupini u odnosu na kontrolnu u terenskom eksperimentu, dok je u laboratoriju za prirodne znanosti to bitno olakšano), d) *komparativni pristup* (istražuje sličnosti i razlike među pojavama, društvima, društvenim skupinama, kulturama i sl. u istom vremenu ili različitim vremenskim razdobljima. Taj je pristup u prednosti pred eksperimentom što proučava pojave u njihovim prirodnim uvjetima.)[39]

*Kvalitativna* istraživanja polaze od toga da ljudi imaju svijest te njome interpretiraju i doživljavaju svijet posredstvom *značenja*. Pojave u društvu nemoguće je razumjeti kroz kauzalni odnos, već jedino razumijevanjem subjektivnih stanja pojedinaca koji se proučavaju. Kvalitativna metodologija rjeđe koristi formalizirano mjerenje i statističko zaključivanje. Cilj je te metodologije dubinski ispitati i razumjeti pojavu, a ne donositi općenite zaključke utemeljene na statističkom zaključivanju. Za razliku od utvrđivanja uzročno-posljedičnih odnosa koje važe za široku skupinu pojava, kvalitativnom se metodologijom nastoje objasniti specifični uzroci koji važe za jednu ili manji broj pojava (tzv. *lokalna uzročnost*). Primjerice, ako pokušamo objasniti zašto se neki umjetnički pravac pojavio baš u određenoj zemlji i u određeno vrijeme, obično ćemo se oslanjati na specifične okolnosti (kritična masa umjetnika sa sličnim senzibilitetom, podrška države, povijesne i društvene okolnosti, umjetnička tradicija i sl.), odnosno nećemo tu pojavu pokušati objasniti pomoću opće teorije o tome kako se i zašto pojavljuju novi umjetnički pravci.

Navedimo ovdje dva najčešća pristupa (paradigme) koje koriste kvalitativna istraživanja (metode):

*a) Interakcionistički pristup* suprotan je kvantitativnom iskazivanju ljudskih situacija. Taj pristup čovjekovo djelovanje tumači *interakcijom* s okruženjem koja

[39] O tradiciji kvantitativnog i kvalitativnog pristupa istraživanju u društvenim znanostima vidi: Šundalić, 2011: 290-292.

daje značenje njihovim životima. Tako, ako pojedinca okolina percipira kao dobrog i poštenog, njegovo će ponašanje ići u tom smjeru. Dakle, taj pristup naglašava deskripciju, ne kvantifikaciju.

*b) Fenomenološki pristup* polazi od uvažavanja unutarnje logike koja proizvodi određeno djelovanje. Bitno je razumjeti *stanje duha* pojedinih aktera, otkrivanje značenja djelovanja pomoću *interpretacije i intuicije*. U sociologiju taj pristup uvode Wilhelm Dilthey i Max Weber. Weberovo inzistiranje na razumijevanju društvenih pojava odvaja društvene od prirodnih znanosti. Za Webera je uvijek pojedinac u središtu kulturno-historijskih istraživanja i njegova uvjetovanost kulturno-povijesnim okolnostima.

Kako je vidljivo iz ranije izrečenog, kvantitativna i kvalitativna istraživanja razlikuju se u svojim ontološkim i epistemološkim pretpostavkama, kao i pretpostavkama o ljudskoj prirodi i metodologiji, a te razlike prikazujemo u sljedećoj tablici.

*Tablica 8. Razlike između kvantitativne i kvalitativne metodologije*

| | **Kvantitativna metodologija** | **Kvalitativna metodologija** |
|---|---|---|
| Ontologija | Realizam | Nominalizam |
| Epistemologija | Pozitivizam | Antipozitivizam |
| Ljudska priroda | Determinizam | Voluntarizam |
| Metoda | Nomotetička | Idiografska |

Izvor: Burrell i Morgan, 1979; navedeno prema Cohenu i sur., 2007: 7.

Kvantitativna metodologija prihvaća realističku ontologiju,[40] tj. smatra da opći pojmovi postoje izvan pojedinačnog uma (da objektivno postoje). Prema nominalističkoj ontologiji, koju predstavlja subjektivistički pristup (kvalitativna metodologija), opći pojmovi ne postoje izvan subjektivne svijesti, tj. ne predstavljaju objektivnu stvarnost. U društvenim znanostima realizam podrazumijeva realno postojanje društvenog svijeta i njegovih značenja, a nominalizam da ljudi sami izgrađuju njegovo značenje. Primjerice, istraživač koji se drži ontološkog realizma proučavat će različite oblike društvene devijantnosti (kriminal, ovisnosti i sl.) pod pretpostavkom da su ove pojave devijantne u svim društvima (devijantne same po sebi). Istraživač koji se drži ontološkog nominalizma istraživat će zašto se u društvima neke pojave označavaju devijantnima, a neke ne. Drukčije rečeno, polazit će od toga da ne postoji objektivno značenje pojma „devijantnost", tj. da se taj pojam u različitim društvima može odnositi na različite pojave.

[40] Ontologija je filozofska disciplina koja proučava osnovnu strukturu stvarnosti.

U epistemološkom smislu[41] kvantitativna je metodologija pozitivistička, tj. smatra da je društvo i ljude moguće proučavati „izvana", na način na koji postupaju i prirodne znanosti. Prema antipozitivističkoj epistemologiji, znanje je subjektivno pa se istraživati može samo proučavajući ljude iznutra, tj. da se razumije smisao koji oni daju svojemu djelovanju.

Kvantitativna i kvalitativna metodologija razlikuju se i u pogledu shvaćanja ljudske prirode. Objektivisti smatraju da ljudsko ponašanje određuju sile koje su izvan kontrole pojedinca (determinizam), dok subjektivisti smatraju da čovjek slobodno djeluje smisleno određujući svoje ponašanje (voluntarizam).

Sve te razlike u konačnici se odražavaju i u metodama istraživanja. Kvantitativno usmjereni istraživači tragaju za općim zakonitostima (nomotetički pristup), te će nastojati primjenjivati metode koje primjenjuju znanstvenici u prirodnim znanostima, tj. kvantitativne metode (eksperiment, korelacijska istraživanja i slične nacrte utemeljene na objektivnim podatcima). Kvalitativno orijentirani istraživači smatraju da nije moguće pronaći opće zakonitosti te pokušavaju što detaljnije opisati specifične situacije (idiografski pristup). Kvalitativni pristup, dakle, uključuje češću upotrebu metoda kao što su dubinski intervjui, fokus grupe, promatranje sa sudjelovanjem i sl.

***Kvalitativna se metodologija sastoji od pristupa koji nastoje dubinski proniknuti u pojave koje proučavaju, upotrebljavajući najčešće metode kao što su intervjui, fokus grupe, promatranje i sl. Kvantitativna metodologija nastoji postići kvantitativne generalizacije pomoću preciznijih podataka prikupljenih na većim uzorcima.***

Odluka o tome koju metodologiju primijeniti ovisi o ciljevima istraživanja, ali i o vrsti pojave koja se proučava. Naime, iako bi konačni cilj svih znanosti vjerojatno trebao biti pronalaženje općih zakonitosti (uzročno-posljedičnih odnosa), primjenom kvantitativne metodologije taj cilj nije moguće u svim znanostima postići na isti način i u istoj mjeri. Primjerice, književnu je kritiku teško kvantificirati, ona primarno ovisi o intuiciji i razumijevanju istraživača. Isto tako, proučavanje određenih političkih ideologija, religija ili svjetonazora nije moguće posve analizirati kvantitativnom metodologijom, potrebno je razumijevanje različitih vrijednosnih pozicija, tj. „uživljavanje" u poziciju drugih, koje se teže može po-

[41] Epistemologija je filozofska disciplina koja proučava prirodu znanja (što se može spoznati i kako).

stići kvantitativnim istraživanjem tih pojava, odnosno nastojanjem utvrđivanja općih zakonitosti.

### 4.1.4. Prethodna i konačna istraživanja

*Prethodna* istraživanja sva su ona istraživanja kojima je osnovna svrha „snimanje situacije" kako bi se pripremio teren za konačno istraživanje. Zbog toga se ta istraživanja još nazivaju pilot, preliminarna ili orijentacijska. Zbog „upitnosti" i „nesigurnosti" polazišta i načina pristupa ta se istraživanja obavljaju na malom uzorku kako bi se stvorili što manji troškovi istraživanja. Uočene slabosti i propusti u pripremi (postavljanje hipoteza, odabir uzorka, odabir metoda i tehnika istraživanja) i provedbi (priprema terena istraživanja, osposobljavanje istraživača-anketara) prethodnog istraživanja korigiraju se kako bi konačno istraživanje bilo s minimumom pogrešaka.

*Konačno* istraživanje slijedi poslije prethodnog. Ono je ciljano, dubinsko istraživanje jer su jasna polazišta (konkretizirani uzroci), preciziran uzorak i definirane metode i tehnike istraživanja. Hipotetski su precizno usmjerena s jasnim predmetom i ciljem istraživanja. Konačna istraživanja se stoga još nazivaju i završna, finalna istraživanja. Njihov rezultat su konačna izvješća koja se daju na uvid stručnoj i široj javnosti.

### 4.1.5. Povremena i stalna istraživanja

*Povremena* istraživanja su sva ona koja nemaju zadaću pratiti i mjeriti promjene na istraživanoj pojavi u određenim vremenskim intervalima. To su istraživanja koja provode pojedinci, skupine ili institucije prema aktualnosti određenog problema ili pojave u prirodi ili društvu. Kada se istraži određena pojava ili problem i nađe im se rješenje, istraživanje prestaje. Naručitelji ovakvih *ad hoc* istraživanja mogu biti državne institucije, političke stranke, velika poduzeća i drugi.

*Stalna* (longitudinalna) istraživanja vremenski se ne ograničavaju. Njima se prati određena pojava ili problem u kontinuitetu te se bilježe, mjere, uspoređuju uočene promjene. Ta su istraživanja vrlo korisna u proučavanju društvenog razvoja kako bi se predvidio smjer i vrsta promjena u društvu. Također su korisna i u istraživanju prirode, u praćenju prirodnih fenomena kako bi se objasnile promjene i predvidjele buduće.

### 4.1.6. Istraživanja prema nositelju istraživanja

Nositelj znanstvenih istraživanja može biti pojedinac, tim ili institucija. Koja će istraživanja tko provoditi, ovisi o prirodi samog istraživanja (njegovom opsegu, složenosti, interdisciplinarnosti, veličini materijalnih sredstava i slično).

*Individualno* istraživanje provode pojedinci potaknuti vlastitom motivacijom da nešto istraže (slobodno istraživanje) ili narudžbom od zainteresiranih stranaka da se određeni problem ili pojava istraži (usmjereno istraživanje). Doktorske bi disertacije trebale biti tipičan primjer individualnog istraživanja.

*Timsko* istraživanje sve je zastupljenije zbog prirode predmeta istraživanja (njegove složenosti i česte interdisciplinarnosti). Timovi istraživača mogu biti znanstvenici iz jedne ili više institucija (fakulteta, instituta), povezani predmetom istraživanja u okviru istraživačkog projekta u kojemu svatko ima svoju dionicu. U timu je najčešće određen glavni istraživač koji pred naručiteljem preuzima odgovornost za provedbu istraživanja.

*Institucijsko* istraživanje je u osnovi timsko glede provođenja, s tom razlikom da je institucija nositelj istraživanja. Nositelji mogu biti instituti, akademije (HAZU posebice), sveučilišta, fakulteti, veleučilišta i visoke škole, državna tijela (istraživački centri pri ministarstvima, gospodarskim komorama i sl.), specijalizirana trgovačka društva i drugi. Već prema prirodi institucije, one su sposobne biti nositelji samo nekih istraživanja (npr. instituti za poljoprivredu) ili svih (npr. HAZU).

### 4.1.7. Istraživanja prema disciplinarnosti

U današnje je vrijeme sve teže znanstvena istraživanja ograničiti na određenu disciplinu. Vrlo često ono se širi izvan vlastitog područja pa postaje interdisciplinarno i multidisciplinarno.

*Disciplinarno* je istraživanje ono koje se provodi u okviru jedne discipline, neovisno je li riječ o polju (npr. ekonomija, sociologija) ili grani (npr. mikroekonomija, sociologija kulture). Sve je teže, međutim, zadržati se u okviru jednog područja, osobito kada je riječ o istraživanju društva.

*Interdisciplinarno* istraživanje uvjetovano je predmetom istraživanja, tj. u nemogućnosti da se određeni predmet istraži u okviru jedne discipline, angažiraju se istraživači iz drugih, za sâm predmet bitnih disciplina (npr. istraživanje učinaka pada stope gospodarskog rasta traži interdisciplinarni pristup: ekonomije, sociologije, politologije i sl.).

*Multidisciplinarno* istraživanje također je uvjetovano predmetom istraživanja. No, za razliku od interdisciplinarnog pristupa koji objedinjuje srodne znanosti (iz istog područja, npr.), multidisciplinarno istraživanje povezuje nesrodne discipline (iz različitih područja i polja). Npr. ako želimo istražiti utjecaj klimatskih promjena na suvremeni način života, potrebno je poduzeti istraživanja iz fizike, geografije, demografije, sociologije, medicine, ekonomije i slično.

### 4.1.8. Istraživanja prema razini obuhvata

Znanstvena se istraživanja mogu razlikovati i prema razini dosega svojih rezultata. Ta se razlika najčešće razlikuje kao makro-, mezo- i mikrorazina.

*Makroistraživanja* su ona istraživanja koja se poduzimaju da bi se istražila jedna pojava ili problem na razini cjeline. Npr. istraživanje gospodarskog rasta u Republici Hrvatskoj odnosi se na ukupno gospodarstvo države.

*Mezoistraživanja* su ona istraživanja koja se poduzimaju kada se istražuje jedna pojava ili problem na ograničenom prostoru, određenom dijelu cjeline. Npr. ako se istražuje gospodarski rast neke regije u odnosu na cijelu državu. To znači da rezultati mezoistraživanja imaju određeno značenje samo u odnosu na makroistraživanje.

*Mikroistraživanje* je ono istraživanje koje se poduzima na najnižoj razini ili na najmanjem dijelu cjeline. Npr. istraživanje gospodarskog rasta na primjeru jednog poduzeća. Da bi ono imalo određeno značenje, valja ga povezati s istraživanjima u okviru pripadajuće privredne grane, na razini regije i države u cjelini.

Dakle, mikro-, mezo- i makroistraživanja treba povezivati kako bi se dobilo pravo značenje rezultata istraživanja određene razine.

### 4.1.9. Istraživanja prema razini znanstvene spoznaje

Znanstvena se istraživanja prema razinama znanstvene spoznaje mogu podijeliti na (Mejovšek, 2008: 19):

1. Deskripciju pojava,
2. Klasifikaciju pojava,
3. Utvrđivanje povezanosti pojava,
4. Utvrđivanje uzroka pojava.

*Deskripcija* se odnosi na opisivanje obilježja pojava koje se proučavaju. U kvantitativnim se istraživanjima to najčešće odnosi na osnovna kvantitativna obilježja varijabli (frekvencije, prosječne vrijednosti, mjere raspršenosti i sl.), kao i na osnovna obilježja uzorka. Na taj se način stječe prvi dojam o mjerenim varijablama i karakteristikama uzorka. U kvalitativnim istraživanjima obično je riječ o verbalnom opisu prikupljenih podataka (npr. opisivanje podataka dobivenih individualnim ili skupnim intervjuima, promatranjem i sl.).

*Klasifikacija* pojava odnosi se na podjelu pojmova ili podataka u grupe na osnovi posjedovanja određenih obliježja, odnosno na temelju njihove sličnosti/različitosti. Klasifikacijom se tako unosi neka vrsta reda u pojave koje se analiziraju ili u mnoštvo prikupljenih podataka. Svaka klasifikacija mora ispunjavati određene logičke preduvjete kako bi bila uspješna (prilagođeno prema Šešiću, 1974; navedeno prema Kukiću i Markiću, 2006: 206-207). Prema načelu *određenosti predmeta klasifikacije*, pojam koji se klasificira mora biti određen jasno i nedvosmisleno, odnosno mora se znati njegov sadržaj i opseg. Načelo *jedinstvenosti* govori nam da se pri klasifikaciji ne smiju miješati različiti kriteriji jer se u tom slučaju dobivaju međusobno neusporedive kategorije. Primjerice, ako ljude klasificiramo prema etničkoj pripadnosti, ne možemo usred klasifikacije promijeniti kriterij i početi ih klasificirati prema religijskoj pripadnosti jer ćemo, primjerice, dobiti podjelu na Austrijance, Nijemce i katolike. Načelo *potpunosti podjele* kaže nam da podjela mora biti iscrpna, tj. mora obuhvatiti sve kategorije i cjelokupni opseg nekoga pojma. Primjerice, klasifikacija ljudi prema stupnju obrazovanja na one sa završenom osnovnom i srednjom školom nije potpuna jer su izostavljeni ljudi s visokoškolskim obrazovanjem.

Kombiniranjem više kriterija klasifikacije stvaraju se *tipologije*. Tipovi se stvaraju na osnovi istovremenog posjedovanja dvaju (ili više) obilježja koji se dobivaju dvama različitim načelima klasifikacije. Npr., prema tipologiji devijantnog ponašanja koju je iznio sociolog Robert Merton, ljudi se, u ovisnosti o tome prihvaćaju li društveno prihvaćene vrijednosti (materijalni uspjeh) i društveno prihvatljive načine njihova postizanja (rad, obrazovanje...), mogu podijeliti na nekoliko tipova prikazanih u sljedećoj tablici.

*Tablica 9. Mertonova tipologija devijantnosti*

| **Tip** | **Prihvaćanje vrijednosti** | **Prihvaćanje načina njihova postizanja** |
|---|---|---|
| Konformist | + | + |
| Inovator (npr. kriminalci) | + | - |
| Buntovnik (supkulture, alternativni životni stilovi) | - | - |
| Ritualist | - | + |

Tako, primjerice, konformist istovremeno prihvaća dominantne društvene vrijednosti (npr. materijalni uspjeh), a istovremeno prihvaća i društveno određena sredstva načina njihovog ostvarenja (obrazovanje i rad). Inovatori, poput kriminalaca, kao i konformisti prihvaćaju vrijednost materijalnog uspjeha, ali ih pokušavaju ostvariti na druge načine, odbijajući društveno prihvatljiva sredstva.

Klasificiranje (tipologiziranje) pojava može se izraditi na različite načine (prema različitim kriterijima), a uspješnost klasifikacije u znanosti ocjenjuje se prema njihovoj plodnosti, tj. prema novim znanstvenim spoznajama koje klasifikacija donosi. Npr., ako različite oblike devijantnog ponašanja uspijemo povezati s društvenim slojem i uspijemo objasniti zašto su npr. pripadnici viših slojeva češće „konformisti", a nižih slojeva češće „inovatori", tada se navedena Mertonova klasifikacija može označiti kvalitetnom (plodonosnom).

*Povezanost pojava* najčešće se utvrđuje statističkom analizom i izražava određenim koeficijentom asocijacije (korelacije). Povezanost pojava znači da su vrijednosti jedne varijable na određeni način povezane s vrijednostima druge varijable (npr. više vrijednosti na jednoj varijabli znače i višu vrijednost na drugoj varijabli). Na primjer, ako ljudi višeg obrazovanja obično imaju više, a ljudi nižeg obrazovanja niže prihode, tada možemo reći da postoji (pozitivna) povezanost između varijabli obrazovanja i prihoda.

*Utvrđivanje uzroka pojava*, odnosno kauzalnosti, označava najvišu razinu znanstvenog istraživanja, a važno je istaknuti da sve pojave koje su statistički povezane nisu nužno i uzročno-posljedično (kauzalno) povezane. Sâm se pojam kauzalnosti odnosi na postojanje reda i pravilnosti koji stoje iza mnoštva empirijskih pojava, stoga je u slučaju kauzalnosti riječ o povezanosti između teorijskih pojmova (konstrukata) koji nisu neposredno mjerljivi. Drukčije rečeno, unatoč tome što je empirijski svijet u stalnom kretanju i promjenama, kauzalnost pretpostavlja da se pravilnosti koje se mogu primijetiti mogu objasniti teorijskim pojmovima čiji se učinak manifestira u empirijskom svijetu i koji se tako može izmjeriti pomoću odgovarajućih indikatora.

***Prema razini analize, istraživanja se mogu odnositi na deskripciju, klasifikaciju, utvrđivanje povezanosti (korelacije) te utvrđivanje uzročnosti (kauzalnosti).***

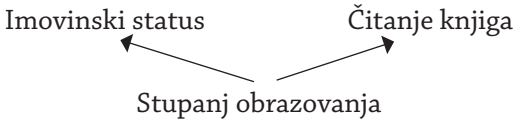
U pravilu se može reći da postoje tri preduvjeta koji moraju biti kumulativno zadovoljena da bi se neke varijable mogle smatrati uzročno-posljedično povezanim:

1. Pojave moraju biti korelirane (kovarijacija pojava),

2. Uzrok mora vremenski prethoditi posljedici,
3. Utjecaj drugih varijabli mora se isključiti (kontrolirati).

Varijable moraju biti empirijski povezane (korelirane), inače ne mogu biti niti uzročno-posljedično povezane. Npr., ako rezultati na jednoj pojavi (uzroku, nezavisnoj varijabli) nisu pozitivno ili negativno korelirani s rezultatima na drugoj varijabli (posljedici, zavisnoj varijabli), tada nema smisla niti govoriti o uzročnosti (kauzalnosti).[42] Slično tome, ako uzrok vremenski ne prethodi posljedici, ne možemo govoriti da jedna pojava uzrokuje drugu.

Prije nego što se iz korelacije dviju varijabli zaključi i da su kauzalno povezane, potrebno je isključiti utjecaj drugih varijabli koje mogu utjecati na ovu korelaciju. Npr., utvrdimo li da imućniji pojedinci češće čitaju knjige, to ne mora značiti da su ove dvije pojave doista i kauzalno povezane. Naime, stupanj obrazovanja mogao bi biti pozitivno povezan i s imovinskim statusom i s čitanjem knjiga, pa bi se njime mogla objasniti korelacija između tih dviju pojava. U tom slučaju kažemo da je u pitanju *lažna korelacija*, tj. korelacija iza koje ne stoji uzročno-posljedični (kauzalni) odnos između koreliranih pojava.




***Da bi u nekom slučaju mogli govoriti o uzročno-posljedičnoj vezi između dviju pojava, one moraju biti korelirane, uzrok se mora pojaviti prije posljedice te moramo isključiti mogući utjecaj trećih varijabli.***

Tek se utvrđivanjem uzročno-posljedičnih povezanosti neka pojava objašnjava i razumije u punom smislu riječi. Naime, utvrđivanje povezanosti pojava najčešće omogućuje predviđanje, ali ne i dublje razumijevanje koje u nekim slučajevima može omogućiti i intervencijsko djelovanje, tj. usmjeravanje pojava u željenom tijeku. Primjerice, uzmimo da smo utvrdili negativnu povezanost između količine vremena provedenog u gledanju televizije i ocjena koje dijete postiže u školi. Na temelju ove povezanosti možemo predvidjeti da će dijete koje manje gleda televiziju

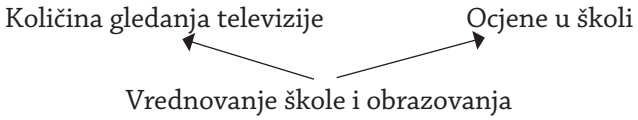
[42] U praksi uzročno-posljedični odnos može doista postojati i u situacijama u kojima se u istraživanju ne utvrdi korelacija između dviju pojava. Riječ je o tome da neka treća varijabla može smanjiti korelaciju između dvije varijable, ako je pozitivno povezana s jednom, a negativno s drugom varijablom (tzv. supresija).

imati bolje ocjene. No, za moguću intervenciju potrebno je bolje shvatiti uzročno posljedičnu povezanost koja stoji u pozadini ovakve korelacije. Jedno od mogućih objašnjenja utvrđene korelacije količina je vremena potrošenog na učenje, a koje se umanjuje gledanjem televizije. Drugim riječima, količina vremena potrošena na učenje može djelovati kao tzv. intervencijska varijabla u utvrđenoj korelaciji:

Količina gledanja televizije → količina vremena potrošena na učenje → ocjene u školi

Ako je ovo objašnjenje točno, tada bi se smanjenjem količine vremena koje dijete provede gledajući televiziju moglo djelovati na poboljšanje ocjena.

Međutim, moguća su i druga objašnjenja utvrđene korelacije. Primjerice, i količina vremena provedenog u gledanju televizije i ocjene u školi mogu biti posljedica vrednovanja škole i djetetova vrednovanja obrazovanja. Drukčije rečeno, dijete možda više gleda televiziju i ima lošije školske ocjene zbog toga što nisko vrednuje važnost škole i obrazovanja:




Ako je ovo objašnjenje točno, smanjenjem količine gledanja televizije (npr. zabranom) vjerojatno se ne bi polučio poželjan učinak. Dijete bi vrijeme koje je bilo utrošeno u gledanje televizije možda provelo družeći se s prijateljima ili na neki drugi način, a ne povećavajući količinu vremena provedenog u učenju. Intervencija bi u ovom slučaju bila uspješna ako bi se promijenilo vrednovanje škole i obrazovanja, odnosno ako bi dijete u većoj mjeri nego do tada smatralo da su škola i znanje poželjni i vrijedni truda.

**John Stuart Mill** postavio je četiri pravila za izradu kauzalnog nacrta istraživanja, tj. utvrđivanje uzročno-posljedičnih odnosa – tzv. Millove induktivne metode (prema Mejovšeku, 2008: 21):

1. Pravilo slaganja,
2. Pravilo razlike.
3. Pravilo ostatka,
4. Pravilo popratnih promjena.

Tim se pravilima dodaje i peto – pravilo kombiniranog slaganja i razlike zasnovano na uporabi dvaju prvih pravila.

Prema pravilu slaganja, ako se uvijek kada se jedna pojava pojavljuje istovremeno pojavljuje i druga pojava, postoji povećana vjerojatnost kauzalne veze. U donjoj shemi to znači da pojava „a" uzrokuje pojavu „y" jer se u obje situacije pojavljuje skupa s njom. Ostale pojave (b, c, d, i e) pojavljuju se s „y" u samo jednoj situaciji.

a, b, c ⟶ y

a, d, e ⟶ y

Prema pravilu razlike, ako se okolnosti u kojima se jedna pojava pojavljuje i ne pojavljuje razlikuju u samo jednom elementu, tada je taj element vjerojatni uzrok te pojave. Npr., ako su dvije skupine učenika slične u svemu, ali uče iz dvaju različitih udžbenika, tada se njihov različiti školski uspjeh može pripisati različitim udžbenicima. Pravilo razlike predstavlja osnovno načelo eksperimentalnih istraživanja. U donjoj shemi to znači da pojava „a" uzrokuje pojavu „y" jer se pojavljuje kada se pojavljuje i „y", a kada se ne pojavljuje, ne pojavljuje se ni „y".

a, b, c ⟶ y

b, c ⟶ ne-y

Pravilo ostatka nešto je drukčije od ostalih i polazi od nekoliko uzroka koji izazivaju nekoliko posljedica. Ako sve posljedice možemo povezati s uzrocima, osim jednoga uzroka i jedne posljedice, tada je taj preostali uzrok vjerojatno doveo do pojave preostale posljedice. Shematski to izgleda ovako, a iz te sheme zaključujemo da pojava „a" uzrokuje pojavu „y":

a, b, c ⟶ x, y, z

b ⟶ z

c ⟶ x

Pravilo popratnih promjena kaže da su pojave vjerojatno uzročno povezane ako se mijenjaju na sličan način (njihovi intenziteti mijenjanja su slični i idu u istom smjeru), tj. međusobno su korelirane. Shematski to prikazujemo ovako (kada pojava „a" raste, raste i „y"; kada pojava „a" pada, pada i „y"):

a ⟶ y

a+ ⟶ y+

a- ⟶ y-

## 4.2. KOMPONENTE ZNANSTVENO-ISTRAŽIVAČKOG PROCESA

Svako je znanstveno istraživanje proces koji počinje, traje i završava. Kao takvo, ono je ustavljena cjelina koju čine dijelovi, svojevrsni podsustavi koji, svaki za sebe, mora ispuniti svoju zadaću da bi cjelina istraživačkog procesa donijela očekivane rezultate.

Znanstveno istraživanje, prema Lj. Babanu i dr. (2000: 68-86), obuhvaća osam ključnih komponenti, koraka ili faza koje su nezaobilazne i međusobno usko povezane. To su: (1) problem koji se istražuje, (2) cilj istraživanja, (3) predmet istraživanja, (4) hipoteze, (5) izvori informacija i informacije, (6) metode istraživanja, (7) tehnike istraživanja, (8) instrumenti prikupljanja podataka. Nabrojanim komponentama dodat ćemo još tri: (9) uzorak i (10) analizu i interpretaciju podataka te (11) završno izvješće.

1. *Problem* koji se istražuje svojevrsni je motiv istraživanja, odnosi se na predmet istraživanja s kojim ga ne treba poistovjetiti. Problem se može defnirati i kao traženje odgovora na neko zanimljivo znanstveno (teorijsko) ili praktično pitanje. Ovdje je važno naglasiti da bi svako istraživanje trebalo započeti i završiti s teorijom. Naime, problemi i ciljevi istraživanja te hipoteze trebaju proizaći iz općenite teorije koja se operacionalizira i testira u istraživanju. Ateorijska istraživanja obično nisu previše korisna i ne pridonose napretku znanstvene spoznaje, iako mogu biti praktično i komercijalno važna.[43]

Kao što se razlikuju znanosti (prema području, polju, grani i ogranku), tako se razlikuju i problemi koji se istražuju. No, neovisno o predmetu znanstvenog istraživanja, problemi koji se istražuju mogu se klasificirati prema nekim kriterijima. Postoji više kriterija klasifikacije, spomenimo neke:

1. prema znanstvenim područjima (ekonomski, politički, sociološki, psihološki...),
2. prema gospodarskim granama (industrijski, poljoprivredni, trgovinski...),
3. prema broju osoba (individualni, grupni, društveni),
4. prema složenosti (jednostavni i složeni/strukturirani),
5. prema vremenu pojave (primordijalni, derivirani),
6. prema učestalosti javljanja (povremeni i stalni), ...

[43] Tipičan su primjer marketinška istraživanja, ispitivanja javnog mnijenja ili istraživanja vezana uz odnose s javnošću.

Problem se može uočiti *empirijski, znanstveno i kombinirano*. Već prema važnosti uočenog problema odlučuje se treba li ili ne poduzimati znanstveno istraživanje radi njegova rješavanja.

2. *Cilj istraživanja* onaj je motiv zbog kojega se istraživanje poduzima, stoga ga treba tražiti u svakom znanstvenom istraživanju. Istraživački ciljevi znače specifikaciju istraživačkog problema, a postavljene hipoteze služe postizanju istraživačkih ciljeva. Na primjer, istraživački se problem može odnositi na činjenicu da se ljudi razlikuju u svojim kulturnim ukusima, a istraživački cilj možemo uže definirati kao pokušaj objašnjenja zašto su neki ljudi skloniji visokoj, a neki popularnoj kulturi. Na temelju tog cilja, iz odgovarajuće se teorije npr. može postaviti hipoteza da se kulturni ukus stječe obiteljskim odgojem, tj. količinom kulturnog kapitala koji se stekne u obitelji.

3. *Predmet istraživanja* usko je povezan s ciljem istraživanja. Ta se povezanost postiže u samom procesu istraživanja. Naime, kada je predmet istraživanja neki prirodni proces, a cilj je pokazati koliko čovjek utječe na njegov tijek razvoja, tada je nužno da zbog cilja istraživanja i sâm čovjek te njegova kultura postanu predmet istraživanja. Primjerice, istraživanje prirodne pojave, globalnog zagrijavanja atmosfere, poremećeno je uslijed čovjekovih aktivnosti, što spada u područje kulture, pa se predmet istraživanja proširuje i na društvo.

Dakle, predmet istraživanja u znanosti su priroda i društvo, kao i sve pojave i procesi u njima. Zbog cilja istraživanja predmet istraživanja je teško izdvojiti kao samo prirodni ili društveni fenomen.

4. *Informacije i njihovi izvori* važna su sastavnica svakog istraživanja. Svako istraživanje podrazumijeva traganje za izvorima informacija o pojavi i problemu koji se istražuje. Naime, svaki ozbiljan istraživač nastojat će prije postavljanja hipotetskog okvira istraživanja prikupiti sve relevantne informacije o spoznajama već provedenih istraživanja o problemu kojim se želi baviti. Izborom literature donosi se pregled dosadašnjih teorija i istraživanja vezanih uz proučavani problem. Isto tako, moguće je preuzeti gotove mjerne instrumente koje su stvorili drugi istraživači i koji imaju provjerene mjerne karakteristike. Znanstveno bi se istraživanje trebalo nadovezivati na već dostignute spoznaje, kako bi se spriječilo „otkrivanje" već otkrivenih stvari, ali i omogućio kumulativni napredak znanosti.

5. *Hipoteza* je polazišna pretpostavka, tvrdnja koju treba istraživanjem provjeriti. Kada je istraživani problem dovoljno poznat, ali su se otkrile nove nepoznanice, istraživači postavljaju hipoteze unaprijed. U slučajevima kada se tijekom istraži-

vanja otkriju nove činjenice, hipoteze se mogu postaviti i za vrijeme istraživanja. Postavlja se jedna ili više hipoteza koje istraživanjem mogu biti u cijelosti ili djelomično potvrđene, ili u potpunosti odbačene.

Kakve sve hipoteze mogu biti, ovisi o tome kako ih i s kojim ciljem postavljamo. Tako R. Zelenika navodi 26 vrsta hipoteza.[44] Mi ćemo ovdje prikazati samo neke.

*Opća hipoteza* je ona hipoteza koja pretpostavkom želi predodrediti nešto za opću pojavu ili predmet. Npr., općom se hipotezeom tvrdi da je slab izlazak hrvatskih građana na izbore posljedica nepovjerenja u kandidate na stranačkim listama. Tom se hipotezom daje smjer istraživanju uzroka „slabog izlaska na izbore", kao i kriterija „slabog", „prosječnog" i „visokog" postotka izlaska.

*Posebna hipoteza* usmjerena je na neko posebno, specifično obilježje pojave ili predmeta istraživanja. Tako, na primjer, posebnom hipotezom možemo ustvrditi da niže obrazovani razmjerno više izlaze na izbore jer više vjeruju u predizborne programe stranaka od višeobrazovanih. Tom se hipotezom daje smjer istraživanju obilježja „stupnja obrazovanja" i „vjerovanja u programe".

*Radna hipoteza* postavlja se kako bi dala okvir i smjer istraživanju. Njome se često nešto tvrdi o predmetu i problemu istraživanja, što se tijekom procesa istraživanja može korigirati. U našem bi primjeru radna hipoteza mogla izgledati ovako: izlazak na izbore hrvatskih građana veći je u gradovima. Time se dao okvir istraživanju uzroka razlike brojnosti izlaska na izbore poput, obrazovnih razlika, razlika u informiranosti, razlika u slobodnom vremenu, razlika u osjećaju građanske dužnosti i slično.

*Pomoćna hipoteza* je svaka naknadno (tijekom istraživanja) postavljena hipoteza kojom se dopunjuje već postavljena hipoteza. Na primjeru naše hipoteze o slabijem izlasku seoskog stanovništva na izbore zbog obrazovnih razlika, razlika u informiranosti, razlika u slobodnom vremenu, razlika u osjećaju građanske dužnosti, ako se izbori događaju u jeku poljskih radova, možemo toj hipotezi dodati pomoćnu hipotezu kojom ćemo pretpostaviti da će seosko stanovništvo u slabijem broju izići na izbore zbog intenzivnih radova u poljoprivredi.

---

[44] Zelenika nabraja sljedeće vrste hipoteza: 1. teorijske, 2. realne, 3. fiktivne, 4. jednostavno implikacijske, 5. induktivne, 6. reduktivne, 7. deduktivne, 8. statističke, 9. moguće, 10. vjerojatne, 11. slučajne, 12. nulte, 13. opće, 14. posebne, 15. pojedinačne, 16. hipoteze empirijske jednoobraznosti, 17. hipoteze statističke generalizacije, 18. hipoteze idealnih tipova, 19. hipoteze relacijskih analitičkih varijabli, 20. *ad hoc* hipoteze, 21. radne hipoteze, 22. pomoćne, 23. znanstvene, 24. plodne, 25. prazne, 26. preliminarne hipoteze (Zelenika 1998: 419).

Kvalitetno postavljene hipoteze u pravilu imaju sljedeća obilježja (prema Tkalac Verčič i sur., 2010: 62-64):

1. Jasne su i jednodimenzionalne.
2. Specifične su.
3. Moraju imati mogućnost operacionalizacije i provjeranja.
4. Povezane su s postojećim spoznajama.

Hipoteza je *jasna i jednodimenzionalna* ako sadrži pojmove jasnog značenja te ako se hipotezom tvrdi postojanje samo jednog odnosa. Npr. hipoteza „socijalna disperziranost povezana je s dobi i obrazovanjem" nije jasna jer sadrži pojam nejasnog značenja („socijalna disperziranost"), a nije ni jednodimenzionalna jer tvrdi postojanje dvaju odnosa.

Hipoteza mora biti dovoljno *specifična* jer preopćenite hipoteze ne tvrde ništa. Npr. „društva mogu napredovati samo ako ulažu u razvoj" nije specifična hipoteza jer se u njoj upotrebljava pojmovi „društveni napredak" i „razvoj" koji su previše općeniti, pa se hipotezom zapravo ne tvrdi ništa konkretno (specifično). Prevelika općenitost hipoteza dovodi nas u opasnost da vrlo raznolike empirijske podatke smatramo potvrdom naše hipoteze jer vrlo općeniti pojmovi impliciraju vrlo velik broj mogućih indikatora i operacionalizacija, odnosno selektivnog dokazivanja (Goode i Hatt, 1962). No ranije navedena razlika između općih (generalnih) i posebnih (specifičnih hipoteza) pokazuje da nisu sve hipoteze nužno i vrlo specifične. Naime, iz jedne opće hipoteze, koja sama po sebi nije provjerljiva, ali nije ni vrlo udaljena od provjerljivosti, može proizlaziti niz specifičnih hipoteza. Primjerice, iz teorije prema kojoj u suvremenoj obitelji još uvijek postoji rodno determinirana podjela rada možemo izvesti opću hipotezu prema kojoj će zaposlene žene doživljavati veći broj obiteljskih problema od zaposlenih muškaraca. Iz ove će hipoteze proizlaziti specifične hipoteze prema kojima će zaposlene žene u prosjeku postizati viši rezultat na nekoj od razina mjerenja stresa od muškaraca, da će njihova subjektivna procjena kvalitete odnosa s članovima obitelji biti znatno niža da će se češće suočavati s depresijom i drugim problemima mentalnog zdravlja i sl.

Sve hipoteze moraju se *operacionalizirati i provjeriti*, inače ne predstavljaju znanstvene hipoteze. Znanost je, naime, zasnovana na načelu empirijske verifikacije teorijskih ostavki. Ovaj se kriterij donekle preklapa s kriterijem specifičnosti, no moguće je zamisliti i vrlo specifične hipoteze koje nije lako empirijski provjeriti. Primjerice, hipoteza prema kojoj je nečiji dohodak usko povezan s njegovom lijenošću vrlo je specifična, no nije lako utvrditi na koji bi se način valjano i pouzdano mogla izmjeriti nečija lijenost kao karakterna osobina.

Hipoteze bi prema mogućnosti trebale biti *povezane s postojećim znanstvenim spoznajama*, tj. proizlaziti iz određene teorije jer je konačno cilj postavljanja hipoteza upravo testiranje neke teorije. Na primjer, iz teorije prema kojoj se u školama uči dominantna kultura (kultura viših socijalnih slojeva) proizlazi hipoteza da će djeca iz nižih socijalnih slojeva imati slabiji školski uspjeh zbog manje količine kulturnog kapitala (manjeg fonda riječi, slabijeg izražavanja, nepoznavanja elitne kulture i sl.). Navedimo i drugi primjer hipoteze prema kojoj se vjerojatnost da će se osoba češće upustiti u kriminalne aktivnosti povećava s brojem ljudi koje ta osoba poznaje, a bave se takvim aktivnostima, osobito ako se s njima identificira.

***Dobre hipoteze moraju biti jasne i jednodimenzionalne, moraju biti specifične, moraju se moći provjeriti te biti povezane s postojećim teorijskim spoznajama.***

Nasumično postavljanje ovakve hipoteze svakako bi bilo manje korisno kada ona ne bi bila dio tzv. teorije diferencijalne asocijacije čiji je začetnik sociolog Edwin Sutherland (Sutherland, Cressey i Luckenbill, 1992, prvo izdanje čiji je autor Sutherland tiskano je 1924. godine). Naime, ta teorija pretpostavlja da se kriminalna aktivnost uči u komunikaciji s drugim osobama, odnosno da se ne može objasniti različitim motivacijskim sustavima delinkvenata i nedelinkvenata. Ovo je samo jedna od hipoteza koje proizlaze iz te teorije, a njihovo zajedničko testiranje čini teoriju više ili manje potvrđenom, ovisno o rezultatima testiranja. Primjerice, iz teorije se može izvući i hipoteza prema kojoj će osoba koja poznaje više drugih osoba koje se bave kriminalnim aktivnostima moći navesti više opravdavanja, odnosno racionalizacija bavljenja kriminalom (jedno od tih opravdavanja bilo bi: svijet je nepravedan i nemaju svi jednake šanse uspjeti na zakonit način).

Teorijski postavljene hipoteze obično se precizno izražavaju u obliku statističkih hipoteza, koje zapravo predstvaljaju treći stupanj u nizu koji ide od općih preko specifičnih do statističkih hipoteza. Ovisno o tome tvrdi li se da postoji ili ne postoji povezanost između pojava ili razlika između grupa, statističke se hipoteze obično dijele na dvije vrste:

1. Nulta hipoteza ($H_0$),
2. Alternativna hipoteza ($H_1$).

*Nulta hipoteza* najčešće se definira negativno, iako to nije nužno uvijek točno. Ako istraživanjem želimo utvrditi čitaju li obrazovaniji ljudi u prosjeku više knji-

ga od manje obrazovanih, tada bi nulta hipoteza glasila: „Ne postoji povezanost između stupnja obrazovanja i čitanja knjiga." *Alternativna hipoteza* definira se afirmativno, npr. „Postoji povezanost između stupnja obrazovanja i čitanja knjiga." Alternativna hipoteza može se, osim na neusmjeren način, kako je učinjeno na gornjem primjeru, definirati i na usmjeren način. U tom se slučaju predviđa ne samo razlika između grupa nego i smjer te razlike (koja grupa ima viši rezultat), a u slučaju korelacije ne predviđa se samo da je korelacija različita od nule nego i je li veća ili manja od nule. U gornjem bi primjeru usmjerena (direktivna) alternativna hipoteza glasila: „Postoji pozitivna povezanost između stupnja obrazovanja i čitanja knjiga." Drugim riječima, alternativnom hipotezom tvrdilo bi se ne samo da povezanost postoji, nego i da obrazovaniji pojedinci u prosjeku čitaju više knjiga (pozitivna korelacija).

Preciznije govoreći, nulta je hipoteza zapravo pretpostavka koja se odbacuje ako u istraživanju dobijemo podatke čija je vjerojatnost pojavljivanja relativno mala ako je nulta hipoteza točna. Drukčije rečeno, provjerava se koliko je vjerojatno da se određeni podatci (primjerice, određena veličina razlike između dviju grupa na nekoj varijabli) pojave ako se prepostavi da je nulta hipoteza točna. Kako je rečeno, u većini se slučajeva nulta hipoteza odnosi na nepostojanje razlika, no moguće je postaviti i nultu hipotezu o veličini razlika i testirati je. Primjerice, naša nulta hipoteza može biti da se prosječna dob posjetitelja dvaju internetskih portala razlikuje za pet godina, a alternativna hipoteza u tom bi slučaju mogla biti da se dob ne razlikuje za pet godina (nego manje ili više od toga), odnosno da je razlika u dobi manja od pet godina ili veća od pet godina (jedno od tog dvoga – usmjerena hipoteza).

Pri testiranju hipoteza moguće je napraviti dvije statističke pogreške:

1. Pogreška tipa I (alfa),
2. Pogreška tipa II (beta).

Pogreška tipa I znači odbacivanje nulte hipoteze kada je ona točna, a pogreška tipa II neodbacivanje nulte hipoteze kada je ona pogrešna.

*Tablica 10. Pogreške prilikom statističkog zaključivanja*

| | **Razlika doista postoji** | **Razlika ne postoji** |
|---|---|---|
| Istraživač tvrdi da razlika postoji | Točna odluka | Pogreška tipa I |
| Istraživač tvrdi da razlika ne postoji | Pogreška tipa II | Točna odluka |

Vjerojatnost činjenja te dvije pogreške ovisi o izabranoj razini *statističke značajnosti*. Razina statističke značajnosti označava vjerojatnost da se određena poveza-

nost pojavi sasvim slučajno, iako povezanost u stvarnosti ne postoji u populaciji. Primjerice, u istraživanju na uzorku od 500 muškaraca i 500 žena utvrdimo da žene češće od muškaraca čitaju knjige. To, međutim, ne znači nužno da se u ukupnoj populaciji žene i muškarci razlikuju u tome pogledu, budući da se ta razlika mogla slučajno pojaviti u našemu uzorku (npr. u naš uzorak su slučajno ušli muškarci koji manje čitaju i žene koje čitaju više od prosjeka). Vjerojatnost pojave takve razlike u uzorku, čak i onda kad u populaciji ne postoji razlika, može se procijeniti i naziva se razina statističke značajnosti, te na temelju te razlike odlučujemo o prihvaćanju ili odbacivanju nulte hipoteze. Najčešće korištena razina statističke značajnosti je 0,05 (5%). Npr. u istraživanju (1 000 ispitanika) utvrdimo da knjige čita 42% žena i 28% muškaraca. U statističkim tablicama utvrdimo da se ovakva razlika na uzorku veličine 1 000 slučajno pojavljuje u oko 1% slučajeva čak i kada u populaciji nema nikakve razlike u čitanju knjiga između muškaraca i žena. Na temelju tog nalaza, na razini značajnosti od 0,05 (5%) odbacit ćemo nultu hipotezu da nema razlike između muškaraca i žena u čitanju knjiga. Drukčije rečeno, ustanovljena razlika prevelika je da bi bila slučajna, odnosno vjerojatnost da se ona pojavi slučajno (zbog slučajne varijabilnosti uzorka) manja je od vjerojatnosti koju istraživač prihvaća odabirući razinu rizika 0,05 (5%). Testiranje hipoteza i pojam statističke značajnosti mogu se ilustrirati i na primjeru bacanja novčića. Uzmimo da 100 puta bacimo novčić za kojega pretpostavljamo da je ispravan, tj. da bi se „pismo" i „glava" trebali pojavljivati jednako često (svaki u 50% slučajeva). Međutim, u 100 bacanja novčića rijetko ćemo, zbog toga što ishod ovisi o nizu slučajnih čimbenika, dobiti 50 pisama i 50 glava, čak i ako je novčić ispravan. Na osnovi statističke distribucije ipak možemo znati koliko je vjerojatno pojavljivanje pojedinih ishoda kada je vjerojatnost pojavljivanja pisma i glave jednaka. Primjerice, ako u našem primjeru dobijemo 15 pisama i 85 glava, iz statističkih ćemo tablica vidjeti da se taj rezultat pojavljuje vrlo rijetko u situaciji kada je pojavljivanje pisma i glave jednako (50%). U tom ćemo slučaju odbaciti hipotezu prema kojoj je novčić ispravan. Ako u našem primjeru dobijemo 52 pismo i 48 glava, tada iz statističkih tablica možemo vidjeti da se taj rezultat pojavljuje vrlo često u situaciji kada je vjerojatnost pojavljivanja pisma i glave jednaka. Stoga nećemo odbaciti hipotezu da je vjerojatnost pojavljivanja pisma i glava jednaka i iznosi 50%.

Bacanje novčića predstavlja primjer tzv. binomnog eksperimenta, odnosno eksperimenta u kojemu postoji više nezavisnih pokušaja koji se sastoje od dva ishoda, pri čemu svaki od njih ima stalnu vjerojatnost. Jedan od ovih ishoda se naziva „uspjeh", a drugi „neuspjeh". Pomoću kombinatorike i teorije vjerojatnosti može se izvesti formula za dobivanje X uspjeha u N pokušaja ako vjerojatnost uspjeha u jednom pokušaja iznosi P, a pomoću ove formule moguće je, na primjer, izra-

čunati vjerojatnost da će u 4 bacanja novčića pasti određeni broj pisama. Te su vjerojatnosti prikazane u sljedećoj tablici.

*Tablica 11. Primjer distribucije podataka*

| **Događaj** | **Broj pisama** | **Vjerojatnost događaja** | **Kumulativna vjerojatnost** |
|---|---|---|---|
| (G G G G) | 0 | 1/16 | 1/16 |
| (P G G G), (G P G G), (G G P G), (G G G P) | 1 | 4/16 | 5/16 |
| (P P G G), (P G P G), (G P G P), (G G P P), (G P P G), (P G G P) | 2 | 6/16 | 11/16 |
| (G P P P), (P G P P), (P P G P), (P P P G) | 3 | 4/16 | 15/16 |
| (P P P P) | 4 | 1/16 | 16/16 |

Ako je naša nulta hipoteza bila da ne postoji razlika u vjerojatnosti dobivanja pisma i glave, a alternativna hipoteza da je vjerojatnost dobivanja glave veća od dobivanja pisma, na temelju podatka da smo u 4 bacanja novčića dobili četiri glave možemo odbaciti našu nultu hipotezu, odnosno prihvatiti alternativnu hipotezu. Vjerojatnost pogreške tipa I iznosila bi 1/16 jer se, kako je vidljivo iz tablice, u 1/16 slučajeva (tj. 6,25%) u četiri bacanja dobije 4 glave i nijedno pismo. Krenimo od pretpostavke da smo u četiri bacanja dobili tri glave i jedno pismo. I tada bismo mogli odbaciti nultu hipotezu, ali bi vjerojatnost da smo pogriješili, tj. neopravdano odbacili nultu hipotezu iznosila 5/16. Naime, upravo u toliko se slučajeva u četiri bacanja dobije jedno ili nijedno pismo. Iz ovoga se primjera može vidjeti da odbacivanje nulte hipoteze ovisi o izabranoj razini statističke značajnosti, tj. o tome koliku smo količinu rizika od neopravdanog odbacivanja nulte hipoteze spremni preuzeti. U slučaju da je posljedice pogrešnog zaključka moguće kvantificirati, što je ponekad slučaj u ekonomiji, moguće je i izabrati optimalnu razinu statističke značajnosti. No, u društvenim je znanostima to rijetko slučaj, pa se kao konvencionalne razine statističke značajnosti uzimaju 1% ili 5%, tj. preuzima se 1% ili 5% rizika od neopravdanog odbacivanja nulte hipoteze.

***U empirijskim istraživanjima obično postavljamo statističke nulte hipoteze koje se odbacuju samo ako se pojave podatci koji su malo vjerojatni ako je takva nulta hipoteza točna.***

6. *Istraživački nacrt i metode istraživanja* svojstvene su svakom znanstveno-istraživačkom procesu. Izborom nacrta istraživanja zapravo se operacijski određuje kako će se određeni problem istražiti. Nacrtom istraživanja pregledno se iznosi osnovna logika istraživanja iz koje se vidi na koji će se način ostvariti istraživački

ciljevi. Kako će biti vidljivo iz idućeg poglavlja, logika istraživanja može biti eksperimentalna, korelacijska ili longitudinalna.

Metodu se može odrediti kao skup unaprijed planiranih i ustustavljenih različitih postupaka kojima se znanstvenik koristi u znanstveno-istraživačkom radu da bi istražio i izložio rezultate znanstvenog istraživanja u određenom znanstvenom području, znanstvenom polju, grani ili ogranku. Metode (*methodos*, grč. – put, hod) kao načini dolaženja do spoznaje zakonitosti istraživanih pojava u prirodi i društvu nisu svojstvene samo znanosti već i filozofiji, teologiji, ali i empirijskoj svakodnevici.

7. *Tehnike istraživanja* vezuju se uz metode i često se teško pravi razlika između njih. *Metode* su opći pristupi u provedbi istraživanja i čine široki okvir unutar kojeg se mogu smjestiti tehnike kao osobit način primjene svake od njih. Na primjer, metoda eksperimenta okuplja tehnike poput nacrta ponovljenih mjerenja ili grupnog nacrta, metoda ankete obuhvaća telefonsko, poštansko i usmeno komuniciranje, metoda opažanja koristi tehnike sudioničkog ili strukturiranog promatranja i slično (Milas, 2009: 14-15).

8. *Instrumenti prikupljanja podataka* predstavljaju svojevrsna tehnička pomagala u prikupljanju podataka, npr. anketni upitnik ili skale mogu biti shvaćeni kao instrumenti prikupljanja podataka. Podatci se prikupljaju metodom predviđenom u istraživačkom nacrtu, a te metode mogu biti različite (terensko istraživanje, prikupljanje sekundarnih podataka i sl.). U ovisnosti o tome tko je prikupio podatke koji se koriste u istraživanju, obično se razlikuju:

1. Primarni podatci,
2. Sekundarni podatci.

*Primarne podatke* skuplja sam istraživač za potrebe istraživanja. Osnovna je prednost primarnih podataka da su skupljeni upravo za svrhu kojoj služe (istraživač skuplja upravo one podatke koji mu/joj trebaju), a osnovni je nedostatak činjenica da prikupljanje novih podataka zahtijeva vremenske i financijske troškove. *Sekundarni podatci* oni su podatci koje je prikupio netko drugi, a istraživač ih koristi u svojem istraživanju. Najčešće se koriste podatci iz popisa stanovništva, podatci Statističkog zavoda i drugih državnih institucija, baze poslovnih podataka (financijski izvještaji i sl.), podatci prikupljeni u drugim znanstvenim istraživanjima i slično. Prednost je tih podataka da su dostupni te da se obično mogu preuzeti bez ikakvih troškova. Osnovni nedostatak sekundarnih podataka odnosi se na njihovu prilagođenost konkretnom istraživanju. Naime, često se događa da sekundarni podatci nisu upravo onakvi kakvi bi trebali biti za ostvarenje ciljeva istraživanja.

9. *Uzorak* je moguće najopćenitije odrediti kao dio osnovnog skupa na kojemu se istraživanje vrši. Kako je istraživanjem najčešće nemoguće obuhvatiti sve jedinice populacije koja se istražuje, uobičajeno je odabrati uzorak, a izbor pojedine vrste uzorka ovisi o raspoloživosti, dostupnim vremenskim i financijskim resursima te ciljevima istraživanja. S obzirom na obilježja uzorak može biti *reprezentativan* (kada sadrži sva bitna obilježja osnovnog skupa) ili *nereprezentativan*. Različiti načini izbora uzorka i njihova podjela bit će prikazani u posebnom poglavlju.

10. *Analiza i interpretacija podataka* nužni su kako bi se vidjelo u kojoj mjeri podatci potvrđuju ili opovrgavaju postavljene hipoteze. Drukčije rečeno, analizom i interpretacijom podataka testiraju se postavljene hipoteze i donose zaključci o postavljenom istraživačkom problemu. Prikupljeni podatci obično se logički kontroliraju, editiraju, unose u baze podataka i obrađuju statističkom analizom ili nekom od metoda kvalitativne analize podataka. Danas se u obje situacije obično koriste računalni programi.

11. *Završno izvješće* kruna je svakog istraživačkog projekta. U njemu glavni istraživač donosi rezultate istraživanja koji trebaju biti jasno prikazani glede provjere postavljenih hipoteza. Rezultati uvijek trebaju biti potvrda riješenosti problema zbog kojeg se istraživanje i poduzimalo. Također, ako je riječ o naručenom istraživanju, izvješćem se mora predočiti tijek istraživanja po fazama, utrošena sredstva (planirana i neplanirana), kao i nejasnoće (ako postoje) vezane uz rješenje problema. Koliko je ovo važna komponenta pokazuje Milas (2009: 560-563), koji izvješće strukturira u četiri dijela: *uvod* (kratko prikazuje svrhu istraživanja, problem i postojeća istraživanja o problemu), *metodološki dio* (precizno navodi kako je koncipirana i provođena istraživačka studija, operacionalizirane definicije, način korištenja literature, primarno istraživanje, kodiranje podataka, metode statističke obrade podataka), *rezultati* (opis primarnih istraživanja, njihovih rezultata i njihove homogenosti, zajedničke rezultate), *rasprava* (osim što uspoređuje sadašnje i rezultate prijašnjih istraživanja, ukazuje na moguće pogreške uslijed pristranosti, odabira uzorka i slično).

## 4.3. ISTRAŽIVAČKA ETIKA

Istraživačka etika mora pratiti svaki dio istraživačkog procesa jer se dileme vezane uz ispravno postupanje mogu pojaviti u svakom dijelu istraživanja, od njegova planiranja i organiziranja do interpretacije i objave podataka te pisanja istraživačkog izvještaja. Pri tome je osobito važna dobrobit sudionika istraživanja,

odnosno izbjegavanje bilo štete koja bi za njih mogla nastupiti sudjelovanjem u istraživanju. Istraživač bi u svakom trenutku morao voditi računa o očuvanju integriteta vlastite struke jer nepristrana potraga za istinom vođena ciljem poboljšanja životnih uvjeta ljudi predstavlja samu srž znanstvenog *ethosa*. Govoreći sa stajališta utilitarne etike, jedino znanost vođena moralnim načelima može očuvati povjerenje cijeloga društva u korisnost znanstvenih istraživanja, čime se omogućava daljnje sudjelovanje javnosti u znanstvenim istraživanjima, ali i društveno financiranje znanosti. Budući da etička načela vezana uz pisanje i objavu znanstvenih radova navodimo u posebnom poglavlju o pisanju znanstveno-istraživačkih radova, ovdje se posebno osvrćemo na pitanja sukoba interesa znanstvenika te na istraživačku etiku vezanu uz poštovanje prava sudionika istraživanja.

U idealiziranoj situaciji znanstvenik bi trebao biti pojedinac potpuno posvećen pronalaženju znanstvene istine. No, znanstvenik je istovremeno i nositelj drugih uloga te ima svoje interese  i vrijednosti koji mogu biti u manjem ili većem sukobu s imperativom bezinteresnog pronalažanja znanja i posvećenosti općem dobru (Werhane i Doering, 1997). Tako se financijski interesi znanstvenika i potreba osiguravanja izvora financiranja vlastitog znanstveno-istraživačkog rada često sudaraju s načelima govorenja istine i očuvanja osobnog integriteta. Često se pojavljuje iskušenje da se rezultati istraživanja „prilagode“ interesima naručitelja ili da se vlastita znanstvena ekspertiza stavi u službu ciljeva koji su nezakoniti ili neetični. Ove su dileme danas vjerojatno najizraženije u biomedicinskim znanostima, u kojima se uz istraživanja učinkovitosti lijekova ili terapijskih postupaka vezuju jaki financijski interesi, no njima obiluju i društvene znanosti. Uzmimo, primjerice, situaciju u kojoj nevladina udruga koja se bavi zaštitom ljudskih prava financira istraživanje o raširenosti i uzrocima društvene diskriminacije. Istraživač može doći u iskušenje da u nekoj mjeri krivo prikaže raširenost diskriminacije, bilo izravnim krivotvorenjem rezultata bilo njihovom interpretacijom, smatrajući da bi naručitelj želio dobiti upravo takve podatke. Motiv za takav postupak mogao bi biti osiguravanje daljnje suradnje i omogućavanje daljnjeg financiranja istog naručitelja za buduća istraživanja. U dilemu može doći i ekonomski institut koji velika korporacija unajmi da izradi studiju o smanjenju troškova poslovanja. Naputci o izbjegavanju poreznih obveza putem različitih oblika „pranja novca“ možda će zadovoljiti očekivanja naručitelja, ali će sigurno kompromitirati profesionalni integritet te institucije i znanstvenika koji u njoj rade. U takvim je situacijama, unatoč financijskim interesima da se učini suprotno, potrebno djelovati u skladu s potrebom očuvanja profesionalnog integriteta. U svakom je slučaju prilikom objave rezultata potrebno obznaniti

sve podatke, osobito naručitelja istraživanja, koji mogu upućivati na mogući sukob interesa. Na taj se način omogućava javna procjena i kontrola etičnosti rada znanstvenika. Odnos naručitelja i istraživača obično je određen etičkim kodeksima koje donose pojedina strukovna udruženja, a najpoznatiji je takav kodeks onaj koji su donijeli ICC (International Chamber of Commerce) i ESOMAR (European Society for Opinion and Marketing Research), a naziva se International Code of Marketing and Social Research Practice. Primjerice, njime su određene obveze istraživača, poput one da naručitelja uvijek obavijesti ako jedan dio ugovorenog posla daje podizvođačima te da naručitelj uvijek mora znati ako se istraživački podatci nude/prodaju većem broju naručitelja. Također su navedene i obveze naručitelja, poput one da bez eksplicitnog pristanka ne smije objaviti ime istraživačke organizacije koja je provela neko istraživanje, kao i da ne smije pokušavati snižavati cijenu istraživanja „ucjenjivanjem" pomoću ponuda dobivenih od drugih istraživačkih organizacija (Singer, 2008). Ovaj se kodeks obično primjenjuje u komercijalnim (marketinškim, medijskim i sl.) istraživanjima, a istraživačke se organizacije obično obvezuju na njegovu primjenu. Sličan kodeks ima i Svjetsko udruženje za ispitivanje javnog mnijenja (World Association for Public Opinion Research – WAPOR).

Sukob interesa može se pojaviti i onda kada znanstvenik želi javno prezentirati rezultate svojega rada, osobito onda kada se u tome služi medijima. Javna prezentacija vlastitog rada može povećati ugled znanstvenika, stvoriti javnu percepciju o kvaliteti i važnosti njegova rada, a time i osigurati daljnje financiranje. Međutim, uobičajene forme medijske produkcije vijesti mogu utjecati na to da se rezultati prikažu na neodgovarajući način. Naime, mediji obično traže jasne i nedvosmislene zaključke te pojednostavljenja, a izbjegavaju tehničke detalje koji mogu biti ključni za razumijevanje rezultata i važnosti istraživanja. Tako se rezultati istraživanja mogu prikazati na način koji ne uvažava njegova ograničenja i specifičnosti. Unatoč tome što nije u pitanju lagan zadatak, znanstvenik bi prilikom medijske prezentacije istraživanja trebao jasno ukazati na njegove dometa i ograničenja, ne predstavljajući rezultate istraživanja važnijim i pouzdanijim nego što to oni doista i jesu prema njegovim najboljim uvjerenjima.

Provođenje istraživanja u znanosti obično zahtijeva neki oblik pomoći i suradnje drugih ljudi koji nisu znanstvenici, a ovo je osobito čest slučaj u društvenim znanostima. Odnos prema sudionicima istraživanja osobito je važan jer je povezan s cijelim nizom etičkih dilema. Prve neetične prakse i kršenja prava sudionika istraživanja pojavile su se u biomedicinskim istraživanjama, osobito tijekom Drugog svjetskog rata, u vidu prisilnih eksperimenata. Stoga su se i prvi etički

kodeksi na tom području razvili unutar biomedicine i ponajviše odnosili na nju (*Nirnberški kodeks* i *Helsinška deklaracija*). U njima su se formulirala pravila poput toga da istraživanje mora biti zasnovano na slobodnom pristanku sudionika, da mora biti nužno i društveno korisno, da ispitanik može prekinuti istraživanje u svakom trenutku, da mu istraživanje ne smije uzrokovati psihičku ili tjelesnu bol i sl. Ta načela preuzeli su i etički kodeksi na području društvenih i humanističkih znanosti, za čije su poštivanje nadležni etički odbori profesionalnih udruženja ili znanstveno-istraživačkih institucija. Zadatak je etičkih odbora da pomoću vlastitog akumuliranog znanja i iskustva pomognu istraživaču u rješavanju potencijalnih etičkih dilema, ali i da na objektivan način sagledaju opravdava li kvaliteta istraživanja i njegov znanstveni doprinos postupke koji se nalaze u „sivoj zoni", odnosno na samoj granici etičnosti.

Posebnu važnost u etičkim kodeksima imaju načela *informiranog pristanka* i obmane prilikom provođenja istraživanja, kao i pitanja *povjerljivosti* prikupljenih podataka i *anonimnosti* sudionika istraživanja (vidjeti npr. American Sociological Association, 2008.). Informirani pristanak, uz nekoliko iznimaka, nužan je uvijek kada se od sudionika istraživanja traži neki oblik aktivnosti ili komunikacije, odnosno kada se istraživanje provodi u situacijama koje su privatne naravi, tj. osoba ne očekuje da bi u njima mogla biti proučavana na bilo koji način. Drugo načelo implicira da se informirani pristanak ne mora dobiti za opažanje ili bilježenje podataka o ponašanjima koja se zbivaju na javnim mjestima. Informirani pristanak kao pretpostavku uključuje informiranje potencijalnog sudionika o naravi istraživanja, kao i mogućim rizicima i neugodnostima koje iz njega mogu proizaći. Obmana sudionika istraživanja događa se u situacijama kada ispitanik zna da sudjeluje u istraživanju te je dao informirani pristanak, no taj pristanak nije bio zasnovan na točnim informacijama koje je pružio istraživač. Drukčije rečeno, istraživač prilikom traženja suglasnosti nije otkrio pravi cilj istraživanja ili točne okolnosti koje bi se tijekom istraživanja mogle dogoditi.

***Najvažnija su etička načela u istraživanjima u društvenim znanostima načelo informiranog pristanka, te povjerljivosti i anonimnosti prikupljenih podataka.***

Dva, sada već klasična, eksperimenta koje su proveli socijalni psiholozi ukazuju na opasnosti koje se kriju prilikom obmanjivanja ispitanika, odnosno na moguću psihološku štetu koja im se može nanijeti. Prvi se od njih odnosi na istraživanje pokoravanja autoritetu koje je proveo Stanley Milgram (1963). U tom eksperimentu sudionicima je rečeno da sudjeluju u istraživanju procesa učenja, tj. bili

su obmanuti u pogledu stvarnih ciljeva. Njihov je zadatak bio da kao „učitelji" zadaju elektro-šok „učeniku" (u stvari suradniku eksperimentatora) u slučaju da pogriješe u odgovoru na zadatak. Naravno, elektro-šok nije bio stvaran, a učenik-sudionik eksperimentatora glumio je bol i nelagodu. Nadalje, jačina navodnog elektro-šoka povećavana je sa svakom pogreškom. Rezultati su pokazali da je čak oko 65% sudionika nastavilo sa zadavanjem elektro-šokova do maksimalne granice (450 volti), odnosno da su poslušali provoditelja eksperimenta kada je on to od njih tražio u pismenoj formi. Pri tome su pokazivali očigledne znakove nelagode i stresa jer su morali naštetiti drugom ljudskom biću, odnosno mislili su da to čine. Milgram je utvrdio da je većina ispitanika, nakon što im je rečeno o čemu je u eksperimentu zapravo bilo riječ i nakon što im je istaknuto da je njihova reakcija bila uobičajena, izjavila da su zadovoljni time što su u njemu sudjelovali. Međutim, nije moguće isključiti da je eksperiment sudionicima nanio određenu psihološku štetu jer ih je izložio samospoznaji da su spremni nanijeti bol drugom ljudskom biću bez valjanih razloga nakon što ih na to navede osoba koja se nalazi u poziciji autoriteta. U drugom eksperimentu, Solomon Asch (1951) istraživao je utjecaj grupnog pritiska na konformiranje. U eksperimentu je sudjelovao sudionik te sedam drugih sudionika koji su bili sudionici eksperimentatora. Zadatak je bio utvrditi koja je od ponuđene tri linije iste dužine kao i ponuđena linija, pri čemu je točni odgovor bio posve očit. Sudionik eksperimenta bio je obmanut jer mu je rečeno da je u pitanju istraživanje vida. Sudionik eksperimenta bio je posljednji u nizu, odnosno posljednji je davao odgovor. Rezultati su pokazali da je oko 75% ispitanika u seriji od 12 ponuđenih situacija (linija) bar jednom dalo očito krivi odgovor jer su krivi odgovor dali ostali članovi grupe. Pri tome je čak oko jedne trećine sudionika dalo krivi odgovor u svakoj takvoj situaciji.[45] I u ovom je slučaju bilo riječ o izlaganju ispitanika potencijalno neugodnoj situaciji, odnosno samospoznaji o vlastitoj sklonosti podlijeganju grupnom pritisku.

Obmanu sudionika istraživanja trebalo bi izbjegavati, tj. ona bi trebala biti izuzetak od pravila kojem se pribjegava samo u situacijama u kojima bi otkrivanje pravog cilja istraživanja ugrozilo njegovo samo provođenje. Čak i u takvim je situacijama potrebno razmotriti je li taj cilj moguće postići nekim drugim istraživanjem koje ne uključuje obmanu, odnosno jesu li spoznaje do kojih bi se došlo u istraživanju s obmanom toliko važne da opravdavaju obmanu. Kada su

[45] Naknadno Perrinovo i Spencerovo ponavljanje ovog eksperimenta (1980), također na studentskoj populaciji, pokazalo je mnogo manji stupanj sklonosti konformizmu. Ovo ukazuje na probleme temporalne vanjske valjanosti eksperimenta, odnosno Aschovi rezultati možda se mogu tumačiti autoritarnom klimom makartizma u SAD-u početkom 1950-ih godina, odnosno pasivnom društvenom ulogom tadašnjih studenata.

u pitanju eksperimentalna istraživanja, igranje uloga (eng. role play) može biti korisna alternativa. Naime, umjesto da se sudionika eksperimenta izloži realnoj eksperimentalnoj intervenciji, može ga se zamoliti da opište kako bi reagirao u takvoj situaciji, odnosno kako bi u njoj reagirala većina drugih pojedinaca. Na taj se način obmana uklanja i smanjuje mogućnost da eksperimentalna intervencija izazove neugodno psihološke i druge posljedice. Naravno da je i ovdje potrebno istaknuti da igranje uloga nije stvarna eksperimentalna situacija, odnosno da će sudionici eksperimenta u igranju uloga reagirati drukčije nego što bi reagirali u stvarnoj eksperimentalnoj situaciji jer ne mogu dobro procijeniti vlastitu reakciju ili žele sačuvati vlastito samopoštovanje. Isto tako, kada sudionike eksperimenta tražimo da procijene reakciju drugih ljudi, moguće je da takva procjena bude pogrešna. S druge strane, može se istaknuti da i stvarna eksperimentalna intervencija ne predstavlja prirodnu situaciju, odnosno da i u njoj sudionici ne reagiraju na način na koji bi reagirali u prirodnim okolnostima. Stoga je igranje uloga svakako alternativa koju valja razmotriti u eksperimentima koji uključuju obmanu sudionika istraživanja.

Ako je obmana ipak bila dio istraživanja, tada bi na njegovu kraju svakako trebalo provesti tzv. *debriefing*, odnosno sudionicima istraživanja okriti pravu svrhu istraživanja te otkloniti moguće štete do kojih je došlo. Uobičajeno je i da istraživač sudionicima nakon provedenog istraživanja omogući naknadno kontaktiranje ako dođe do dugoročnijih posljedica sudjelovanja u istraživanju. No i ovdje se s pravom možemo pitati može li *debriefing* pouzdano ukloniti štetne posljedice, odnosno hoće li situacija u kojoj se sudionik istraživanja suočava s vlastitim reakcijama u eksperimentalnoj situaciji dovesti do „neutralizacije" eksperimentalne intervencije. Primjerice, hoće li se sudionici spomenutih Milgramovih i Ashovih eksperimenata nužno osjećati bolje kada saznaju o čemu je u istraživanju doista bilo riječ? U svakom slučaju, *debriefing* istraživaču može pomoći da shvati proces istraživanja iz sudionikove perspektive, odnosno da unese moguće etičke i metodološke korekcije u istraživački nacrt budućih istraživanja.

U svim situacijama koje uključuju obmanu istraživač se treba posavjetovati s etičkim odborima institucije u kojoj radi ili profesionalnog udruženja čiji je član. Etički bi odbori, između ostalog, trebali objektivno procijeniti je li riječ o istraživanju koje je kvalitetno i koje donosi važan doprinos znanosti. Naime, ako je riječ o istraživanju upitne metodološke kvalitete, kojim se istražuje nešto što je već dovoljno istraženo ili se istraživanjem neće doći do znatnijeg teorijskog napretka u proučavanju određenog pitanja, tada takvo istraživanje sigurno ne treba provesti. Treba napomenuti i da informirani pristanak u slučaju istraži-

vanja na poslovno nesposobnim pojedincima (maloljetnici, mentalno oboljeli i sl.) treba dobiti od njihovih zakonskih skrbnika, kao i da u istraživanjima koja uključuju djecu treba dobiti i od djece, ako su dovoljno odrasla, i od roditelja. Izuzetak mogu predstavljati situacije u kojima takav pristanak nije očekivan (npr. zlostavljana djeca), no i tada je nužno posavjetovati se s etičkim odborima. Valja imati na umu i da zakonski zahtjevi, koji mogu postojati u pojedinim zemljama, uvijek imaju jaču snagu od etičkih kodeksa pojedinih udruženja ili struka. Primjerice, prema ICC/ESOMAR etičkom kodeksu potrebno je zatražiti dopuštenje za anketiranje djece do 14 godina starosti, no u nekim je zemljama zakonskom regulativom određena viša dobna granica od navedene.

***Obmanu sudionika istraživanja treba upotrijebiti samo u iznimnim situacijama, ako je to nužno za postizanje ciljeva istraživanja koji su iznimno važni te ako obmana ne izaziva veće psihološke i druge štete sudionicima.***

Informirani pristanak, dakako, nije jednoznačna kategorija, nego se može promatrati na kontinuumu od potpunog skrivanja teme i detalja istraživanja do iscrpnog obavještavanja ispitanika i o jednom i o drugom. U većini istraživanja se iz praktičnih razloga, najčešće vremenskog pritiska, informacije koje se daju sudioniku svode na kraću formu, osobito kada je riječ o komercijalnim istraživanjima koja se ne tiču osobnih i osjetljivih pitanja.

Te načelne smjernice ne moraju uvijek omogućiti jasne odgovore na moralna pitanja koja se pojavljuju prilikom istraživanja. Naime, nije uvijek lako odrediti nanosi li skrivanje određenih informacija od ispitanika štetu njemu samome, je li obmana nužna, odnosno, opravdava li skrivanje informacija korist dobivenu istraživanjem. Primjerice, iz istraživanja je poznato (vidjeti Groves i sur., 2004.) da navođenje teme istraživanja u uvodu anketnog istraživanja dovodi do određene samoselekcije ispitanika, odnosno do toga da će se ispitanici koji su jače zainteresirani za određenu temu vjerojatnije odlučiti za sudjelovanje. Ako zainteresirani sudionici imaju drukčiji prosječni rezultat od manje zainteresiranih, tada će i procjene rezultata na populaciji biti iskrivljene (pristrane). Stoga je u takvim situacijama preporučljivo da se tema istraživanja izrazito ne naglašava u uvodu, a što se može smatrati djelomičnim kršenjem informiranog pristanka. S jedne je strane opravdano skrivati temu jer to utječe na kvalitetu rezultata/istraživanja, pri čemu nije došlo do nikakvog skrivanja potencijalnih rizika ili neugodnosti za ispitanika. S druge strane, može se argumentirati da ispitanik ima pravo procijeniti hoće li sudjelovati u istraživanju na temelju informacije o tome istraživanju jer on sâm najbolje može procijeniti koliko mu/joj je određena tema neugodna, psihološki zamorna ili osjetljiva

i slično. Iz ovoga je primjera vidljivo da nije uvijek lako odvagnuti štete i koristi prilikom strožije ili labavije primjene prava na informirani pristanak. K tome, moguće je da samo spominjanje etičkih načela i traženje informiranog pristanka može pobuditi sumnjičavost sudionika istraživanja u pogledu stvarnih namjera istraživača, odnosno potencijalnih problema i šteta do kojih može doći sudjelovanjem u istraživanju. S druge strane, neka istraživanja (npr., Singer, 1978) pokazala su da eksplicitno navođenje jamstva povjerljivosti podataka, kao i objašnjavanje teme istraživanja prije početka ankete, nisu dovele do povećane stope pristanka na sudjelovanje, ali su dovele do veće voljnosti na davanje odgovora na osjetljiva pitanja, kao i manje psihološke neugode prilikom odgovaranja.

Etički sporan, i do sada neriješen, aspekt informiranog pristanka odnosi se na pitanje financijskog nagrađivanja sudionika istraživanja. Naime, u situacijama koje zahtijevaju veći napor za ispitanike ponekad se sudjelovanje stimulira novčanom ili nekom drugom vrstom materijalne kompenzacije (primjerice, kuponi za besplatnu kupovinu ili kupovinu s popustom). Nagrađivanje je etički dvojbeno jer se može argumentirati da sudionika istraživanja može navesti da sudjeluje u istraživanju za koje smatra da mu je psihološki neugodno ili zadire u njegovu/njezinu intimnost. Drugim riječima, novčanom nagradom istraživač bi mogao iskoristiti ranjivu situaciju pojedinih skupina ispitanika (npr. ljudi slabijeg socioekonomskog statusa) te im na taj način nanijeti određenu štetu (Singer, 2008: 88). S druge strane, pitanje je u kojoj mjeri manji iznos kompenzacije, razmjeran uloženom trudu, može navesti sudionike istraživanja da se izlože nečemu što smatraju izrazito štetnim i neugodnim. No, u svakom slučaju, riječ je o etički dvojbenoj situaciji u kojoj istraživač treba biti oprezan i razmotriti iznos nagrade i etičke implikacije nagrađivanja sudionika.

Osim obmane, ispitanicima se potencijalno može naštetiti i uskraćivanjem potencijalno korisne intervencije u situacijama kada se eksperimentalno istraživanje izvodi u prirodnim uvjetima. Primjerice, zamislimo situaciju u kojoj se jedna grupa nezaposlenih ljudi poučava vještinama koje se smatraju poželjnim za pronalaženje posla (informatičke vještine, prezentacijske vještine i sl.), a druga skupina prolazi neku drugu vrstu savjetovanja ili čak ne prolazi bilo kakvu drugu vrst savjetovanja ili edukacije. Nakon toga se u vremenskom intervalu koji slijedi mjeri broj ljudi koji će pronaći posao u obje skupine. Može se tvrditi da bi takav eksperiment bio etički sporan zbog toga što ispitanicima iz kontrolne skupine uskraćuje mogućnost da nauče vještine koji će im popraviti ekonomsku/životnu situaciju. S druge strane, može se argumentirati da je slučajan izbor ispitanika, tj. njihovo svrstavanje u ovakve skupine nužno da bi se došlo do spoznaja o učin-

kovitosti određenih intervencija bez kojih takva učinkovitost ne bi mogla biti utvrđena. Isto tako, može se tvrditi da ispitanicima koji nisu sudjelovali u edukaciji nije nanesena bilo kakva šteta. Nešto etički složenija situacija pojavljuje se onda kada imamo dvije vrste intervencije – jednu stariju za koju znamo da ima određene učinke, i drugu noviju za koju se može pretpostaviti da će donijeti bolje učinke od one starije. U tom slučaju, ako se ova pretpostavka pokaže netočnom, sudionici koji su dio eksperimentalne skupine mogu biti oštećeni. Takva bi se situacija, primjerice, dogodila ako bi uveli eksperimentalnu metodu poučavanja za koju se ispostravi da je manje učinkovita od stare. Ovakva se situacija može pokušati ispraviti naknadnim izlaganjem eksperimentalne skupine staroj intervenciji, ako je to izvodivo u praktičnom smislu.

*Načelo povjerljivosti podataka* odnosi se na pravo sudionika istraživanja da se istraživački podatci koji se odnose na njih koriste samo u skladu s namjenom koju su eksplicitno ili prešutno odobrili. Drukčije rečeno, podatci dobiveni istraživanjem ne bi se trebali koristiti u svrhe koje sudionik istraživanja nije odobrio. Primjerice, drastičan slučaj kršenja načela povjerljivosti podataka predstavlja korištenje podataka dobivenim „istraživanjem" za nuđenje nekog proizvoda sudionicima koji su u istraživanju iskazali potrebu za njim. Takvi slučajevi, prilično česti u praksi, predstavljaju nedopušteno postupanje jer sudionik istraživanja nije upozoren da će podatci biti korišteni u tu svrhu, odnosno smatra da je riječ o klasičnom istraživanju čiji je cilj dobivanje i interpretacija skupnih podataka.

*Načelo anonimnosti* kaže da se sudionik istraživanja nikako ne bi trebao moći identificirati na temelju prikazanih podataka, niti bi trebalo biti poznato da je uopće sudjelovao u istraživanju, osim ako to sâm ne želi. Čuvanjem anonimnosti sudionika najčešće se čuva i povjerljivost podataka, no to nije uvijek slučaj. Primjerice, sudionika se istraživanja može navesti na pomisao da sudjeluje u znanstvenom istraživanju, iako je riječ o marketinškom istraživanju koje provodi neka tvrtka. U tom bi se slučaju, unatoč očuvanju anonimnosti, podatci koristili za svrhe koje sudionik nije odobrio, tj. kršilo bi se pravilo povjerljivosti podataka.

Za razliku od načela informiranog pristanka nad kojim istraživač najčešće ima potpunu kontrolu, pitanja anonimnosti i povjerljivosti podataka vrlo su osjetljiva i mogu izmaknuti kontroli istraživača. Naime, istraživački podatci i odnos istraživača i sudionika istraživanja nisu zaštićeni zakonom, primjerice kao što je to određeno u slučaju odvjetničke tajne. Stoga je moguće da istraživač bude prisiljen otkriti podatke o sudionicima pod prijetnjom zakonske kazne. Babbie (2010: 68) navodi primjer izlijevanja *Exxon Valdez* tankera na obalama Aljaske 1991. godine. S obzirom na ekološku i gospodarsku štetu do koje je došlo, lokalna je zajednica

doživjela psihološku i društvenu štetu u vidu povećanog alkoholizma, obiteljskog nasilja i sličnih pojava koje su dokumentirane u sociološkim istraživanjima. Kako je sud tužio tvrtku Exxon zbog počinjene štete, uspio je prema pribavljenom sudskom nalogu tražiti istraživača da ustupi anketne upitnike zajedno s podatcima koji mogu identificirati pojedine ispitanike. Kršenje prava ispitanika na anonimnost i povjerljivost podataka spriječeno je isključivo zbog toga što je tužba riješena izvansudskom nagodbom. Postoje i slučajevi istraživača koji su odslužili zatvorsku kaznu zbog odbijanja dostavljanja istraživačkih podataka sudovima (Babbie, 2010:68). Takvi slučajevi upućuju na osobit oprez prilikom jamčenja povjerljivosti i anonimnosti, odnosno na poduzimanje dodatnih mjera u slučajevima u kojima se može pretpostaviti postojanje potencijalnih prijetnji po obećanja dana sudionicima istraživanja (npr. istraživanja svih vrsta nezakonitih ponašanja).

Anonimnost ispitanika najbolje je osigurati uklanjanjem identifikacijskih podataka, odnosno njihovim neprikupljanjem. U kvantitativnim anketnim istraživanjima podatke koji rezultate (pojedinačne upitnike) vezuju uz imena sudionika najbolje je uništiti odmah nakon što je izvršena provjera terenskog rada anketara. Na taj se način dobrim dijelom osigurava nemogućnost da će netko drugi te podatke iskoristiti na načine koji nisu predviđeni istraživanjem. Takvu tehniku moguće je primijeniti i prilikom terenskog istraživanja organizacija (najčešće studija slučaja) i osobnih intervjua s manjim brojem sudionika, iako je u prvom slučaju potrebno uložiti dodatne napore kako se identitet organizacije ne bi mogao prepoznati u prikupljenim podatcima i istraživačkom izvještaju (vidjeti poglavlje o studiji slučaja). Međutim, i u jednom i u drugom slučaju prisutan je problem moguće zakonske obveze otkrivanja identiteta jer istraživač ne može „zaboraviti" koju je organizaciju ili pojedince istraživao.

## DODATNA LITERATURA UZ ČETVRTO POGLAVLJE

Karpinski, Jakub (2012). *Causality in Sociological Research.* Dordrecht, Boston, London: Kluwer Academic Publishers.

U knjizi se polazi od najjednostavnijih slučaja kauzalnosti te se nakon toga konceptualno i na primjerima ilustriraju moguća kauzalna tumačenja empirijskih povezanosti varijabli u korelacijskim istraživanjima, longitudinalnim (dijakronijskim) istraživanjima te eksperimentalnim istraživanjima.

Mertens, Donna M.; Ginsberg, Pauline E. (2009). *The Handbook of Social Research Ethics*, Thousand Oaks: Sage Publications.

Zbornik radova koji uključuje povijesni prikaz razvoja istraživačke etike i njezine filozofske pretpostavke, kao i specifična pitanja kao što su institucionalna regulacija istra-

živačke etike, etika u eksperimentalnim istraživanjima, etika u etnografskm i akcijskim istraživanjima, etika prilikom istraživanja kulturalno različitih društvenih grupa i sl.

## PITANJA UZ ČETVRTO POGLAVLJE

1. Kada je neko istraživanje znanstveno?
2. Što se mora osigurati da bi se znanstveno istraživanje provelo?
3. Kojim trima zahtjevima treba udovoljiti svako znanstveno istraživanje?
4. Kako se dijele znanstvena istraživanja prema stupnju znanstvenosti (UNESCO-va klasifikacija)?
5. Kakva su to nomotetska, a kakva su idiografska istraživanja?
6. Kakva su to kvantitativna, a kakva kvalitativna istraživanja?
7. U koja se četiri pristupa mogu prepoznati kvantitativna istraživanja?
8. U koja se dva pristupa mogu prepoznati kvalitativna istraživanja?
9. Kakva su to prethodna, a kakva konačna istraživanja?
10. Kakva su to povremena, a kakva stalna istraživanja?
11. Kako se dijele istraživanja prema nositelju istraživanja?
12. Kako se dijele istraživanja prema disciplinarnosti?
13. Kako se dijele istraživanja prema razini obuhvata?
14. Objasnite tipove istraživanja prema razini znanstvene spoznaje.
15. Koja obilježja mora imati dobra klasifikacija?
16. Što je to tipologija?
17. U čemu je razlika između korelacije i kauzalnosti?
18. Čemu služe Millove induktivne metode? Koje sve metode postoje?
19. Koje su to komponente znanstveno-istraživačkog procesa?
20. Što je to istraživački problem, a što istraživački cilj?
21. Koje su prednosti i nedostatci primarnih, odnosno sekundarnih podataka?
22. Koja obilježja moraju imati kvalitetno postavljene hipoteze?
23. Kako se dijele statističke hipoteze i koje je pogreške moguće napraviti za vrijeme njihova testiranja?
24. Što je to statistička značajnost?
25. Što znači pojam informiranog pristanka kada je riječ o sudjelovanju u istraživanju?
26. Što znače pojmovi anonimnosti i povjerljivosti podataka u istraživanju?

# 5. MJERENJE I MJERNI INSTRUMENTI

## 5.1. RAZINE MJERENJA

Mjerenje predstavlja dodjeljivanje brojeva prema određenim pravilima, tj. kvantifikaciju objekata ili događaja, odnosno njihovih atributa (Mejovšek, 2009: 35). Drukčije rečeno, objekti istraživanja – u društveno-humanističkim znanostima to su najčešće ljudi ili društvene grupe – imaju određena obilježja kojima se mogu pridružiti brojevi. Mjerenjem se znanstvena spoznaja čini preciznijom, a time najčešće i praktično korisnijom.

Mejovšek (2009: 36) izdvaja tri osnovne vrste mjerenja:

1. Mjerenje utemeljeno na zakonima koji određuju odnose pojedinih obilježja,
2. Mjerenje „prema odluci“,
3. Fundamentalno mjerenje.

*Mjerenje utemeljeno na zakonima* koji određuju odnose pojedinih obilježja odnosi se na omjere pojedinih obilježja koji služe kao definicija i podloga za mjerenje pojedinih pojava. Tako se, primjerice, u fizici gustoća određuje i mjeri kao omjer mase i volumena neke tvari, a u društvenim znanostima dohodak kućanstva omjerom ukupnog dohodka i broja članova kućanstva. Drukčije rečeno, u tom se tipu mjerenja varijabla izvodi iz već prethodno postojećih varijabli.

*Mjerenje „prema odluci“* često je u društveno-humanističkim znanostima, a predstavlja mjerenje neke pojave na osnovi indikatora koje možemo izravno izmjeriti. Npr. socioekonomski status, koji ne možemo izravno izmjeriti, mjeri se pomoću obrazovanja, društvenog ugleda i imovinskog statusa. Drukčije rečeno, indikatori služe za mjerenje apstraktnih konstrukata.

*Fundamentalno mjerenje* reflektira prirodne ili društvene zakonitosti. Tako se npr. količina neke tvari mjeri brojem čestica, a dohodak svim novčanim primitcima pojedinca (onime što zarađuje iz svih izvora). U oba slučaju mjere direktno reflektiraju obilježja koja se mjere.

Mjerenje može biti provođeno na nekoliko razina, pa se i varijable na osnovi tih razina dijele na:

1. Nominalne,
2. Ordinalne ,
3. Intervalne,
4. Omjerne.

*Nominalne varijable* odnose se na klasifikaciju objekata koji imaju ili nemaju neko obilježje, pri čemu tim obilježjima nije moguće dodijeliti numeričku vrijednost. Takve su varijable npr. spol, etnička pripadnost, mjesto u kojemu pojedinac živi i sl. U svim tim slučajevima ispitanika je moguće svrstati u neku kategoriju, ali nije moguće uspostaviti odnose „većeg i manjeg" između tih kategorija. Na primjer, pojedinac se prema spolu može svrstati u kategorije muškaraca i žena, no nije moguće reći koliko „spola" pojedinac ima. Kad je riječ o nominalnim varijablama, moguće je samo odrediti broj objekata u pojedinim kategorijama, a brojevi u tim varijablama služe samo kao oznake, a ne kao pokazatelj količine tog obilježja. Primjerice, označimo li žene brojkom „1", a muškarce brojkom „2", ovdje brojevi zapravo služe kao brojke, tj. služe za razlikovanje pojedinih kategorija varijable spola.

U *ordinalnim varijablama* ispitanike možemo svrstati u pojedine kategorije, ali možemo i utvrditi koja kategorija ima veći stupanj određenog obilježja, tj. mogući su odnosi „više i manje" između tih obilježja. Važno je reći da u ordinalnim varijablama ne možemo biti sigurni jesu li razlike između pojedinih kategorija podjednake. Tako ispitanike prema stupnju obrazovanja možemo svrstati u one s osnovnom, srednjom školom i fakultetom, pri čemu svaka pojedina kategorija označava viši stupanj obrazovanja. Pri tome razlike između tih kategorija nisu jednake, pa tako ne možemo reći da je pojedinac sa srednjom školom upravo toliko više obrazovan od onoga s osnovnom školom, koliko je i manje obrazovan od onoga s fakultetom.

Poredak kategorija također postoji i u *intervalnim* varijablama, no razlike među pojedinim stupnjevima na mjernoj skali posve su jednake. Primjerice, razlika u nekom testu znanja između 100 i 101 postignutih bodova ista je kao i razlika između 123 i 124 boda. Pri tome valja napomenuti da intervalne varijable nemaju stvarnu nulu, tj. rezultat „nula" na toj varijabli ne znači stvarni nedostatak mjerenog obilježja. U navedenom slučaju testa znanja rezultat „nula" ne znači da osoba koja je postigla takav rezultat nužno nema nikakvog znanja u području koje je mjereno testom.

*Omjerne varijable* slične su intervalnim, ali imaju stvarnu nulu, tj. izmjerena nula na varijabli znači upravo to da je mjereno obilježje odsutno. Npr., novčani dohodak omjerna je varijabla jer izmjerena visina dohotka od nula kuna doista znači da pojedinac nema nikakvog dohotka. Temperatura u Celzijevim stupnjevima nije omjerna varijabla jer nula na toj varijabli ne predstavlja nepostojanje temperature (npr. na Fahrenheitovoj ljestvici neće iznositi nula). Slično je, primjerice, i s kvocijentom inteligencije jer rezultat nula ne predstavlja potpuno nepostojanje inteligencije nego samo rezultat na toj skali. Činjenica postojanja stvarne nule i jedna-

ka udaljenost između dijelova skale omogućava računanje omjera, po čemu je taj tip varijabli i dobio ime. Primjerice, za osobu koja ima mjesečni dohodak od 5 000 kuna moguće je reći da ima dvaput veći dohodak od osobe koja mjesečno zarađuje 2 500 kuna. S druge strane, zbog nepostojanja stvarne nule nije moguće reći da je osoba s kvocijentom inteligencije 150 dvaput inteligentnija od osobe čiji kvocijent iznosi 75. Naime, njihov rezultat zapravo upućuje na položaj u distribuciji (poretku) inteligencije u nekoj populaciji, a ne apsolutnu količinu obilježja. Ako je prosječan rezultat na tome testu 100, rezultat osobe s kvocijentom inteligencije 150 označava osobu koja je inteligentnija od velike većine drugih ljudi, a rezultat 75 osobu koja je ispodprosječno inteligentna. Dakle, rezultat 150 ne označava posjedovanje 150 „jedinica inteligencije" nego usporedbu s drugim članovima populacije. Ta informacija bila bi sačuvana čak i kad bi od svih rezultata npr. oduzeli broj 50. Tada bi prosječan rezultat iznosio 50, prva bi osoba imala rezultat 100, a druga 25. Vidimo da bi u tom slučaju omjer tih dvaju rezultata iznosio 4, što ukazuje na besmislenost njegova računanja u intervalnim varijablama.

*Tablica 12. Varijable prema razini mjerenja*

| **Vrsta varijable** | **Opis** | **Primjeri** | **Dopušteni statistički pokazatelji** |
|---|---|---|---|
| Nominalna | Kategorije bez odnosa „više" i „manje", moguća samo klasifikacija entiteta (ispitanika) u pojedine kategorije. | Spol, etnička pripadnost, religijska pripadnost, podjela umjetnosti, podjela znanosti na znanstvena područja i sl. | Frekvencija pojavljivanja kategorija; mod. |
| Ordinalna | Kategorije između kojih postoji odnos „više" i „manje", ali udaljenost između kategorija nije poznata. | Stupanj obrazovanja (osnovna škola, srednja škola, fakultet), socijalni status (niži, srednji, viši). | Frekvencija pojavljivanja kategorija; mod; medijan; decili i percentili. |
| Intervalna | Kategorije između kojih postoji odnos „više" i „manje", ali udaljenost između kategorija je jednaka. Ne postoji tzv. stvarna nula. | Rezultat na testu inteligencije, rezultat dobiven na mjernim skalama. | Frekvencija pojavljivanja rezultata; mod; medijan; decili i percentili; aritmetička sredina; standardna devijacija. |
| Omjerna | Kategorije između kojih postoji odnos „više" i „manje", ali udaljenost između kategorija je jednaka. Postoji tzv. stvarna nula. | Visina, težina, dohodak. | Frekvencija pojavljivanja rezultata; mod; medijan; decili i percentili; aritmetička sredina; standardna devijacija; omjer. |

Razine varijabli vrlo su važne zato što određuju vrstu statističke analize koju je moguće primijeniti na njima. U načelu je sve vrste analize koje je moguće primijeniti na varijablama niže razine moguće primijeniti i na varijablama više razine, dok obrnuto nije slučaj (Triola, 1989: 20). Primjerice, učestalost pojavljivanja neke kategorije moguće je izbrojati u svim vrstama varijabli, dok je računanje aritmetičke sredine opravdano samo u intervalnim i omjernim varijablama.

Drugo je važno pravilo vezano uz razine mjerenja tzv. *načelo maksimalne razine* koje glasi da, kad god je to moguće, treba upotrebljavati varijable na višim razinama mjerenja. Naime, poželjno je da su varijable na što većoj razini mjerenja jer se time povećava i snaga upotrijebljenih statističkih tehnika. Primjerice, ako možemo utvrditi točnu dob ispitanika i ako smatramo da pitanje o točnoj dobi neće biti previše osjetljivo za sudionike istraživanja, nepotrebno je upotrebljavati dobne intervale jer se tada varijabla „spušta" na ordinalnu razinu mjerenja.

***Varijable se prema razini mjerenja dijele na nominalne, ordinalne, intervalne i omjerne. Razine mjerenja za sobom povlače vrste i snagu statističkih postupaka koji se mogu primijeniti na varijablama, stoga je važno mjerenje pokušati provesti na što je većoj razini moguće.***

## 5.2. MJERNE SKALE

### 5.2.1. Definicija i osnovne vrste mjernih skala

Mjerne *skale* sastoje se od niza čestica (pitanja) kojima se nastoji izmjeriti neki konstrukt (apstraktna ideja). Skale treba razlikovati od relativno sličnog pojma *indeks*. Neki autori (npr. Babbie, 2010.) drže da se i indeks i skala sastoje od niza čestica, no u indeksu svaka čestica nosi jednaku težinu, dok u skalama različite čestice mjere različite intenzitete posjedovanja nekog obilježja. Moglo bi se reći da skale mjere obrazac odgovora, dok indeksi mjere odgovore. Uzmimo da, primjerice, religioznost pojedinca mjerimo brojem tvrdnji koje uključuju vjerske istine, a s kojima se pojedinac složio. U tom je slučaju riječ o indeksu religioznosti, a ne o skali. Ako svaka čestica nosi određenu težinu (neke označavaju veću religioznost, a neke manju), a od pojedinca tražimo da zaokruži one s kojima se slaže, tada je riječ o (Thurstoneovoj) skali religioznosti. Prema takvoj definiciji skale bi u načelu imale veću valjanost od indeksa jer preciznije mjere intenzitet neke pojave, iako je i u slučaju indeksa, kao i skala, potrebno pažljivim izborom čestica pokušati poboljšati mjerne karakteristike. To je određenje problematič-

no zbog toga što postoje indeksi čije se čestice ponderiraju (daje im se različita „težina"), kao i skale koje nose istu težinu, poput Likertove skale. Stoga se preciznije može reći da se skala od indeksa razlikuje po tome što ima izraženu logičku i empirijsku strukturu čestica, odnosno skale imaju dokazanu jednodimenzionalnost, a indeksi ne (Blaikie, 2010.). Primjerice, od Likertove će se skale religioznosti tražiti pouzdanost, odnosno pojedinac će se u jednakoj mjeri trebati složiti sa svim tvrdnjama koje čine skalu. Za razliku od te skale, gdje su samo određeni obrasci odgovora prihvatljivi, za indeks religioznosti bilo koja kombinacija slaganja s tvrdnjama bit će jednako valjana. Dakle, skala određena na ovaj način pretpostavlja da je mjerenje obavljeno na adekvatan način, odnosno da je postiglo rezultate koji se mogu smatrati pouzdanim, valjanim i sl. Na koji ga god način odredili, skaliranje se može smatrati sinonimom mjerenja, s obzirom na to da se prilikom skaliranja pretpostavljeno latentno obilježje izražava određenim brojem na nekoj skali/ljestvici.

Postoji mnoštvo različitih skala i pristupa skaliranju pa je skale moguće podijeliti na temelju različitih kriterija klasifikacije. Najčešće se upotrebljava podjela na komparativne i nekomparativne skale (Coldwell i Herbst, 2004), pri čemu se ove prve konstruiraju tako da se objekti stava ili ponašanja koje se mjeri međusobno uspoređuju, a u drugom se ne uspoređuju, nego mjere na nekoj apsolutnoj ljestvici. Najčešće su komparativne skale (1) skale rangiranja, (2) skale uspoređivanja u parovima i (3) skale konstantne sume. Nekomparativne skale mogu se dodatno podijeliti na kontinuirane ljestive procjene i višečestične skale procjene (eng. itemised rating scales), kao što su Stapelove, Likertove, Thurtstoneove i Guttmanove skale te semantički diferencijal.

***Mjernim skalama obično se naziva niz čestica/pitanja s jasnom strukturom, a može ih se podijeliti na komparativne i nekomparativne.***

### 5.2.2. Skale rangiranja

*Skale rangiranja* od ispitanika zahtijevaju da niz ponuđenih opcija rangiraju na osnovi nekog kriterija. Primjerice, gornje pitanje o filmskim preferencijama u formi ranga postavilo bi se na sljedeći način:

Rangirajte filmske žanrove na osnovi toga koliko Vam se sviđaju, pri čemu žanru koji Vam se najviše sviđa dodijelite rang „1", a onome koji Vam se najmanje sviđa rang „5".

Komedija ☐
Drama ☐
Triler ☐
Akcijski film ☐
SF ☐

Želimo li dobiti ukupnu ljestvicu preferencija ovih filmskih žanrova, možemo zbrojiti rezultate ovih rangiranja za sve ispitanike koji su sudjelovali u istraživanju, pri čemu valja imati na umu da su u pitanju ordinalne varijable.

Rangiranje je obično vrlo zahtjevno za ispitanike, pa se smatra da se pri rangiranju ne bi trebalo nuditi više od pet opcija. Ako ima više opcija, tada se preporučuje da se ispitanicima kaže da izaberu pet stvari i rangiraju ih na skali od „1" do „5". Zbog mentalne zahtjevnosti rangiranja, prilikom terenskog anketiranja dobro je sudionicima istraživanja vizualno predočiti objekte koji se rangiraju, odnosno dati im kartice na kojima su navedeni objekti.[46] Osim zahtjevnosti za ispitanike, treba napomenuti da su odgovori koji se dobiju rangiranjem prema svojoj naravi na ordinalnoj razini mjerenja, pa je najčešće bolje upotrijebiti ljestvice procjene, ako je to moguće. S druge strane, skale rangiranja, kao uostalom i druge komparativne skale, dobro je upotrijebiti onda kada pretpostavljamo da će stav prema svim objektima biti vrlo pozitivan ili vrlo negativan, a mi ipak želimo utvrditi razlike među njima. Primjerice, za pretpostaviti je da će ispitanici u istraživanju reći da su im sva ili gotovo sva obilježja nekog proizvoda važna (cijena, kvaliteta, jednostavnost upotrebe i sl.), no neka od tih obilježja ipak su važnija od drugih.

### 5.2.3. Skale uspoređivanja u parovima

Skala uspoređivanja u parovima (eng. *paired comparisons scale*) ponekad se naziva i skala prisilnog izbora. Naime, njezinom primjenom od ispitanika se zahtijeva da sve objekte stava međusobno usporedi u parovima te da navede koji od njih preferira. Primjerice, od menadžera bismo mogli zatražiti da 10 zaposlenika koji su dio njegove radne jedinice međusobno usporedi u parovima uzimajući u obzir ukupnu kvalitetu rada ili neke njezine posebne dimenzije (točnost, kvaliteta rada, brzina rada, slaganje s ostalim zaposlenicima i sl.). Pri tome valja napomenuti da broj usporedbi u parovima brzo raste kako se povećava broj objekata

[46] Zbog mogućeg utjecaja redoslijeda, dobro je imati više kartica s različitim poretkom objekata koji se rangiraju.

usporedbe. Tako ukupan broj usporedbi iznosi $\frac{N*(N-1)}{2}$, pri čemu je „N" broj objekata. Primjerice, u gornjem primjeru postoji ukupno 45 usporedbi u parovima ako imamo 10 zaposlenika. Stoga prilikom primjene ove skale treba voditi računa o broju usporedbi, odnosno mogućnostima ispitanika da donesu odgovarajući broj usporedbi u kratkom vremenu imajući u vidu umor. Nakon što ispitanik napravi usporedbe, obično se izradi tablica u kojoj je prikazan ukupan broj pozitivnih i negativnih usporedbi u svakom paru, odnosno udjeli pozitivnih i negativnih usporedbi. Primjerice, donja bi tablica prikazivala rezultate usporedbi u parovima četiri zaposlenika koje je ocjenjivalo ukupno pet menadžera. Brojevi koji se nalaze u tablici predstavljaju udjele pozitivnih usporedbi zaposlenika koji se nalaze u stupcima. Primjerice, iz tablice se vidi da 80% menadžera (četiri od pet) smatra da je zaposlenik B bolji od zaposlenika A, 60% menadžera smatra da je zaposlenik D bolji od zaposlenika B itd. Iz rezultata je vidljivo da je zaposlenik D ocijenjen kao najbolji, a zaposlenik A kao najlošiji. Valja napomenuti i da se ukupni rezultat ponekad izražava kao standardizirana, odnosno z-vrijednost, pri čemu se računa odstupanje od neutralne usporedbe (od broja 0,50). Primjerice, rezultat 0,60 odgovara z-vrijednosti 0,23, odnosno to je z-vrijednost koja odgovara površini od +0,10 (udaljenost od 0,60 do 0,50). Ove se z-vrijednosti mogu zbrojiti kako bi se dobio ukupni rezultat nekog objekta usporedbe u ovom slučaju zaposlenika).

*Tablica 13. Primjer uspoređivanja u parovima*

| **Zaposlenik** | **A** | **B** | **C** | **D** |
|---|---|---|---|---|
| A | - | 0,80 | 0,60 | 1,00 |
| B | 0,20 | - | 0,20 | 0,60 |
| C | 0,40 | 0,80 | - | 0,80 |
| D | 0,00 | 0,40 | 0,20 | - |

### 5.2.4. Skale konstantne sume

Skale konstantne sume (eng. *constant sum scale*) upotrijebe se tako da se ispitaniku da neka konstantna suma (10, 50, 100, ...) koju može raspodijeliti na objekte stava na način na koji želi. Primjerice, kvalitetu rada zaposlenika u gornjem primjeru mogli bismo izmjeriti tako da svaki menadžer može 100 bodova raspodijeliti na četiri zaposlenika na način na koji to želi. Primjerice, može svih 100 bodova dodijeliti zaposleniku kojeg smatra najboljim, po 50 bodova dati dvojici koje smatra izvrsnim i sl. Ova je skala vrlo korisna u istraživanjima tržišta kojima se želi utvrditi preferencija pojedinih roba ili usluga koje imaju nejednaku cijenu

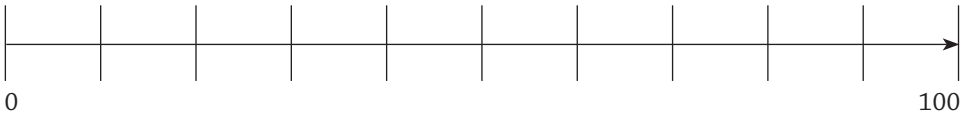
(Coldwell i Herbst, 2004: 69-70). Primjerice, pri proizvodnji novoga automobila treba odlučiti koja će se dodatna oprema nuditi potencijalnim kupcima, odnosno potrebno je utvrditi koju je dodatnu opremu uopće smisleno proizvoditi i nuditi. U tom se slučaju ispitanicima ponudi popis dodatne opreme s njihovim cijenama, a ispitaniku se ponudi fiktivna manja suma novca koju treba raspodijeliti na ono što bi htio kupiti. S obzirom na to da u našemu primjeru ukupna cijena opreme iznosi 20.000 kuna, ispitaniku bi se mogla ponuditi suma od 13.000 kuna koju može utrošiti onako kako želi. Nakon toga se utvrdi koja je vrsta opreme birana koliko često.

*Tablica 14. Primjer skale konstantne sume*

| **Vrsta oprema** | **Cijena (HRK)** |
|---|---|
| Metalik boja | 4.000 |
| Produženo jamstvo | 5.000 |
| Dodatna sigurnosna oprema | 5.000 |
| Dodatni komfor u kabini | 4.000 |
| Dodatne usluge prilikom servisa | 2.000 |

### 5.2.5. Kontinuirana ljestvica procjene

Kontinuirana ljestvica procjene odnosni se na vrstu skale gdje se od ispitanika traži da na nekoj kontinuiranoj liniji označi svoju poziciju, najčešće svoj pozitivan ili negativan stav prema nečemu. Pri tome se intenzitet stava može mjeriti tako da se izmjeri dužina (u centimetrima ili milimetrima) koju je ispitanik označio. Primjer jedne kontinuirane ljestvice procjene bio bi kada bismo od ispitanika tražili da označi svoj stav prema određenoj osobi ili pojavi na sljedeći način na ljestvici od 0 do 100:




### 5.2.6. Stapelova skala

Stapelova skala ime je dobila prema nizozemskom istraživaču Janu Stapelu koji ju je prvi predložio/konstruirao. Ova je skala slična kontinuiranoj ljestvici procjene, no ocjenjuje se na ljestvici od -5 do +5, i to bez neutralne točke. Ljestvica se obično konstruira vertikalno, pri čemu se u sredini nalazi pridjev koji je povezan s objektom stava, a ispitanik na spomenutoj ljestvici od -5 do 5 treba označiti

u kojoj je mjeri objekt stava povezan, odnosno može se povezati s navedenim pridjevom. Ispitanik najčešće zaokružuje broj koji označava percipiranu razinu povezanosti.

Primjer Stapelove skale s jednim pridjevom navodimo niže, a on bi se mogao odnositi na istraživanje u kojemu istražujemo stavove o nekom mediju (televizijskoj postaji, internetskoj stranici i sl.).

+5

+4

+3

+2

+1

Vjerodostojan

-1

-2

-3

-4

-5

### 5.2.7. Semantički diferencijal

Semantičkim diferencijalom mjeri se konotativno značenje pojmova (osjećaji i doživljaji vezani uz pojam). Skala se obično sastoji od niza parova suprotnih pridjeva, kojima je pridružena numerička ljestvica procjene od (obično) 7 stupnjeva. Skalu su razvili **Charles Osgood** i sur. (1954.), a njihovo je istraživanje pokazalo da skala nije jednodimenzionalna, nego se sastoji od tri faktora (sub-skala):

1. Evaluativni faktor (dobro-loše),
2. Faktor snage (jako-slabo),
3. Faktor aktivnosti (aktivan-pasivan).

Npr., ako bismo semantičkim diferencijalom ispitivali odnos ljudi prema nekom političaru, vidjeli bismo kako ga ispitanici procjenjuju na tim dimenzijama (dobar-loš, jak-slab, aktivan-pasivan). Valja napomenuti da se semantičkim diferencijalom najpouzdanije mjeri evaluativna komponenta stava. Primjer semantičkog diferencijala s navedenim dimenzijama prikazan je u sljedećoj tablici.

*Tablica 15. Primjer semantičkog diferencijala*

| | 7 | 6 | 5 | 4 | 3 | 2 | 1 | |
|---|---|---|---|---|---|---|---|---|
| Dobar | | | | | | | | Loš |
| Čist | | | | | | | | Prljav |
| Aktivan | | | | | | | | Pasivan |
| Brz | | | | | | | | Spor |
| Jak | | | | | | | | Slab |
| Velik | | | | | | | | Malen |

Valja napomenuti da se skala semantičkog diferencijala ne mora sastojati isključivo od navedenih atributa ili dimenzija, iako je originalno tako zamišljena. Naime, istraživači u skalu stavljaju atribute koje žele ispitati, iako nužno ne spadaju u te tri dimenzije (npr. tradicionalan/moderan, blizak/udaljen i sl.).

Bodovanje semantičkog diferencijala samorazumljivo je, a obično se izračunavaju i rezultati za pojedine sub-skale te pokušava utvrditi jesu li rezultati na njima povezani.

Velika je prednost skale semantičkog diferencijala da ju je relativno lako konstruirati. Naime, moguće je preuzeti gotove atribute s neke od postojećih skala ili relativno lako smisliti vlastite atribute koji nas zanimaju u konkretnom slučaju. Prednost je semantičkog diferencijala u odnosu na Likertovu skalu nepostojanje problema slaganja ispitanika sa svim česticama. Naime, ispitanik treba procijeniti neki objekt na osnovi para suprotnih atributa, pa nije jasno koji od atributa predstavlja slaganje. Nedostatak je skale semantičkog diferencijala, slično kao i u Likertovoj skali, dvojbena intervalnost skale jer nije jasno jesu li razmaci između intervala jednaki, odnosno shvaćaju li ih ispitanici na takav način. I u semantičkom diferencijalu, kao i Likertovoj skali, postoje i problemi sklonosti k ekstremnim odgovorima, kao i nejasnog statusa srednje točke na skali (Coolican, 1994: 142). Problem ekstremnih odgovora još je veći nego u Likertovoj skali jer ispitanici ovdje nemaju verbalni opis stupnjeva na skali, kao što je slučaj u Likertovoj skali. Primjerice, odgovori „4“ i „5“ u Likertovoj skali opisani su verbalno kao „slažem se“ i „potpuno se slažem“, dok u semantičkom diferencijalu to nije slučaj. Kao i u Likertovoj skali, i u semantičkom diferencijalu, srednji stupanj skale za ispitanike može značiti neutralan stav prema objektu mjerenja ili nepostojanje stava u odnosu na njega.

***Skala semantičkog diferencijala sastoji se od evaluativnog faktora, faktora snage i faktora aktivnosti, a svaki je zastupljen nizom suprotnih pridjeva.***

### 5.2.8. Likertova skala

Likertovu skalu konstruirao je američki psiholog **Rensis Likert**, a ona uključuje niz tvrdnji (obično 20 do 30), pri čemu se od ispitanika traži da izraze svoj stupanj slaganja s njima. Likertovom se skalom, dakle, mjeri smjer (pozitivan ili negativan) i intenzitet stava prema nekom objektu stava (osobi, organizaciji, ideji, ...). Obično se koristi skala od pet stupnjeva (od „uopće se ne slažem" do „potpuno se slažem"), iako su česte i skale od sedam stupnjeva. Općenito govoreći, više stupnjeva donosi i veću osjetljivost skale, odnosno mogućnost da izmjeri sitnije razlike u prisutnosti mjerenog obilježja. S druge strane, ispitanicima je skala s pet stupnjeva kognitivno lakša, a kod nje je pojedinim stupnjevima moguće dodijeliti i tekstualne oznake, što dodatno pridonosi lakoći odgovaranja. Primjerice, četvrti i peti stupanj na skali relativno je jednostavno odrediti kao „slažem se" i „potpuno se slažem", a opis je petog i šestog stupnja na skali od sedam stupnjeva znatno teže opisati riječima. Ovakva je lakoća odgovaranja osobito važna u telefonskim istraživanjima, odnosno istraživanjima u kojima skala nije vizualno prisutna.

Kao primjer skale s pet stupnjeva slaganja navodimo kraću Likertovu skalu kojom se može mjeriti stav prema rodnim ulogama (tablica 16).

*Tablica 16. Primjer Likertove skale*

| | **Uopće se ne slažem** | **Ne slažem se** | **Niti se slažem niti se ne slažem** | **Slažem se** | **Potpuno se slažem** |
|---|---|---|---|---|---|
| Rukovodeća mjesta u poslovnom svijetu trebaju biti u rukama muškaraca | 1 | 2 | 3 | 4 | 5 |
| Muškarac treba imati glavnu riječ u obitelji | 1 | 2 | 3 | 4 | 5 |
| Žene se ne trebaju miješati u politiku | 1 | 2 | 3 | 4 | 5 |
| Najvažnija vrlina svake žene jest da bude dobra majka i supruga | 1 | 2 | 3 | 4 | 5 |

Izvor: Šram, 2008: 55.

***Skala Likertovog tipa sastoji se od niza pitanja s kojima sudionik istraživanja treba označiti vlastiti stupanj slaganja.***

Prilikom konstrukcije, Likertova se skala često „uravnotežuje". Naime, polovica čestica formulira se pozitivno, tj. pitanja se pišu tako da viši stupanj slaganja znači pozitivniji stav prema onome što se mjeri u istraživanju, a polovica negativno, tj. pitanja se pišu tako da viši stupanj slaganja s tim tvrdnjama znači negativniji stav prema objektu mjerenja. Takav postupak predstavlja pokušaj kontrole tzv. pristranosti slaganja (eng. *acquiescence bias*), tj. tendencije ispitanika da češće izražava slaganje nego neslaganje s ponuđenim tvrdnjama. U ekstremnim slučajevima riječ je o ispitanicima koji bez pozornog čitanja odgovaraju kako se slažu sa svim tvrdnjama. Tada obrtanje čestica skale omogućava identificiranje takvih sudionika istraživanja i isključivanje njihovih rezultata iz daljnje analize. Primjerice, ispitanik koji se istovremeno složi i s tvrdnjom „proizvod XY manje je kvalitetan od većine sličnih proizvoda" i s tvrdnjom „proizvod XY kvalitetniji je od većine sličnih proizvoda" vjerojatno nije ozbiljno shvatio sâmo istraživanje ili nije uložio dovoljan trud u razumijevanje pitanja. U slučajevima kada postoji blaža tendencija slaganja, odnosno kada ispitanici pozorno čitaju pitanja, ali imaju blagu sklonost izražavanja stupnja slaganja koji je veći od stvarnog (npr. biraju odgovor „potpuno se slažem" iako je njihov stupanj slaganja sukladan odgovoru „slažem se"), negativno definiranje pitanja omogućit će ublažavanje ove pogreške. Uzmimo kao primjer da ispitanik na dvije tvrdnje s kojima se slaže zbog pristranosti slaganja odgovara s „potpuno se slažem" (odgovori se pomiču jedan stupanj „udesno"). Formuliramo li jednu od tih tvrdnji negativno, tada bi ispitanik na nju trebao odgovoriti s „ne slažem se", no zbog pristranosti slaganja odgovor će se pomjeriti jedno mjesto udesno i ispitanik će odgovoriti s „niti se slažem niti se ne slažem". Zbroj odgovora na dvije pozitivno formulirane tvrdnje bit će 10 (dva odgovora „potpuno se slažem"), što je zbog pristranosti slaganja više od realnog rezultata koji iznosi 8 (dva odgovora „slažem se"). Zbroj odgovora na jednoj pozitivno i jednoj negativno definiranoj tvrdnji bit će 8, što odgovara realnom rezultatu.

Konstruiranje Likertove skale često počinje većim brojem tvrdnji koje ispitanici procjenjuju u predtestiranju (pilot istraživanju). Nakon toga se izbacuju one tvrdnje koje nisu visoko korelirane s ostalima, a preostale čine čestice skale. Ukupni rezultat na skali najčešće se dobije zbrajanjem rezultata na pojedinim česticama, pri čemu se na petostupanjskoj skali odgovoru „uopće se ne slažem" dodjeljuje broj 1, a odgovoru „potpuno se slažem" broj 5.

Velika je prednost Likertove skale ta što ju je relativno lako konstruirati jer nužno ne zahtijeva panel stručnjaka, odnosno može je konstruirati sâm istraživač. Prednost je Likertove skale u odnosu na Thurstoneovu i mogućnost ispitivanja

pouzdanosti skale pomoću kriterija unutarnje konzistencije. Naime, sve čestice Likertove skale trebale bi mjeriti isti konstrukt pa je stoga moguće primijeniti taj kriterij, dok u Thurstoneovoj skali to nije moguće jer čestice nemaju jednaku „težinu", odnosno slaganja s pojedinim česticama označavaju različite stupnjeve posjedovanja mjerenog obilježja (vidjeti sljedeće poglavlje o Thurstoneovoj skali). No njezin je nedostatak da nije posve sigurno da su podatci na intervalnoj razini mjerenja. Primjerice, ne možemo biti sigurni da je razmak između „niti se slažem niti se ne slažem" i „slažem se" jednak onome između „slažem se" i „potpuno se slažem". Stoga je i upitno ima li ta skala svojstvo aditivnosti, tj. mogu li se na rezultatima te skale primjenjivati složenije statističke analize, iako se to u praksi uglavnom radi. Nedostatak je Likertove skale i nejasan status srednje točke na skali („niti se slažem, niti ne slažem"). Naime, srednju točku na skali birat će i oni ispitanici koji imaju neutralan stav prema nečemu, ali često i oni ispitanici koji nemaju stav o nečemu (Coolican, 1994: 140). Čak i uključivanje dodatnog odgovora na skali (primjerice: „ne znam, nisam siguran/na" ili „nemam stav o tome") ne mora riješiti ovaj problem jer ispitanici i ovaj odgovor mogu shvatiti na dva prethodno navedena i posve različita načina.

### 5.2.9. Thurstoneova skala

Skala koju je konstruirao američki psiholog **Louis Leon Thurstone** sastoji se od tvrdnji o nekom objektu stava, a ispitanik treba označiti sve one tvrdnje s kojima se slaže. Za razliku od Likertove skale u kojoj sve tvrdnje nose jednaku težinu, u Thurstoneovoj skali sve čestice nose različitu količinu bodova, tj. slaganje s njima označava različite razine intenziteta stava prema onome što se u istraživanju mjeri. Udaljenosti između tih tvrdnji trebale bi biti približno jednake, pa se stoga Thurstoneova skala još često naziva i *skala prividno jednakih intervala*.[47]

***Thurstoneova skala sastoji se od niza čestica koje nose različit broj bodova unutar nekoga intervala.***

U donjoj je tablici naveden primjer Thurstoneove skale s devet stupnjeva (čestica, tvrdnji) kojom se mjeri odnos radnika prema vlastitoj tvrtki, odnosno njihova procjena stupnja u kojem tvrtka cijeni njihova postignuća i pravedno se odnosi prema njima. Treba naglasiti da se pri primjeni skale rezultati na skali

[47] Ovo je zapravo samo jedna od tri metode stvaranja skale koju je predložio Thurstone, a druge su dvije metoda sukcesivnih intervala i metoda uspoređivanja u parovima.

izostavljaju, odnosno da ih ispitanici ne vide. Njihov je zadatak da u tom stupcu označe s kojima se od prikazanih tvrdnji u tablici slažu. Također treba napomenuti da se tvrdnje u skali obično randomiziraju, odnosno da je njihov redoslijed određen slučajno. U donjoj smo tablici, radi lakšeg objašnjavanja i razumijevanja, tvrdnje poredali prema intenzitetu stava.

*Tablica 17. Primjer Thurstoneove skale*

| **Tvrdnja** | **Rezultat na skali** |
|---|---|
| 1. Tvrtka istinski cijeni moj doprinos. | 9 |
| 2. Moj je posao siguran sve dok dobro radim. | 8 |
| 3. Nadređeni mi govore što doista misle o meni. | 7 |
| 4. Tvrtka nagrađuje sukladno uloženom trudu. | 6 |
| 5. Tvrtka bi trebala poboljšati svoj program treninga zaposlenika. | 5 |
| 6. Politika tvrtke prema zaposlenicima prilično je nejasna. | 4 |
| 7. Moj posao uključuje malo mogućnosti za slobodno odlučivanje. | 3 |
| 8. Moji nadređeni rijetko mi govore što misle o meni. | 2 |
| 9. Mnogi zaposlenici ostaju u ovoj tvrtki samo zato što ne mogu naći drugi posao. | 1 |

Izvor: McKenna, 2000: 270.

Rezultat na ovoj skali dobije se izračunavanjem prosječne vrijednosti tvrdnji s kojima se ispitanik složio. Npr., ispitanik koji bi se složio samo s tvrdnjama „3“ i „4“, imao bi rezultat 6,50 (13/2) na ovoj skali.

Približna jednakost i pokrivenost cijelog kontinuuma vrijednosti povećava osjetljivost (diskriminativnost) skale zbog toga što će moći biti „uhvaćeni“ različiti intenziteti posjedovanja određenog stava. Pretpostavimo li, primjerice, da je u Thurstoneovoj skali prikazanoj u donjoj tablici izostavljena četvrta tvrdnja, koja govori o tome da tvrtka radnike nagrađuje sukladno njihovom učinku i ima vrijednost 6, a da je dodana još jedna tvrdnja čija vrijednost iznosi 3. U tom bi slučaju jedan dio zaposlenika koji bi se složio s donjim tvrdnjama, ali i s četvrtom tvrdnjom, bio izjednačen s onima koji bi se složili s donjim tvrdnjama, ali ne i s četvrtom tvrdnjom. Tako bi se izgubila razlika između onih koji imaju nešto pozitivniji stav prema tvrtki od onih čiji je stav nešto negativniji.

Kako bi se izabrale tvrdnje koje će činiti skalu i odredilo koliko bodova nosi svaka od njih, u predtestiranju veća skupina procjenitelja – obično stručnjaci koji se bave tim područjem – procjenjuje veći broj tvrdnji na skali od 1 do 11, pri čemu ocjena 1 znači da slaganje s tom tvrdnjom znači izrazito negativan, a ocjena 11 da slaganje s tvrdnjom znači izrazito pozitivan stav prema objektu stava. Drukčije rečeno, zada-

tak je procjenjivača procijeniti u kojoj mjeri slaganje s pojedinim tvrdnjama znači negativniji, a u kojoj mjeri pozitivniji stav prema nečemu ili nekome. Primjerice, u slučaju stvaranja skale kojom bi se mjerio etnocentrizam tvrdnja kojoj bi procjenjivači vjerojatno davali ocjene 1 ili blizu 1 označavala bi nepostojanje etnocentrizma – npr.: „Svaka etnička skupina zaslužuje isti tretman i poštovanje." Primjer tvrdnje kojoj bi procjenjivači vjerojatno davali visoku ocjenu (oko 11) bio bi: „Moja etnička skupina uvjerljivo je bolja od svih drugih." Ovdje treba naglastiti da procjenjivači daju svoj stav o tome u kojoj mjeri pojedine tvrdnje mjere određeni fenomen, odnosno da se od njih ne traži da navedu koliko se *osobno* slažu s tim tvrdnjama. Uspješnost konstrukcije Thurstoneove skale ovisi o tome koliko su sudačke procjene neovisne o njihovim stavovima. Na primjer, u gornjem bi slučaju procjenjivač, koji bi u ranije navedenoj tvrdnji („Moja etnička skupina uvjerljivo je bolja od svih drugih.") dao 11 bodova, to učinio zato što misli da se s tom tvrdnjom slažu osobe koje imaju najviši stupanj etnocentrizma, a ne zato što se on sâm slaže s njom. Nakon što su procjenjivači donijeli svoje procjene, izračunaju se prosječni rezultati za pojedine tvrdnje – u pravilu medijan, zbog smanjenja utjecaja ekstremnih rezultata, odnosno atipičnih vrednovanja pojedinih stručnjaka – te se zadržavaju one tvrdnje u kojima je slaganje između procjenjivača bilo najveće, odnosno tvrdnje koje imaju najmanji interkvartilni raspon (udaljenost između trećeg i prvog kvartila). Ilustrirajmo to primjerom u kojemu su navedene samo tvrdnje za prva dva stupnja na skali (tablica 18). U ovom slučaju najbolji kandidat za prvu tvrdnju (tvrdnju koja nosi jedan bod) bila bi tvrdnja br. 22 zato što ima manji interkvartilni raspon od tvrdnji br. 7 i 19 koje imaju isti medijan kao navedena tvrdnja. Analogan slučaj postoji u tvrdnji 6 koja je najbolji izbor za tvrdnju koja će nositi dva boda.

*Tablica 18. Ilustracija izbora tvrdnji u Thurstoneovoj skali*

| **Redni broj tvrdnje** | **Medijan** | **Interkvartilni raspon** |
|---|---|---|
| 7 | 1 | 2 |
| 19 | 1 | 2 |
| 22 | 1 | 1 |
| 3 | 2 | 2 |
| 6 | 2 | 1 |
| 12 | 2 | 2 |

Najvažniji je nedostatak Thurstoneove skale taj da ju je vrlo teško konstruirati. Naime, teško je naći veći broj procjenitelja koji će ocjenom tvrdnji pomoći u konstrukciji skale, a čak i kada je to moguće učiniti, postupak obično zahtijeva više vremena od konstrukcije drugih skala. Prednost skale u odnosu na onu Likertovu je ta da su dobiveni podatci na intervalnoj razini mjerenja.

### 5.2.10. Guttmanova skala

Guttmanova skala, koju je konstruirao sociolog **Louis Guttman**, sastoji se od niza tvrdnji koje mjere određeni koncept, pri čemu se pretpostavlja da će se svaki od ispitanika koji se složi s tvrdnjom koja se odnosi na jače prihvaćanje određenog koncepta složiti i s onim tvrdnjama koje označavaju slabije prihvaćanje određenog koncepta. Drukčije rečeno, tvrdnje su formulirane tako da postaju sve „ekstremnije", tj. da svaka sljedeća tvrdnja označava veće slaganje s određenim konceptom, odnosno posjedovanje određenog svojstva u većoj mjeri. Primjer jedne Guttmanove skale s pet stupnjeva – čestica kojom se mjeri stav prema nasilnim sadržajima u igrano-serijskom televizijskom programu naveden je u donjoj tablici.

*Tablica 19. Primjer Guttmanove skale*

| **Razmislite o svakoj od navedenih tvrdnji i označite one s kojima se slažete.** | |
|---|---|
| 1. Tjelesno nasilje u igrano-serijskom televizijskom programu može biti štetno za društvo. | |
| 2. Prilikom gledanja igrano-serijskog televizijskog programa s djecom trebaju biti odrasli koji će ga interpretirati i staviti u perspektivu. | |
| 3. Roditelji nikada ne trebaju dopustiti svojoj djeci gledanje tjelesnog nasilja u igrano-serijskom televizijskom programu. | |
| 4. Urednici na televiziji trebali bi izbjegavati prikazivanje tjelesnog nasilja u igrano-serijskom televizijskom programu. | |
| 5. Vlada treba cenzurirati tjelesno nasilje u igrano-serijskom televizijskom programu. | |

Izvor: Du Plooy, 1995: 79.

Jedna je od varijanti Guttmanove skale tzv. *Bogardusova skala socijalne distance*[48] kojom se mjeri bliskost između pojedinih društvenih skupina. Na primjer, od ispitanika tražimo da označe koji su im stupnjevi bliskosti s pripadnicima neke etničke skupine prihvatljivi a koji neprihvatljivi. Pretpostavka je da je ova skala kumulativna, tj. da, primjerice, osoba koja nema ništa protiv da pripadnik neke etničke skupine postane član njegove obitelji, nema ništa protiv niti da bude prijatelj pripadniku te skupine, da živi u istom susjedstvu, radi na istom mjestu kao i ona, i tako dalje.

[48] Dobila je ime prema američkom sociologu Emoryju S. Bogardusu.

*Tablica 20. Primjer varijante Bogardusove skale socijalne distance*

| **Vrsta odnosa** | **Da** | **Ne** |
|---|---|---|
| Isključio bih ih iz moje zemlje. | | |
| Nemam ništa protiv da posjećuju moju zemlju. | | |
| Nemam ništa protiv da budu državljani moje zemlje. | | |
| Nemam ništa protiv da radim na istom mjestu kao i oni. | | |
| Nemam ništa protiv da žive u mome susjedstvu. | | |
| Nemam ništa protiv da budem blizak prijatelj nekome od njih. | | |
| Nemam ništa protiv da mi netko od njih bude član obitelji. | | |

Ovdje treba napomenuti da je u ovom slučaju čestica koja govori o isključivanju iz zemlje formulirana na obrnut način, tj. da slaganje s njom, za razliku od ostalih tvrdnji, ukazuje na viši, a ne na niži stupanj socijalne distance.

***Guttmanova skala sastoji se od niza čestica različitog intenziteta te se pretpostavlja da će se sudionik istraživanja, u skladu sa svojim stavovima, slagati s određenim brojem čestica, a neće se složiti s preostalim česticama.***

Guttmanova skala boduje se na različite načine koji imaju različite stupnjeve složenosti. Pri najjednostavnijem načinu bodovanja, ako se ispitanik, primjerice, složio s prve tri tvrdnje i nije složio s preostale tri tvrdnje, njegov/njezin rezultat na skali iznosi tri. Drukčije rečeno, pri primjeni ovakvog načina, Guttmanova skala boduje se tako da ispitanik dobije rezultat jednak broju tvrdnji s kojima se složio. Složeniji načini bodovanja upotrebljavaju tzv, skalogramsku analizu kojom se utvrdi „težina" određenih čestica, pa one stoga imaju i različite brojeve bodova.

Guttmanova skala također se konstruira tako da se tvrdnje daju na procjenu nizu stručnjaka, a skala se obično i predtestira u manjem (pilot) istraživanju. Vrlo je važno, naime, da se ispitanici koji se slože s tvrdnjom koja označava viši stupanj slaganja slože i s onim tvrdnjama koje označavaju niži stupanj slaganja. Primjerice, u donjoj tablici ispitanik 1 i ispitanik 2 dali su konzistentne odgovore, no ispitanik 3 nije se složio s tvrdnjom 2 („neka žive u mome gradu"), s kojom se trebao složiti. U slučaju da imamo veći broj takvih pogrešaka, skala je neupotrebljiva. Kao mjera kvalitete skale računa se tzv. *koeficijent reproducibilnosti*, a on se dobiva tako da se prvo izračuna ukupan broj pogrešaka koje se definiraju kao oni odgovori koji se ne uklapaju u obrazac. Drukčije rečeno, broj pogrešaka jednak je broju odgovora koji moraju biti ispravljeni kako bi se dobio savršen obrazac. U donjem primjeru postoji jedna pogreška, i to u ispitanika br. 3. (kod odgovora na tvrdnju „neka žive u mom gradu". Nakon toga se koeficijent reproducibilnosti računa kao 1 - (broj pogrešaka/broj odgovora). U našem slučaju on bi iznosio 1 – (1/15) = 0,93, tj. bio bi viši od preporučenog minimalnog iznosa od 0,90.

*Tablica 21. Primjer rezultata na Guttmanovoj skali*

| | **Neka žive u mojoj zemlji.** | **Neka žive u mome gradu.** | **Neka žive u mom susjedstvu.** | **Nemam ništa protiv da mi budu prijatelji.** | **Nemam ništa protiv da mi budu članovi obitelji.** |
|---|---|---|---|---|---|
| Ispitanik 1 | + | + | - | - | - |
| Ispitanik 2 | + | + | + | + | - |
| Ispitanik 3 | + | - | + | + | - |

Prednosti i nedostatci Guttmanove skale slične su onima koji se odnose na Thurstoneovu skalu. Guttmanova skala, naime, zahtijeva mnogo vremena i napora za konstruiranje, no donosi podatke na intervalnoj razini mjerenja, što omogućuje kvalitetniju statističku analizu. Pri tome valja naglasiti da se intervalna razina mjerenja postiže tek onda kada se pojedinim stupnjevima na skali dodijeli odgovarajuća težina.

Osim Guttmanove skale u užem smislu, ponekad se i pitanja čije opcije odgovora imaju strukturu Guttmanove skale (eng. *Guttman-type response options*) nazivaju pitanjima Guttmanova tipa. Primjerice, Situational Humor Response Questionnaire (SHQR), jedna od skala kojima se mjeri smisao za humor, i uključuje opis niza društvenih situacija u kojima pojedinac treba označiti svoju vjerojatnu reakciju zakoruživanjem jedne od sljedećih opcija:

- Ne bih to smatrao osobito zabavnim.
- Bilo bi mi zabavno, ali to ne bih otvoreno pokazao.
- Nasmiješio bih se.
- Nasmijao bih se.
- Nasmijao bih se iz sveg srca.

Ovdje je vidljivo da svaki sljedeći odgovor pretpostavlja jači intenzitet doživljavanja humorističnosti situacije.

## 5.3. MJERNI INSTRUMENTI

Pojedine mjerne skale mogu se primjenjivati u različite svrhe, a prema tim svrhama Mejovšek (2009: 45) mjerne instrumente dijeli na:

1. Test,
2. Upitnik ličnosti,
3. Skala procjene,
4. Anketni upitnik.

*Testovi* su standardizirani postupci za procjenu znanja, što znači da se samo oni testovi koji imaju provjerene metrijske karakteristike (baždareni su) mogu smatrati testovima u pravome smislu riječi. Testovi su baždareni ako su poznate njihove prosječne vrijednosti i raspršenje rezultata na relevantnoj populaciji. Npr., ako znamo da se na nekom testu iz matematike u prosjeku postiže određeni rezultat te koliki će dio učenika riješiti koliko zadataka, tada taj test možemo koristiti za mjerenje znanja iz matematike. Ako test nije baždaren, tada je njegova primjena nepouzdana. Npr., ako napravimo *ad hoc* test za ispit te niti jedan student ne dobije najvišu ocjenu, tada ne možemo pouzdano znati je li test pretežak ili nijedan učenik doista nema znanje potrebno za najvišu ocjenu.

*Upitnik ličnosti* odnosi se na mjerenje obilježja ličnosti, uglavnom u psihologiji. U upitnicima ličnosti najčešće se koriste Likertove skale.

*Skale procjene* instrumenti su kojima stručnjaci u određenom području procjenjuju ponašanje ili karakteristike ispitanika. Ponekad se koriste i skale samoprocjene, pri čemu ispitanik procjenjuje samoga sebe. Skale procjene imaju i neke nedostatke (Guion, 1967; navedeno prema Mejovšek, 2008: 47):

1. Moguće nisko slaganje među procjenjivačima,
2. Halo-efekt (procjenjivanje osobe na temelju općeg dojma o njoj),
3. Blagost-strogost u ocjenjivanju (neki su blaži neki stroži u ocjenama),
4. Tendencija davanja prosječnih procjena (zbog opreza).

*Anketni upitnik* sastoji se od niza unaprijed pripremljenih pitanja na koja ispitanik daje odgovor, pri čemu je obično riječ o mjerenju stavova, znanja ili ponašanja. Prema tome je li ili nije ponuđen odgovor, pitanja mogu biti:

1. Zatvorenog tipa (ispitaniku se nude opcije)
2. Otvorenog tipa (opcije se ne nude)

Primjer pitanja zatvorenog tipa:

Kakav je Vaš stav prema suvremenom hrvatskom filmu?

a. pozitivan b. neutralan c. negativan

Isto pitanje otvorenog tipa glasilo bi:

Kakav je Vaš stav o suvremenom hrvatskom filmu?

_____

Najčešće se primjenjuju pitanja zatvorenog tipa jer ih je lakše unijeti, obraditi i analizirati. S druge strane, pitanja otvorenog tipa mogu dovesti do zanimljivih

rezultata, tj. u njima se mogu pojaviti odgovori koji nisu bili predviđeni, a zanimljivi su iz različitih razloga.

### 5.3.1. Mjerne karakteristike instrumenata

Mjerne (metrijske) karakteristike instrumenata odnose se na određene standarde koje mora ispunjavati svaki instrument kako bi se smatrao kvalitetnim i upotrebljivim. U tom smislu, postoje četiri osnovne mjerne karakteristike (prema Mejovšeku, 2008: 53):

1. Valjanost,
2. Pouzdanost,
3. Osjetljivost,
4. Objektivnost.

Tome se može dodati i da je poželjno da instrument bude baždaren, tj. da su poznati njegovi rezultati na populaciji na kojoj se upotrebljava.

***Najvažnija su mjerna obilježja mjernih instrumenata valjanost, pouzdanost, osjetljivost i objektivnost.***

Mjerni je instrument *valjan* ako mjeri upravo ono što treba mjeriti. Posve je jasno da mjerni instrument kojime zapravo mjerimo nešto drugo, a ne ono što želimo, ne može biti upotrebljiv. Valjanost se u najširem smislu može shvatiti kao podudaranje konceptualne (teorijske) i operacionalizirane definicije nekog konstrukta. Ako smo neki konstrukt operacionalizirali na način da dobro pokriva ono što smo teorijskom definicijom uključili u sadržaj nekog konstrukta, tada možemo govoriti o valjanom mjerenju toga konstrukta.

***Mjerni instrument valjan je ako mjeri ono što bi trebao mjeriti.***

Postavlja se pitanje kako utvrditi je li instrument valjan, a odgovor se krije u tri osnovne vrste valjanosti (Mejovšek, 2008: 54):

1. Sadržajna,
2. Konstruktna,
3. Kriterijska.

Sadržajna se valjanost (eng. content validity) utvrđuje sustavnom analizom čestica mjernog instrumenta. Pri tome se vodi računa da su u instrumentu za-

stupljeni svi relevantni aspekti onoga što se ispituje. Npr., instrumentom kojim bismo mjerili u kojoj mjeri ispitanici pohađaju određene kulturne događaje, sadržajna valjanost bi značila da smo pokrili sve relevantne kulturne događaje koje ispitanici mogu pohađati i koji su u interesu našeg istraživanja. Pri utvrđivanju sadržajne valjanosti ponekad se koriste i statističke tehnike. Tako npr. faktorskom analizom možemo otkriti da instrument pohađanja kulturnih događaja mjeri dvije međusobno neovisne stvari – pohađanja događaja koje vezujemo uz elitnu i onih koje povezujemo uz popularnu kulturu.

Konstruktna valjanost utvrđuje se usporedbom instrumenta s drugim sličnim instrumentima, odnosno instrumentima koji mjere konstrukte koji bi trebali biti povezani ili nepovezani s konstruktom koji mjerimo. Mogu se izdvojiti dvije osnovne vrste konstruktne valjanosti:

1. Konvergentna,
2. Divergentna.

Konvergentna valjanost odnosi se na povezanost instrumenta s drugim instrumentima koji mjere isti konstrukt. Ako je ta povezanost visoka, tada možemo reći da naš instrument ima visoku konstruktnu valjanost. Divergentna valjanost odnosi se na nepostojanje povezanosti s instrumentom koji mjeri druge, nepovezane konstrukte. Konvergentnu i divergentnu konstruktnu valjanost moguće je provjeriti jednostavnom korelacijom između rezultata koji smo dobili mjerenjem našeg konstrukta i rezultata na skalama koji mjere slične (konvergetna valjanost) ili različite konstrukte (divergentna valjanost). U prvom slučaju ta bi korelacija trebala postojati, a u drugome ne.

Osim na ovaj način, konstruktnu valjanost moguće je provjeriti i složenijim metodama. Tako je, primjerice, konvergentnu i divergentnu valjanost moguće izmjeriti u jednom istraživanju ako imamo dva nepovezana konstrukta, pri čemu je svaki od njih mjeren na dva različita načina (Milas, 2009:367). Primjerice, imamo instrument kojim se mjeri proekološka orijentacija te instrument kojim se mjeri stvarno proekološko ponašanje. S druge strane imamo instrument kojim se mjeri stav ispitanika prema određenom proizvodu A te instrument kojim se mjeri stvarna kupovina tog proizvoda. Pretpostavka je da su proekološka orijentacija i preferencija prema proizvodu A nepovezani jer njegova upotreba nema izraženu ekološku dimenziju ili ekološke implikacije. U tom bi se slučaju konvergentna valjanost naše mjere proekološke orijentacije odnosila na njezinu visoku povezanost sa stvarnim proekološkim ponašanjem, pri čemu bi valjalo uvažiti i činjenicu da se ove mjere ne odnose na posve iste konstrukte. Naime, u jednom je slučaju riječ o stavovima, a u drugom o ponašanju. Divergentna valjanost od-

nosila bi se na nisku povezanost između mjera različitih konstrukata dobivenih istom ili različitim metodama. Primjerice, ako bi dobili višu povezanost između mjere samoiskazane proekološke orijentacije i mjere samoiskazane sklonosti proizvodu A, tada je očigledno riječ o učinku metode mjerenja – primjerice, sklonosti ispitanika da u istraživanju zauzmu srednji stupanj skale.

U praksi se konvergentna i divergentna valjanost, umjesto opisanom metodom, češće mjere pomoću tzv. faktorske analize pa se često valjanost izmjerena na taj način naziva i *faktorskom valjanošću*. Pojam konvergentne faktorske valjanosti podrazumijeva da se čestice iz dva instrumenta koja mjere isti konstrukt „pomiješaju" i podvrgnu faktorskoj analizi kojom se utvrđuje jesu li ove čestice visokopovezane, tj. stoji li u njihovoj pozadini ista latentna varijabla. U slučaju divergentne faktorske valjanosti, pomiješane čestice iz dva nepovezana konstrukta trebale bi u faktorskoj analizi donijeti dvije nepovezane latentne varijable.

Kriterijska valjanost odnosi se na povezanost rezultata na mjernom instrumentu u prognoziranju nekih drugih važnih varijabli (tzv. kriterijskih varijabli) koje su teorijski povezane s tim rezultatom (prediktorskom varijablom). Najčešće je u pitanju druga mjera istog konstrukta koja se smatra nekom vrstom „zlatnog standarda", a koju u tom trenutku nije moguće izmjeriti. Čest je slučaj i da se provjerava kriterijska valjanost kraće skale u usporedbi s dužom, već dobro validiranom skalom. Klasični slučaj visoke kriterijske valjanosti bio bi klasifikacijski ispit na fakultetu koji dobro prognozira budući uspjeh na studiju (viši rezultat na ispitu znači bolji uspjeh na studiju). Kriterijska se valjanost dijeli na:

1. Dijagnostičku,
2. Prognostičku.

Dijagnostička valjanost odnosi se na situaciju kada kriterijsku varijablu mjerimo u sadašnjem vremenu, a prognostička kada je mjerimo u budućnosti. Primjerice, dijagnostička valjanost klasifikacijskog ispita može se utvrditi ako skupinu studenata koja već studira podvrgnemo provjeri znanja klasifikacijskim ispitom, te nakon toga odredimo koliko je rezultat na njemu povezan s uspjehom na studiju. Prognostičku valjanost utvrdili bismo, kada bismo skupinu studenata koja je pristupila klasifikacijskom ispitu pratili tijekom nekoliko godina te utvrdili njihov uspjeh na studiju. Tada bismo utvrdili povezanost (koeficijent korelacije) između uspjeha na ispitu i uspjeha na studiju, i ta bi korelacija označavala prognostičku valjanost. Kriterijska valjanost presudno ovisi o tome koliko je uistinu rezultat na našoj skali povezan s kriterijskom varijablom; ako je ta povezanost mala, tada koeficijent korelacije neće biti dobra mjera valjanosti mjernog instrumenta, odnosno kriterijsku valjanost u tom slučaju bit će teško utvrditi. Uzmimo, primje-

rice, da smo konstruirali mjerni instrument kojim mjerimo političku orijentaciju pojedinaca na kontinuumu lijevo-desno. Teorijski pretpostavimo da bi politička orijentacija trebala biti povezana s glasovanjem za stranke ljevice ili desnice na izborima, tj. glasovanje na izborima izaberemo kao kriterij prilikom provjere kriterijske valjanosti. Drukčije rečeno, pretpostavimo da bi pojedinci koji su na našem instrumentu lijevo orijentirani trebali glasati za stranke ljevice, a desno orijentirani za stranke desnice pa izračunajmo korelaciju između političke orijentacije na našem instrumentu i glasovanja na izborima. Ta je korelacija dobra mjera kriterijske valjanosti samo ako su prediktor i kriterij doista povezani. Ako, primjerice, glasovanje na izborima ne ovisi izrazito o političkoj orijentaciji, nego je važnija glasačka procjena kandidata na izborima (poštenje, stručnost i sl.), tada je spomenuta korelacija loša mjera kriterijske valjanosti. Naime, naš je instrument možda doista valjan kada je u pitanju mjerenje političke orijentacije, ali to u ovom slučaju ne možemo utvrditi na temelju korelacije s glasovanjem na izborima. Kriterijska se valjanost često utvrđuje korištenjem mjernog instrumenta na nekoj skupini koja ima ili bi prema pretpostavci trebala imati poznat rezultat na njemu (Neuman, 2004: 116). Primjerice, visok rezultat na mjernom instrumentu koji mjeri liberalizam trebali bi imati ljudi za koje znamo da su inače liberalne orijentacije (npr. glasaju za liberalne stranke).

Osim ovih, najvažnijih, vrsta valjanosti često se izdvajaju i tzv. očigledna valjanost (eng. *face validity*) i nomološka valjanost. Očigledna valjanost najčešće predstavlja prvi korak prema „ozbiljnijem" utvrđivanju valjanosti, a sastoji se od preliminarne analize valjanosti, odnosno od utvrđivanja je li mjera valjana „na prvi pogled". Nomološka se valjanost često smatra i podvrstom konstruktne valjanosti, a odnosi se na teorijsku korisnost mjere određenog konstrukta. Primjerice, ako su istraživanja društvenih vrijednosti koja koriste određeno mjerenje tog konstrukta (tj. društvenih vrijednosti) donijela rezultate koji pokazuju da se pojedinci razlikuju prema svojim društvenim vrijednostima na teorijski predvidljiv i objašnjiv način (npr. da su stariji ljudi konzervativniji od mlađih), tada je takvo mjerenje nomološki valjano.

Ilustrirajmo pojedine vrste valjanosti na primjeru validacije tzv. Situational Humor Response Questionnaire, skale smisla za humor koju su osmislili i učinili validnom Martin i Lefcourt (1984). Ova skala sadržajno pokriva niz društvenih situacija koje su opisane u upitniku, pri čemu se od ispitanika traži da navede koliko je vjerojatno da bi se u njima našalio, odnosno shvatio ih na humoristočan način. Konstrukt humora vrlo je složen, odnosno uključuje vrednovanje humora, sposobnost produkcije humora, učestalost upotrebe humora i smijeha i mnoga

druga ponašanja i stavove. Stoga SHRQ skala nije posve sadržajno valjana jer uglavnom pokriva samo učestalost upotrebe humora i smijeha u društvenim situacijama, a ne i druge sadržaje na koje se konstrukt humora, odnosno smisla za humor, odnosi. Konstruktnu valjanost ove skale Martin i Lefcourt provjerili su na način da su korelirali rezultat na skali s nizom drugih teorijski povezanih i nepovezanih konstrukata. Primjerice, konvergentna valjanost provjerena je koreliranjem rezultata sa skalom kojom se mjeri opći ton raspoloženja. Pri tome je pretpostavka, koja je i potvrđena validacijom skale, da je učestalost upotrebe humora pozitivno korelirana s pozitivnim općim tonom raspoloženja pojedinca. Imajući u vidu da gotovo svi pojedinci vjeruju da su duhoviti, odnosno da bi odgovor na pitanja iz SHQR skale mogao odražavati poželjnost smisla za humor, divergentna valjanost provjerena je koreliranjem rezultata na skali s Crowne-Marlowe skalom socijalne poželjnosti, pri čemu nije pronađena korelacija. Drukčije rečeno, odgovori na SHQR skali ne odražavaju sklonost pojedinaca da se predstave kao vedre i duhovite osobe. Kriterijsku valjanost Martin i Lefcourt također su provjeravali na nekoliko načina, korelirajući rezultat na skali s nekim jasnim kriterijima smisla za humor. Kriteriji procjene duhovitosti osoba odredili su njihovi prijatelji, prema sposobnosti proizvodnje humora u različitim situacijama, mjerene tako da se od ispitanika tražilo da smisle duhoviti komentar neke situacije koja im je opisana u eksperimentalnoj situaciji. U oba ova slučaja postojala je pozitivna korelacija između kriterija i rezultata na SHQR skali. Korelacija između sposobnosti produkcije humora i SHQR skale donekla ublažava i činjenicu da, kako je ranije navedeno, produkcija humora nije mjerena ovom skalom, odnosno da skala nema potpunu sadržajnu valjanost.

*Pouzdanost instrumenta* odnosi se na njegovu stabilnost, odnosno na dobivanje konzistentnih rezultata tijekom više uzastopnih mjerenja, pod uvjetom da se sâmo obilježje, tj. stvarni mjerni rezultat nisu promijenili. Pouzdano mjerenje ne mora nužno biti i valjano mjerenje, a valjano je mjerenje uvijek i pouzdano. Drukčije rečeno, pouzdanost je nužan, ali ne i dovoljan uvjet da bi neko mjerenje bilo valjano. Jednostavan primjer s mjerenjem težine pomoću vage može ilustrirati taj odnos. Uzmimo da neka vaga zbog pogreške stalno pokazuje pet kilograma više u odnosu na stvarnu težinu osobe koja se važe. U tom bi slučaju u više uzastopnih mjerenja bila dobivena ista težina, no ta bi težina uvijek bila pogrešna. Stoga bi takva vaga bila pouzdana, ali ne bi bila valjana.

***Mjerni instrument pouzdan je ako u više uzastopnih mjerenja daje iste rezultate.***

Gore navedena definicija implicira da pouzdanost mjerenja ovisi o količini slučajne pogreške prilikom mjerenja – što je ta količina manja, pouzdanost je veća. Točna matematička formulacija glasi P = T(p)/[T(p) + T(e)], pri čemu je T(p) stvarni (ispravni, točni...) rezultat mjerenja, a T(e) slučajna pogreška. Drukčije rečeno, pouzdanost je to veća što su manje slučajne varijacije oko pravog rezultata. U društvenim i humanističkim znanostima ta se pogreška obično odnosi na loše konstruiran upitnik (nejasna i/ili dvosmislena pitanja), pogreške koje se odnose na samoga ispitanika (zamor, nedovoljna motiviranost, loša memorija i sl.) ili pogreške do kojih dolazi zbog samog istraživača (loše pročitana pitanja, loš odnos s ispitanikom i sl.).

S obzirom na to da je vremenska stabilnost temeljno obilježje pouzdanog instrumenta, u idealnoj situaciji pouzdanost bi se uvijek provjeravala upravo na taj način. No kako to uvijek nije moguće, pouzdanost se može definirati te mjeriti i *ekvivalentnošću*, odnosno *unutarnjom konzistentnošću* mjernog instrumenta. Sukladno navedenom, pouzdanost se može mjeriti na tri načina:

1. Test-retest metoda,
2. Paralelne forme,
3. Unutarnja konzistencija.

Svaka od tih mjera prikladna je u određenim situacijama, a preporučuje se da se prilikom analize pouzdanosti ili u situacijama kada se mjere pouzdanosti koriste kao korekcija u statističkim analizama navedu sve mjere koje je moguće izračunati.

Test-retest metoda zasniva se na ideji vremenske stabilnosti mjerenja, odnosno označava ponovnu primjenu istog instrumenta na istim ispitanicima nakon određenog razdoblja, te mjerenje korelacije između dvaju rezultata. Ako je korelacija vrlo visoka, tada se može govoriti o visokoj pouzdanosti instrumenta. Preciznije govoreći, ova se korelacija najčešće računa tako da se ukupna varijabilnost rezultata podijeli na onu koja se tiče unutrašnje varijabilnosti (razlike u rezultatima istog ispitanika u ponovljenim mjerenjima) i varijabilnosti između ispitanika (razlike u rezultatima koje postižu različiti ispitanici). Tada se test-retest pouzdanost izračuna tako da se podijeli varijabilnost između ispitanika i ukupna varijabilnost koju čini zbroj dviju navedenih varijabilnosti. Na ovaj se način tako uvažava ukupna varijabilnost rezultata, odnosno pouzdanost će biti veća ako promjene u rezultatima koje ispitanik postiže u različitim mjerenjima čine tek manji dio ukupne varijabilnosti. Oprimjerimo to sljedećom jednostavnom situacijom. Vaga koja pokazuje razliku od 0,5 kilograma u ponovljenim mjerenjima

bit će pouzdanija ako masa pojedinaca jako varira (npr. između 60 i 150 kilograma), nego ako je ta varijacija manja, zato što će u tom slučaju varijabilnost unutar pojedinca (pogreška mjerenja) biti samo manji dio ukupne varijabilnosti. Test-retest metoda jedini je način mjerenja pouzdanosti u situacijama kada se neki koncept mjeri pomoću samo jedne čestice ili u situacijama kada pouzdanost nije moguće provjeriti pomoću alternativnih formi ili unutarnje konzistentnosti.

Postoje dva temeljna teorijska nedostatka test-retest metode. Prvi je taj da se ispitanici mogu prisjećati odgovora koje su dali u prvom istraživanju i ponoviti ih u drugome, što umjetno povećava pouzdanost. Drugi je mogućnost da se tijekom vremena promijeni stvarni rezultat mjerenja, čime nekonzistentnost između dvaju rezultata prestaje implicirati i manju pouzdanost. Primjerice, ljudi između dvaju mjerenja mogu promijeniti stavove, a time se i rezultat primjene test-retest metode ne može jednoznačno interpretirati.

Veoma je važan praktični nedostatak test-retest metode taj da su nam sudionici istraživanja često nedostupni nakon nekog vremena, odnosno da nije moguće provesti ponovno istraživanje na istim ispitanicima. Čest izuzetak predstavljaju eksperimentalna istraživanja s eksperimentalnom i kontrolnom grupom te predtest i posttest mjerenjem. U toj situaciji, naime, usporedbom dvaju rezultata kontrolne grupe lako dobijemo test-retest pouzdanost upotrijebljenih instrumenata.

Pouzdanost se pomoću paralelnih formi računa tako da se prvo konstruira veći broj čestica, a zatim se instrument podijeli na dvije ekvivalentne forme, pri čemu u svaku od njih ulazi polovina čestica. Drukčije rečeno, sve čestice koje uzimamo u obzir podijelimo na dva dijela i napravimo dvije verzije istog instrumenta. Nakon toga se izračuna korelacija između tih alternativnih verzija mjernog instrumenta, pri čemu veća korelacija znači i veću pouzdanost. U donjoj je tablici navedena hipotetička paralelna forma nekoliko čestica preuzetih iz *skale nove ekološke paradigme* kojom se mjeri proekološka orijentiranost (Dunlap i sur., 2000.).

*Tablica 22. Primjer alternativnih formi mjernog instrumenta*

| **Originalne čestice** | **Alternativna forma** |
|---|---|
| Čovjek bi trebao vladati nad ostatkom prirode. | Čovjek ima pravo sve što postoji koristiti za svoje svrhe. |
| Čovjek ozbiljno zloupotrebljava okoliš. | Ljudsko postupanje nanosi ozbiljnu štetu okolišu. |
| Približavamo se maksimalnom broju ljudi koje Zemlja može podnijeti. | Ljudska populacija postaje prevelika za dostupne resurse na Zemlji. |

Tipična je situacija u kojoj se upotrebljava metoda alternativnih formi eksperiment u kojemu imamo dva mjerenja na istim ispitanicima, no u svakom mjerenju želimo upotrijebiti različite verzije mjernog instrumenta kako bismo smanjili učinak mjerenja – npr. pamćenje odgovora u prvom mjerenju i njihovo ponavljanje u drugome. Pri tome se kao dodatna kontrola može napraviti randomizacija ispitanika – polovica ispitanika formu A dobit će u prvom testiranju, a polovica u drugom (Gomm, 2009:10). Druga je tipična situacija testiranje koje su u različitim vremenima koristi na različitim područjima pa se želi spriječiti da sudionici testiranja dojave odgovore onim sudionicima koji test pišu poslije njih (npr. testiranje učenika u državama s različitim vremenskim zonama).

Unutarnja konzistencija označava situaciju u kojoj se rezultati ispitanika na svim česticama koje mjere neki konstrukt visoko povezani. Primjerice, instrument kojim mjerimo pohađanje kulturnih događaja imao bi visoku unutarnju konzistenciju u situaciji u kojoj bi ispitanici, koji u usporedbi s drugim pojedincima rijetko idu u kazalište, u pravilu rijetko išli i u galerije, muzeje, različite koncerte, i slično. Ako to nije tako, tada se može ustanoviti da je riječ o nekoliko različitih konstrukata, čija se pouzdanost može posebno izračunavati. U našem primjeru možemo ustanoviti da su pohađanje događaja elitne i pohađanje događaja popularne kulture međusobno neovisni, tj. da je riječ o dva neovisna konstrukta. Tako bi pojedinac koji rjeđe od većine drugih ljudi ide u kazalište ili na koncerte klasične glazbe mogao iznadprosječno često ići na koncerte popularne glazbe.

Unutarnja se dosljednost obično izračunava nekom mjerom koja koristi korelacije između čestica, a najčešće se upotrebljavaju sljedeće mjere:

1. Prosječna korelacija između čestica,
2. Prosječna korelacija čestica s ukupnim rezultatom (eng. *item-to-total reliability*),
3. Korelacija između dviju polovica instrumenta (eng. *split-half reliability*),
4. Cronbachov alfa.

Kako sâmo ime kaže, prosječna korelacija između čestica predstavlja aritmetičku sredinu svih korelacija između čestica instrumenta. I druga je mjera samorazumljiva. Prvo se izračuna ukupni rezultat na instrumentu, nakon toga korelacija između svih čestica i tog ukupnog rezultata, a na kraju prosječna veličina tih korelacija.

Korelacija između polovica instrumenata dobije se podjelom instrumenta na dvije polovice pomoću slučajnog izbora (primjerice, polovicu skale čine neparna, a drugu polovicu parna pitanja) te izračunom koeficijenata pouzdanosti. Primjeri-

ce, moguće je izračunati Pearsonovu korelaciju između sume rezultata ispitanika na dvije polovice ili Cronbachov alfa za svaku od polovica, no najčešće se računa tzv. Spearman-Brownov koeficijent u čiji izračun ulazi Pearsonova korelacija (r).

$$\rho = \frac{2r}{1+r} \tag{1.1.}$$

Formula 1.1. važi za situacije s parnim brojem ukupnih čestica (odnosno jednakim brojem čestica u polovicama instrumenta), a u slučaju neparnog broja primjenjuje se malo korigirana formula koju ovdje ne navodimo.

*Split-half* metoda relativno je slična pouzdanosti pomoću paralelnih formi, no paralelne se forme upotrebljavaju kada želimo upotrijebiti dvije alternativne forme nekog instrumenta, a u *split-half* metodi mjeri se unutarnja konzistencija samo jednog instrumenta, odnosno instrumenta koji će biti upotrijebljen kao cjelina. U skladu s time, *split-half* metoda primjenjuje se na istim ispitanicima istovremeno (ispitanici popunjavaju cjeloviti upitnik odjednom), a paralelne forme najčešće se primijene u dva različita navrata (npr., dva različita dana) na istim ispitanicima.

Cronbachov alfa predstavlja mjeru pouzdanosti koja se može izračunati na svakoj skali koja se dobije zbrajanjem rezultata na pojedinim česticama, odnosno jednodimenzionalna je. Kao i u drugih mjera, pouzdanost se kreće od 0 (niska pouzdanost) do 1 (visoka pouzdanost). Ova je mjera konceptualno bliska navedenom Spearman-Brownovu koeficijentu, a može se predočiti kao pouzdanost koja se dobije na svim mogućim podjelama instrumenta u dvije polovice, odnosno izračunom njihove pouzdanosti. Formula za Cronbachov alfa glasi:

$$\alpha = \frac{K*\bar{C}}{(\bar{V}+(K-1)*\bar{C}} \tag{1.2.}$$

Pri tome je $K$ broj čestica, $\bar{C}$ prosječna kovarijanca između svih parova varijabli, a $\bar{V}$ prosječna varijanca između svih varijabli. Ponekad se računa i standardizirani Cronbachov alfa, a u njegovoj se formuli kovarijance zamijene s prosječnim korelacijama između parova varijabli, odnosno prosječna se varijanca zamijeni s brojem 1. Standardizirani se Cronbachov alfa odnosi na situacije u kojima je varijanca svih čestica ista, što je u praksi rijedak slučaj. Iz formule 1.2. može se vidjeti da će se Cronbachov alfa povećavati s brojem čestica, odnosno s povećanjem kovarijance između varijabli.

Ne postoje jasni naputci kolika bi trebala biti pouzdanost mjernog instrumenta jer to ovisi o praktičnoj ili znanstvenoj važnosti rezultata. Primjerice, instru-

menti kojim se dijagnosticiraju duševni poremećaji ili selekcioniraju kandidati za radno mjesto moraju biti vrlo pouzdani jer o njima ovisi postupanje u tim situacijama, odnosno kriva odluka može imati znatne posljedice na ljude čija se obilježja žele izmjeriti. U mnogim drugim situacijama koje se susreću u društvenim i humanističkim znanostima, iako pouzdanost mjernog instrumenta pridonosi kvaliteti istraživanja, dodatni troškovi vezani uz povećanje pouzdanosti (npr. produljenje upitnika) mogu nadmašivati dobivenu korist. No, u praksi se najčešće koristi pravilo da bi pouzdanost mjerena Cronbachovim alfa koeficijentom trebala biti najmanje 0,70.

Pouzdanost mjernog instrumenta najčešće se u praksi povećava na dva načina:

1. Povećavanjem broja čestica,
2. Selekcijom čestica.

Povećavanje broja čestica povećava i pouzdanost zbog toga što slučajne pogreške imaju tendenciju međusobnog poništavanja. Primjerice, rezultat na mjernom instrumentu sa samo jednim pitanjem u velikoj će mjeri ovisiti i o slučajnoj pogreški – lošem shvaćanju pitanja, umoru ispitanika, niskoj motivaciji za sudjelovanje i sl. U slučaju skale s većim brojem čestica ti izvori pogreške imaju tendenciju poništavanja jer će slučajne pogreške nekada ići u jednom, a nekada u drugom smjeru. Primjerice, ispitanik će kod jedne čestice unijeti stupanj slaganja koji je niži od stvarnog, ali će kod neke druge čestice stupanj slaganja biti viši od stvarnog. No, instrument iz praktičnih razloga ne može biti predugačak (ograničeno vrijeme, zamor ispitanika i sl.). Selekcijom čestica (tzv. *item analiza*) izbacuju se one čestice koje imaju nisku korelaciju s ostalim česticama te tako smanjuju ukupnu pouzdanost instrumenta.

U slučaju da želimo povećati ili, u praksi još češće, skratiti neki mjerni instrument, tada se pomoću tzv. Spearman-Brownove formule može utvrditi koliko će se povećati ili smanjiti pouzdanost novog instrumenta (upitnika). Ova formula glasi:

$$\rho_2 = \frac{n * \rho_1}{1+(n-1)*\rho_1} \qquad (1.3.)$$

Pri tome $\rho_2$ označava pouzdanost novog testa, $\rho_1$ pouzdanost starog testa, a $n$ predstavlja odnos veličine novog i starog testa. Primjerice, ako je novi test dvaput veći od starog (ima dvaput više čestica/pitanja), tada $n$ iznosi 2. Formula 1.3. korisna je kada želimo upotrijebiti nečiji mjerni instrumnet čija je pouzdanost poznata, odnosno utvrđena u ranijem istraživanju, ali ga zbog praktičnih razloga želimo skratiti (primjerice, ako nam je mjerni instrument previše dugačak i time

zamoran za ispitanike). Na taj način možemo utvrditi hoće li nam predviđeno smanjenje upitnika previše smanjiti pouzdanost mjerenja.

*Osjetljivost (diskriminativnost) instrumenta* odnosi se na mogućnost instrumenta da utvrdi i najmanje razlike među ispitanicima. Instrument je osjetljiv ako su odgovori na pojedine čestice (pitanja) raznoliki, tj. otprilike normalno (gaussovski) distribuirani. Čestice instrumenta u kojima svi ispitanici daju iste ili vrlo slične odgovore nisu diskriminativne i treba ih isključiti iz instrumenta. Slično tome, pitanja iz testova znanja ili sposobnosti na koja svi ispitanici ili nijedan od njih ne nudi točne odgovore nisu diskriminativna i treba ih isključiti iz testa.

***Mjerni instrument osjetljiv je ako se njime mogu utvrditi i najmanje razlike među sudionicima istraživanja u onome što se mjeri.***

Neprimjerenost mjernog instrumenta za mjerenje određenog obilježja na nekoj skupini ispitanika ponekad se naziva i *učinak stropa i poda* (Milas, 2005: 114). Uzmimo da je naša hipoteza da znanje o kulturi utječe na pohađanje kulturnih događaja. Mjerimo li znanje o kulturi pojednostavljenim instrumentom na kojemu svi ispitanici postižu maksimalan rezultat (točno odgovaraju na sva pitanja), dogodit će se učinak stropa, tj. naša nezavisna varijabla neće varirati, pa nećemo moći niti provjeriti našu hipotezu. Učinak poda dogodio bi se kad nijedan ispitanik ne bi mogao odgovoriti ni na jedno pitanje (svi postižu minimalan rezultat), a u toj situaciji također ne bismo mogli provjeriti našu hipotezu. Čak i kada se ne događaju ovako ekstremne situacije, smanjena diskriminativnost obično utječe na preciznost procjene populacijskih parametara. Primjerice, u regresijskim modelima standardna pogreška procjene regresijskih koeficijenata ovisi o varijanci prediktora. Drukčije rečeno, što je varijanca prediktora manja (rezultati su slični), to je pogreška procjene veća (Darlington i Hayes, 2017: 108).

*Objektivnost instrumenta* znači da bi rezultat trebao ovisiti o objektivnim obilježjima koja se mjere, a ne o subjektivnim obilježjima istraživača. Drukčije rečeno, rezultat na nekom mjernom instrumentu ne bi trebao ovisiti o tome tko ga je primijenio niti tko je izračunao rezultat nakon njegove primjene. Objektivnost instrumenta povećava se standardizacijom njegove primjene odnosno ujednačavanjem okolnosti u kojima se neki instrument primjenjuje. Primjerice, za rješavanje nekog testa ličnosti ili testa inteligencije svaki bi istraživač sudionicima trebao dati jednaku količinu vremena. Također, bodovanje bi trebalo napraviti pomoću jasno definiranih kriterija koji ne bi smjeli biti podložni subjektivnim procjenama i odlukama.

***Mjerni instrument objektivan je ako rezultati ne ovise o osobi koja provodi mjerenje.***

### 5.3.2. Baždarenje mjernih instrumenta

Rezultat koji ispitanik postigne na nekom mjernom instrumentu potrebno je usporediti s rezultatima koje postiže cjelokupna referentna populacija (populacija kojoj pripada ispitanik). Postupak utvrđivanja tih referencijskih standarda naziva se baždarenje instrumenta.[49] Osnovni su referencijski standardi aritmetička sredina (prosječan rezultat koji se postiže na mjernom instrumentu) i standardna devijacija (odstupanje rezultata od aritmetičke sredine). Kada je instrument baždaren, tada zapravo znamo kakav je rezultat pojedinca na tom mjernom instrumentu u usporedbi s drugim pojedincima. Ako, primjerice, neki test inteligencije ima aritmetičku sredinu 100 i standardnu devijaciju 10, tada znamo da je pojedinac koji postigne rezultat 100 prosječan, a onaj koji postigne rezultat 140 vrlo iznadprosječan.

Mjerni instrumenti moraju se povremeno ponovno baždariti budući da se rezultati na prosječnoj populaciji mijenjaju zbog promjene same populacije. Na primjer, ustanovljeno je da svaka nova generacija obično ima nešto veći prosječni kvocijent inteligencije, pa bi primjena starijih testova inteligencije na mlađe ispitanike dovela do situacije da bi većina ispitanika bila iznadprosječno inteligentna. Slično tome, instrument kojim bi se mjerio odnos među spolovima (liberalizam-konzervativizam u stavovima o spolnim ulogama), morao bi se povremeno baždariti jer se stavovi o spolnim ulogama brzo mijenjaju. Tako bi pojedinac koji je nekada u ovom pogledu bio vrlo liberalan, danas zapravo bio vrlo konzervativan.

## DODATNA LITERATURA UZ PETO POGLAVLJE

Blalock, Hubert M. (ur.) (1974). *Mesaurement in the Social Sciences. Theories and Strategies*. Dordrecht, Boston, Chicago: Aldine Publishing Company.

Ovaj zbornik radova pokriva osnove konstrukcije mjernih skala u društvenim znanostima, osobito kada su u pitanju društveni stavovi i ponašanje. Posebno je poglavlje posvećeno skalama na ordinalnim razinama mjerenja i situacijama u kojima nastaju. Knjiga se

[49] Mejovšek (2008: 75).

bavi svim fazama istraživanja, od prikupljanja podataka do analize podataka, te pitanjima vezanim za mjerenje koja se u njima pojavljuju.

Bandalos, Deborah L. (2018). *Measurement Theory and Applications for the Social Sciences*, New York: The Guilford Press.

U ovoj knjizi objašnjavaju se teorijska pitanja mjerenja, razine mjerenje i povijesni razvoj mjerenja u društvenim znanostima, ali se prikazuje i proces konstrukcije mjernih skala i prateća pitanja njihovih mjernih obilježja. Daje se i pregled eksploratorne i konfirmacijske faktorske analize te drugih složenijih modela koji se primjenjuju u provjeri metrijskih obilježja.

## PITANJA UZ PETO POGLAVLJE

1. Što je to mjerenje i na kojim se načelima zasniva?
2. Koje osnovne vrste mjerenja postoje?
3. Kako dijelimo varijable na osnovi razine mjerenja i na čemu se zasniva ta podjela?
4. Što označava načelo maksimalne razine?
5. Što su mjerne skale, a što indeksi?
6. Koje su najvažnije vrste mjernih skala?
7. Kako se konstruira Likertova skala, koje su njezine prednosti i nedostatci?
8. Zašto je Likertovu skalu potrebno uravnotežiti?
9. Kako se konstruira Thurstoneova skala, koje su njezine prednosti i nedostatci?
10. Zašto se Thurstoneova skala naziva i skala prividno jednakih intervala?
11. Kako se konstruira Guttmanova skala, koje su njezine prednosti i nedostatci?
12. Koji kriterij Guttmanova skala neizostavno mora zadovoljiti?
13. Što je to Bogardusova skala socijalne distance?
14. Kako se konstruira semantički diferencijal, koje su njegove prednosti i nedostatci?
15. Od kojih se dimenzija sastoji semantički diferencijal?
16. Na koje se vrste dijele mjerni instrumenti?
17. Koja su osnovne mjerne (metrijske) karakteristike mjernih instrumenata?
18. U čemu je razlika između valjanosti i pouzdanosti?
19. Koje vrste valjanosti postoje?
20. Koje vrste konstruktne valjanosti postoje?
21. Kako se sve određuje pouzdanost?
22. Zašto mjerni instrument mora biti diskriminativan (osjetljiv)?
23. Što je to baždarenje mjernih instrumenata?

# 6. UZORKOVANJE

## 6.1. TEMELJNI POJMOVI UZORKOVANJA

Pri istraživanju nužno je razlikovati pojmove populacije, uzorka i okvira uzorka. *Populaciju* čine svi ispitanici (ili drugi entiteti) koji su od interesa za istraživača u određenom istraživanju. Zbog ograničenosti vremena i drugih resursa, istraživanja se gotovo uvijek provode na *uzorku*, tj. dijelu ispitanika, a ne na cijeloj populaciji. *Okvir uzorka* predstavlja popis jedinica populacije iz koje se uzima uzorak, odnosno svojevrsnu operacionaliziranu definiciju populacije. Okvir uzorka često nije jednak populaciji jer nemamo popis svih jedinica iz populacije. Primjerice, pri telefonskom istraživanju kućanstava populaciju čine sva kućanstva na određenom teritoriju, no okvir uzorka čine samo ona kućanstva koja imaju telefonski priključak i čiji su telefonski brojevi poznati. Iz navedenog je vidljivo da bi se okvir uzorka i populacija trebali što više poklapati, kako bi se izbjegla greška do koje dolazi zbog nepokrivenosti jednog dijela populacije prilikom izbora uzorka.

***Uzorak je dio populacije, pri čemu se u slučaju slučajnog uzorkovanja može pouzdano izračunati pogreška procjene, odnosno interval unutar kojeg se nalazi populacijska vrijednost onoga što se mjeri.***

Budući da uzorak prema definiciji ne predstavlja cijelu populaciju, rezultat dobiven istraživanjem na uzorku u pravilu ne odgovora rezultatu populacije, nego postoji određena tzv. *standardna pogreška uzorkovanja*. Dakle, ta se pogreška ne javlja zbog lošeg izbora uzorka, nego zbog same činjenice uzorkovanja. Primjerice, želimo istražiti koliki dio populacije pročita barem jednu knjigu mjesečno te pri tome upotrijebimo jednostavno slučajno uzorkovanje. Matematička teorija vjerojatnosti nam kaže da bi se u slučaju izvlačenja velikog broja uzorka njihovi rezultati „gomilali“ oko pravog rezultata na populaciji, a ona nam i govori koliko su vjerojatna odstupanja oko toga prosjeka. Primjerice, uzmimo da smo u istraživanju koje je uključivalo 1 000 ispitanika utvrdili da njih 40% pročita barem jednu knjigu mjesečno. Sada nas zanima, budući da znamo da nismo istraživali cijelu populaciju RH, koliko ljudi u Hrvatskoj pročita barem jednu knjigu mjesečno, tj. koliko je pravi rezultat u populaciji udaljen od rezultata kojega smo dobili istraživanjem (40%). Teorija vjerojatnosti nam kaže da se standardna pogreška uzorkovanja pri istraživanju proporcija računa kao

$$SP = \sqrt{\frac{P*Q}{n}} \qquad (2.1.)$$

pri čemu „P" označava dobivenu proporciju (u našem slučaju 40%), „Q" se računa kao 1-P, a „n" označava veličinu uzorka. Ubacimo li ove brojeve u formulu, dobit ćemo da je standardna pogreška uzorka u našem slučaju oko 1,55. Budući da se, prema teoriji vjerojatnosti, može reći da se pravi rezultat populacije nalazi unutar dvije standardne pogreške,[50] tako je i pravi rezultat na našoj populaciji +/- 3,10%. Drukčije rečeno, postotak ljudi koji u RH pročitaju barem jednu knjigu mjesečno iznosi 40% +/- 3,10%, tj. nalazi se između 36,90% i 43,10%, a pouzdanost te procjene iznosi 95%. Dakle, računanjem standardne pogreške uzorka moguće je odrediti interval unutar kojeg se nalazi pravi rezultat na populaciji, tj. koliko je pravi rezultat udaljen od rezultata koji smo dobili istraživanjem.

Ako uzorak vjerno odražava populaciju iz koje je izabran, nazivamo ga *reprezentativnim uzorkom*. Drukčije rečeno, reprezentativan je onaj uzorak u kojemu je očekivana vrijednost nekog obilježja jednaka vrijednosti tog obilježja na razini populacije, tj. populacijskom parametru. Pojednostavljeno rečeno, ako ćemo izvlačeći neki uzorak i računajući neki pokazatelj (npr. aritmetičku sredinu) u najvećem broju slučajeva dobiti rezultat koji je blizu stvarne vrijednosti tog obilježja na populaciji, dok će veća odstupanja biti rijetka, tada je riječ o reprezentativnom uzorku. Primjerice, uzmimo da u hrvatskoj populaciji 40% ljudi više voli hrvatske filmove od stranih filmova. Napravimo li anketno istraživanje na tri uzorka iste veličine i dobijemo da hrvatske filmove preferira 38%, 40%, odnosno 42% anketiranih građana, tada smo istraživanje vjerojatno radili na reprezentativnim uzorcima. Naime, prosječni rezultat na tim trima uzorcima iznosi 40%, a upravo je to vrijednost populacijskog parametra. Ako vrijednost obilježja dobivenog pomoću uzoraka sustavno odstupa od populacijskog parametra, tad je riječ o nereprezentativnom, odnosno pristranom uzorku. Primjerice, ako bismo u uzorak uključili samo starije ispitanike, odnosno napravili selekcijsku grešku, tada bismo na temelju ovako izabranog uzorka vjerojatno sustavno dobivali rezultat viši od populacijskog parametra.[51] Osim navedenog shvaćanja, pojam reprezentativnosti u teoriji uzorkovanja shvaća se na još niz sličnih načina. Ponekad se uzorak smatra reprezentativnim i ako ima malu standardnu pogrešku uzorkovanja, odnosno ako su procjene koje računamo iz uzorka relativno malo raspršene, odnosno ako su precizne. Drugim riječima, prema ovom shvaćanju uzorak je reprezentativan ako nije pristran i ako se na temelju njega procjena

[50] Točnije, unutar 1,96 standardne pogreške s pouzdanošću od 95%, tj. vjerojatnošću od 5% da se rezultat nalazi izvan tog intervala.

[51] Polazimo od pretpostavke da stariji ljudi češće od mladih više vole hrvatske filmove od stranih filmova.

populacijskih parametara može napraviti precizno, odnosno uz relativno uzak interval pouzdanosti. U nešto manje obveznom shvaćanju, uzorak se smatra reprezentativnim ako se podudara s populacijom u nizu obilježja koja se smatraju važnim, primjerice ako dobro reflektira spolnu, obrazovnu, dobnu i druge populacijske strukture. U izlaganju koje slijedi, pod reprezentativnošću uzorka smatramo uzorak koji je nepristran i precizan. Drugim riječima, očekivana vrijednost pokazatelja na uzorku jednaka je vrijednosti koja postoji na populaciji, a ova procjena ima malu (t. j. što manju) standardnu pogrešku.

Ako reprezantativnost definiramo kako smo to učinili gore, tada ona ovisi o sljedećim obilježjima uzorka i uzorkovanja:

1. Veličini uzorka,
2. Varijabilnosti obilježja koje se ispituje,
3. Načinu izbora uzorka.

Veći je uzorak reprezentativniji od manjeg, ako su druge stvari jednake. Pogreška uzorka, međutim, u pravilu opada s kvadratnim korijenom veličine. To, primjerice, znači da ćemo, ako uzorak povećamo 4 puta, dobiti samo 2 puta manju pogrešku uzorka. Ova pravilnost implicira da je povećanje uzorka iznad određene kritičke točke često neracionalno. Tako npr. povećanje uzorka s 2 000 na 4 000 ispitanika donosi smanjenje pogreške uzorka na manje od 1%, što je u većini slučajeva neracionalno (preskupo). Stoga se u komercijalnim i znanstvenim istraživanjima najčešće upotrebljavaju uzorci veličine 1 000.

Ilustrirajmo odnos veličine uzorka i standardne pogreške pomoću sljedećeg primjera. Uzmimo da pokušavamo procijeniti udio koji bi neka predsjednička kandidatkinja dobila na izborima, pri čemu pretpostavimo da broj glasača s pravom glasa iznosi četiri milijuna. S obzirom na to da je ovdje riječ o procjeni udjela (proporcija), ranije navedena formula 1.4. za standardnu pogrešku iznosi:

$$\mathrm{SP} = \sqrt{\frac{P*(1-P)}{n}} \qquad (2.1.)$$

Kako smo ranije naveli, pri tome „SP“ označava standardnu pogrešku, „P“ pretpostavljeni udio ovoga kandidata u populaciji, a „n“ veličinu uzorka.

Iz formule je vidljivo da će standardna pogreška procjene (uzorkovanja) ovisiti o tome kolika je pretpostavljena proporcija glasovanja za kandidatkinju. Tako ćemo u situaciji kada kandidat ima 50% glasova imati najveću standardnu pogrešku, tj. bit će nam potreban veći uzorak za postizanje iste preciznosti procjene (tzv. intervala pouzdanosti) u odnosu na situaciju kada se udio koji dobiva kan-

didatkinja bliži 0% ili 100%. Za ilustraciju pretpostavimo da je udio koji kandidatkinja dobiva 50%, odnosno da „p" koji smo dobili u istraživanju iznosi 0,5. S obzirom na to da se proporcije distribuiraju prema standardnoj normalnoj disitribuciji, za izračun intervala pouzdanosti, tj. za dobivanje naše procjene, trebat ćemo dobivenu standardnu pogrešku pomnožiti s $\pm 1{,}96$. Navedeni koeficijent, odnosno granična z-vrijednost odnosni se na pouzdanost procjene od 95%, odnosno uz pretpostavljenu pogrešku od 5%. Drugim riječima, naša procjena intervala pouzdanosti bit će točna u 95% slučajeva. Primjerice, uzmimo da veličina uzorka iznosi n = 100, tada interval pouzdanosti iznosi:

$$IP = 0{,}5 \pm 1{,}96 * \sqrt{\frac{0{,}5*0{,}5}{100}} = 0{,}5 \pm 1{,}96 * 0{,}05 = 0{,}5 \pm 0{,}098$$

Dakle, naša procjena kaže da će kandidatkinja na izborima dobiti između 0,402 i 0,598, odnosno između 40,2% i 59,8% glasova na izborima. Nastavimo li dalje s istim izračunom mijenjajući veličinu uzorka, dobit ćemo sljedeću tablicu:

*Tablica 23. Promjena intervala pouzdanosti s povećanjem veličine uzorka*

| **Veličina uzorka** | **Interval pouzdanosti (naša procjena) u %** |
|---|---|
| 100 | 40,2 do 59,8 |
| 200 | 43,1 do 56,9 |
| 400 | 45,1 do 54,9 |
| 800 | 46,5 do 53,5 |
| 1500 | 47,5 do 52,5 |
| 1600 | 47,6 do 52,4 |
| 3000 | 48,2 do 51,8 |

Uočavamo da se procjena povećavanjem uzorka prvo izrazito poboljšava, a da naknadna povećanja uzorka u apsolutnom smislu donose sve manji dobitak. Primjerice, povećanjem uzorka od samo 100 (sa 100 na 200) dobili smo poboljšanje procjene od ±9,8% na ±6,9% (čak 2,9%). Povećanje istog apsolutnog iznosa u situaciji kada uzorak povećavamo s 1500 na 1600 donijelo nam je poboljšanje procjene od samo 0,1%. Stoga se i može zaključiti da u praktičnom smislu preveliki uzorci donose malo poboljšanje preciznosti, a istovremeno izazivaju velike troškove planiranja i provedbe istraživanja, odnosno prikupljanja podataka.

***Preciznost se procjene u relativnom smislu smanjuje s povećanjem uzorka. Stoga preveliki uzorci nisu racionalni kada su u pitanju omjer troškova i preciznost procjene.***

Još je važno napomenuti da pogreška uzorka u znatnoj mjeri ne ovisi o veličini populacije, osobito kad je riječ o većim populacijama, što je najčešće i slučaj i u znanstvenim i u komercijalnim istraživanjima. Tako je npr. uzorak veličine 1 000 gotovo jednako precizan neovisno o tome istražujemo li stanovništvo Osijeka ili Zagreba, iako je u potonjem slučaju populacija veća. Drukčije rečeno, sa stajališta uzorkovanja praktično nije važno jesmo li ispitali 2% ili 10% ukupne populacije, važna je samo apsolutna veličina uzorka. Ovo pravilo ilustrirano je sljedećom tablicom,[52] a u njoj su prikazani veličina populacije i potrebna veličina uzorka ako se želi postići da maksimalna pogreška bude ± 5%, a vjerojatnost točnog zaključka 95%.

*Tablica 24. Odnos veličine populacije i potrebne veličine uzorka*

| **Veličina populacije** | **Potrebna veličina uzorka** |
|---|---|
| 50 | 44 |
| 100 | 79 |
| 500 | 217 |
| 5 000 | 357 |
| 50 000 | 381 |
| 100 000 | 383 |
| 1 000 000 | 384 |

Izvor: Cohen i sur., 2007: 95.

Valja napomenuti da neki autori (npr. Coolican, 1994.) smatraju da veći uzorci u nekim slučajevima mogu biti i otežavajuća okolnost. Naime, ustanovljavanje razlike (efekta) može istraživača odvući od detektiranja interakcija između varijabli ili popravljanja istraživačkog nacrta putem uključivanja trećih varijabli koje iskrivljuju povezanost između nezavisne i zavisne varijable. Iako dovoljno veliki uzorak u nekim situacijama doista može omogućiti detektiranje razlika i time odvratiti nedovoljno promišljenog istraživača od poboljšanja istraživačkog nacrta i operacionalizacije te kvalitetnog planiranja uzorkovanja, može se reći da se u slučaju kvalitetnog istraživačkog nacrta i dobro promišljenog teorijskog okvira istraživanja veći uzorak ipak u pravilu može smatrati prednošću, a ne nedostatkom.

U slučaju da je pojava varijabilnija (ispitanici su međusobno različiti), reprezentativnost uzorka je manja nego u slučaju da je pojava manje varijabilna (svi ispitanici imaju sličan rezultat na nekoj varijabli). Npr. u teoretskoj situaciji kad bi

[52] Modificirano prema Cohen i sur. (2007: 95).

svi ljudi u populaciji imali jednak stupanj obrazovanja, bilo bi dovoljno ispitati samo jednog ispitanika kako bismo procijenili stupanj obrazovanja cijele populacije. Iako postoji jasan odnos između varijabilnosti populacije i potrebne veličine uzorka, u praksi je varijabilnost populacije rijetko poznata i ne može poslužiti za planiranje veličine uzorka. No u nekim je situacijama to ipak moguće. Primjerice, pretpostavimo da želimo utvrditi proporciju pušača u Republici Hrvatskoj te da želimo da nam ta procjena bude najviše za 2% udaljena od stvarne populacije pušača u populaciji uz 95% pouzdanosti ovakvoga zaključka. Na temelju ranije navedene formule 2.1. za procjenu standardne pogreške proporcije, a koja glasi:

$$\mathrm{SP} = \sqrt{\frac{P*(1-P)}{n}} \tag{2.1.}$$

možemo zaključiti da je varijacija obilježja u populaciji najveća kada imamo 50% pušača i 50% nepušača, s obzirom na to da će tada umnožak $P*(1-P)$ biti najveći. Iz navedenog možemo izračunati potrebnu veličinu uzorka koja predstavlja najgori mogući scenarij, odnosno situaciju u kojoj je standardna pogreška najveća. Iz formule za testiranje proporcije, možemo izlučiti potrebnu veličini uzorka:

$$Z_{0,95} = \frac{P-\hat{P}}{\sqrt{\frac{\hat{P}*(1-\hat{P})}{n}}} \tag{2.2.}$$

$$Z_{0,95}{}^2 = \frac{(P-\hat{P})^2}{\frac{\hat{P}*(1-\hat{P})}{n}} \tag{2.3.}$$

$$\frac{\hat{P}*(1-\hat{P})}{n} = \frac{(P-\hat{P})^2}{Z_{0,95}{}^2} \tag{2.4.}$$

$$n = \frac{Z_{0,95}{}^2}{(P-\hat{P})^2} * \hat{P} * (1-\hat{P}) \tag{2.5.}$$

U našem slučaju potrebna veličina uzorka iznosit će:

$$n = \frac{1{,}96^2}{0{,}02^2} * 0{,}5 * 0{,}5 = 2401$$

Manja varijacija obilježja u populaciji, pri testiranju proporcija podrazumijeva situacije kada je populacijska proporcija udaljenija od 50%, što će dovesti do manje potrebne veličine uzorka. Ako proporcija pušača u populaciji iznosi npr. 20%, tada se potrebna veličina uzorka može dobiti iz formule 1.5. i iznosi 1537.

Uzorci se u ovisnosti o tome kako se biraju jedinice uzorka mogu podijeliti na:

1. Slučajne (probabilističke),
2. Neslučajne (neprobabilističke).

U *slučajnim uzorcima* izbor jedinica ovisi o slučajnosti, a svaka jedinica populacije ima poznatu, najčešće jednaku mogućnost izbora u uzorak. Drugim riječima,

uzorak je slučajan ako svaka jedinica ima jednaku vjerojatnost ulaska u uzorak, a ako to nije slučaj, tada istraživač zna kolike su vjerojatnosti ulaska u uzorak za pojedinu jedinicu. Nejednaka se vjerojatnost može dogoditi iz niza razloga. Ponekad sâm istraživač donese odluku da će neke jedinice biti nadzastupljene (vidjeti u daljnjem tekstu opis neproporcionalne stratifikacije) te nejednaku vjerojatnost ispravi ponderiranjem podataka. Drugim riječima, u nekim slučajevima nejednaka vjerojatnost ugrađena je u način izbora uzorka. Primjerice, ako u nekom istraživanju anketiramo samo jednu slučajno izabranu osobu iz svakog kućanstva koje je ušlo u uzorak, tada će pojedinci koji žive u kućanstvima s većim brojem članova imati manju vjerojatnost ulaska u uzorak. Primjerice, osoba koja živi s još dva člana kućanstva ima 33,33% šansi ući u uzorak nakon što je njezino kućanstvo ušlo u uzorak, a osoba koja živi s još jednom osobom ima 50% šansi. No ove su vjerojatnosti dakle poznate te se također mogu ispraviti ponderiranjem (utežavanjem, eng. *weighting*) podataka. Važno je naglasiti da je upravo poznata/jednaka vjerojatnost izbora jedinica ključna za definiciju slučajnog uzorka. Naime, često se susreće krivo mišljenje prema kojemu je slučajan uzorak onaj uzorak gdje istraživač odlučuje tko ulazi u uzorak, a ne da se to određuje na nekakav nasumičan način. Primjerice, uzorak nasumično izabranih studenata na fakultetskom hodniku ne može se smatrati slučajnim uzorkom, iako se do njega došlo na „nasumičan" način, bez želje da se određene skupine studenata favoriziraju ili diskriminiraju. Međutim, s obzirom na to da uzorak nije biran s popisa svih studenata, sasvim je realno da će u njega ući oni studenti koji češće dolaze na fakultet.

***Osnovna razlika između slučajnih i neslučajnih uzoraka krije se u tome je li vjerojatnost izbora pojedinog člana populacije unaprijed određena i poznata (slučajni uzorci) ili je navedena vjerojatnost nepoznata (neslučajni uzorci).***

Slučajne bi uzorke trebalo koristiti kad god je moguće i dati im prednost u odnosu na neslučajne uzorke. Naime, reprezentativnost uzorka obično se povećava ako u istraživanju koristimo slučajan uzorak, budući da slučajno biranje uzorka smanjuje moguće pristranosti. Npr., novinarska anketa ljudi na ulici, budući da ne upotrebljava slučajan uzorak, češće će ispitati mišljenja učenika/studenata, umirovljenika i drugih skupina populacije koje u tom trenutku nisu na radnom mjestu. Nadalje, statističko je zaključivanje zasnovano na slučajnim uzorcima. Strogo govoreći, generalizaciju s uzorka na populaciju moguće je napraviti samo ako je uzorak slučajan jer je jedino u tom slučaju moguće pouzdano izračunati statističku pogrešku, odnosno vjerojatnost odstupanja populacijskog parametra

od izračunatog pokazatelja. Povećavanjem veličine uzorka, smanjuju se i margine pogreške. U neslučajnim uzorcima može postojati sustavna pogreška koja ne omogućuje statističku generalizaciju s uzorka na populaciju, što znači i da veličina uzorka ne poboljšava procjenu. Primjerice, mnoge televizijske emisije tijekom emitiranja organiziraju televizijske „referendume" u kojima se gledatelji mogu javiti telefonski ili SMS-om i dati svoje mišljenje ili stav o nekom pitanju. Rezultati koji se dobiju nisu temeljeni na slučajnom uzorku jer je vjerojatnije da će na televizijskom referendumu glasovati gledatelji koji su zainteresiraniji i motivirani za davanje svojega stava i, naravno, ljudi koji gledaju navedenu emisiju. Stoga nije moguće sa sigurnošću pretpostaviti da je ovako selekcionirana skupina reprezentativna skupina u odnosu na cijelu populaciju. Povećavanje veličine uzorka u neslučajnim uzorcima također ne jamči da će uzorak postati reprezentativan jer veličina uzorka ne mora ukloniti sustavnu pogrešku. Primjerice, pokazalo se da mnogi televizijski referendumi ne odražavaju stvarno javno mnijenje iako uključuju veliki broj sudionika (Vujević-Hećimović i Vujević, 2003). Najpoznatiji povijesni slučaj pogreške prilikom korištenja selekcioniranog uzorka predstavlja američki časopis *Literary Digest*. Naime, taj je časopis slanjem anketnih upitnika građanima koji imaju automobile i telefonske priključke u nekoliko navrata prije izbora 1936. godine točno prognozirao pobjednika američkih predsjedničkih izbora. Međutim, te je godine na izborima prognozirao pobjedu republikanskog kandidata Alfa Landona, a pobijedio je premoćno demokratski kandidat Franklin D. Roosevelt. Unatoč uzorku koji je brojao čak 10 milijuna ljudi, okvir uzorka bio je neadekvatan jer je isključivao ljude bez automobila i telefona, a ti su pojedinci češće glasali za Roosevelta (Neuman, 2004: 143). Na engleskom govornom području danas se ovakav tip istraživanja javnog mnijenja, koji ne vodi računa o reprezentativnosti uzorkovanja, naziva *straw poll*,[53] a može biti koristan jedino ako ga uzimamo u obzir kao grubu orijentaciju koja ne može poslužiti za precizne prognoze.

Ovo nikako ne znači da je korištenje neslučajnih uzoraka uvijek loše i da se ničim ne može opravdati. Naime, neslučajni uzorci mogu biti logičniji izbor ako je riječ o pilot istraživanju, ako se tolerira veća pogreška ili ako bi korištenje slučajnog uzorka donijelo troškove koji se ne mogu opravdati važnošću dobivenih podataka. Ako je riječ o pilot istraživanju, u kojemu želimo steći neke osnovne uvide u problemu koji kasnije želimo istražiti pomoću šireg istraživanja, tada je često opravdano upotrijebiti neslučajni uzorak. Uzmimo za primjer i situaciju u kojoj neka tvrtka želi utvrditi kako njezini potrošači gledaju na njezine proizvode

[53] Izraz dolazi od običaja bacanja slame u zrak kako bi se vidjelo odakle vjetar puše.

(primjerice, zašto ih kupuju ili ne kupuju). Ako je riječ o maloj tvrtki i proizvodu koji ne zauzima veliki udjel na tržištu, može biti logičnije koristiti uzorak stanovnika nekog grada, umjesto da se uzima uzorak stanovnika cijele države. Naime, iako postoji vjerojatnost da stanovnici tog grada ne predstavljaju reprezentativan uzorak kupaca tog proizvoda, upotreba uzorka na razini cijele države znatno poskupljuje istraživanje.

## 6.2. OSNOVNE VRSTE UZORAKA

Kako je ranije navedeno, uzorci se mogu podijeliti na slučajne (probabilističke) i neslučajne (neprobabilističke). Kada su u pitanju slučajni uzorci, postoji cijeli niz mogućih uzoraka, kao i njihovih međusobnih kombinacija. Kao najčešći se mogu izdvojiti:

1. Jednostavni slučajni uzorak,
2. Sistematski (sustavni) uzorak,
3. Stratificirani uzorak,
4. Klaster uzorak,
5. Stratificirani višeetapni uzorak.

*Jednostavni slučajni uzorak* bira se tako da se s popisa svih članova populacije, tj. okvira uzorka, nekom od metoda izabere potreban broj članova uzorka. Npr., ako imena svih ispitanika iz populacije napišemo na komade papira i zatim slučajnim odabirom izdvojimo 100 papira, tada smo izvukli slučajan uzorak veličine 100. U praksi se danas za izvlačenje slučajnog uzorka najčešće koriste generatori slučajnih brojeva, tj. brojevi se ne izvlače fizički (kao u gore navedenom slučaju izvlačenja papira).

*Sistematski uzorak* koristi se u situacijama kad imamo poredak svih ispitanika, tj. njihov popis. Primjer je izvlačenje svake desete osobe iz telefonskog imenika. U praksi se na temelju veličine populacije i potrebne veličine uzorka određuje tzv. korak uzorka. Tako, ako npr. između 100 ljudi želimo izvući uzorak od 10 ljudi, tada ćemo u uzorak izabrati svaku desetu osobu. Od koje ćemo osobe krenuti, odlučuje se slučajnim izborom. Iz načina izbora vidljivo je da će članovi populacije koji su međusobno bliži na popisu imati manju zajedničku vjerojatnost ulaska u uzorak, odnosno da svi uzorci nisu jednako mogući, kao što je to slučaj u jednostavnom slučajnom uzorkovanju. Unatoč tome, sistematski uzorak predstavlja nepristrani uzorak, odnosno očekivana vrijednost procjena jednaka je oče-

kivanoj vrijednosti populacije. Dapače, sistematski uzorak može biti precizniji od jednostavnog slučajnog uzorka, odnosno procjene dobivene na temelju njega mogu imati manju varijancu. To se događa u situacijama kada su elementi populacije poredani tako da se veličina varijable koja se nastoji procijeniti smanjuje ili povećava s mjestom na popisu. Tako bismo efikasnije procijenili plaću zaposlenika u nekoj velikoj tvrtki na temlju sistematskog uzorka uzetog s popisa na kojem su zaposlenici poredani od onoga s najmanjom plaćom na početku popisa, do onoga s najvećom plaćom na kraju popisa. Možemo uzeti i primjer procjene broja putnika u autobusu na nekoj autobusnoj liniji. Ako pretpostavimo da postoje velike varijacije u broju putnika u odnosu na doba dana, ako upotrijebimo sistematski uzorak koji bismo izvukli s popisa na kojem bi prvo bili navedeni svi intervali u jednom tjednu, tada bi naša procjena bila preciznija, odnosno mogli bismo broj putnika procijeniti s užim intervalom pouzdanosti. Takav bi popis bio sastavljen tako da bismo prvo uzeli autobus koji vozi u šest sati ujutro svih dana u tjednu (on bi imao redni broj jedan do sedam na ovakvom popisu), nakon toga autobus koji vozi u sedam sati ujutro po svim danima u tjednu (on bi imao redne brojeve od osam do četrnaest na ovom popisu), itd. (za detalje i konkretan numerički primjer, vidjeti Bethlehem, 2009: 80-82)

Pri izvlačenju sistematskog uzorka treba voditi računa da se korak uzorka ne poklapa s nekom pravilnošću unutar populacije. Npr. pri istraživanju u nekoj tvrtki koja se sastoji od odjela od po 10 zaposlenika, korak uzorka veličine 10 mogao bi nam u uzorak donijeti samo voditelje odjela (ukoliko su njihova imena navedena na početku popisa članova odjela). Ili npr. biranjem svakog sedmog broja novina za analizu sadržaja dobili bismo samo novine koje izlaze isključivo određenim danom. U tom bismo slučaju dobili uzorak koji ne bi bio pristran jer bi očekivana vrijednost uzoraka bila jednaka očekivanoj vrijednosti populacije, a vrijednost na uzorku ovisila bi o slučajnom izboru koraka uzorkovanja. No istovremeno bi efikasnost procjenjivača bila manja od situacije jednostavnog slučajnog uzorka. U našem slučaju procjena bi jako ovisila o tome jesmo li slučajnim izborom u uzorak uvrstili samo voditelje odjela.

*Stratificirani uzorak* određuje se izborom stratuma (slojeva) neke populacije u ovisnosti koja se obilježja populacije smatraju važnim, te se u uzorak najčešće bira upravo onaj udjel pojedinog stratuma kakav je i udjel tog stratuma u ukupnoj populaciji. Uzmimo da procjenjujemo koliko ljudi u populaciji čita knjige te da, na temelju dosadašnjih istraživanja, znamo da se muškarci i žene razlikuju u čitanju knjiga. Kako bi povećali reprezentativnost uzorka, tada ćemo u naš uzorak izabrati omjer žena i muškaraca upravo onakav kakav postoji u populaciji (otprilike

50% jednih i 50% drugih). Za ovakav bi se uzorak reklo da je stratificiran prema spolu. Važno je napomenuti da se izbor ispitanika u stratume mora napraviti na slučajan način. Stratificirati se može i prema više varijabli. Primjerice, ako uzorak stratificiramo prema spolu i obrazovanju, to znači da ćemo u uzorku imati odgovarajuće udjele osoba određenog spola i stupnja obrazovanja. Uzmimo da radimo proporcionalnu stratifikaciju te da udio muškaraca sa završenom srednjom školom u ukupnoj populaciji iznosi 20%. Tada bismo u naš uzorak uzeli upravo ovaj udio muškaraca sa završenom srednjom školom (npr. 200 ako veličina uzorka iznosi 1000). Za stratifikaciju prema više varijabli potrebni su nam udjeli ovako dobivenih kombiniranih skupina u populaciji.

Kako je navedeno u početnoj definiciji, stratificirani uzorak najčešće znači proporcionalni izbor određenih stratuma u uzorak, no to nipošto uvijek ne mora biti tako. Sa stajališta teorije uzorkovanja, veličina stratuma trebala bi ovisiti o varijabilnosti obilježja koje se istražuje unutar pojedinog stratuma (vidjeti npr. Bethlehem, 2009). Primjerice, ako su muškarci između sebe mnogo različitiji prema čitanju knjiga (npr. neki ih čitaju jako često, a neki nikada), a žene su mnogo manje unutar sebe različite u tom pogledu, tada bi stratificirani uzorak trebalo konstruirati tako da uključuje veći udio muškaraca u usporedbi s njihovim udjelom u populaciji. Drugim riječima, stratum muškaraca bio bi nadzastupljen, a stratum žena podzastupljen.

U skladu s navedenim, stratificirani uzorci mogu se podijeliti na:

- Proporcionalne
- Neproporcionalne

U proporcionalnom uzorku udjeli stratuma iznose upravo onoliko koliko iznose u ukupnoj populaciji. Dok u neproporcionalnom uzorku namjerno povećamo udio nekih stratuma, najčešće kako bismo omogućili preciznije statističko zaključivanje zbog manjeg udjela pojedinih stratuma u populaciji, ili zbog veće varijabilnosti obilježja koje istražujemo u nekom stratumu. Npr., ako imamo uzorak od 500 ispitanika i znamo da u populaciji ima svega 10% visokoobrazovanih osoba, u proporcionalnom stratificiranom uzorku izabrali bismo samo 50 visokoobrazovanih ispitanika. S obzirom na to da je to relativno mali broj za zaključivanje o visokoobrazovanim ispitanicima, možemo ga povećati npr. na 100, čime naš uzorak postaje neproporcionalan. Pri analizi podataka obavlja se statističko ponderiranje podataka (tzv. ponderiranje prema dizajnu) jer smo namjerno nadreprezentirali jednu skupinu (u ovome slučaju visokoobrazovane osobe).

Stratificirani uzorak povećava preciznost procjene populacijskih parametara, a dobitak na preciznosti povećava se s važnošću obilježja koje smo uzeli kao temelj stratifikacije. Ako je npr. spol izrazito povezan s čitanjem knjige, a muškarci i žene unutar sebe ne razlikuju se puno u čitanju knjiga, tada će dobitak na preciznosti procjene biti izrazito velik, a taj se dobitak može i točno izračunati. Prednosti stratificiranog uzorka u odnosu na jednostavni slučajni uzorak mogu se dokazivati i na eksperimentalan način. Tako su Lacy i sur. (1998.) analizom sadržaja novinskih reklamnih oglasa u novinskim magazinima pokazali da stratificirani uzorak veličine 12 (svaki mjesec jedan broj) donosi bolje rezultate od jednostavnog slučajnog uzorka veličine 16 (16 slučajno izabranih brojeva). Takvo poboljšanje vjerojatno je rezultat sezonske distribucije oglašavanja, tj. činjenice da se broj i vrsta oglasa mijenjaju tijekom godine. Analiziranje jednog oglasa svaki mjesec uspijeva zato uzeti u obzir ove varijacije, dok se u slučaju jednostavnog slučajnog uzorka može dogoditi da u uzorak uđe većina brojeva magazina iz samo jednog dijela godine, čime će i rezultati postati manje valjani.

***Stratificirani uzorak smanjit će standardnu pogrešku uzorkovanja u odnosu na jednostavni slučajni uzorak u situacijama kada se izabrani stratumi između sebe razlikuju u varijabli koja se istražuje/mjeri.***

Sve navedeno implicira da formule koje izračunavamo za procjenu populacijskih parametara te standardnu pogrešku procjene pri jednostavnom slučajnom uzorkovanju ne vrijede za stratificirane uzorke.[54] Tako formula za nepristranu procjenu populacijske aritmetičke sredine više nije jednostavna aritmetička sredina uzorka, kao što je to u slučaju jednostavnog slučajnog uzorka, nego u stratificiranom uzorku glasi:

$$\bar{y} = \sum_{s=1}^{M} \frac{N_s}{N} * \bar{y}_s \qquad (2.6.)$$

U navedenoj formuli „$N_s$“ predstavlja veličinu stratuma s (ukupno imamo M stratuma), „$N$“ veličinu populacije, a „$\bar{y}_s$“ aritmetičku sredinu izračunanu na stratumu s. Dakle, izračunamo aritmetičke sredine svih stratuma, svaku od njih pomnožimo s brojem koji je omjer veličine stratuma u populaciji i i ukupne populacije te na kraju zbrojimo ovako dobivene brojeve.

Isto tako, formula za standardnu pogrešku procjene dobivene pomoću stratificiranog uzorka neće biti ista kao u jednostavnog slučajnog uzorka te će glasiti:

[54] U analizi podataka dobivenih stratifikacijom moraju se, stoga, koristiti posebni moduli u softverima za statističku obradu. Primjerice, u SPSS-u riječ je o Complex Survey Data modulu.

$$SP = \frac{1}{N} * \sqrt{\sum_{s=1}^{M} \left( {N_s}^2 * \left(1 - \frac{n_s}{N_s}\right) * \frac{{S_s}^2}{n_s} \right.} \quad (2.7.)$$

Ovdje „$n_s$“ predstavlja veličinu uzorka iz stratuma s,„${S_s}^2$“ varijancu unutar stratuma s, a značenje ostalih simbola ranije je objašnjeno. Iz formule možemo vidjeti da će standardna pogreška biti manja, a procjena time preciznija, ako imamo manju varijancu unutar stratuma (${S_s}^2$), tj. ako su stratumi unutar sebe homogeni.

Kad je riječ o *klaster uzorku*, populacija se također podijeli na nekoliko klastera, no pretpostavlja se da su oni slični i izabire se samo jedan dio njih. U prvom koraku slučajnim se izborom biraju klasteri, a zatim se iz klastera također slučajnim izborom biraju jedinice uzorka[55] ili u istraživanje ulaze sve jedinice iz klastera. Pri tome vjerojatnost biranja klastera u uzorak najčešće ovisi o njihovoj veličini, iako je moguće izabrati i klaster uzorak u kojem će sve primarne jedinice imati jednaku vjerojatnost ulaska u uzorak. Na primjer, klaster uzorak stanovništva Slavonije i Baranje napravio bi se tako da prvo izaberemo određeni broj naselja (npr. 30), pri čemu vjerojatnost izbora naselja ovisi o njegovoj veličini (veća naselja imaju proporcionalno veću mogućnost biti izabrana u uzorak). Nakon toga bismo iz svakog naselja, opet na slučajan način, izabrali jednak broj ispitanika. Na ovaj se način osigurava da svaki ispitanik ima jednaku šansu izbora u uzorak, a upravo je ovakva vrsta klaster uzorka najčešće upotrebljavana u praksi.

I pri klaster uzorkovanju za nepristranu procjenu aritmetičke sredine te izračun standardne pogreške moraju se upotrijebiti drukčije formule nego u jednostavnom slučajnom uzorkovanju. Tako procjena populacijske aritmetičke sredine u slučaju da imamo „m“ klastera od kojih svaki ima „r“ članova glasi:

$$\bar{y} = \frac{1}{N} * \frac{M}{m} * \sum_{i=1}^{m} \sum_{j=1}^{r} y_{ij} \quad (2.8.)$$

Pri tome je „N“ veličina populacije, „M“ ukupan broj klastera u populaciji, „m“ veličina uzorka klastera, tj. broj izabranih klastera iz populacije. Iako formula može izgledati složeno, zapravo je potrebno zbrojiti sve elemente uzorka te ih pomnožiti s izrazom $\frac{1}{N} * \frac{M}{m}$.

Formula za standardnu pogrešku glasi:

$$SP = \sqrt{\left(\frac{M}{N}\right)^2 * \frac{1}{m} * \left(1 - \frac{m}{M}\right) * {s_t}^2} \quad (2.9.)$$

Izraz „${s_t}^2$“ označava varijancu aritmetičkih sredina između klastera, odnosno izražava različitost onoga što se mjeri između pojedinih klastera. Primjerice, ra-

[55] Tada se ovaj uzorak obično naziva višeetapnim ili višestupanjskim.

čunamo li iznos prosječnog dohotka u 20 gradova koje smo izabrali kao klastere iz populacije 150 gadova i ako su dohotci u tim gradovima međusobno vrlo slični, tada će iznos $s_t{}^2$ biti mali. Iz navedenog je jasno da međusobna sličnost klastera povećava preciznost procjene, a različitost ju smanjuje. Isto tako, vidimo da će standardna pogreška biti to manja što u istraživanju upotrijebimo veći broj klastera u apsolutnom smislu (veći „$\frac{m}{M}$“ smanjuje ukupni izraz pod korijenom), kao i u relativnom smislu (veći „ smanjuje ukupni izraz pod korijenom). Nadalje, poželjno je i da je ukupni broj klastera u populaciji što manji u odnosu na ukupnu veličinu populacije (manji „$\frac{M}{N}$“smanjuje ukupni izraz pod korijenom).

Klaster uzorak znatno smanjuje troškove istraživanja u usporedbi sa slučajnim uzorkom, te je stoga čest u terenskim istraživanjima. U gornjem primjeru tako moramo otići u samo 30 naselja, dok bi u slučaju jednostavnog slučajnog uzorka u naš uzorak vrlo vjerojatno ušli ispitanici iz mnogo većeg broja naselja. Preciznost klaster uzorka smanjuje se ako su klasteri međusobno različiti, a unutar sebe homogeni, a moguće je izračunati smanjenje ove preciznosti, tj. smanjenje efektivne veličine uzorka u odnosu na jednostavni slučajni uzorak. Naime, formula za učinak dizajna uzorkovanja (klaster učinak), tj. smanjenje preciznosti procjene do kojeg dolazi primjenom klaster uzorkovanja glasi (Bickel, 2007):

$$D_{eff} = 1 + (n - 1) * ICC \qquad (2.10.)$$

pri čemu su $D_{eff}$= učinak dizajna uzorka (tj. klaster uzorkovanja), n = prosječna veličina uzorka po klasteru, a ICC = koeficijent intraklasne korelacije. Intraklasna korelacija odnosi se na sličnost grupa, u ovom slučaju klastera u uzorku, a računa se tako da se varijabilnost između grupa podijeli s ukupnom varijabilnošću, a koju čine varijabilnost između grupa i varijabilnost unutar grupa, odnosno zbroj ovih dviju varijabilnosti. Iz definicije je vidljivo da će ICC biti to veći kada varijabilnost između grupa čini veći dio ukupne varijabilnosti, odnosno kada su grupe međusobno različite, a unutar sebe slične. Primjerice, pretpostavimo da smo u istraživanju u kojemu želimo procijeniti samopercepciju zdravlja u populaciji napravili uzorak koji čine 10 klastera (npr. naselja) i da smo iz svakog naselja uzeli po 100 članova uzorka. Uzmimo u obzir i to da je sličnost članova uzorka iz pojedinog naselja relativno velika, tj. da ICC iznosi 0,5. Tada učinak dizajna ($D_{eff}$) iznosi 1 + (100 - 1) ∗ 0,5 = 50,5. Drugim riječima, varijabilnost (pogreška naše procjene) je povećana za oko 50 puta. Iz ovoga broja možemo izračunati i efektivnu veličinu uzorka, a dobijemo je tako da veličinu uzorka podijelimo s učinkom dizajna. U našem slučaju ukupna veličina uzorka iznosi 1 000 ispitanika, ali efektivna veličina uzorka iznosi 1 000/50,5, odnosno svega oko 20 ispitanika! Slijedom toga, ako prilikom analize podataka zanemarimo da smo

upotrijebili klaster uzorak ovakvih obilježja i podatke analiziramo kao da imamo jednostavni slučajni uzorak, lako je moguće da ćemo doći do posve krivih zaključaka. Stoga je ovakve podatke potrebno analizirati pomoću posebnih statističkih modela (tzv. višerazinskog modeliranja) koji uzimaju u obzir stvarnu veličinu pogreške procjene.

Na temelju opisanog, ako klaster uzorak usporedimo sa stratificiranim, vidimo da je u stratificiranom uzorku dobro postići stratume koji su unutar sebe homogeni, a između sebe heterogeni, a u klaster uzorkovanju slučaj je suprotan. Naime, u klaster uzorkovanju poželjno je da klasteri unutar sebe budu heterogeni, a između sebe homogeni.

*Stratificirani višeetapni uzorak* predstavlja kombinaciju stratificiranog i klaster uzorka koji se primjenjuju u više koraka, odnosno na jedinice različite razine. Ovaj je tip uzorkovanja osobito čest u terenskim istraživanjima. Primjerice, ako istražujemo političke preferencije na razini jedne države, cijela država se može podijeliti u regije iz kojih se uzima broj ispitanika proporcionalan veličini regije. Drukčije rečeno, uzorak se stratificira prema regijama. Na taj način osiguravamo da ćemo dobiti dovoljan broj ispitanika iz svake regije, odnosno da ćemo moći procijeniti parametre (u ovom slučaju političke preferencije) u svakoj regiji, a stratifikacijom dobijemo i mogućnost preciznije procjene parametara na razini populacije (Lohr, 2008: 109-110). Nakon toga se može primijeniti klaster uzorak, i to u više koraka. Primjerice, unutar svake regije možemo izabrati određena naselja, pri čemu je izbor proporcionalan njihovoj veličini. Iz svakog naselja slučajnim izborom biramo isti broj kućanstava, a nakon toga anketiramo sve ispitanike u izabranom kućanstvu.

Osim slučajnih uzoraka koje smo naveli, spominjemo i tzv. *uzorak s nejednakom vjerojatnošću izbora* (eng. *unequal probability sample*), koji se može smatrati ili posebnom vrstom uzorka ili samo posebnim slučajem stratificiranog uzorka. Naime, u ovoj vrsti uzorka vjerojatnost izbora u uzorak ovisi od veličine ciljne varijable, odnosno varijable koja se želi procijeniti. S obzirom na to da nemamo njezinu veličinu, vjerojatnost izbora u uzorak ovisit će o nekoj pomoćnoj varijabli za koju pretpostavljamo da je povezana s našom ciljnom varijablom. Razlog proizlazi iz statističke teorije uzorkovanja koja kaže da je preciznost uzorka veća ako vjerojatnost izbora elementa u uzorka ovisi o veličini ciljne varijable. Bethlehem (2009: 83) daje primjer istraživanja prosječnog broja krađa u trgovinama. U tom bi slučaju bilo opravdano nadzastupiti površinom veće trgovine jer možemo pretpostaviti da se u njima događa više krađa. Nakon što se prikupe podatci, potrebno je napraviti ponderiranje podataka. Primjerice ako

su manje trgovine u uzorku bile zastupljene sa samo polovicom svoga udjela u populaciji, treba im dati ponder dva, odnosno procjenu prosječnog broja krađa u manjim trgovinama pomnožiti s dva. Ako su velike trgovine bile dva puta nadzastupljene, tada njihov ponder iznosi 0,5. Na ovaj se način dobije manja varijacija u procjenama. Drugim riječima, u većem broju istraživanja procjene broja krađa bile bi međusobno sličnije nego ako bismo svaki put upotrijebili jednostavni slučajni uzorak. Izbor proporcionalan veličini pomoćne varijable u praksi se najčešće provodi pomoću tzv. kumulativne sheme ili pomoću tzv. Lahirijeve sheme (vidjeti Bethlehem, 2009: 84-86). U prvom slučaju napravimo intervale koji su proporcionalni veličini pomoćne varijable za određeni element populacije te izvlačimo slučajni broj $u$ od 0 do 1 (interval ne uključuje broj 1). Uzorak ulazi element u čijem se intervalu nalazi broj $u * T_N$, pri čemu je $T_N$ ukupna širina intervala. Primjerice, uzmimo da imamo tri elementa populacije koji imaju vrijednosti pomoćnih varijabli 10, 50 i 100, u našem ranijem primjeru to bi mogla biti veličina trgovina u kvadratnim metrima, te da želimo napraviti izbor porporcionalan njihovoj veličini. Tada bi njihovi intervali iznosili 0-10, 10-60 i 60-160. Ako bismo slučajnim izborom izvukli broj 0,5, tada bi u uzorak ušla najveća trgovina jer je $0,5 * 160 = 80$, taj se broj nalazi u intervalu treće trgovine. Lahirijeva shema upotrebljava se kada ne znamo koliko je najveća veličina pomoćne varijable, nego ju jednostavno pretpostavimo. Uzmimo da u našem slučaju pretpostavimo da je najveća veličina 500 kvadratnih metara. Tada bismo postupili na sljedeći način. Slučajnim izborom izabrali bismo jednu trgovinu i zabilježili njezinu veličinu. Krenimo od pretpostavke da ta veličina iznosi 100 kvadratnih metara. Tada bismo opet slučajnim izborom izvukli jedan broj između 1 i 500. Ako je taj broj veći od veličine trgovine koju smo izvukli, tada trgovina ne ulazi u uzorak, u suprotnom trgovina postaje dio uzorka. Lahirijeva shema možda na prvi pogled izgleda neobično, ali se odmah može vidjeti da će na ovaj način elementi populacije s manjim rezultatom na pomoćnoj varijabli imati manju vjerojatnost ulaska u uzorak.[56]

Kako je napomenuto, neslučajni su uzorci oni uzorci u kojima je nemoguće pouzdano utvrditi vjerojatnost izbora pojedinog člana populacije u uzorak, što posljedično onemogućava i pouzdanu procjenu populacijskih parametara. No neslučajni uzorci mogu biti korisni u inicijalnim eksploratornim istraživanjima te u situacijama kada nam nisu na raspolaganju dovoljni resursi za izbor slučajnog uzorka. Najčešće su vrste neslučajnih uzoraka:

[56] Za dokaz da je kod Lahirijeve sheme vjerojatnost izbora točno proporcionalna veličini pomoćne varijable, vidjeti Bethlehem, 2009: 85-86.

1. Prigodni uzorak,
2. Kvotni uzorak,
3. Prosudbeni uzorak,
4. Uzorak grude snijega (eng. *snowball sample*),
5. Uzorak maksimalne varijacije.

***Iako neslučajni uzorci ne nude pouzdanu procjenu populacijskih parametara, mogu biti posebno korisni u novim situacijama u kojima je potrebno provesti eksploratorna istraživanja.***

*Prigodni uzorak* nije slučajan i odnosi se na situaciju kada za istraživanje odaberemo ispitanike koji su nam u tom trenutku dostupni. S obzirom na to da taj uzorak nije slučajan, treba biti oprezan kada se iz takvih istraživanja izvlače zaključci. Prigodni uzorak praktično i znanstveno može biti vrlo upotrebljiv u situacijama kada se može pretpostaviti da razlike među ljudima nisu previše relevantne, pa je svaka skupina ispitanika dovoljno dobra. Npr. za ispitivanje učinkovitosti nekog lijeka za smanjenje krvnog tlaka, istraživači mogu uzeti prigodni uzorak jer se može pretpostaviti da taj lijek jednako djeluje na sve osobe s povišenim krvnim tlakom. Pri ispitivanju stavova i mišljenja, s druge strane, prigodni će uzorci u pravilu dati znatno slabije rezultate. Prigodni uzorci u kojima sudjeluju dobrovoljci (najčešće studenti) donose posebne probleme, zbog toga što se pokazuje da se kao dobrovoljci za istraživanja češće javljaju inteligentnije i društvenije osobe, višeg obrazovanja, društvenog sloja i jače izražene potrebe za odobravanjem (Rimac, 2005: 407).[57] Zbog toga se npr. može dogoditi da takvi pojedinci prepoznaju problem i hipoteze koje se koriste u istraživanju, što izrazito utječe na njegovu valjanost (npr. pojedinci mogu odgovarati tako da potvrde postavljene hipoteze).

Dakle, prigodni uzorci ne mogu nam pružiti jamstvo da će procjene dobivene na temelju njih biti nepristrane upravo zbog toga što nam je vjerojatnost ulaska u uzorak pojedinog člana populacije nepoznata. Situacija se donekle može „spasiti" poststratifikacijom podataka, odnosno ispravljanjem podzastupljenosti/nadzastupljenosti pojedinih skupina u uzorku u odnosu na njihove udjele u

[57] Npr. poznato istraživanje seksualnog ponašanja koje je 1950-ih godina u SAD-u proveo Alfred Kinsey dovelo je do znatnijeg precjenjivanja seksualno nekonvencionalnog ponašanja u populaciji i zbog toga što su u njemu sudjelovali dobrovoljci koji su imali visoku razinu samopouzdanja, a koja je opet povezana s nekonvencionalnim seksualnim ponašanjem (prema Rimac, 2005: 408).

populaciji. Postupak je sličan ponderiranju podataka u slučaju neproporcionalne stratifikacije, samo što se u ovom slučaju ponderiranje radi nakon provedenog istraživanja. Ako radimo poststratifikaciju na temelju više varijabli, i ovdje nam je potrebna kombinirana distribucija iz populacije i uzorka, na temelju kojih računamo pondere pojedinih skupina. Primjerice, u slučaju da u našem uzorku imamo 10% muškaraca sa završenom srednjom školom, a u populaciji njihov udio iznosi 20%, tada naš poststratifikacijski ponder iznosi 2 jer u uzorku imamo dva puta manje članova ove skupine nego što smo ih trebali imati prema udelu u populaciji. Ako to nije slučaj, odnosno imamo samo udjele pojedinačnih varijabli u populaciji, na temelju podataka iz uzorka moguće je napraviti multiplikativno ponderiranje (eng. *raking*) kojim se dobiju traženi ponderi. Na primjer, možemo zamisliti situaciju u kojoj znamo koliki su udjeli muškaraca i žena u populaciji te koliki su udjeli osoba pojedinog stupnja obrazovanja u populaciji, ali ne znamo kombinirane udjele. Primjerice, ne znamo koliki je udio visokoobrazovanih žena u populaciji.

*Kvotni uzorak* sličan je stratificiranom, no izbor ispitanika u stratum nije slučajan. U praksi se to najčešće izvodi tako da se anketarima zada broj ljudi u pojedinom stratumu, a izbor ispitanika prepusti njima. Npr. anketarima se kaže da uzorak mora sadržavati 50% muškaraca i 50% žena, a njima se prepusti način njihova izbora. Zbog činjenica da kvotni uzorak nije slučajan, treba biti vrlo oprezan u njegovoj primjeni. Npr. u ovakav će uzorak znatno češće ući one osobe koje su dostupnije (npr. umirovljenici, nezaposleni i sl.). Takva pristranost može se elinirati tako da ova obilježja također budu temelji za stvaranje kvota (npr. da kažemo da u uzorku mora biti 15% nezaposlenih osoba jer ih toliko ima i u populaciji), no to znatno komplicira kvotni uzorak, čija je osnovna prednost upravo jednostavnost izvedbe i praktičnost (a time i niža cijena).

*Prosudbeni uzorak* koristi se u onim situacijama u kojima istraživač ima dobre razloge za vjerovati da zna koji članovi populacije dobro reprezentiraju cijelu populaciju, pa stoga u uzorak smišljeno uzima upravo te članove populacije. Npr. ukoliko se u nizu istraživanja ispostavi da određeni grad ima rezultate koji su prosječni na razini cijele države, tada može biti opravdano istraživanje raditi samo u tom gradu (zbog jednostavnosti provedbe i znatno nižih troškova), a rezultate generalizirati na cijelu državu. Često je to slučaj u istraživanjima tržišta jer se pretpostavlja da neki grad i regija, zbog toga što demografski dobro reprezentiraju cijelu državu, mogu poslužiti kao testno tržište za neki proizvod ili uslugu (Rwegoshora, 2014). Prosudbeni uzorak koristi se i u onim situacijama u kojima imamo razloga pretpostaviti da su neki elementi uzorka važniji od

drugih. Primjerice, u istraživanju medijskih učinaka (npr. kultivacijskog učinka medija ili postavljanja agende) može se prepostaviti da nemaju svi mediji jednak učinak, odnosno može se pretpostaviti da su neki mediji u tom smislu važniji jer imaju jači utjecaj na medijsku publiku. Stoga se u takvim istraživanjima u uzorak uvrštavaju oni mediji koje najviše konzumira medijska publika (tj. koji su najposjećeniji). U primjeni ovoga uzorka potreban je oprez, s obzirom na to da uvjerenje istraživača da pojedini članovi populacije dobro reprezentiraju populaciju može biti potpuno pogrešno.

*Uzorak grude snijega* konstruira se tako da se prvo dođe do jednog ili nekoliko ispitanika koji imaju obilježje koje nas zanima, a nakon toga sami ispitanici preporučuju druge članove uzorka i omogućavaju kontakt s njima. Taj uzorak koristi se kada sami nemamo popis članova populacije koju želimo proučavati ili takav popis niti ne postoji (npr. maloljetni delinkventi, pripadnici supkulturnih skupina, manjih religija i sl.). Pri upotrebi te vrste uzorka osobito treba imati na umu da će u uzorak češće ući ljudi s više društvenih kontakata (drugi članovi skupine češće će ih preporučivati), a oni ne moraju biti tipični za proučavanu populaciju. Upravo to obilježje može predstavljati dodatnu, doduše ne statističku, kvalitetu uzorka grude snijega. Naime, prema broju upućivanja koje je pojedini član neke grupe izvršio možemo vidjeti kolika je njegova/njezina integriranost u grupu, tj. zauzima li taj pojedinac središnju ili marginalnu poziciju unutar grupe (Noy, 2008.). Stoga, uzorak grude snijega može biti koristan u situacijama kad se istražuje tzv. socijalni kapital (društvene veze unutar grupe). Dodatna specifičnost ovog tipa uzorka nalazi se i u čestom vremenskom prožimanju procesa uzorkovanja i procesa prikupljanja podataka. Naime, ispitanici koji su završili sudjelovanje u istraživanju predlažu sljedeće sudionike, ali voljnost na predlaganje novih sudionika ovisi o vlastitom iskustvu sudjelovanja (Noy, 2008.). Ispitanici koji istraživanje nisu doživjeli zanimljivim i korisnim, ili ga smatraju previše nametljivim, mogu biti neskloni predlagati nove sudionike ili vlastita negativna iskustva prenijeti drugim članovima grupe. Dakle, loše zamišljen ili proveden postupak prikupljanja podataka u ovom tipa uzorka utječe ne samo na kvalitetu podataka, nego istovremeno i na kvalitetu uzorkovanja.

*Uzorak maksimalne varijacije* odnosi se na situaciju u kojoj pokušavamo uzorkovati tako da izaberemo što različitije ljude unutar populacije (tzv. ektremne slučajeve), s idejom da će nam takva različitost donijeti reprezentativnost, odnosno vjernu sliku populacije. Drukčije rečeno, ideja je da će nam spajanje ekstrema donijeti pravu sliku, odnosno neku vrstu prosjeka. Najčešće se odnosi na situacije kada biramo manje uzorke (osobito kada su u pitanju kvalitativna istraživa-

nja) jer je u većim uzorcima moguće primijeniti druge vrste neprobabilističkih uzoraka (npr. kvotno uzorkovanje). Uzmimo, primjerice, da želimo napraviti 20 intervjua koji se bave pitanjem kvalitete života u nekoj četvrti. Kad je riječ o uzorku maksimalne varijacije, birali bismo ljude za koje pretpostavljamo da imaju izrazito različita iskustva kada je u pitanju život u četvrti i stanovanje. Tako bismo mogli izabrati pojedince izrazito visokog i izrazito niskog dohotka, pojedince koji žive u izrazito velikim i izrazito malim stambenim jedinicama, ljude bez djece ili s većim brojem djece i sl.

## DODATNA LITERATURA UZ ŠESTO POGLAVLJE

Bethlehem, Jelke (2009). *Applied Survey Method. A Statistical Perspective*. Hoboken: John Wiley & Sons.

Knjiga pruža izvrstan uvod u teoriju uzorkovanja i vrste uzoraka, a bavi se i detaljima vezanim za dizajn anketnih upitnika i prikupljanje podataka. Daje izvode pojedinih formula vezanih za procjenu nepristranosti i efikasnosti procjenjivača, no ne zahtijeva napredno matematičko znanje kako bi se razumjeli osnovni pojmovi uzorkovanja i odluke koje treba donijeti u pojedinim istraživačkim situacijama.

## PITANJA UZ ŠESTO POGLAVLJE

1. Što je uzorak, a što okvir uzorka?
2. Što je reprezentativnost uzorka i o čemu ovisi?
3. Što je standardna pogreška uzorka?
4. Kakav je odnos standardne pogreške i veličine uzorka?
5. Koja je razlika između slučajnih i neslučajnih uzoraka?
6. Što je to jednostavni slučajni uzorak?
7. Što je sustavni (sistematski) uzorak i na što treba obratiti pozornost prilikom njegova izvlačenja?
8. Što je stratificirani uzorak i zašto je precizniji od jednostavnog slučajnog uzorka?
9. Što je klaster uzorak i kada se koristi?
10. Što je kvotni uzorak i po čemu se razlikuje od stratificiranog?
11. Što je prosudbeni uzorak?
12. Što je uzorak grude snijega?
13. Što je prigodni uzorak?

# 7. ISTRAŽIVAČKI NACRTI

## 7.1. TIPOVI ISTRAŽIVAČKIH NACRTA

*Nacrt istraživanja* predstavlja općeniti pristup u traženju odgovora na postavljeno istraživačko pitanje (hipoteze). U širem smislu u nacrtu se istraživanja detaljno opisuje definirati što će se istraživati i na koji način, odnosno nacrt istraživanja može sadržavati i plan uzorkovanja, vremenski plan rada, resurse potrebne za provođenje istraživanja, način financiranja i slično. U užem smislu, istraživački se nacrt odnosi na način dokazivanja postavljenih hipoteza ili istraživačkih pitanja, odnosno na logičku i epistemološku strukturu samoga istraživanja. Pri tome se može reći da se najbolje potvrđenim teorijama mogu smatrati one koje su testirane različitim tipovima istraživačkih nacrta. Naime, svaki od nacrta ima svoje manjkavosti, no ako svi oni upućuju na sličan zaključak, odnosno potvrđuju ili ne potvrđuju neku teoriju, tada se taj zaključak može smatrati valjanim. Na taj se način teorija dokazuje pomoću kovergentne validnosti pojedinih nalaza koji ju potvrđuju. Ovakav multimetodološki pristup naziva se i *triangulacija*,[58] a može se provoditi i unutar pojedinih istraživačkih nacrta. Primjerice, testiranje neke teorije može se provesti primjenom različitih eksperimentalnih nacrta. Unutar korelacijskog nacrta mogu se provesti anketno istraživanje, istraživanje sekundarnih podataka, intervjui, studije slučaja i sl.

*Kauzalnost pojava*, što je krajnji cilj znanstvenog istraživanja, obično se pokušava dokazati pomoću tri tipa istraživačkih nacrta (navedeno na temelju Mejovšek, 2008: 20):

1. Korelacijski,
2. Longitudinalni,
3. Eksperimentalni.

***Istraživački nacrti mogu se podijeliti na eksperimentalne, longitudinalne i korelacijske.***

Na općenitijoj razini istraživački se nacrti mogu podijeliti na opservacijske i eksperimentalne, pri čemu se opservacijski nacrti temelje na podatcima koji se prikupljaju onako kako se prirodno javljaju, a u eksprimentalnom je nacrtu riječ

[58] U metodologiju društvenih znanosti ovaj je pojam došao iz pomorstva i geodezije te označava mjerenje položaja neke točke na osnovi konvergencija mjerenja udaljenosti drugih dviju točaka od navedene točke.

o kontroliranom mijenjanju pojava (tzv. nezavisnih varijabli). Eksperimentalni nacrti stoga uvijek imaju vremensku dimenziju, a opservacijski nacrti mogu ju ili ne moraju imati. Tako longitudinalna istraživanja uključuju podatke iz više vremenskih točaka, a korelacijska iz samo jedne vremenske točke. Upravo se u pitanju vremenske dimenzije i kontrole varijabli kriju razlike, odnosno snage i slabosti pojedinih istraživačkih nacrta. Dakle, ukratko rečeno, *eksperimentalnim istraživanjem* (nacrtom) kauzalnost se dokazuje smišljenim i kontroliranim variranjem proučavanih varijabli.[59] Dakle, pri eksperimentalnom istraživanju istraživač ima kontrolu nad varijablama, tj. odlučuje o tome koje će varijable biti primijenjene i u kojem intenzitetu. Kontrola se primarno odnosi na nezavisne i kontrolne varijable u eksperimentu jer istraživač nema utjecaj na intenzitet pojavljivanja zavisne varijable, odnosno on ovisi o djelovanju nezavisne varijable. Primjerice, u nekom se istraživanju želi utvrditi utječe li čitanje vijesti o kriminalu na percepciju učestalosti kriminaliteta u nekoj zemlji. U eksperimentalnom istraživanju istraživač bi, primjerice, podijelio sudionike eksperimenta na dvije skupine, a ova podjela bila bi slučajna (npr. izvlačanjem iz kutije u kojoj se nalaze imena sudionika). Nakon toga jednoj bi skupini dao medijske napise koji se odnose na kriminal, a drugoj medijske napise o nekoj drugoj temi. Na kraju bi izmjerio percepciju kriminaliteta u obje skupine. Kažemo da istraživač ima *kontrolu* nad nezavisnom varijablom upravo zato što je odredio njezin intenzitet kod svakog pojedinog sudionika eksperimenta. *Korelacijskim se istraživanjima* (nacrtom) proučavaju odnosi između varijabli u određenom vremenskom trenutku te se pokušavaju rasvijetliti njihovi odnosi. S obzirom na to da se istraživanje radi u jednoj točki vremena, korelacijska se istraživanja obično nazivaju i istraživanja poprečnog presjeka (eng. *cross-sectional research*). U ovom istraživačkom nacrtu istraživač ne mijenja varijable, kao što je to prethodno opisano u eksperimentu, nego samo mjeri pojavljivanje varijabli. *Longitudinalnim istraživanjem* tijekom duljeg vremenskog razdoblja prati se jedna skupina ispitanika te se proučavaju promjene i odnosi među varijablama.

## 7.2. KORELACIJSKI NACRT

Kako je napomenuto, jednu od razina znanstvenog istraživanja predstavlja i povezanost (korelacija) između varijabli koje se istražuju. Osnovna je razlika između

[59] Varijabla predstavlja neko obilježje koje se može mjeriti i koje je različito zastupljeno u različitih pojedinaca. Npr., možemo mjeriti nečiji stupanj obrazovanja, a stupnjevi obrazovanja različiti su u različitih pojedinaca.

korelacijskih i eksperimentalnih istraživanja u tome što u korelacijskim istraživanjima, za razliku od eksperimentalnih, nemamo potpunu kontrolu nad proučavanim varijablama, tj. proučavamo ih onako kako se prirodno javljaju. Povezanost između varijabli može biti pozitivna (veće vrijednosti na jednoj varijabli znače i veće vrijednosti na drugoj varijabli) ili negativna (veće vrijednosti na jednoj varijabli znače manje vrijednosti na drugoj varijabli). Kada su u pitanju intervalne varijable,[60] povezanost između varijabli obično se mjeri tzv. *Pearsonovim koeficijentom korelacije* (oznaka „r"). Veličina ovog koeficijenta može ići od +1 (maksimalna pozitivna povezanost), preko 0 (nepostojanje povezanosti) do -1 (maksimalna negativna povezanost). Petpostavimo npr. da želimo izmjeriti povezanost dohodka pojedinca i njegove učestalosti pohađanja kulturnih događaja. Dohodak mjerimo u kunama, a pohađanje kulturnih događaja na skali od 1 do 5.[61] U donjoj tablici prikazana je savršena pozitivna korelacija između varijabli (r = 1).

*Tablica 25. Maksimalna pozitivna povezanost između dviju varijabli (r = 1)*

| | **Dohodak (kn)** | **Pohađanje kulturnih događaja** |
|---|---|---|
| Ispitanik 1 | 1 000 | 1 |
| Ispitanik 2 | 2 000 | 2 |
| Ispitanik 3 | 3 000 | 3 |
| Ispitanik 4 | 4 000 | 4 |
| Ispitanik 5 | 5 000 | 5 |

Maksimalna negativna povezanost između ovih dviju varijabli prikazana je u sljedećoj tablici.

*Tablica 26. Maksimalna negativna povezanost između dviju varijabli (r = - 1)*

| | **Dohodak (kn)** | **Pohađanje kulturnih događaja** |
|---|---|---|
| Ispitanik 1 | 1 000 | 5 |
| Ispitanik 2 | 2 000 | 4 |
| Ispitanik 3 | 3 000 | 3 |
| Ispitanik 4 | 4 000 | 2 |
| Ispitanik 5 | 5 000 | 1 |

Kvadriranjem Pearsonova koeficijenta korelacije dobije se postotak zajedničke varijance između varijabli. Npr. u slučaju da je r = 0.5, postotak zajedničke varijance iznosi 0,25, što znači da se oko 25% variranja jedne varijable oko vlastitog prosjeka može protumačiti povezanošću s drugom varijablom.

60 Vidjeti poglavlje o razinama mjerenja.

61 Pri čemu „1" označava rijetko, a „5" često pohađanje kulturnih događaja.

***Korelacijski se nacrt odnosi na istraživanja u jednoj točki vremena u kojima se mjeri korelacija između varijabli.***

Za tumačenje veličine koeficijenta korelacije nije moguće dati definitivne preporuke, jer to ovisi o teoretskoj i praktičnoj važnosti te povezanosti, tj. istraživanja. Npr. ako bi promjene u obrazovnom sustavu koje koštaju vrlo malo bile povezane s povećanim obrazovnim uspjehom s koeficijentom korelacije od 0.2, tada bi se ta povezanost mogla smatrati vrlo zadovoljavajućom. No ako bi te promjene zahtijevale velika ulaganja, tada bi se taj koeficijent mogao smatrati vrlo niskim. Praktična pravila o tumačenju Pearsonova koeficijenta korelacije prikazana su u sljedećoj tablici.

*Tablica 27. Tumačenje veličine koeficijenta korelacije*

| **Iznos koeficijenta** | **Povezanost** |
|---|---|
| Do 0,2 | Vrlo slaba |
| Od 0,2 do 0,4 | Slaba |
| Od 0,4 do 0,6 | Umjerena |
| Od 0,6 do 0,8 | Jaka |
| Iznad 0,8 | Vrlo jaka |

Pri tumačenju koeficijenta korelacije treba imati na umu da koeficijent, osim stvarne povezanosti između varijabli, može odražavati i dvije dodatne činjenice:

1. Povezanost dviju varijabli s nekom trećom varijablom,
2. Kvalitetu mjernih instrumenata.

Povezanost između dvije varijable može odražavati činjenicu da su obje povezane s nekom trećom varijablom. Npr. u istraživanju utvrdimo da su dohodak nekog pojedinca i njegov/njezin stupanj pohađanja kulturnih događaja vrlo visoko povezani, iz čega zaključimo da nedostatak novca utječe na smanjeni odlazak na kulturne događaje. Međutim, stupanj obrazovanja pojedinca može biti pozitivno povezan i s njegovim/njezinim dohotkom i s odlaskom na kulturne događaje. Drukčije rečeno, obrazovaniji pojedinci više zarađuju i češće odlaze na kulturne događaje, pa odlazak na kulturne događaje može biti stvarno determiniran stupnjem obrazovanja, a ne količinom novca koju netko ima.

U korelacijskom istraživanju za razliku od eksperimentalnih u kojima se kontrola postiže slučajnim raspoređivanjem ispitanika (vidjeti poglavlje o eksperimentalnim istraživanjima), kontrola se obavlja pomoću multivarijantnih statističkih postupaka. Intuitivno se statistička kontrola može predočiti na sljedeći način

– ako povezanost između dviju varijabli postoji na cijelom uzorku, a ne postoji na poduzorcima treće varijable, tada se može reći da je korelacija između varijabli lažna, tj. da vjerojatno nije riječ o kauzalnom odnosu. Uzmimo npr. fiktivnu i pojednostavljenu istraživačku situaciju prikazanu u tablici 28, koja prikazuje povezanost između čitanja knjiga i stupnja etnocentrizma. Na temelju podataka iz te tablice može se zaključiti da čitanje knjiga smanjuje etnocentrizam, tj. da ljude čini tolerantnijim prema drugim kulturama različitim od one vlastite.[62] Naime, među osobama koje imaju nisku razinu etnocentrizma dvaput je više osoba koje često čitaju knjige (80: 40), dok je kod onih s visokim etnocentrizmom dvaput više onih koji rijetko čitaju knjige.

*Tablica 28. Odnos između čitanja knjiga i etnocentrizma – ukupan uzorak*

| | **Nizak etnocentrizam** | **Visok etnocentrizam** | **Ukupno** |
|---|---|---|---|
| Često čitanje knjiga | 80 | 40 | 120 |
| Rijetko čitanje knjiga | 40 | 80 | 120 |
| Ukupno | 120 | 120 | 240 |

Međutim, moguće je pretpostaviti da varijabla stupnja obrazovanja utječe i na učestalost čitanja knjiga i na stupanj etnocentrizma, tj. da se korelacija između čitanja knjiga i etnocentrizma pojavljuje zbog utjecaja treće varijable, tj. stupnja obrazovanja. U tablici 29 prikazan je odnos između čitanja knjiga i etnocentrizma niskoobrazovanih, a u tablici 30 visokoobrazovanih osoba.

*Tablica 29. Odnos između čitanja knjiga i etnocentrizma – niskoobrazovani*

| | **Nizak etnocentrizam** | **Visok etnocentrizam** | **Ukupno** |
|---|---|---|---|
| Često čitanje knjiga | 5 | 15 | 20 |
| Rijetko čitanje knjiga | 25 | 75 | 100 |
| Ukupno | 30 | 90 | 120 |

Vidljivo je da ne postoji povezanost između čitanja knjiga i etnocentrizma niskoobrazovanih osoba, a isti je slučaj i sa visokoobrazovanim osobama. Npr., u slučaju niskoobrazovanih osoba i u skupini onih koji imaju visok i u skupini onih koji imaju nizak etnocentrizam, osobe koje često čitaju knjige 5 puta su rjeđe od onih koji ih rijetko čitaju (5: 25, odnosno 15: 75). Visokoobrazovane osobe u obje skupine imaju 5 puta veći broj onih koji često čitaju knjige (75: 15, odnosno 25: 5).

[62] Zbog jednostavnosti nisu izračunati koeficijenti statističke povezanosti.

*Tablica 30. Odnos između čitanja knjiga i etnocentrizma – visokoobrazovani*

| | **Nizak etnocentrizam** | **Visok etnocentrizam** | **Ukupno** |
|---|---|---|---|
| Često čitanje knjiga | 75 | 25 | 100 |
| Rijetko čitanje knjiga | 15 | 5 | 20 |
| Ukupno | 90 | 30 | 120 |

Iz ovih se podataka, dakle, može se zaključiti da se povezanost između čitanja knjiga i nižeg stupnja etnocentrizma može pripisati činjenici da visokoobrazovane osobe češće čitaju knjige, kao i da istovremeno češće imaju nizak stupanj etnocentrizma. Stoga, nakon kontrole treće varijable, korelacija između čitanja knjiga i stupnja etnocentrizma pokazuje se „lažnom", što znači da te dvije varijable vjerojatno nisu uzročno-posljedično povezane.

Kvaliteta mjernih instrumenata također utječe na povezanost između varijabli. Što su mjerni instrumenti manje kvalitetni i izmjerene varijable imaju nisku valjanost i pouzdanost,[63] to je i teže postići visok stupanj korelacije, čak i onda kada povezanost između varijabli doista postoji. Naime, rezultat dobiven pomoću mjernog instrumenta lošijih mjernih karakteristika uključuje znatan udio slučajnih varijacija, tj. mjerne pogreške, a ta mjerna pogreška skriva korelaciju između konstrukata koji nas zanimaju. Pretpostavimo, primjerice, da želimo utvrditi korelaciju između ekoloških stavova i spremnosti na proekološko ponašanje. Uzmimo i da je naš upitnik kojim smo mjerili ekološke stavove većini ispitanika bio težak i nerazumljiv i većina je ispitanika na njega odgovarala ili nasumično ili pogrešno razumijevajući pitanja. Tada će, zbog nepostojanja povezanosti između takvih odgovora i spremnosti na proekološko ponašanje, korelacija između ekoloških stavova i proekološkog ponašanja, čak i ako je u stvarnosti vrlo jaka, biti skrivena i nećemo je moći utvrditi našim istraživanjem. Upravo je iz tih razloga prilikom evaluacije istraživačkih rezultata važno imati u vidu i kvalitetu mjernih instrumenata koji su u istraživanju korišteni.

## 7.3. LONGITUDINALNI NACRT

Kako je navedeno, longitudinalna su istraživanja ona istraživanja koja imaju vremensku dimenziju, a svojom vremenskom dimenzijom ponekad mogu osvijetliti uzročno-posljedične odnose bolje nego korelacijska. Npr., korelacijskim istraživanjem možemo utvrditi da su nezaposlenost i loše zdravlje međusobno povezani.

[63] Vidjeti poglavlje o metrijskim karakteristikama instrumenata.

Međutim, ipak nismo sigurni je li nezaposlenost dovela do lošeg zdravlja (stres, nedostatak novca za liječenje i sl.) ili je loše zdravlje dovelo do nezaposlenosti (nesklonost poslodavaca da zapošljava ljude slabijeg zdravlja). Longitudinalnim bi istraživanjem pratili jednu skupinu ljudi te bi vidjeli što se događa s onima koji ostaju bez posla, tj. je li došlo do pogoršanja njihovoga zdravlja u usporedbi s onima koji nisu nezaposleni. Primjer ovakvog istraživačkog nacrta predstavlja istraživanje utjecaja razvoda braka na životno zadovoljstvo koje je proveo Lucas (2005, navedeno prema Shaughnessyju i sur., 2012: 158). Naime, on je, počevši od 1984. godine, pratio stupanj životnog zadovoljstva skupine osoba te je usporedio promjene do kojih dolazi prije i nakon razvoda. Unatoč tome što su u korelacijskim istraživanjima utvrđene razlike u životnom zadovoljstvu razvedenih i nerazvedenih osoba (osoba koje su u braku), iz toga nije moguće pouzdano utvrditi da razvod uzrokuje niže zadovoljstvo. Lucas je utvrdio da razina životnog zadovoljstva opada prije samog razvoda (vjerojatno reflektirajući probleme u braku), odnosno da poraste nakon samog razvoda. Međutim, unatoč porastu nakon razvoda, životno zadovoljstvo ne dosegne razine prije pojave bračnih problema i početka opadanja životnog zadovoljstva. Lucas je također utvrdio i da su razine životnog zadovoljstva prije sklapanja braka u prosjeku niže kod osoba koje su se razvele u odnosu na one koje se nisu razvele.[64] Stoga je i zaključio da se razlika u životnom zadovoljstvu razvedenih i nerazvedenih osoba može pripisati razlikama u početnim razinama životnog zadovoljstva, kao i negativnom učinku razvoda. Važno je napomenuti da se do ovakvih zaključaka nikako nije moglo doći primjenom korelacijskog nacrta.

***Longitudinalni nacrt odnosi se na praćenje nekih pojava u nekoliko vremenskih točaka.***

Longitudinalni nacrt također na bolji način od eksperimentalnog omogućava istraživanje medijacijskih i moderacijskih učinaka, tj. složenijih odnosa među varijablama. Naime, u eksperimentalnim istraživanjima zbog činjenica da se zavisne varijable pojavljuju u isto vrijeme ne možemo biti sigurni koja je od tih varijabli varijabla medijator (Hayes, 2013). U nekim slučajevima, doduše, imamo dobre teorijske razloge za vjerovati da je neka varijabla medijator određenog učinka. Primjerice, u nekom eksperimentalnom istraživanju želimo utvrditi na koji način nezadovoljstvo političkom situacijim utječe na želju odlaska iz zemlje. Eksperimentalnoj grupi možemo dati negativni opis političke situacije u zemlji (npr. iz-

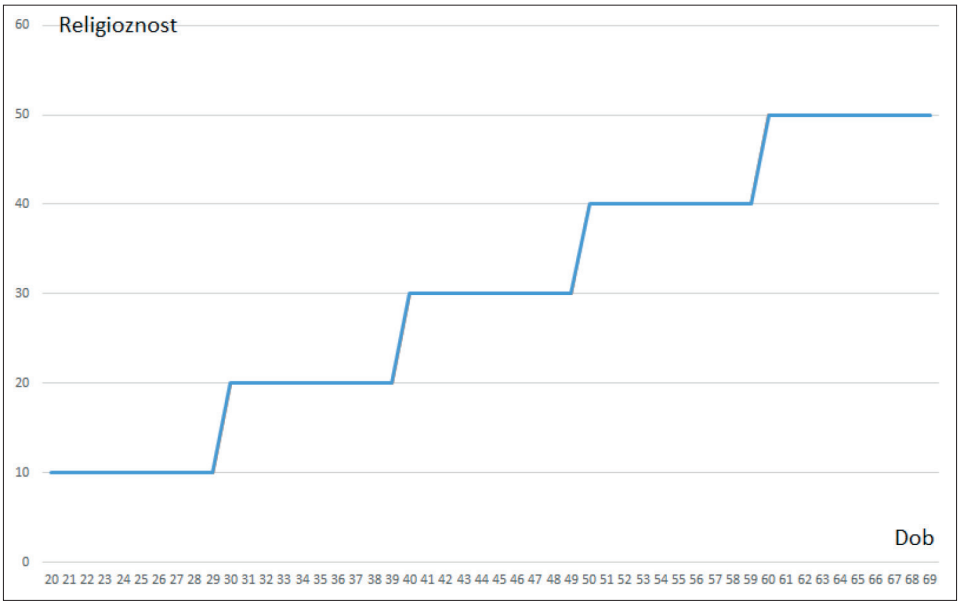
[64] Moguće je objašnjenje da osobe nižeg socioekonomskog statusa posjeduju nižu razinu životnog zadovoljstva pa je u njih i veća vjerojatnost razvoda.

vješće o korupciji), a drugoj pozitivno ili neutralno izvješće, te nakon toga izmjeriti zadovoljstvo političkom situacijom te namjere odlaska iz zemlje. U takvoj situaciji za pretpostaviti je da negativni opis političke situacije vodi do nezadovoljstva političkom situacijom te namjeri odlaska iz zemlje, tj. da je nezadovoljstvo političkom situacijom medijacijska varijabla. Drugim riječima, čitanje o negativnoj političkoj situaciji vodi do želje za odlaskom tako što ljudi postanu nezadovoljni političkom situacijom te nakon toga žele otići iz zemlje. Druga situacija, u kojoj je želja za odlaskom medijacijska varijabla, manje je teorijski prihvatljiva. Naime, teško je vjerovati da ljudi nakon čitanja o negativnoj političkoj situaciji žele otići iz zemlje te tek zbog toga što žele otići iz zemlje postanu nezadovoljni političkom situacijom. No postoje i situacije kada kauzalni slijed nije tako jasan, odnosno ne možemo biti sigurni koja je varijabla medijacijska varijabla. Primjerice, uzimo da radimo eksperiment u kojemu istražujemo utječe li percepcija kriminala na pad povjerenja u ljude i institucije. Eksperimentalna grupa dobije izvještaj o visokoj razini kriminala u zemlji, a kontrolna neutralni izvještaj. Nakon toga izmjerimo dvije zavisne varijable – općenito povjerenje u ljude te povjerenje u policiju. Uzmimo da u eksperimentalnoj grupi izmjerimo nižu razinu i jednog i drugog povjerenja u odnosu na kontrolnu grupu. Međutim, zbog toga što su obje varijable mjerene u isto vrijeme, ne možemo reći koja je od njih medijacijska varijabla. Drugim riječima, percepcija rasta kriminala može dovesti do pada povjerenja u policiju, a zatim i općenitog povjerenja u ljude. Mogući je razlog, primjerice, uvjerenje da nas neučinkovita policija ne može zaštiti od drugih ljudi, pa im onda ne možemo unaprijed ni vjerovati. U tom bi slučaju povjerenje u policiju bilo medijacijska varijabla. No ne možemo biti sigurni da percepcija rasta kriminala ne izazove opće nepovjerenje u sve ljude i institucije, pa time i u policiju. U tom bi slučaju općenito (ne)povjerenje u ljude bilo medijacijska varijabla. Dakle, u eksperimentalnom istraživanju ne možemo dobro razlučiti je li i koja je od dvije varijable zavisna medijacijska varijabla. U longitudinalnom istraživanju, s druge strane, mogli bismo vidjeti dolazi li do pada općenitog povjerenja u ljude prije ili poslije pada povjerenja u policiju, tj. je li neka od tih varijabli možda medijacijska varijabla.

Longitudinalna istraživanja omogućavaju nam i bolje istraživanje uzročnosti u smislu odvajanja učinaka dobi i kohortnog učinka. Na primjer, uzmimo da korelacijskim istraživanjem utvrdimo negativnu korelaciju između dobi i religioznosti. No, takva korelacija ne mora nužno značiti da ljudi starenjem postaju religiozniji (učinak dobi), nego može i značiti da mlađe generacije odrastaju u društvenim okolnostima koje ih čine manje religioznim (kohortni učinak). Naime, starije su generacije možda odgajane tradicionalnije i u religioznom duhu, što možda nije slučaj s mlađim generacijama. Kohortni učinak možemo ilustrirati pomoću gra-

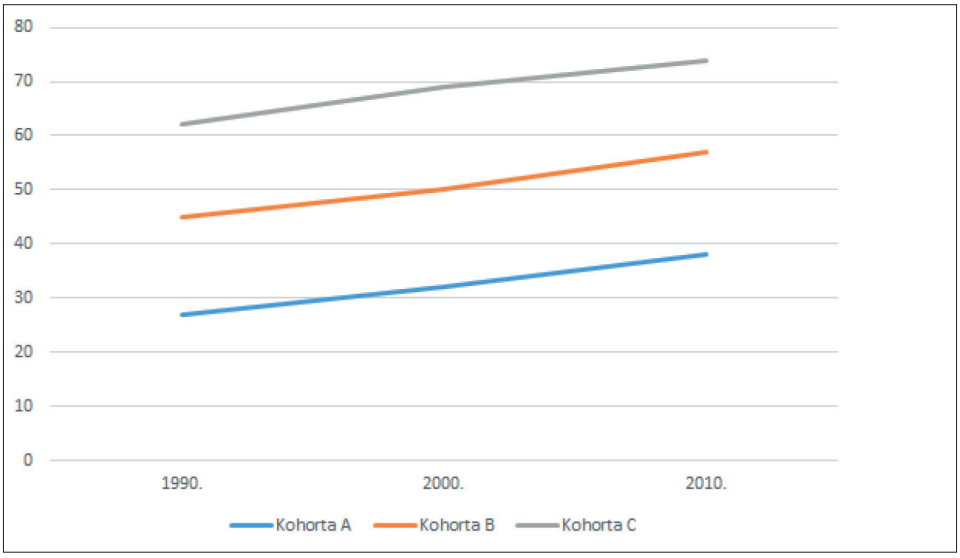
fikona 1, na kojemu je na apscisi prikazana dob, a na ordinati rezultat na skali religioznosti. Naime, promotrimo li desetogodišnje dobne kohorte (osobe između 20. i 30. godine života čine jednu kohortu, one između 30. i 40. godine života sljedeću itd.), možemo vidjeti da unutar njih sa starenjem ne dolazi do porasta religioznosti. Primjerice, osobe stare 33 godine jednako su religiozne kao i osobe koje imaju 37 godina, osobe koje imaju 52 godine jednako su religiozne kao i one s 59 godina itd. S druge strane, svaka sljedeća dobna kohorta religioznija je od one prethodne. Primjerice, osobe između 20. i 30. godine života imaju religoznost u iznosu 10, osobe stare između 30 i 40 godina imaju religioznost u iznosu 20 itd. Kada bismo napravili korelacijsko istraživanje, dobili bismo jasnu pozitivnu korelaciju između dobi i religioznosti, no ona ne bi bila rezultat dobnog učinka, nego bismo ju mogli u potpunosti objasniti kohortnim učinkom. Dakle, pojedine kohorte imaju početnu razinu religioznosti koja je rezultat društvenih okolnosti u kojima su odrastali pripadnici kohorte te se ta religioznost tijekom života ne mijenja. Stoga i iskaz „osobe starije dobi religioznije su od osoba mlađe dobi", odnosno „postoji pozitivna korelacija između dobi i religioznosti" nikako nije isto što i iskaz „starenjem osobe postaju religioznije". Ovaj potonji izraz implicira učinak dobi, a u prvom izrazu povezanost dobi i religioznosti može biti rezultat i učinka dobi i kohortnog učinka, odnosno neke kombinacije obaju učinaka. Stoga se u korelacijskom istraživanju ova dva učinka i ne mogu odvojiti.

*Grafikon 1. Ilustracija kohortnog učinka*



Praćenjem jedne skupine ispitanika u vremenu mogu se razdvojiti ova dva učinka. Naime, ako pratimo mlađe generacije tijekom vremena i one starenjem postaju onoliko religiozne koliko i sadašnje starije generacije, tada možemo govoriti o postojanju učinka dobi, tj. zaključak da ljudi starenjem postaju religiozniji postaje vjerojatniji. Primjerice, uzmimo da smo napravili longitudinalno istraživanje u kojemu smo pratili tri dobne kohorte koje su na početku istraživanja (npr. 1990. godine) imale 20 (kohorta A), 30 (kohorta B) i 40 godina (kohorta C). Početne (1990.) godine izmjerili smo njihovu religioznost te smo istraživanje ponovili još dva puta (2000. i 2010. godine). Rezultati su prikazani u grafikonu 2. Iz njega možemo vidjeti mali dobni učinak, imajući u idu da se religioznost ljudi unutar pojedinih dobnih kohorti blago povećala. Primjerice, osobe iz dobne kohorte A 1990. godine imale su prosječnu religioznost od 27, a 2010. godine 38 bodova. S druge strane, kohortne su razlike veće. Primjerice, osobe iz kohorte C 1990. godine imale su 40 godina i prosječnu religioznost koja je iznosila 62 boda. Dvadeset godina poslije (2010. godine), osobe iz kohorte A također su napunile 40 godina, ali njihova prosječna religioznost iznosila je svega 38 bodova. Stoga se u ovom slučaju može zaključiti da je kohortni učinak znatno veći od dobnog učinka (učinka starenja).

*Grafikon 2. Usporedba dobnog i kohortnog učinka*




Međutim, valja napomenuti da u ovakvoj situaciji moramo imati podatke vezane uz različite dobne skupine, što može biti vrlo skupo. Ako oni nedostaju, tada je i učinak dobi i kohortni učinak međusobno teže odvojiti. Primjerice, pratimo li

jednu skupinu ispitanika i ako je ona tijekom desetogodišnjeg razdoblja postala religioznija, ne možemo reći je li to zbog toga što ih je starenje učinilo religioznijim ili je to možda zbog toga što su se promijenile društvene okolnosti i cijela je populacija zbog toga postala religioznija (tzv. učinak razdoblja).

Obično se razlikuju tri vrste longitudinalnih istraživanja:

1. Kohortna istraživanja,
2. Panel istraživanja,
3. Ponovljena korelacijska istraživanja (eng. *repeated cross-sectional research*).

*Kohortna istraživanja* sastoje se od praćenja skupine ljudi – tzv. kohorte, koji su rođeni u isto vrijeme ili ih veže neki drugi životni događaj (npr. počeli su raditi iste godine), a osobito su pogodna upravo za utvrđivanje utjecaja pojedinih događaja na životne situacije ljudi. Pretpostavimo, primjerice, da proučavamo koliko dugotrajna nezaposlenost tijekom životnog ciklusa utječe na vjerojatnost da će se osoba razvesti. U tom slučaju praćenje jedne kohorte ispitanika tijekom duljeg vremena osigurava uravnoteženje drugih varijabli jer su svi članovi kohorte rođeni u isto vrijeme i proživjeli iste sociokulturne promjene. Problem je kohortnih istraživanja njihova dugotrajnost, a što izrazito utječe i na cijenu istraživanja. *Panel istraživanja* odnose se na proučavanje iste skupine ljudi (tzv. panela) tijekom duljeg vremena, no ovi ljudi ne predstavljaju kohortu, nego obično presjek opće populacije. Primjerice, pomoću tzv. panela kućanstava marketinške agencije promatraju promjene do kojih dolazi u potrošačkim navikama pod utjecajem različitih pojava (npr. smanjenja dohotka, rođenje djeteta i sl.). Veliki je nedostatak panel istraživanja, kao i kohortnih istraživanja, odustajanje mnogih sudionika tijekom istraživanja, što može utjecati na valjanost istraživanja i dobivenih rezultata. *Ponovljena korelacijska istraživanja*, kako sâmo ime kaže, sastoje se od ponavljanja istog istraživanja u više vremenskih točaka na nekom uzorku populacije, pri čemu je svaki put riječ o drugom uzorku, tj. drugim ljudima. Pri tome je važno da su uzorci na kojima se vrše ponovljena korelacijska istraživanja međusobno usporedivi. Radimo li, primjerice, prvo istraživanje na slučajnom, a drugo na prigodnom uzorku, ustanovljene promjene možda su rezultat različite kvalitete uzoraka u ova dva istraživanja. Kako ovakav tip istraživanja ne omogućuje odvajanja učinka dobi i vremena, nije riječ o longitudinalnim istraživanjima u punom smislu te riječi, no takva istraživanja omogućuju praćenje proučavanih trendova. Primjerice, *Eurobarometar* istraživanje koje provodi statistički ured Europske unije takva je vrsta istraživanja. U njemu se u svakoj europskoj državi koristi isti upitnik kojim se, svaki put na različitom uzorku stanovnika pojedine zemlje, istražuju društveni stavovi, vrijednosti i ponašanje. Važno je reći da ponovljena korelacijska istraži-

vanja služe za procjenu promjene *populacijskih* parametara, a ne za procjenu promjena u stavovima ili ponašanju *pojedinaca*. Kao ilustraciju uzmimo primjer koji koriste Shaughnessy i sur. (2003: 143). U dva ponovljena korelacijska istraživanja provedena u razmaku od 6 godina ustanovljeno je da je udio Amerikanaca koji ne vjeruju vlastitoj vladi porastao s 36% na 52%, s odgovarajućim smanjenjem onih koji donekle ili potpuno vjeruju vladi. Iz ovih brojki ne može se zaključiti da je 16% pojedinaca koji su ranije vjerovali vladi postalo nepovjerljivo. Primjerice, moguće je da je 20% pojedinaca prestalo vjerovati vladi, dok je istovremeno 4% onih koji ranije nisu iskazivali povjerenje vladi sada to počelo činiti.

Osim ovakve podjele, uobičajene u društvenim znanostima, u biomedicinskim znanostima (ponajviše u epidemiološkim istraživanjima) česta je podjela na prospektivna, retrospektivna i *case-control* longitudinalna sitraživanja. U prvom je slučaju riječ o praćenju skupine ispitanika, pri čemu su neki izloženi utjecaju određenog čimbenika, a neki nisu. Nakon toga se prati razlika u određenim ishodima, najčešće obolijevanju od neke bolesti, između ove dvije skupine. Primjer jednoga prospektivnog istraživanja odnosio bi se na praćenje skupine pušača i nepušača i utvrđivanje razlike u oboljevanju od karcinoma pluća. Retrospektivna istraživanja odnose se na praćenje skupine ispitanika „unatrag" u vremenu, odnosno utvrđivanju relevantnih podataka nakon što su se dogodili. Primjerice, istraži se uzorak ispitanika te se zabilježi jesu li oboljeli od karcinoma pluća, odnosno jesu li bili pušači u proteklom razdoblju. U tzv. *case-control* studijama istražuju se osobe koje imaju, odnosno nemaju određeni ishod (najčešće bolest) te se nakon toga uspoređuju kako bi se utvrdili mogući uzroci tih ishoda. Primjerice, nasumično se odredi 100 osoba koje su oboljele i 100 osoba koje nisu oboljele od karcinoma pluća te se ispitaju njihove pušačke navike i drugi mogući uzorci oboljevanja. Prilikom izbora u uzorak moguće je izjednačiti ispitanika i prema drugim važnim varijablama. Prednost *case-control* studija je mogućnost proučavanja rijetkih bolesti jer je u prospektivnim i retrospektivnim studijama potreban vrlo veliki uzorak kako bi se dobio dovoljan broj ljudi oboljelih od nekih rijetkih bolesti. Iz ovako definiranih longitudinalnih istraživanja u biomedicinskim znanostima može se vidjeti razlika u shvaćanju ovoga nacrta u odnosu na društvene znanosti. Naime, retrospektivna istraživanja u društvenim bi znanostima spadala u korelacijske nacrte, a *case-control* u pravilu u tzv. kvazieksperimentalne nacrte.

Longitudinalna istraživanja, s obzirom na to da uglavnom traju mnogo dulje od korelacijskih ili eksperimentalnih istraživanja, obično su znatno skuplja i uključuju veći angažman istraživača. Osim ovog nedostaka, longitudinalna istraživanja često pate i od „mortaliteta" sudionika istraživanja, kao i od specifičnih po-

grešaka mjerenja vezanih uz reakciju sudionika istraživanja (Shaughnessy, 2003: 146-147). Mortalitet sudionika, stvarni ili simbolički, odnosi se na nemogućnost nekih sudionika koji su sudjelovali u prvom valu longitudinalnog istraživanja da sudjeluju u valovima koji dolaze poslije. Mogući su razlozi bolest ili smrt sudionika, gubljenje kontakta s istraživačima, seljenje u drugi grad ili državu, gubitak motivacije za sudjelovanjem u istraživanju. Stoga je u longitudinalnim istraživanjima uvijek potrebno provjeriti razlikuju li se oni koji su od njega odustali prema sociodemografskim obilježjima ili prema drugim obilježjima izmjerenim do tada od onih sudionika koji su u istraživanju ostali do kraja. Drugi je važan nedostatak longitudinalnih istraživanja pojačana reaktivnost sudonika istraživanja uslijed toga što se mjerenja ponavljaju dva ili više puta. Najčešće se događa da sudionici istraživanja pamte odgovore i ponavljaju ih u naknadnom mjerenju jer žele ispasti „konzistentni", iako su se promijenili. Također, ako je riječ o retrospektivnim istraživanjima, često postoji opasnost od pogreške prisjećanja jer se ispitanici moraju sjetiti događaja koji su se dogodili u prošlosti.

## 7.4. EKSPERIMENTALNI NACRT

### 7.4.1. Osnovna obilježja eksperimentalnih istraživanja

Riječ eksperiment dolazi od latinskog *experimentum*, a ta je riječ derivirana od glagola *experior*, *experiri*, što znači „testirati" i „osjećati". Analogna je grčka riječ *empeiria*. U doba renesanse te riječi dobivaju današnja značenja pa se eksperiment koristi za pažljivo planirane i kontrolirane testove hipoteza, a empirija ima značenje bilježenja iskustva (npr. „empirijski podatci").

Eksperimentalni nacrt u pravilu je najbolji istraživački nacrt zbog toga što najbolje i najpouzdanije omogućuje utvrđivanje uzročno-posljedičnih odnosa. U eksperimentalnom nacrtu, naime, istraživač ima bolju kontrolu nad svim elementima istraživačkog procesa, u usporedbi s ostalim istraživačkim nacrtima. Drukčije rečeno, valjanost uzročno-posljedičnog zaključivanja na visokoj je razini u eksperimentalnim istraživanjima jer istraživač dobro kontrolira sva tri elementa koji su potrebni za utvrđivanje kauzalnosti – (1) korelacija (kovarijacija), (2) odgovarajući vremenski slijed (uzrok dolazi prije posljedice) i (3) isključivanje utjecaja trećih varijabli (alternativnih objašnjenja). Kako ćemo vidjeti, sama činjenica da istraživač određuje da se potencijalni uzrok pojavljuje prije posljedice, kao i da se slučajnim izborom sudionika eksperimenta isključuje utjecaj trećih varijabli, čine ovaj nacrt dobrim izborom u određenim okolnostima, tj. u slučajevima kada je provediv.

***Eksperimentalni nacrt uključuje smišljeno mijenjanje nekih pojava kako bi se utvrdilo kako će navedene promjene utjecati na neke druge pojave.***

Varijable koje se koriste u eksperimentima možemo podijeliti na:

1. nezavisne varijable,
2. zavisne varijable.

*Nezavisne* su varijable one varijable koje eksperimentator ima pod kontrolom i čiji utjecaj na zavisne varijable želi utvrditi. Drukčije rečeno, u eksperimentu istraživač namjerno mijenja nezavisnu varijablu (ili više njih). Manipulacija nezavisnom varijablom može se napraviti na dva osnovna načina (Christiansen, 1997; navedeno prema Milasu, 2005:107-109):

1. eksperimentalna manipulacija,
2. upravljanje individualnim razlikama.

Za vrijeme *eksperimentalne manipulacije* mijenjamo situacije u kojima se ispitanici nalaze. Npr., u istraživanju skupinu ljudi izlažemo različitoj količini medijskog nasilja te nakon toga mjerimo njihovu količinu agresivnog ponašanja. Druga je vrsta eksperimentalne manipulacije manipuliranje uputama. Npr., ispitanicima u eksperimentu opisujemo situaciju traženja povišice na poslu, ali polovici ispitanika kažemo da povišicu traži muškarac, a drugoj polovici da je u pitanju žena. Nakon toga ispitanike pitamo smatraju li da je povišica opravdana ili ne, pokušavajući utvrditi postoje li spolni stereotipi u tom pogledu (hoće li veći broj ispitanika reći da je povišica opravdana kada je u pitanju muškarac ili žena).

*Upravljanje individualnim razlikama* ispitanike svrstava u različite skupine na osnovi nekog obilježja koje imaju. Primjerice, ispitanike svrstamo u različite skupine na osnovi stupnja obrazovanja te pokušavamo utvrditi hoće li te skupine u nekom eksperimentu pokazati različiti stupanj konformizma. Upravljanje individualnim razlikama bliže je kvazieksperimentu jer često nismo sigurni postoji li utjecaj neke druge nezavisne varijable. U gornjem primjeru na stupanj konformizma mogla bi utjecati i inteligencija, koja je povezana sa stupnjem obrazovanja. Drukčije rečeno, obrazovaniji pojedinci možda su manji konformisti jer su inteligentniji, pa ne možemo pouzdano reći da je stupanj obrazovanja uzročno-posljedično povezan s konformizmom.

U ovisnosti o tome je li u nezavisnoj varijabli riječ o prisutnosti nekog modaliteta ili o različitim razinama prisutnosti toga modaliteta, nezavisne varijable možemo podijeliti na (Mejovšek, 2008: 119):

1. kvalitativne,
2. kvantitativne.

Primjerice, želimo napraviti eksperiment kojim treba utvrditi utječe li izlaganje medijskom nasilju na stvarnu agresivnost. Ako nezavisnu varijablu postavimo tako da ima samo dva modaliteta – izlaganje medijskom nasilju ili ne – tada je riječ o kvalitativnoj varijabli. Ako istražujemo različite količine izloženosti medijskom nasilju i njihov utjecaj na agresivnost, tada je riječ o kvantitativnoj nezavisnoj varijabli.

*Zavisne su (kriterijske) varijable* one varijable čije se mijenjanje pod utjecajem nezavisne varijable ispituje u eksperimentu. Drukčije rečeno, mijenjanjem nezavisne varijable u eksperimentu ispitujemo kako se mijenja zavisna varijabla. U gornjem bi primjeru zavisna varijabla bila agresivnost u stvarnom životu, a nezavisna izloženost medijskom nasilju.

U ovisnosti izlažemo li utjecaju različitih razina nezavisne varijable istu skupinu ispitanika ili različite skupine, eksperimentalne nacrte možemo podijeliti na dvije vrste:

1. Eksperimentalni nacrt „unutar ispitanika“ (eng. *within subject design*),
2. Međugrupni eksperimentalni nacrt (eng. *between group design*).

Pođimo od prepostavke da želimo eksperimentalnim načinom utvrditi utječe li interkulturna edukacija na smanjenje etnocentrizma. Ako bismo jednu skupinu ispitanika izložili interkulturalnoj edukaciji te nakon toga mjerili pokazuje li ta skupina ispitanika povećani stupanj tolerancije prema drugim kulturama ili etničkim grupama, tada bi koristili eksperimentalni nacrt „unutar ispitanika“. U slučaju da je jedna skupina ispitanika prošla interkulturnu edukaciju, a druga ne, te kad bismo nakon toga mjerili razlikuju li se te dvije skupine u toleranciji prema drugim kulturama, tada bismo koristili međugrupni eksperimentalni nacrt. Pri tome treba napomenuti da nezavisna varijabla može imati više od dvije razine, neovisno o tome o kojem je eksperimentalnom nacrtu riječ. Primjerice, u gornjem slučaju mogli smo dvije grupe ispitanika (dvije ekperimentalne grupe) izložiti dvjema različitim interkulturnim edukacijama, a jedna ne bi prošla nikakvu edukaciju (kontrolna skupina). Eksperimentalne grupe mogli bismo podijeliti i prema intenzitetu edukacije – jedna bi grupa mogla proći jednotjednu, a druga dvotjednu edukaciju i sl. U eksperimentu se može upotrijebiti i više od jedne intervencije, odnosno nezavisne varijable. Primjerice, u gornjem primjeru mogli smo istražiti utjecaj tri različite vrste interkulturne edukacije (prva nezavisna varijabla) i duljine trajanja edukacije (jednotjedna ili dvotjedna – druga nezavi-

sna varijabla). Ako bismo u svaku od ovako formiranih skupina stavili određeni broj slučajno izabranih sudionika (npr. deset po skupini), tada bismo dobili tzv. faktorijalni eksperiment. U ovom bi slučaju bilo riječ o 3 x 2 faktorijalnom eksperimentu jer imamo dvije nezavisne varijable od kojih prva ima tri, a druga dvije razine. Valja napomenuti da pri većem broju nezavisnih varijabli postaje sve složenije interpretirati njihove moguće interakcije.

U ovisnosti o tome koliko se puta zavisna varijabla mjeri, možemo razlikovati dva temeljna eksperimentalna nacrta:

1. pretest-posttest,
2. posttest.

U nacrtu *pretest-posttest* zavisna se varijabla mjeri i prije početka eksperimenta, kako bi se vidjelo jesu li eksperimentalna i kontrolna grupa u njoj izjednačene, i nakon uvođenja nezavisne varijable. Dok se u nacrtu *posttest* zavisna varijabla mjeri samo nakon uvođenja nezavisne varijable, tj. na kraju eksperimenta. Posttest nacrt upotrebljava se onda kad imamo jake razloge vjerovati da su prije početka eksperimenta obje grupe izjednačene u zavisnoj varijabli.

Shematski prikaz *pretest-posttest* međugrupnog eksperimentalnog nacrta izgledao bi ovako (Milas, 2005: 165):

| | | | | |
|---|---|---|---|---|
| Eksperimentalna grupa - | S | $O_1$ | E | $O_2$ |
| Kontrolna grupa - | S | $O_3$ | | $O_4$ |

Objašnjenje simbola:

S – slučajno raspoređivanje u grupe

O – mjerenje zavisne varijable

E – eksperimentalna intervencija (nezavisna varijabla)

U primjeru s istraživanjem utjecaja interkulturne edukacije na stupanj tolerancije, zavisna varijabla („O“) bio bi stupanj tolerancije, a eksperimentalna intervencija („E“, zavisna varijabla) odnosila bi se na interkulturnu edukaciju.

Ponekad se, najčešće zbog praktičnosti ili pokušaja da početnim mjerenjem ne senzibiliziramo ispitanike, prvo mjerenje ispušta, pa imamo međugrupni nacrt s mjerenjem samo poslije intervencije (posttest). Senzibilizacija se odnosi na činjenicu da ispitanici pod utjecajem prvog mjerenja mogu promijeniti ponašanje. Na primjer, mogu zapamtiti odgovore na prvom mjerenju i ponoviti ih i na drugom mjerenju zavisne varijable.

Shematski prikaz posttest međugrupnog eksperimentalnog nacrta izgledao bi ovako:

| | | | |
|---|---|---|---|
| Eksperimentalna grupa - | S | E | $O_1$ |
| Kontrolna grupa - | S | | $O_2$ |

Nedostatak ovoga nacrta je da ne znamo kakve su bile početne razlike između grupa (nema početnoga mjerenja), no slučajan izbor ispitanika uz veći uzorak trebao bi osigurati da te razlike ne budu znatno velike i ne ugroze valjanost eksperimenta.

Sažmimo sve do sada navedeno u jednom primjeru. Dittmar, Halliwell i Ive (2006, navedeno prema Shaughnessyju i sur., 2003: 188-193) proveli su istraživanje čiji je cilj bilo utvrditi utječe li tip ljepote prikazan u dječjim igračkama/lutkama na nezadovoljstvo djevojčica vlastitim izgledom. Hipoteza je bila da će nerealistični prikaz žene u Barbie lutkama utjecati na navedeno nezadovoljstvo kod djevojčica najranije dobi. U njihovu istraživanju sudjelovale su petogodišnje djevojčice koje su podijeljene u tri skupine, pri čemu je svrstavanje u skupine bilo određeno na slučajan način. Svim trima skupinama djevojčica ispričana je priča o djevojci „Miri" koja se priprema za odlazak na zabavu te odlazi u kupovinu. Svim trima skupinama prikazane su slike vezane za kupovinu i rođendansku zabavu. Pri tome je u jednoj skupini ulogu Mire igrala lutka Barbie, u drugoj lutka Emme koja ima tjelesne proporcije bliže stvarnim ženama, a u trećoj su skupini prikazani samo događaji bez aktera (bez ikakve lutke). Nakon toga je mjereno nezadovoljstvo vlastitim izgledom, i to tako da su djevojčice među ponuđenim ilustracijama ženskog tijela (koje su išle od izrazito mršavih do izrazito pretilih) trebale zaokružiti izgled koji najbolje opisuje kako trenutno izgledaju te izgled koji najbolje opisuje kako bi željele izgledati. Udaljenost između stvarnosti i ideala mjeren brojem ilustracija koje se nalaze između izabranih ilustracija označavala je mjeru nezadovoljstva vlastitim izgledom. U ovom se slučaju eksperimentalna manipulacija odnosila na tri različita eksperimentalna uvjeta, pri čemu je jedan (lutka Emme) uveden kako bi se eliminirala mogućnost da prikazivanje bilo kakvog ljudskog tijela (bilo kakve lutke u eksperimentu) utječe na nezadovoljstvo vlastitim izgledom. U pitanju je bio posttest nacrt, vjerojatno zbog pretpostavke da bi dva mjerenja u vrlo kartkom razmaku dala vrlo slične rezultate zbog zapamćivanja odgovora, što bi onemogućilo utvrđivanje učinka nezavisne varijable.

Osim eksperimenata koji se provode u laboratorijskim uvjetima, česti su i oni koji se provode u prirodnim uvjetima, a obično su vezani za konkretne progra-

me i intervencije. Dobri su primjeri eksperimentalne intervencije koje provodi američka vlada s ciljem poboljšavanja društvenog položaja depriviranih skupina. Primjerice, vjerojatno je najstariji takav program tzv. Head Start, čiji je cilj pružiti sveobuhvatnu pomoć djeci iz obitelji nižeg društvenog položaja, a koja se odnosi na predškolsko obrazovanje te poboljšavanje prehrane i zdravlja. Kao zavisne varijable mjere se promjene obrazovnih ishoda, devijantnog ponašanja, emocionalne prilagođenosti i slični ishodi koji bi trebali biti poboljšani ovakvom vrstom intervencije. Sličan je, iako vremenski ograničen, i tzv. Moving to Opportunity for Fair Housing (MTO) koji je provođen 1990-ih godina u pet američkih gradova. Sudionici eksperimenta, obitelji nižeg socioekonomskog statusa, bile su nasumično određene u tri skupine. Prva je skupina dobila vaučere koje su mogli upotrijebiti za plaćanje stanarine u „boljim" četvrtima tijekom prve godine, a nakon prve godine vaučerima su stanarinu mogli platiti gdje god su htjeli. Ova je grupa prilazila i savjetovanje vezano uz pronalaženje adekvatnog stanovanja. Druga je skupina, koja nije dobila bilo kakvo stanovanje, vaučere mogla iskoristiti gdje god je htjela, a treća nije dobila vaučere iako je mogla dobiti druge vrste socijalnih beneficija na koje je i inače imala pravo. Cilj je ovog eksperimenta bio ekonomsko-sociološki. Ekonomski je cilj bio provjeriti je li ovakav način subvencioniranja stanarina za osobe nižeg socioekonomskog statusa isplativiji od klasičnog oblika izgradnje socijalnih stanova. Sociološki je cilj bio utvrditi na koji će se način, ako uopće, promijeniti pojedini individualni ishodi (uspjeh na tržištu rada, sklonost počinjenju kriminala, obrazovni ishodi, osjećaj zadovoljstva životom i sl.) nakon što se osobe presele u četvrti s boljim socijalnim sastavom stanovništva.[65] Kako smo napomenuli u poglavlju o istraživačkoj etici, ovakvi eksperimenti za sobom povlače pitanje etičnosti načina izbora osoba koje će biti izloženi određenoj, potencijalno korisnoj intervenciji, i onih koji neće imati takvu mogućnost.

### 7.4.2. Eksperimentalna kontrola

Osnovno pitanje valjanosti svakog eksperimenta predstavlja tzv. kontrola, odnosno stupanj u kojemu eksperimentator ima kontrolu nad svim onim čimbenicima koji, uz nezavisnu varijablu, imaju utjecaj na zavisnu varijablu. Primjerice,

[65] Analize ovakvih programa uglavnom pokazuju mješovite i nekonzistentne rezultate eksperimentalnih intervencija. Primjerice, MTO eksperiment nije doveo do boljeg položaja na tržištu rada, ali je povećao osjećaj zadovoljstva i sigurnosti osoba koje su se preselile u bolje četvrti. U mlađih djevojaka preseljenjem se smanjila vjerojatnost delinkventnog ponašanja, a u mladića ta se vjerojatnost čak i povećala. Nije utvrđeno ni znatnije poboljšanje obrazovnih ishoda. O samom eksperimentu više u: Shroder i Orr (2012).

u primjeru s utjecajem medijskog nasilja na stvarnu agresivnost sigurno je da na agresivnost pojedinca utjecaj imaju i njegovo biološko naslijeđe, obiteljski odgoj, trenutna životna situacija (frustracije) i sl. Ako je skupina koju izlažemo medijskom nasilju posve slučajno u prosjeku češće agresivna, tj. ima navedene osobine, tada u ovome eksperimentu nećemo dobiti pravu sliku o utjecaju medijskog nasilja, tj. nećemo moći utvrditi uzročno-posljedični odnos. Naravno, kontroliraju se samo oni čimbenici za koje se sumnja da bi mogli imati utjecaj na zavisnu varijablu jer u istraživanju nikada nije moguće u potpunosti izjednačiti sve čimbenike u različitim grupama ili u različitim mjerenjima na istim ispitanicima. Primjerice, eksperimentalna i kontrolna grupa mogu biti smještene u sobama različite veličine ili se eksperiment u kontrolnoj grupi može odigrati vremenski malo kasnije od onoga u kontrolnoj, no to nije važno ako veličina sobe i doba dana nisu povezani s istraživanim varijablama.

U eksperimentima se moraju kontrolirati tri skupine čimbenika (prema Milasu, 2005: 115-116):

1. fizički čimbenici;
2. pristranost sudionika u eksperimentu;
3. osobna obilježja ispitanika.

*Fizički čimbenici* odnose se na uklanjanje svih vanjskih čimbenika koji bi mogli utjecati na zavisnu varijablu (npr. buka, temperatura i sl.), kao i na uravnotežene svih uvjeta koji bi mogli djelovati na zavisnu varijablu (npr. mijenjanje rasporeda izlaganja različitim oblicima nezavisne varijable).

*Pristranost sudionika* u eksperimentu odnosi se kako na pristranost ispitanika, tako i na pristranost eksperimentatora. Pristranost do koje dolazi zbog svijesti ispitanika da sudjeluju u eksperimentu (i zbog čega mijenjaju uobičajeno ponašanje) obično se naziva *Hawthorne efekt*. Naime, skupina istraživača 30-ih godina 20. stoljeća istraživala je utjecaj poboljšavanja radnih uvjeta na proizvodnost rada u tvornici Hawthorne jedne američke tvrtke. Eksperimentalnoj skupini uvjeti rada su poboljšani, a kontrolnoj su ostali isti. Rezultati su, međutim, pokazali da je i kontrolna skupina postigla znatno bolju proizvodnost rada jer su radnici osjetili da se na njih obraća pozornost i prati ih se, počeli su se natjecati s eksperimentalnom skupinom i sl. To istraživanje, osim što je pokazalo da odnos prema radnicima može utjecati na njihov učinak, pokazalo je i da u eksperimentima treba obratiti pozornost na činjenicu da ispitanici znaju da sudjeluju u eksperimentu, odnosno da to može promijeniti njihovo ponašanje.

Pristranost eksperimentatora odnosi se na činjenicu da očekivanja istraživača mogu utjecati na rezultate eksperimenta. Primjerice, u jednom su istraživanju (Rosenthal i Jacobson, 1968.) istraživači rekli nastavnicima da se od jedne skupine učenika može očekivati veći napredak u usvajanju školskog gradiva (budući da su inteligentniji), iako je u stvarnosti ta skupina učenika bila izabrana posve slučajno (i nisu bili inteligentniji). Nakon određenog vremena pokazalo se da su ti učenici doista i postigli bolji školski uspjeh i da im se povećao kvocijent inteligencije, u usporedbi s drugom skupinom učenika, vjerojatno zato jer su se nastavnici drukčije odnosili prema njima (više obraćali pažnju na njih, više ih ohrabrivali i sl.). To istraživanje pokazuje da način na koji se eksperimentator odnosi prema pojedinim ispitanicima može utjecati na njihove rezultate. Radi jasnoće navedimo primjer medicinskog istraživanja učinkovitosti nekog lijeka. Ako eksperimentator vjeruje da je lijek doista učinkovit, može se na drukčiji način odnositi prema skupini ispitanika koja je dobila lijek (eksperimentalna skupina), nego prema onima koji nisu dobili lijek (kontrolna skupina). Ispitanici bi mogli shvatiti da se prema njima odnosi drukčije te bi lijek mogao djelovati zbog autosugestije, a ne zbog stvarne učinkovitosti.

Kako bi se otklonile pristranosti sudionika u eksperimentu, koriste se dvije metode (nacrta):

1. slijepi (*blind*) nacrt,
2. dvostruko slijepi (*double blind*) nacrt.

U prvom slučaju (*slijepi nacrt*) ispitanici ne znaju jesu li dio eksperimentalne skupine ili su dio kontrolne skupine. U medicinskim istraživanjima ispitanici u kontrolnoj skupini dobiju tzv. placebo.[66] Placebo se vrlo jednostavno primjenjuje u medicinskim istraživanjima, no česte su situacije u društvenim i humanističkim znanostima u kojima je placebo teško ili nemoguće primijeniti. Npr., ako jednu skupinu učenika poučavamo iz udžbenika prema kojemu se do tada radilo, a drugu prema novome udžbeniku, teško je primijeniti placebo. Naime, učenici će biti svjesni koji od njih rade po novom, a koji po starom udžbeniku i mogu promijeniti svoje ponašanje – npr. oni koji rade po novome mogu biti uvjereni da su izabrani jer su sposobniji, pa to može povećati njihovu motivaciju, a time i rezultate. Stoga je u društveno-humanističkim znanostima pristranost ispitanika najbolje kontrolirati tako da ispitanici ne znaju što je pravi predmet ekspe-

[66] Placebo se odnosi na tretman koji je prividno sličan eksperimentalnom tretmanu, ali stvarno nema nikakve učinkovitosti. Na primjer, u istraživanjima učinkovitosti lijekova placebo je supstanca koja sliči lijeku, ali nema nikakvo djelovanje. Na taj način ispitanici iz kontrolne skupine također misle da su dobili lijek, čime se kontrolira učinak autosugestije.

rimentalne intervencije. Primjerice, u ranije navedenom primjeru istraživanja postojanja spolnih stereotipa eksperimentalna varijacija sastojala se u manipuliranju uputama, tj. polovici ispitanika rečeno je da je u opisanoj situaciji riječ o muškarcu, a polovici da je riječ o ženi. Međutim, niti jedna od ove dvije skupine nije znala što je rečeno drugoj skupini, odnosno nije im otkriveno u čemu se sastoji eksperimentalna manipulacija.

U *dvostruko slijepom eksperimentu* ni eksperimentator koji obavlja intervenciju ne zna u kojem je slučaju riječ o eksperimentalnoj, a u kojem o kontrolnoj grupi. Na taj se način onemogućava nesvjesno eksperimentatorovo kontaminiranje rezultata, npr. drukčije ponašanje prema eksperimentalnoj u odnosu na kontrolnu skupinu, a mnoga su istraživanja pokazala, kako je ranije napomenuto, da se to može dogoditi.

Slijepi i dvostruko slijepi eksperiment u društvenim znanostima često mogu biti teško izvodivi jer se ne može onemogućiti svijest ispitanika o tome da sudjeluju u istraživanju. Uzmimo jedan primjer iz istraživanja obrazovnih učinaka. U SAD-u često se primjenjuje tzv. vaučerski model obrazovanja u kojemu roditelji biraju u koje će škole slati svoju djecu, a država financira škole na temelju broja učenika koji ih izaberu. Ovaj je model jedna od mogućih realizacija tržišnog pristupa obrazovanju, pri čemu se pretpostavlja da će, između ostalog, obrazovni učinci biti bolji od onih u javnim školama. Ovakve situacije služe kao prirodni eksperiment jer je moguće usporediti obrazovne rezultate učenika koji su iskoristili vaučer i pohađaju neku od privatnih škola i onih koji su se javili za vaučer, ali nisu uspjeli dobiti mjesto u školama zbog nedostatka mjesta. S obzirom na to da se u takvim situacijama (manjak mjesta) odluka koji će učenici realizirati vaučer donosi lutrijom, tj. slučajnim izvlačenjem, za prepostaviti je da su učenici koji su dobili mjesto i oni koji ga nisu dobili slični prema svim relevantnim čimbenicima. Primjerice, njihova obrazovna motivacija vjerojatna je slična, što ne bi bio slučaj kada bi se uspoređivali učenici koji su se javili za vaučere i one koji to nisu napravili. Međutim, ovakav je prirodni eksperiment kontaminiran činjenicom da i oni koji su dobili mjesto i oni koji ga nisu dobili znaju da sudjeluju u projektu i znaju vlastiti status (Lubienski i Brewer, 2017). Drugim riječima, može se dogoditi da prilika koju su dobili oni koji su izvlačenjem osigurali mjesto u privatnoj školi djeluje kao dodatni motivator, a da onima koji nisu imali sreće padne motivacija za obrazovanje. Dakle, moglo bi se reći da je ovaj prirodni eksperiment slijep, kao i većina prirodnih eksperimenata, jer eksperimentori/istraživači nemaju utjecaja na ponašanje sudionika eksperimenta. Međutim, eksperiment nije dvostruko

slijep jer sami sudionici eksperimenta, odnosno učenici, znaju vlastiti status, tj. znaju pripadaju li eksperimentalnoj ili kontrolnoj skupini.

Kada je smanjivanje utjecaja eksperimentatora u pitanju, osim dvostruko slijepog nacrta, može se navesti i još nekoliko dodatnih strategija (prema Milasu, 2005: 213-215).

1. povećavanje broja eksperimentatora,
2. smanjivanje broja kontakata između ispitanika i eksperimentatora,
3. standardizacija eksperimentalnog postupka,
4. primjena kontrolne grupe poznatih očekivanja.

*Povećavanjem broja eksperimenatora* smanjuje se pogreška jer se pogreške većeg broja eksperimentatora tendencijski međusobno poništavaju.[67]

*Smanjivanjem broja kontakata* između ispitanika i eksperimentatora te *standardizacijom* situacije također se smanjuje mogući utjecaj eksperimentatora jer se sužava prostor za subjektivnost, odnosno eksperimentatorove kontaminacije rezultata.

*Primjena kontrolne grupe poznatih očekivanja* odnosi se na unošenje očekivanja eksperimentatora u sam eksperiment i statističku analizu njegova učinka. Npr., u eksperimentu u kojem bi eksperimentator imao različita očekivanja od muškaraca i žena kada je u pitanju uspješnost obavljanja nekog zadatka, ova očekivanja (spolni stereotipi) bi se izmjerili, te bi se nakon toga statističkom analizom utvrdilo postoji li razlika u uspješnosti obavljanja zadatka između muškaraca i žena neovisna o različitim očekivanjima.[68]

*Osobna obilježja* uklanjaju se nekim oblikom raspoređivanja u eksperimentalnu i kontrolnu grupu. U međugrupnim eksperimentalnim nacrtima kao metoda kontrole koristi se kontrolna grupa ispitanika. Naime, eksperimentalna i kontrolna grupa izjednače se u rezultatu na zavisnoj varijabli i svim drugim relevantnim čimbenicima, a jedina razlika je u djelovanju nezavisne varijable. Naime, u eksperimentalnoj grupi inducira se djelovanje nezavisne varijable, a u kontrolnoj ne. Primjerice, pri istraživanju utjecaja interkulturne edukacije na smanjenje etnocentrizma ispitanike bi prvo izjednačili u svim relevantnim čimbenicima (ob-

---

67 Npr. jedan će eksperimentator biti srdačniji s kontrolnom, a drugi s eksperimentalnom skupinom pa će se ove pogreške međusobno poništavati.

68 Pretpostavka je da bi eksperimentator mogao svoja očekivanja prenijeti na ispitanike, npr. iskazivati više podrške ženskim ili muškim sudionicima eksperimenta.

razovanje, spol i sl.) te ih podijelili na eksperimentalnu i kontrolnu grupu. To se najčešće radi na tri načina (prema Milasu, 2005: 158):

1. slučajnim izborom,
2. randomizacijom,
3. izjednačavanjem u parovima.

*Slučajan izbor* odnosi se na situaciju kada ispitanici uključeni u eksperiment čine slučajan uzorak istraživane populacije. Primjerice, u slučaju da istražujemo studentsku populaciju nekog sveučilišta, s popisa svih studenata slučajnim bi izborom izabrali jednak broj studenata koji bi bili uključeni u eksperimentalnu, odnosno kontrolnu grupu. Slučajan izbor ispitanika omogućuje dobru unutrašnju i osobito vanjsku valjanost eksperimenta, ali je ponekad vrlo neekonomičan i teško ostvariv.

*Randomizacijom* ispitanike stavljamo u eksperimentalnu ili kontrolnu grupu na osnovi slučajnog izbora (npr. pisanjem imena na papir i slučajnim izvlačenjem papira iz posude), ali uzorak ispitanika koji služe za izbor nije slučajan. Dakle, randomizacija se od slučajnog izbora razlikuje na način da uzorak ispitanika koje se randomizacijom raspodjeljuje u eksperimentalnu i kontrolnu grupu nije slučajno izabran iz populacije. Primjerice, istražujemo studente nekog sveučilišta i u prvom koraku izaberemo prigodan uzorak (studente koji su nam dostupni), a nakon toga slučajnim izborom iz tog prigodnoga uzorka ispitanike svrstavamo u eksperimentalnu i kontrolnu grupu. Izbor ispitanika randomizacijom smanjuje vanjsku valjanost eksperimenta,[69] ali je često vrlo praktičan.

Kad je riječ o *izjednačavanju u parovima*, pronalazimo parove ispitanika koji su vrlo slični u svim čimbenicima te jednog od njih stavljamo u eksperimentalnu, a drugog u kontrolnu grupu. Na primjer, u istraživanju o utjecaju interkulturne edukacije na smanjenje etnocentrizma dva ispitanika koji imaju istu dob, spol, dohodak i stupanj obrazovanja činili bi par. Jedan od njih bi ušao u eksperimentalnu, a drugi u kontrolnu skupinu. Nakon toga bi eksperimentalna skupina prošla interkulturnu edukaciju, a kontrolna ne. Na kraju bismo mjerili razlike u stupnju etnocentrizma između eksperimentalne i kontrolne skupine. Ako bi razlike postojale, mogli bismo ih pripisati interkulturnoj edukaciji zbog toga što su skupine bile izjednačene u svim drugim važnim čimbenicima (ranije spomenuto Millovo pravilo razlike). Izjednačavanje u parovima osobito je korisno ako smatramo da je u našemu eksperimentalnom nacrtu važno kontrolirati samo jednu varijablu. Npr., pretpostavimo li da bi na stupanj usvajanja interkulturalnih sadržaja izraziti utjecaj mogao imati stupanj obrazovanja, tada ćemo ispitanike

[69] Nikada nismo posve sigurni da nalazi utvrđeni eksperimentom vrijede i za ukupnu populaciju.

podijeliti prema stupnju obrazovanja te ih nakon toga u parovima podijeliti u odgovarajuću skupinu.[70]

Osim ovih metoda, ponekad se upotrebljavaju i korištenje homogenih ispitanika (eng. *matching by constancy*) i uključivanje kontrolne varijable u eksperimentalni nacrt. U prvom slučaju eksperimentalna i kontrolna grupa izjednačavaju se u relevantnim varijablama tako da se koriste sudionici istraživanja koji imaju samo jedan modalitet (vrijednost) te varijable. Primjerice, ako smatramo da bi varijabla spola mogla biti važna, provodimo istraživanje u kojemu sudjeluju samo žene ili samo muškarci. S obzirom na to da varijabla ne pokazuje varijaciju (svi su sudionici isti), ta varijabla ne može imati utjecaj na uzročno-posljedičnu vezu, odnosno unutarnju valjanost eksperimentalnog istraživanja. Uključivanja kontrolne varijable u nacrt znači da varijablu za koju smatramo da može imati „smetajući učinak" u nacrt uključimo kao nezavisnu varijablu. Primjerice, ako smatramo da će u eksperimentu u kojem se ispituje utjecaj medijskog nasilja na stvarno nasilje djevojčice i dječaci reagirati na različite načine, odnosno da će utjecaj medijskog nasilja biti jače izražen kod djevojčica, tada ćemo stvoriti četiri grupe, tj. postojat će dvije eksperimentalne i dvije kontrolne grupe. U prvoj eksperimentalnoj grupi bit će djevojčice, a u drugoj dječaci. Ovakav se nacrt obično naziva randomizirani blok-dizajn, zato što eksperimente provodimo prema blokovima, odnosno modalitetima varijable koju smatramo „ometajućom".

Jedna vrst blok-randomizacije provodi se u situacijama kada eksperiment traje dulje pa želimo onemogućiti utjecaj svih vrsta učinka vremena koji se mogu pojaviti. Primjerice, uzmimo da želimo napraviti eksperiment s četiri vrste individualne edukacije, uz napomenu da ćemo edukacije provoditi na ispitanicima koji nam još nisu dostupni, ali će to postati tijekom razdoblja od dvije godine. Različite edukacije označimo slovima A, B, C i D. Ako predviđamo da ćemo u istraživanju imati 60 ispitanika, tada nam prvi blok može biti (B, C, A, D), drugi (C, D, B, A) itd., pri čemu prva četiri ispitanika redom dobivaju edukacije B, C, A, D, blok od sljedeća četiri ispitanika C, D, B, A itd. Ako bismo prvih 15 ispitanika izložili edukaciji A, drugih 15 edukaciji B itd., tada bi na rezultate mogli utjecati neki učinci vremena koji bi se mogli dogoditi. Primjerice, tada bi edukaciju D pohađali studenti koji su najkasnije upisali kolegij, odnosno pripadaju sljedećoj generaciji studenata, a time bi mogli biti i drukčiji od studenata koji su prošli druge tipove edukacija.

Valja napomenuti da ni slučajno raspoređivanje ispitanika u grupe u potpunosti ne jamči da će eksperimentalna i kontrolna grupa biti izjednačeni u svim rele-

[70] Npr., imamo li dvojicu ispitanika sa završenom srednjom školom, jednog ćemo uvrstiti u eksperimentalnu, a drugoga u kontrolnu grupu.

vantnim osobnim čimbenicima. Naime, sasvim se slučajno može dogoditi, osobito ako su u pitanju manji uzorci, da nam u jednu od grupa dođu sudionici koji imaju drukčija obilježja od onih koji su u drugoj grupi. Primjerice, uzmimo da istražujemo utjecaj socijalnog statusa osobe koja preporučuje određeni proizvod u promidžbenoj poruci na sklonost ispitanika da preporučeni proizvod ocijene na povoljan (ili nepovoljan način). Pretpostavimo da smo jednoj grupi ispitanika prikazali poruku u kojoj proizvod preporučuje osoba višeg socijalnog statusa, a kod druge grupe u pitanju je osoba nižeg socijalnog statusa. S obzirom na to da smo ispitanike u grupe rasporedili slučajno, pretpostavljamo da je početna percepcija toga proizvoda bila vrlo slična u obje grupe. No to možda nije tako, odnosno može se dogoditi da se u prvoj grupi nalazi više osoba koje vole taj proizvod. Ako mjerimo samo sklonost navedenom proizvodu nakon izlaganja propagandnoj poruci, možemo krivo zaključiti da socijalni status osobe koja preporučuje proizvod utječe na uspješnost poruke. Rješenje ovakve situacije nalazi se u dopuni eksperimenta statističkom kontrolom. U navedenom bi slučaju to bila početna sklonost proizvodu, odnosno sklonost koja bi se mjerila prije izlaganja poruci. Nakon toga bi se pomoću odgovarajućeg statističkog modela (najčešće linearne regresije ili analize kovarijance) utvrdilo koliki je utjecaj na procjenu proizvoda nakon izlaganja poruci imao socijalni status osobe koja preporučuje proizvod, a koliki prethodna sklonost samome proizvodu. Zbog čega onda uopće radimo eksperiment, odnosno zašto ne provedemo korelacijsko istraživanje uz statističku kontrolu? Razlog se nalazi u činjenici da nikad nismo sigurni jesmo li statističkom kontrolom uzeli u obzir sve važne varijable koje bi mogle utjecati na naš zaključak, a pri slučajnom raspoređivanju ispitanika u grupe u provođenju eksperimenta kontroliramo i sve takve čimbenike/varijable kojih u tom trenutku možda uopće nismo svjesni. No navedeni primjer upućuje na to da se statistička kontrola i eksperiment ne shvate kao ili-ili situacija, nego kao i-i situacija. Drugim riječima, često je podatke dobivene eksperimentom dobro dopuniti statističkom kontrolom relevantnih varijabli (Darlington i Hayes, 2017).

U eksperimentalnim nacrtima „unutar ispitanika“ postoji manja opasnost utjecaja drugih varijabli na rezultat, budući da se mjerenja rade na istim ispitanicima. U slučaju eksperimena s interkulturnom edukacijom, eksperiment „unutar ispitanika“ odnosio bi se na situaciju u kojoj istoj skupini prvo mjerimo stupanj tolerancije, zatim ih izlažemo interkulturno edukaciji te ponovno mjerimo stupanj tolerancije. U ovom slučaju ne može doći do „smetajućeg“ djelovanja inteligencije, obrazovanja i sl., jer je riječ o istim ispitanicima. Međutim, postoji mogućnost djelovanja drugih čimbenika koji mogu kontaminirati rezultate, od kojih se mogu izdvojiti (Mejovšek, 2008: 122):

1. umor,
2. dosada,
3. slabljenje motivacije,
4. vježba.

Primjerice, ispitujemo li utjecaj primjene dviju metoda poučavanja na stjecanje neke vještine na istim ispitanicima, može se dogoditi da se ispitanici umore nakon prvog dijela eksperimenta (nakon primjene prve metode) te da zbog toga postignu lošiji rezultat kada se primijeni druga metoda poučavanja. Ili se može dogoditi da vještinu uvježbaju tako dobro, da se primjenom druge metode ne može postići veći napredak. U ovim slučajevima nemoguće je zaključiti koja je metoda poučavanja bolja jer su rezultati kontaminirani drugim varijablama. Zbog toga se u nacrtima „unutar ispitanika" kao metoda kontrole primjenjuje tzv. *rotacija*, odnosno redoslijed izlaganja nezavisnoj varijabli nije stalan, nego se mijenja za pojedine skupine ispitanika. U spomenutom bi slučaju na polovici ispitanika primijenili prvo metodu poučavanja A, a zatim B, dok bi kod druge polovice ispitanika redoslijed bio obrnut. Na taj bi način svi remetilački čimbenici (umor, vježba i sl.) imali jednak utjecaj na oba modaliteta nezavisne varijable (u ovome slučaju metode poučavanja).

Iz navedenog je vidljivo da nacrt „unutar ispitanika" ima prednost nad međugrupnim nacrtom, jer nije potrebno učiniti izjednačavanje ispitanika, no postoje druge prijetnje valjanosti eksperimenta. Zbog toga se može reći da eksperimentalni nacrt „unutar ispitanika" ne treba koristiti onda kada:

1. djelovanje nezavisne varijable traje dugo,
2. kad varijabla ima samo dva modaliteta (postojanje ili nepostojanje nezavisne varijable).

Kad djelovanje nezavisne varijable traje dugo, nikada nismo posve sigurni što je moglo djelovati na promjene u zavisnoj varijabli. Npr., izmjerimo ekološke stavove dijela populacije nekoga grada te nakon toga provedemo medijsku kampanju s ciljem povećanja ekološke svijesti (odlaganje otpada, štednja energije i sl.). Nakon godinu dana ponovno izmjerimo ekološke stavove kako bismo utvrdili je li došlo do povećanja ekološke svijesti pod utjecajem medijske kampanje. Međutim, ako je i došlo do promjene, ne možemo biti sigurni da je do nje došlo zbog medijske kampanje. Primjerice, ako je u međuvremenu došlo do povećanja cijene energije, realno je za pretpostaviti da su se ispitanici zbog toga počeli ponašati više proekološki (npr. počeli su više štedjeti energiju).

Kad nezavisna varijabla ima dva modaliteta – postojanje ili nepostojanje – također ne možemo biti sigurni u valjanost eksperimenta jer ne možemo primijeniti rotaciju ispitanika. Primjerice, možemo polovicu ispitanika prvo poučavati, pa ne poučavati, a drugu polovicu ne poučavati, pa poučavati. No taj postupak efektivno znači da smo obje skupine poučavali, samo u različitim vremenskim točkama, pa tako nisu otklonjene moguće kontaminacije rezultata. Drukčije rečeno, rotaciju nije moguće primijeniti te je u tom slučaju bolje primijeniti međugrupni eksperimentalni nacrt.

### 7.4.3. Valjanost eksperimentalnih istraživanja

Valjanost eksperimentalnog istraživanja može se podijeliti na dvije osnovne vrste:

1. Unutrašnju valjanost,
2. Vanjsku valjanost.

Unutrašnja valjanost odnosi se sigurnost da smo u istraživanju dobro kontrolirali sve čimbenike i da se stoga može pouzdano zaključivati o povezanosti nezavisne i zavisne varijable. Dakle, eksperiment ima unutrašnju valjanost ako smo izabrali pravi nacrt istraživanja, obavili podjelu na eksperimentalnu i kontrolnu skupinu izjednačavanjem ispitanika (slučajnim izborom ili izjednačavanjem po parovima), rotirali djelovanje nezavisne varijable, kontrolirali pristranost sudionika istraživanja i sl.

Neki od čimbenika koji mogu narušiti unutrašnju valjanost su sljedeći (prema Mejovšeku, 2008: 141):

1. Povijest,
2. Sazrijevanje,
3. Instrumentacija,
4. Statistička regresija,
5. Osipanje ispitanika,
6. Kontaminacija.

*Povijest* se odnosi na promjene do kojih može doći tijekom istraživanja i koje mogu utjecati na rezultate. Na primjer, uzmimo da ispitujemo utjecaj informiranosti o drugim kulturama na smanjenje etnocentrizma. Ako se tijekom izvođenja eksperimenta u zemlji dogodi nekakav međuetnički incident i naraste stupanj etnocentrizma i netolerancije, to će sigurno narušiti rezultate našega eksperimenta, oso-

bito u slučaju nacrta „unutar ispitanika". U međugrupnom nacrtu, naime, svaki događaj bi jednako trebao djelovati i na eksperimentalnu i na kontrolnu grupu.

*Sazrijevanje* se odnosi na promjene ispitanika do kojih dolazi tjelesnim, psihološkim ili društvenim sazrijevanjem. Primjerice, u eksperimentalnom nacrtu pretpostavimo da će edukacija protiv upotrebe nasilja među mladima dovesti do smanjenja agresivnog ponašanja. Međutim, može se dogoditi da se nasilje smanji zbog sazrijevanja (starenja) ispitanika.

*Instrumentacija* se odnosi na ulogu mjernih instrumenata, tj. njihovu promjenu između dvaju mjerenja. Učinak instrumentacije može se dogoditi ako se između dva mjerenja mjerni instrument dorađuje i popravljaju mu se metrijske karakteristike ili, što je češći slučaj, ako se mjerenje obavlja opažanjem i opažači između dva mjerenja promijene kriterije opažanja (npr. postanu uvježbaniji). Učinkom instrumentacije može se smatrati i interakcija između prvog mjerenja i eksperimentalnog tretmana. Na primjer, pri ispitivanju utjecaja ekološke edukacije na formiranje proekoloških stavova, ispitanike podijelimo u eksperimentalnu i kontrolnu grupe i izmjerimo njihove ekološke stavove. Nakon toga eksperimentalna grupa prođe ekološku edukaciju, a kontrolna ne, te se ponovno izmjere ekološki stavovi te dvije grupe. Međutim, početno mjerenje ekoloških stavova moglo je senzibilizirati obje grupe te su obje zbog toga mogle postati više proekološki orijentirane. Isto tako, ispitanici pamte svoje odgovore na prvom testiranju te su ih skloni ponoviti i na drugome, čak i ako su u međuvremenu promijenili stavove. Na taj način se učinak eksperimentalnog tretmana (u ovome slučaju ekološke edukacije) ne uspijeva izmjeriti, čak i ako stvarno postoji.

*Statistička regresija* odnosi se na vjerojatnost da se, zbog nepouzdanosti mjernih instrumenata, ekstremni rezultat u jednom mjerenju pretvori u umjereni rezultat u drugom mjerenju. Na taj se način početne razlike između skupina mogu smanjiti zbog statističkih zakonitosti, a ne zbog učinka nezavisne varijable. Npr., ukoliko uzmemo skupinu ispitanika s visokim rezultatom na skali etnocentrizma i skupinu s niskim rezultatom, tada će se u sljedećem mjerenju, nakon određenog mjerenja, razlike između skupina vjerojatno smanjiti zbog statističke regresije (ispitanici koji su postigli ekstremne rezultate vjerojatno će biti više u sredini). Statistička regresija osobito je prisutna u eksperimentalnim nacrtima „unutar" ispitanika, dok se njezin učinak može kontrolirati korištenjem eksperimentalne i kontrolne grupe.

*Osipanje* ispitanika događa se zbog toga što neki ispitanici, iz različitih razloga, prestaju sudjelovati u eksperimentu. Ako su ti ispitanici slučajno drukčiji od

onih koji nastave sa sudjelovanjem, može se dogoditi da rezultati ne budu vjerodostojni, tj. da se smanji unutrašnja valjanost.

*Kontaminacija* se događa kada ispitanici saznaju nalaze li se u kontrolnoj ili eksperimentalnoj grupi, ili kada saznaju za svrhu eksperimenta u onim eksperimentima koji uključuju obmanu (skrivanje cilja istraživanja). Primjerice, može se dogoditi da ispitanici u kontrolnoj skupini saznaju da predstavljaju kontrolnu skupinu u nekom istraživanju, na što mogu reagirati na različite načine. Zamislimo situaciju u kojoj se u nekoj tvrtki radi eksperiment u kojem se variraju razni načini organizacije rada kako bi se mjerio njihov utjecaj na produktivnost rada. U tom bi slučaju kontrolna skupina, u kojoj nije bilo nikakvih promjena, tj. koja radi prema starom načinu organizacije, mogla na spoznaju da čini kontrolnu skupinu reagirati frustracijom ili čak poboljšanjem vlastite produktivnosti. Obje situacije negativno bi se odrazile na unutrašnju valjanost eksperimenta. I sâma činjenica uvođenja eksperimentalne intervencije može se smatrati nekom vrstom kontaminacije jer za sudionike eksperimenta predstavlja određenu novost na koju također mogu reagirati na različite načine. Primjerice, uvođenje nove metode poučavanja učenike može učiniti optimističnim u pogledu poboljšanja ishoda njihova učenja ili ih sama novost metode može učiniti motiviranijim nego inače.

Vanjska valjanost odnosi se na mogućnost da se rezultati eksperimenta generaliziraju na druge ljude, situacije i vrijeme. U skladu s ovom definicijom, vanjska se valjanost obično dijeli na:

1. populacijsku,
2. ekološku,
3. temporalnu.

*Populacijska* se valjanost odnosi na mogućnost da rezultate eksperimenta dobivene na jednim ispitanicima generaliziramo na cijelu populaciju. Populacijska bi se valjanost u najvećoj mjeri osigurala upotrebom slučajnog uzorka u eksperimentu, no istraživanja se, iz praktičnih razloga, najčešće rade na prigodnim uzorcima (studentima).

*Ekološka* se valjanost odnosi na mogućnost generalizacije rezultata na druge situacije. Npr. neki laboratorijski psihologijski eksperimenti pokazali su da su ljudi skloni konformizmu, tj. da će odustati od svog mišljenja ako to grupa od njih zahtijeva, čak i onda kada su potpuno uvjereni da su u pravu. Međutim, pitanje je bi li ljudi postupili na isti način u izvanlaboratorijskim situacijama (npr. možda su konformisti jer se ne žele konfrontirati kada znaju da su sudionici eksperimenta i sl.).

*Temporalna* se valjanost odnosi na mogućnost da rezultati dobiveni u eksperimentu važe i u budućnosti. S obzirom na to da se protokom vremena mijenjaju i mnoge okolnosti, zaključci iz jednog eksperimenta ne moraju vrijediti i u budućnosti. Primjerice, može se pokazati da u nekom eksperimentu ispitanici kojima se gospodarsko stanje u zemlji prikazuje lošijim, imaju negativniji stav prema strancima (zbog toga što „otimaju" radna mjesta domaćim stanovnicima). No, ta povezanost ne mora nastaviti postojati ako se gospodarska situacija u zemlji popravi.

Vanjska i unutrašnja valjanost u pravilu su u obrnuto proporcionalnom odnosu. Naime, ako kontroliramo sve čimbenike, tada povećavamo unutrašnju valjanost, no istovremeno smanjujemo vanjsku valjanost jer situacija postaje artificijelna i razlikuje se od stvarnih životnih situacija. Primjerice, u spomenutom slučaju eksperimenta s konformizmom moglo bi se pretpostaviti da se ispitanici neće jednako konformirati u situacijama kad zahtjeve upućuje poslodavac, prijatelj ili bračni partner. U eksperimentalnoj situaciji takva se kontaminacija rezultata poništava jer zahtjev za konfomiranjem upućuje samo eksperimentator ili drugi sudionici eksperimenta. Na taj je način osigurana unutrašnja valjanost, ali je upitno koliko se rezultati mogu generalizirati na druge situacije iz stvarnog života, tj. kolika je vanjska valjanost eksperimenta. S druge strane, ponavljanjem eksperimenta na drugim mjestima, u drugim vremenima i s drugim ispitanicima unosimo izvore varijacije i smanjujemo unutrašnju valjanost eksperimenta.

U skladu s navedenim, jasno je da će u laboratorijskim eksperimentima često biti upitna upravo vanjska valjanost, dok će u terenskim eksperimentima češće biti sporna unutarnja valjanost (Coolican, 1994: 77). Kako smo naveli, eksperiment s konformizmom koji je proveo Ash, ima visoku unutarnju valjanost jer su sve relevantne varijable bile pod kontrolom (broj sudionika eksperimenta, duljina crta, doba dana i sl.), ali je upitno ponašaju li se ljudi na takav način izvan laboratorijskih uvjeta te bi li se ponašali na isti način da su bili u skupini poznatih ljudi a ne u skupini stranaca. S druge strane, terenski ekspriment u kojemu bi dvije skupine učenika poučavali pomoću dvaju različitih udžbenika vjerojatno bi imao visoku vanjsku valjanost jer bi se situacija učenja odigravala upravo na način na koji se odvija u prirodnim uvjetima, tj. učenici bi vjerojatno učili na isti način kao i da nije riječ o eksperimentu. Međutim, unutarnja valjanost bi bila u opasnosti jer se u prirodnim uvjetima uvijek može dogoditi „smetajući" učinak varijabli koje eksperimentator nije uspio kontrolirati. Primjerice, moguće je da je učionica u kojoj uči jedna skupina učenika ugodnija od druge, da je izložena manjoj buci i sl.

Vanjska se valjanost u pravilu povećava ponavljanjem eksperimenta na različitim mjestima, u različitim vremenima i s ispitanicima s različitim obilježjima, kao i kombiniranjem laboratorijskih ekperimenata i eksperimenata koji se izvode u prirodnim uvjetima. Naime, i ovdje nam načelo triangulacije kaže da se vjerojatnost točnosti spoznaja dobivenih jednom vrstom eksperimenta povećava njihovim potvrđivanjem u drugom tipu eksperimenta. Jedna od strategija povećavanja vanjske valjanosti može biti i osiguranje reprezentativnosti uzorka, kao i ugrađivanje nekih varijabli koje se smatraju važnima u sam eksperimentalni nacrt. Primjerice, primjena randomiziranog blok-dizajna u kojem bi kao blok varijable bili spol i socioekonomski status osobe te neutvrđivanje povezanosti ovakvih blokova sa zavisnom varijablom povećavaju vjerojatnost da se rezultati eksperimenta mogu generalizirati i na muškarce i na žene, kao i na ljude različitih socioekonomskih statusa.

### 7.4.4. Kvazieksperimentalna istraživanja

Istraživanja koja imaju osnovnu strukturu eksperimenta, ali im nedostaje kontrola svih čimbenika kakva postoji u stvarnom eksperimentu, nazivaju se *kvazieksperimentalna istraživanja*. Nedostatak kontrole obično se odnosi na nepostojanje utjecaja istraživača na to koji će ispitanici ući u eksperimentalnu, a koji u kontrolnu skupinu, odnosno utjecaja na mijenjanje nezavisne varijable i sl. Primjerice, znanstvenica želi istražiti učinkovitost dviju metoda poučavanja matematike, ali kao grupe mora uzeti već postojeće školske razrede, umjesto nasumičnog raspodjeljivanja ispitanika u skupine. Na taj način ne može biti posve sigurna da se razredi ne razlikuju u nekim relevantnim čimbenicima. Osnovna prednost kvazieksperimentalnih istraživanja sastoji se u tome što je obično riječ o prirodnim situacijama, pa takva istraživanja imaju visoku vanjsku valjanost (ukoliko se unutrašnja valjanost uspije postići).

***Kvazieksperimentalna istraživanja slična su eksperimentalnim, ali im nedostaje razina eksperimentalne kontrole koja postoji u eksperimentalnim istraživanjima.***

Najčešći su kvazieksperimentalni nacrti sljedeći:

1. Nacrt neekvivalentne kontrolne grupe,
2. *Ex post facto* istraživanja,
3. Nacrt prekinutih mjerenja.

*Nacrt neekvivalentne kotrolne grupe* odnosi se na situaciju u kojoj razvrstavanje ispitanika u eksperimentalnu i kontrolnu grupu nije slučajno i kontrolirano, a sve ostale faze eksperimenta odvijaju se na sličan način kao i u pravom eksperimentu. Primjerice, dvije metode poučavanja primjenjuju se u dva razreda, pri čemu istraživač ne zna koja obilježja imaju učenici u ova dva razreda. Ako skupina učenika koja je učila pomoću metode A postigne bolje rezultate nego skupina koja je učila pomoću metode B, tada se može zaključiti da je prva metoda uzrok različitih rezultata. Međutim, prilikom izvođenja zaključaka treba imati u vidu da su grupe neekvivalentne, odnosno da nije upotrijebljena neka od metoda izjednačavanja pa unutrašnja valjanost istraživanja nije posve osigurana. Naime, istraživač nije mogao kontrolirati sve relevantne čimbenike, npr. učenici u prvoj skupini možda su u prosjeku inteligentniji, pa je to moglo utjecati na različite rezultate. Osim toga, neujednačenost grupa, tj. razlika u početnim (pretest) rezultatima nezavisne varijable također ima znatne posljedice i na statističko zaključivanje. Naime, pogreška pretest mjerenja u slučaju neekvivalentnih grupa može dovesti do pogrešnih zaključaka, pa je prilikom upotrebe statističkih tehnika – u ovom slučaju tzv. analize kovarijance – potrebno obaviti korekciju utemeljenu na koeficijentima pouzdanosti mjerenja (o tome više u Trochim, 2012.).

*Ex post facto* (kauzalno-komparativna) istraživanja mogu se smatrati kvazieksperimentalnim jer imaju sličnosti sa strukturom eksperimenta, ali im nedostaje utjecaj na variranje nezavisne varijable. U *ex post facto* istraživanju polazimo od zavisne varijable te naknadno nastojimo rekonstruirati koje su nezavisne varijable utjecale na nju. Na primjer, polazimo od činjenice da neki mladi pokazuju delinkventno ponašanje, a neki ne, te postavljamo hipotezu da loš školski uspjeh utječe na delinkventno ponašanje. Nakon toga skupinu učenika pokušamo izjednačiti u svim relevantnim čimbenicima osim školskog uspjeha, te pokušavamo utvrditi razlikuju li se te skupine u stupnju delinkventnog ponašanja. U pravom eksperimentu izjednačili bismo skupine u svim relevantnim čimbenicima te bi varirali školski uspjeh (što je u ovom slučaju praktično neizvedivo) i pokušali utvrditi dovodi li loš školski uspjeh do delikventnog ponašanja. Dakle, vidljivo je da *ex post facto* istraživanja idu obrnutim slijedom od klasičnih eksperimentalnih istraživanja. U spomenutom slučaju, dakle, utvrdili smo dvije skupine – delinkventne i nedelinkventne učenike – te naknadno nastojali utvrditi u čemu se razlikuju.

*Ex post facto* istraživanja, budući da im nedostaju odlike pravog eksperimenta, imaju sljedeće nedostatke:

1. Nepostojanje kontrole nad relevantnim varijablama – ujednačavanje skupina često je teško postići.
2. Teško je utvrditi kauzalni odnos jer vremenski slijed nije jasan – npr. u navedenom primjeru ne možemo biti sigurni da delinkventno ponašanje nije dovelo do lošeg školskog uspjeha, tj. da kauzalni odnos nije obrnut.

Međutim, *ex post facto* istraživanja imaju i važne prednosti:

1. Može ih se provesti u situacijama kad je teško varirati nezavisnu varijablu.
2. Može ih se provesti u situacijama u kojima bi klasični eksperimentalni nacrt doveo do artificijelnog ponašanja ispitanika.

Primjerice, u gornjem eksperimentu nije bilo moguće varirati školski uspjeh jer bi to bilo neetično. Slično tome, u istraživanju povezanosti između gledanja nasilnih televizijskih emisija i dječjeg agresivnog ponašanja, također ne bi bilo etično sustavno varirati količinu nasilja na televiziji kojima su djeca izložena. U *ex post facto* istraživanjima ispitanike se istražuje retrospektivno, pa oni niti ne znaju da sudjeluju u istraživanju. Stoga i njihovo ponašanje nije artificijelno i ne ugrožava eksperimentalnu valjanost. Zbog navedenih se razloga *ex post facto* istraživanja u društvenim i humanističkim znanostima upotrebljavaju vrlo često, no valja imati na umu da uzročno-posljedični odnos u njima nikada nije moguće sa sigurnošću utvrditi.

*Nacrt prekinutih mjerenja* odnosi se na situaciju u kojoj analiziramo je li došlo do promjene nekoga trenda nakon što se dogodio određeni događaj. Pretpostavimo da želimo utvrditi je li vladina mjera poticanja književnog izdavaštva dovela do stvarne promjene u broju izdanih knjiga. Shematski bi nacrt prekinutih mjerenja izgledao ovako:

X1 X2 X3 X4 **E** X5 X6 X7

Broj izdanih knjiga u pojedinim godinama označava se znakom „X“, a donošenje mjere poticanja izdavaštva znakom „E“. U tom bi se slučaju analizirao trend izdavanja knjiga koji je postojao prije donesene mjere, odnosno je li se taj trend promijenio nakon njezina donošenja.

## 7.5. NEDOSTATCI EKSPERIMENTALNIH ISTRAŽIVANJA

Iako su eksperimentalna istraživanja u pravilu najbolja vrsta istraživanja, kada je u pitanju utvrđivanje uzročno-posljedičnih odnosa, u nekim je situacijama upo-

treba eksperimenta neopravdana ili neizvodiva, odnosno eksperimentalni nacrt ima određene manjkavosti. Osnovni su nedostatci eksperimenta sljedeći (Milas, 2005: 336-340):

1. Artificijelnost,
2. Neprimjerenost,
3. Neetičnost,
4. Neekonomičnost.

*Artificijelnost eksperimenta* povećava se ako sudionici eksperimenta ne shvate eksperimentalnu situaciju kao prirodnu, pa se zbog toga i ponašaju drukčije nego u svakodnevnoj životnoj situaciji. Zbog toga rezultati dobiveni eksperimentalnim istraživanjem ne moraju odražavati stvarne reakcije ljudi, pa time i utvrđene uzročno-posljedične veze ne moraju doista postojati. Primjerice, psiholozi su često ispitivali u kojoj će mjeri ispitanici slijediti mišljenje skupine, čak i kada je ono očigledno pogrešno (konformizam). Međutim, rezultati tih studija mogli bi biti pogrešni jer ispitanici mogu eksperimantalnu situaciju shvatiti kao „igru", a ne kao stvarnu situaciju. Eksperimenti su često artificijelni zbog toga što kontrola utjecaja pojedinih varijabli ne odgovara stvarnim situacijama u kojima taj utjecaj svakako postoji. U često ponavljanim sociološkim eksperimentima pokazalo se da u slučaju istih sposobnosti, radnog iskustva, znanja i sl. ispitanici češće smatraju da promaknuće na poslu zaslužuje muškarac, a ne žena. No, takva situacija mogla bi biti artificijelna jer je upitno koliko se u stvarnom životu doista susreću situacije u kojima su sposobnosti, iskustvo, znanje i sl. jednaki kod dviju osoba koje su kandidati za promaknuće. Npr., možda su znanje i sposobnosti odlučujući čimbenici u situacijima promaknuća, pa spolni stereotipi nemaju stvarni učinak.

*Neprimjerenost eksperimenta* odnosi se na situacije u kojima nije moguće manipulirati nezavisnom varijablom ili bi takva manipulacija dovela do manje kvalitetnih statističkih zaključaka. Nemogućnost manipulacije nezavisnom varijablom najčešće se događa kada se nezavisna varijabla odnosi na stavove, vrijednosti, demografska obilježja, obilježja ličnosti i sl. Npr., ako bismo željeli proučavati utjecaj društvenog statusa na kulturni ukus, u klasičnom bismo eksperimentu ispitanicima na posve slučajan način morali dodijeliti odgovarajući društveni status, a to očigledno nije moguće. Nezavisnu varijablu bilo bi nemoguće kontrolirati i ako bismo željeli proučavati kako vrijednost individualizma utječe na stupanje u brak ili broj djece koji pojedinac želi imati. Naime, ispitanike ne možemo učiniti manje ili više individualcima eksperimentalnom manipulacijom.

Ponekad je utjecaj na nezavisnu varijablu, čak i kad je moguć, *neetičan*. Npr., ako bismo istraživali utjecaj prikazivanja nasilja u medijima na agresivnost pojedinca, tada bismo u klasičnom eksperimentu ispitanike trebali podijeliti na one kojima ćemo duže vrijeme prikazivati veću i one kojima ćemo prikazivati manju količinu nasilja. Međutim, na taj bi način pojedinci kojima su prikazivane velike količine nasilja mogli doista postati agresivniji[71] i tu agresivnost iskazati u svakodnevnom životu. Budući da znanstveno istraživanje ne bi trebalo mijenjati ljude niti im nanositi štetu, takav je eksperiment neetičan, pa bi za ispitivanje ove hipoteze trebalo koristiti korelacijsku metodu.

Eksperimentalni je nacrt često *neekonomičan* jer se u njemu ispituje kazualni utjecaj jedne ili samo nekoliko varijabli. Korelacijskim se istraživanjem može istovremeno ispitati utjecaj mnogo većeg broja varijabli, pa izbor korelacijskog, a ne eksperimentalnog istraživanja ponekad može biti ekonomičniji.

## DODATNA LITERATURA UZ SEDMO POGLAVLJE

Bechhofer, Frank; Paterson, Lindsay (2000). *Principles of Research Design in the Social Sciences*. London, New York: Routledge.

Počevši s osnovama kao što su komparacija, kontrola i kauzalni odnosi, knjiga donosi pregled eksperimentalnih i neeksperimentalnih istraživačkih nacrta, kao i različitih kvantitativnih i kvalitativnih istraživačkih metoda.

Spector, Paul E.; Spector, Paul F. (2000). *Research Designs*. London, Thousand Oaks: Sage Publications.

Kratki pregled osnova istraživačkih nacrta, počevši od osnovne logike istraživanja, preko nacrta koji uključuju jednu grupu ili usporedbu više grupa.

## PITANJA UZ SEDMO POGLAVLJE

1. Što je to istraživački nacrt i koje vrste nacrta postoje?
2. Što je korelacijski nacrt?
3. Što je pozitivna, a što negativna korelacija?
4. Na koji način kvaliteta mjernog instrumenta utječe na korelaciju?
5. Na kojoj se ideji zasniva statistička kontrola treće varijable u korelacijskim istraživanjima?

[71] Ako je hipoteza točna, to bi se doista i dogodilo.

6. Što je longitudinalni nacrt i koje vrste longitudinalnog nacrta postoje?
7. Koje su prednosti i nedostatci longitudinalnog nacrta u usporedbi s korelacijskim nacrtom?
8. Što je učinak dobi, a što učinak vremena?
9. Što je eksperimentalni nacrt i zašto se njime najbolje utvrđuje uzročno-posljedični odnos?
10. Koje dvije osnovne vrste eksperimentalnih nacrta postoje?
11. Što znači pojam eksperimentalne kontrole?
12. Što je unutrašnja, a što vanjska valjanost eksperimenta i u kakvom su odnosu?
13. Koji čimbenici najčešće narušavaju unutrašnju valjanost eksperimenta?
14. Zašto je upotreba eksperimenta u društvenim i humanističkim znanostima često neizvediva?
15. U čemu se kvazieksperiment razlikuje od eksperimenta?
16. Što je nacrt neekvivalentne kontrolne grupe?
17. Što su to *ex post facto* istraživanja?
18. Što je nacrt prekinutih mjerenja?
19. Što su najčešći nedostatci eksperimentalnih istraživanja?

# 8. ANKETNA ISTRAŽIVANJA

## 8.1. DEFINICIJA ANKETNIH ISTRAŽIVANJA

Anketna istraživanja odnose se na postavljanje određenog broja pitanja unaprijed ispitanicima pomoću anketnog upitnika. Pri tome je važno naglasiti da se pitanja moraju postavljati na standardiziran način, odnosno moraju imati uvijek istu formulaciju i ponuđene opcije, pri čemu se dodatna pojašnjenja mogu u pravilu dati samo onda kada to zatraži sâm ispitanik, a pojašnjenje također mora biti standardizirano i unaprijed određeno. Treba napomenuti da se u nekim anketnim istraživanjima, ili u dijelovima pojedinih istraživanja (u pojedinim anketnim pitanjima) može odstupiti od potpune standardizacije upotrebom tzv. razgovornog anketiranja (eng. *conversational interviewing*). Njime se anketarima omogućuje da daju dodatna pojašnjenja kada to sami smatraju potrebnim, i to na način na koji smatraju najboljim. Drugim riječima, u razgovornom anketiranju nastoji se kvalitetno prenijeti smisao pitanja, pri čemu se dobro obučenom anketaru dopusti prosudba o tome kako to najbolje učiniti s pojedinim sudionikom istraživanja. Dosadašnja iskustva pokazuju da razgovorno anketiranje može biti korisno kad je riječ o pitanjima čiji smisao nije lako prenijeti na posve standardiziran način, odnosno pitanja koja će, prema našim očekivanjima ispitanici teško shvatiti ili shvatiti na različite načine. U slučaju jasnih pitanja ovaj bi tip anketiranja samo dodatno produžio proces anketiranja i unio moguću pogrešku mjerenja (Currivan, 2008).

***Osnovno je obilježje metode ankete postavljanje unaprijed određenih pitanja na potpuno standardiziran način.***

Napomenimo ovdje i da se u hrvatskom jeziku u pravilu jasno razlikuju anketa i intervju kao različite metode istraživanja, pri čemu se kod upotrebe riječi „intervju" u pravilu misli na dubinski intervju. U engleskom jeziku, s druge strane, izraz „interview" često označana i proces provođenja anketnog istraživanja (eng. *survey research*), a pri upotrebi intervjua kao kvalitativne metode najčešće se upotrebljava izraz *in-depth interview*, tj. jasno se naznači da je riječ o dubinskom intervjuu.

Budući da se gore navedena definicija može odnositi i na npr. testove znanja ili ličnosti, anketnim se istraživanjima obično nazivaju istraživanja kojima se žele procijeniti vrijednosti, stavovi, ponašanje, mišljenja i sl. neke populacije. Zbog toga se anketna istraživanja često izjednačavaju s ispitivanjima javnog mnijenja,

iako to nužno ne moraju biti. Prva anketna istraživanja u suvremenom smislu riječi počinju krajem 19. i početkom 20. stoljeća, a vezana su uz marketing, odnosno uz pokušaj saznavanja što potrošači vole i žele, a što ne. Tridesetih godina 20. stoljeća George Gallup u SAD-u počinje anketna istraživanja koristiti za prognozu rezultata izbora, kao i za istraživanje drugih društvenih i političkih stavova. Otad se anketna istraživanja koriste za ispitivanje javnog mnijenja a njima se služi i cijeli niz drugih organizacija i aktera (država, mediji, nevladine organizacije i sl.).

Prema stupnju strukturiranosti anketni upitnici mogu biti strukturirani ili polustrukturirani. *Strukturirani upitnici* u potpunosti ili gotovo u potpunosti sadrže zatvorena pitanja, dok *polustrukturirani upitnici* sadrže i nešto veći broj otvorenih pitanja, tj. pitanja u kojima ispitanicima nisu unaprijed ponuđene opcije odgovora nego se traže slobodni odgovori. Otvorena pitanja ponekad mogu dovesti do dubljih uvida nego što je to slučaj sa zatvorenim pitanjima jer se među opcijama odgovora u zatvorenom pitanju možda ne nalaze sve važne mogućnosti izbora. S druge strane, u slučaju kada su opcije odgovora posve jasne i nedvojbeno iscrpne, nepotrebno je postaviti otvoreno pitanje jer je ono zamornije za ispitanika, a čak može umanjiti i kvalitetu odgovora jer ispitanik možda ne očekuje da treba ponuditi detaljniji odgovor na pitanje. Primjerice, Dillman i Christian (2005) su na pitanje otvorenog tipa kojim se od ispitanika tražilo da navede vlastiti bračni status dobili manje odgovora „razveden/a“, „udovac/ica“ i „rastavljen“ u usporedbi sa zatvorenim pitanjem koje je ponudilo ove opcije. U ovorenom pitanju ispitanici su vjerojatno smatrali da je dovoljno navesti samo „oženjen/udana“ i „neoženjen/neudana“.

Praktično pravilo kaže da su stupanj strukturiranosti upitnika i njegova veličina u proporcionalnom odnosu, a slično vrijedi i za veličinu uzorka i stupanj strukturiranosti. Naime, veliki upitnici ne smiju sadržavati veći broj otvorenih pitanja jer dovode do velikog zamora ispitanika, slabije kvalitete odgovora i/ili odustajanja od istraživanja. S druge strane, u anketnim istraživanjima rađenim na velikim uzorcima također se ne preporučuje uključivanje velikog broja otvorenih pitanja jer ona pred istraživače stavljaju velike napore u pogledu obrade podataka (otvorena pitanja teže je obraditi i protumačiti). Oba ova pravila važe u većini situacija, ali nisu nepromjenjiva. Primjerice, ako istraživači imaju na raspolaganju veliku količinu vremena i ljudskih resursa, tada će i istraživanje na većem uzorku moći sadržavati veći broj otovrenih pitanja, tj. upitnik će moći biti manje strukturiran. Slično tome, ako su ispitanici posebno motivirani za sudjelovanje u nekom istraživanju, tada će i veliki upitnik moći biti nešto slabije strukturiran jer otvorena pitanje neće u tolikoj mjeri zamarati ispitanike.

Prije početka pisanja anketnog upitnika istraživač bi trebao definirati dvije osnovne stvari:

1. Koja se vrsta informacije želi dobiti upitnikom i na koji je način povezana s mjerenim konstruktom
2. Tko su ispitanici i mogu li odgovoriti na postavljena pitanja

***Prije pisanja upitnika prije svega treba voditi računa o tome koji se podatci njime žele dobiti te mogu li sudionici istraživanja dati navedene podatke.***

Pitanje iz upitnika moralo bi biti povezano s konstruktom koji se mjeri, odnosno treba predstavljati njegovu dobru operacionalizaciju. Na primjer, u istraživanju u kojemu bi, kao dio mjerenja konstrukta odnosa prema radu i socijalnoj državi, htjeli izmjeriti stav ispitanika prema zakonskom povećanju minimalne plaće, ne bi bilo dobro postaviti sljedeće pitanje: "Smatrate li da bi u Hrvatskoj minimalna plaća trebala biti povećana, smanjena ili bi treba ostati ista?" Naime, ispitanik može smatrati da minimalna plaća treba biti veća, ali se ne mora složiti da bi država trebala zakonskom regulativom određivati njezin iznos. Ispitanik može smatrati da bi povećanje trebalo proizlaziti iz kolektivnih pregovora sindikata i poslodavaca ili iz „dobre volje" poslodavaca. Iz navedenog proizlazi i da upitnik treba sadržavati samo one informacije koje su potrebne kako bi se ostvarili ciljevi istraživanja. Ne treba postavljati pitanja koja se „čine zanimljivima" jer se na taj način upitnik čini nepotrebno dugačkim (zamara ispitanika), a prikupljeni podatci najčešće su neupotrebljivi jer nisu u vezi s postavljenjim ciljevima i hipotezama istraživanja. Drukčije rečeno, prije nego što se neko pitanje uključi u upitnik, mora biti posve jasno čemu to pitanje služi i kako će se odgovori analizirati.

Istraživač uvijek treba imati na umu tko su ispitanici, kako bi pitanja mogao postaviti jezikom koji im je razumljiv i kako bi od njih tražio samo one informacije koje oni mogu pružiti. Primjerice, od ispitanika se teško može tražiti da navedu ukupno vrijeme koje su proveli u razgovoru s članovima svoje obitelji u protekloj godini. Ovaj je podatak u načelu moguće izračunati, no nije vjerojatno da ispitanici ovaj izračun mogu napraviti na precizan i pouzdan način. Isto tako, od ispitanika koji ne rade u sustavu znanosti teško je očekivati da mogu procijeniti kvalitetu hrvatske znanstvene produkcije prema pojedinim područjima znanosti. Njihova bi procjena vjerojatno predstavljala kombinaciju vlastitih uvjerenja, možda i predrasuda, i medijskih napisa. U svakom slučaju, ovakvo pitanje moglo bi mjeriti samo kako javnost percipira znanstvenu produkciju, a nikako ne i njezinu stvarnu kvalitetu. Podrazumijeva se i da sva pitanja trebaju biti postavljena

što jednostavnijim rječnikom, odnosno da ne treba upotrebljavati riječi koje su dio znanstvenog diskursa i s kojima neki sudionici istraživanja nisu upoznati. Naime, potpuna valjanost mjerenja bit će osigurana jedino ako svi sudionici istraživanja sva pitanja razumiju na isti način, odnosno ako odgovori na pitanja odražavaju prisutnost istog konstrukta u svijesti sudionika istraživanja.

## 8.2. VRSTE ANKETNIH PITANJA

Anketna se pitanja mogu podijeliti na osnovi kriterija forme i sadržaja. Prva podjela odnosi se na to kako je pitanje postavljeno (forma), dok se druga podjela odnosi na ono što se pitanjem ispituje, tj. želi dobiti (sadržaj).

Prema *formalnom kriteriju* anketna je pitanja moguće podijeliti na:

1. Mjerne skale (ljestvice procjene),
2. Dihotomna pitanja,
3. Pitanja višestrukog izbora.

*Mjerne skale* (Likertova, Thurstoneova, Gutmannova i semantički diferencijal) objašnjene su ranije, a predstavljaju prema većini kriterija najbolji način postavljanja anketnih pitanja. Naime, skale se obično nalaze na najvišim razinama mjerenja (intervalna i omjerna), a obično imaju i mjerna obilježja koja se mogu utvrditi i, u slučaju da nisu zadovoljavajuća, popraviti. Stoga mjerne skale u upitnicima treba upotrebljavati kad god je to moguće, tj. kad god je u upitniku riječ o mjerenju stavova. Osim u navedenom smislu, ljestvicama procjene često se smatraju sva ona pitanja koja nude višestruke opcije odgovora, odnosno koja stvaraju podatke ordinalnog ili intervalnog tipa. Primjerice, ako ispitanika pitamo koliko mu se sviđa neki televizijski program, s opcijama odgovora „jako“, „donekle“ i „uopće ne“, tada se također može govoriti o ljestivici procjene, iako nije riječ o mjernoj skali u uobičajenom smislu riječi (nema više pitanja, najčešće nije moguće utvrditi mjerna obilježja...).

U *dihotomnim se pitanjima* ispitanicima nudi izbor između dvije opcije, obično „da“ i „ne“. Ako ispitanika pitamo – „volite li klasičnu glazbu“ – i ponudimo mu opcije – „da“ i „ne“ –, tada je riječ o dihotomnom pitanju.

Volite li klasičnu glazbu?

☐ Da.

☐ Ne.

Slično tome, ako ispitanika pitamo je li u posljednjih mjesec dana pročitao ijednu knjigu i damo mu opcije „da“ i „ne“, tada je riječ o dihotomnom pitanju. Prednost dihotomnih pitanja može biti u tome da ispitanika tjera na izjašnjavanje u pitanjima koja su kontroverzna. Nedostatak je dihotomnih pitanja činjenica da se nalaze na nižoj razini mjerenja, tj. da pojednostavljuju odgovore, zbog čega se gubi informativnost i kvaliteta podataka. Primjerice, gornje smo pitanje mogli postaviti u obliku ljestvice procjene i pitati ispitanike koliko su knjiga pročitali u posljednjih mjesec dana (nijednu, jednu, dvije, tri...), a tako postavljeno pitanje donijelo bi podatke na najvišoj razini mjerenja. Stoga, i dihotomna pitanja treba izbjegavati, osim u slučajevima kada su odgovori prirodno dihotomni (npr. spol).

*Pitanja višestrukog izbora* (*multiple choice*) odnose se na postavljanje pitanja u kojima se nudi više od dvije opcije odgovora, a pri tome nije riječ o ljestvicama procjene niti o rangiranju. Primjerice, ako od ispitanika tražimo da zaokruži sve vrste filmskih žanrova koji mu se sviđaju i pri tome navedemo komediju, dramu, triler, akcijski film i znastvenu fantastiku, tada je riječ o pitanju višestrukog izbora.

Koje sve filmske žanrove volite?

☐ Komedija ☐ Triler ☐ Znanstvena fantastika (SF-film)

☐ Drama ☐ Akcijski film

Pri postavljanju takvih pitanja ispitanicima je moguće ponuditi zaokruživanje svih odgovora ili se od njih može zatražiti da izaberu jedan ili nekoliko odgovora.

Pitanja višestrukog izbora zapravo se mogu svesti na dihotomna pitanja ili pitanja koja uključuju rangiranje. Naime, pitanje višestrukog izbora moguće je postaviti kao niz dihotomnih pitanja, tj. zapravo je riječ o sažimanju niza dihotomnih pitanja. Primjerice, gornje je pitanje moguće postaviti kao niz dihotomnih pitanja:

| | | |
|---|---|---|
| Volite li komediju? | ☐ Da | ☐ Ne |
| Volite li dramu? | ☐ Da | ☐ Ne |
| Volite li triler? | ☐ Da | ☐ Ne |
| Volite li akcijski film? | ☐ Da | ☐ Ne |
| Volite li SF-film? | ☐ Da | ☐ Ne |

U slučaju da se ispitanicima nudi samo nekoliko opcija, tada je riječ o posebnom slučaju rangiranja u kojemu se ispitanicima nudi niz objekata od kojih trebaju rangirati samo nekoliko. Primjerice, ako bi u gornjem slučaju od ispitanika tražili da navedu samo dva omiljena žanra, zapravo bi bila riječ o rangiranju.

S druge strane, prema *sadržaju* anketna pitanja mogu biti:

1. pitanja o ponašanju,
2. pitanja o stavovima,
3. pitanja o znanju,
4. demografska pitanja.

Budući da smo ranije naveli načine mjerenja stavova (mjerne skale) i znanja (testovi znanja), u nastavku ćemo objasniti samo načine mjerenja ponašanja i demografskih obilježja.

## 8.3. POSTAVLJANJE SOCIJALNO OSJETLJIVIH PITANJA O PONAŠANJU

Osjetljiva pitanja o ponašanju odnose se na ona ponašanja koja se smatraju društveno poželjnim ili nepoželjnim. Obično su neka od društveno poželjnih ponašanja: davanje novca u dobrotvorne svrhe, čitanje knjiga, izlazak na izbore, provođenje što više vremena s obitelji i sl. Neka od ponašanja koja se obično smatraju društveno nepoželjnim su: prometni prekršaji, neplaćanje poreza, konzumacija alkohola ili droga i sl. U svim je tim slučajevima za pretpostaviti da će se ispitanici nastojati predstaviti u najboljem mogućem svjetlu, odnosno da će iskazati veći stupanj ponašanja koja su socijalno poželjna nego što je to u stvarnosti slučaj, kao i da će iz istog razloga umanjiti učestalost socijalno nepoželjnog ponašanja. U nekim se slučajevima može dogoditi da se neko ponašanje ne želi priznati, čak i u slučaju potpune anonimnosti upitnika, zbog straha od kazne ili zakonskih sankcija (npr., zloupotreba droge ili krađa). Ovome se mogu dodati i teme, poput seksualnog ponašanja i političkih preferencija, koje same po sebi ne moraju biti ni društveno poželjne ni društveno nepoželjne, no ispitanici ih mogu smatrati intimnim i osjetljivim, što može dovesti do veće stope neodaziva ili neodgovaranja na takva pitanja u upitniku.

Pri postavljanju osjetljivih pitanja postoje dva općenita pravila:

1. Istraživanje treba biti što anonimnije i impersonalnije.
2. Pitanja koja su osjetljiva treba stavljati na kraj upitnika ili intervjua.

Primjerice, anketni upitnik koji ispitanici sami ispunjavaju dat će bolje rezultate od intervjua licem u lice, jer jamči veći stupanj anonimnosti odgovora. Ili npr. telefonska istraživanja dat će bolje rezultate ako ih se obavlja pomoću automatiziranih (snimljenih) poruka, nego ako ih „uživo" rade anketari. Postavljanjem osjetljivih pitanja na kraju upitnika, u slučaju ispitanikova prekida istraživanja, imamo određenu količinu skupljenih podataka. Osim toga, osjetljiva pitanja mogu ispitanika učiniti opreznim, pa na preostala pitanja može odgovarati površno (u želji da se istraživanje što prije završi).

***U slučaju da u upitniku imamo socijalno osjetljiva pitanja, istraživanje treba učiniti što anonimnijim te takva pitanja postaviti na kraju. Poželjno je upotrijebiti i neku od tehnika postavljanja (formulacije) takvih pitanja.***

Slijede neke od najčešćih tehnika postavljanja osjetljivih pitanja:

1. *Stvaranje dojma da je određeno ponašanje često i da se ispitanika ne osuđuje*

Ova strategija podrazumijeva uvodni komentar, odnosno priprema pitanja u kojem se ponašanja opiše na neutralan način i ispitaniku se pruži odgovarajući „izgovor" za socijalno nepoželjno ponašanje. Npr., „Mnogi ljudi ne mogu čitati knjige zbog današnjeg brzog tempa života. Koliko knjiga, kada je riječ o književnosti (romani, eseji, knjige poezije...), Vi pročitate mjesečno?"

2. *Projiciranje odgovora ne druge ljude*

Ova se strategija odnosi na traženje razloga za neko ponašanje ili procjenu njegove učestalosti tako da ispitanik ne odgovora o vlastitom ponašanju, nego o ponašanju drugih ljudi. Npr., umjesto da ispitanika izravno pitamo plaća li porez i zašto ga ne plaća ako je to slučaj, možemo ga neizravno pitati: „Zbog čega danas neki ljudi izbjegavaju plaćanje poreza?"

U projiciranju odgovora na treće osobe nikad, doduše, nismo sigurni projiciraju li ljudi vlastiti stav ili ponašanje na druge osobe ili iznose vlastito uvjerenje o svojem ponašanju.

3. *Stavljanje osjetljivih pitanja u odgovarajući kontekst*

Npr., ako želimo saznati koliko često ispitanik čita knjige, možemo ga prije toga pitati koliko često čita časopise ili gleda televiziju, kako bismo skrenuli fokus s osjetljivog pitanja. Općenito govoreći, kontekst u kojemu je smješteno osjetljivo pitanje može izrazito utjecati na iskrenost odgovora. Primjerice, vjerojatno ćemo

dobiti manje iskrene odgovore o učestalosti i količini konzumacije alkohola ako je ovo pitanje postavljeno pored pitanja kojima se mjeri konzumacija droga i pušenje, u usporedbi s istraživanjem u kojem se ovo pitanje nalazi pored pitanja o konzumaciji hrane i bezalkoholnih pića. Naime, u prvom će slučaju ispitanik iz konteksta zaključiti da se konzumacija alkohola svrstava među devijantna i nepoželjna ponašanja, a u drugom među ponašanja koja se tiču neutralne konzumacije hrane i pića.

4. *Postavljanje dužeg pitanja.*

Pitanja koja se odnose na socijalno nepoželjna ponašanja trebaju biti nešto duža. Ako su pitanja kratka, ispitanik stječe dojam „policijskog ispitivanja".

5. *Postavljanje pitanja otvorenog tipa.*

Pitanja otvorenog tipa daju bolje rezultate u ispitivanju učestalosti socijalno nepoželjnih ponašanja od pitanja zatvorenog tipa. Pitanja otvorenog tipa omogućuju ispitaniku da objasni i opravda zašto se ponaša na društveno nepoželjan način.

6. *Odgovarajući redoslijed pitanja u slučaju poželjnih ponašanja.*

Pri postavljanju pitanja koja uključuju socijalno poželjno ponašanje, ispitanike prvo treba pitati jesu li se ikada ponašali na taj način, a zatim ih se može pitati o trenutnom ponašanju. Npr., ispitanika treba pitati je li ikada bio član knjižnice, a zatim je li trenutno član knjižnice. Na taj je način ispitanik skloniji priznati da se trenutno ne ponaša na društveno poželjan način jer mu činjenica da se tako ponašao u prošlosti služi kao opravdanje.

7. *Odgovarajući redoslijed pitanja u slučaju nepoželjnih ponašanja.*

Kad je riječ o pitanjima o društveno nepoželjnom ponašanju, ispitanike prvo treba pitati o trenutnom ponašanju a potom o uobičajenom ponašanju. Primjerice, ispitanika možemo pitati je li danas konzumirao alkohol. Budući da većina ljudi alkohol ne konzumira svakodnevno, ispitanik će biti skloniji priznati da je to učinio u prošlosti (npr. u posljednjih tjedan dana) jer se odgovorom na prvo pitanje (današnja konzumacija alkohola) prikazao na povoljan način.

8. *Model postavljanja pitanja u kojima se se društveno nepoželjno ponašanje pretpostavlja u samome pitanju.*

Npr., u istraživanju o novinarskoj autocenzuri novinare bismo mogli pitati: „Koliko često odustanete od pisanja o nekim temama zbog toga što bi Vam to moglo

donijeti probleme?“ umjesto: „Odustanete li nekad od pisanja o nekim temama zbog toga što bi Vam to moglo donijeti probleme?“

Jednu od mogućnosti za smanjenje učinka socijalno poželjnog odgovaranja predstavlja korištenje neke od skala socijalne poželjnosti i isključivanje pojedinaca koji na njima postižu visok rezultat. Naime, pomoću tih skala mjeri se sklonost pojedinaca da se prikažu u povoljnom svjetlu, što implicira i da su skloni davati socijalno poželjne odgovore u istraživanjima. Skale se zasnivaju na nizu čestica u kojima se opisuje neko ponašanje koje je socijalno poželjno, ali ne odgovara realnim životnim postupcima, odnosno nijedan se pojedinac u stvarnosti ne ponaša na taj način. Kao ilustracija može poslužiti čestica „Ponekad se želim osvetiti, umjesto da oprostim i zaboravim“ iz *Marlowe-Crowneove skale socijalne poželjnosti* (Crowne-Marlowe, 1960). Naime, iako je osvetoljubivost socijalno nepoželjna osobina, rijetki su pojedinci koji se nikada ne ponašaju na taj način. Sukladno tome, pojedinac koji kaže da se nikada ne ponaša na takav način vjerojatno daje socijalno poželjan, a ne istinit odgovor. Iako korištenje takvih skala predstavlja jednu od opcija, činjenica je da se njima osjetno produljuje upitnik, što može imati nepoželjne posljedice za kvalitetu podataka. Isto tako, istraživanja pokazuju da skale socijalne poželjnosti nemaju dokazano dobra metrijska obilježja (za pregled vidjeti Lietz, 2010: 253).

Kao metodu dobivanja točnijih odgovora na socijalno (ne)poželjna pitanja u terenskim (licem-u-lice) anketiranjima neki predlažu i tzv. *tehniku randomiziranih odgovora* (Coolican, 1994, tehnika je prvi put predložena u Warner, 1965). Ova tehnika (eng. *Randomized Response Technique*) funkcionira tako da se ispitaniku ponudi izbor odgovora na jedno od ponuđenih dvaju pitanja, pri čemu se slučajnim izborom određuje na koje će pitanje odgovarati ispitanik, a što je poznato samo njemu/njoj. Pri tome je jedno od pitanja ono pitanje koje je socijalno (ne) poželjno i koje istraživača zanima, a drugo je neutralno pitanje s poznatom distribucijom odgovora u populaciji. Primjerice, u istraživanju korupcije anketar može ispitaniku dati na izbor dvije kartice, pri čemu je na jednoj pitanje o tome je li ispitanik ikada dao ili primio mito, dok je na drugoj kartici pitanje posjeduje li kućanstvo u kojemu ispitanik živi automobil. Ispitanik izvlači jednu od kartica i odgovara na pitanje s „da“ ili „ne“, pri čemu ne govori anketaru na koje pitanje odgovara. Krenimo od pretpostavke da je u takvom istraživanju sudjelovalo 200 osoba. Prema zakonu vjerojatnosti, na pitanje o posjedovanju automobila odgovaralo je 100 ispitanika. Ako istraživač zna da 60% kućanstava posjeduje automobil, može se pretpostaviti da se od svih odgovora „da“ u istraživanju njih 60 odnosi na ovo pitanje. Ako je u istraživanju ukupno 90 odgovora „da“, može se

pretpostaviti da je 30 ljudi odgovorilo pozitivno na pitanje o davanju i uzimanju mita.

Jednom od podvrsta tehnike randomiziranih odgovora može se smatrati i tehnika prisilnih odgovora (eng. *Forced Response Technique*) koju je prvi put predložio Robert F. Boruch (1971) Naime, u njoj odgovor na pitanje ovisi o tome koji je broj prilikom bacanja kocke, ili dviju kocki, dobio ispitanik. Primjerice, ispitaniku se može reći da prilikom dva bacanje kocke daje odgovor „da" ako zbroj brojeva na kockama iznosi 2 ili 3, neovisno o tome koji je njegov pravi odgovor, odnosno iskreno mišljenje. Ako dobije zbroj 11 ili 12, tada odgovara s „ne". U ostalim situacijama odgovara iskreno, odnosno daje svoj pravi odgovor. S obzirom na to da su vjerojatnosti ovih zbrojeva poznate i mogu se izračunati, može se i izračunati koliko je odgovora „da" i „ne" došlo na temelju prisilnog izbora. Primjerice, vjerojatnost dobivanja zbroja 2 ili 3 prilikom dva bacanja kocke iznosi $\frac{1}{12}$. Naime, do ovog događaja moglo je doći tako da je kocka (a) u oba bacanja pala na 1, (b) da je u prvom bacanju pala na 1, a u drugom na 2, odnosno (c) da je u prvom bacanju pala na 2, a u drugom na 1. Stoga se može pretpostaviti da je upravo ovaj udio ispitanika „prisilno" odgovorio s „da" na anketno pitanje.

Procjenu odgovora na neko pitanje može se dobiti i upotrebom tzv. tehnikom neuparenih prebrojavanja (neg. *Unmatched Count Technique*), koju su predložili Dalton i sur. (1994). Naime, ovdje se upotrebljava nacrt eksperimentalne i kontrolne grupe, pri čemu kontrolna grupa dobiva popis nekoliko modela ponašanja, a eksperimentalna grupa dobiva isti popis nadopunjen s ponašanjem koje se želi izmjeriti. Zadatak je obiju grupa, u koje su ispitanici slučajno raspoređeni, da navedu koliko su navedenih aktivnosti obavili u nekom vremenskom razdoblju. Razlika u prosječnom broju ovih aktivnosti upravo mjeri ponašanje koje nas zanima. Primjerice, u istraživanju učestalosti korupcije kontrolnu se grupe može pitati koliko su od stvari s popisa radili u proteklih godinu dana:

a. Odlazak u kino,
b. Odlazak na roditeljski sastanak,
c. Putovanje u inozemstvo,
d. Odlazak na nogometnu utakmicu,
e. Odlazak na liječnički pregled.

Eksperimentalnoj grupi u popis se dodaje i davanje mita liječniku, policajcu, nastavniku, činovniku i drugoj službenoj osobi. Ako je u kontrolnoj grupi koja se sastojala od 500 ljudi navedeno ukupno 1000 aktivnosti, a u eksperimentalnoj, koja se također sastojala od 500 ljudi, navedeno je 1100 aktivnosti, tada je za

pretpostaviti da je od 500 ljudi u eksperimentalnoj grupi njih 100 dalo mito u proteklih godinu dana.

I u ovoj tehnici, kao i u slučaju tehnike randomiziranih odgovora, nije moguće utvrditi koji je ispitanik dao odgovor na koje pitanje. Primjerice, u gornjem primjeru nije moguće reći je li neki ispitanik iz eksperimentalne grupe dao mito ili ne, jer nam je poznat samo broj aktivnosti a ne i njihova struktura. Drukčije rečeno, ove tehnike mogu se upotrijebiti samo kako bi se procijenio populacijski parametar, a ne kako bi se utvrdili prediktori određenog ponašanja ili stava. Tako u gornjem primjeru ne možemo znati jesu li davanju mita sklonije osobe višeg socijalnog statusa, osobe određene dobi, spola i sl. No valja napomenuti da su u slučaju tehnike randomiziranih odgovora razvijeni modeli logističke regresije koji omogućavaju ovakvu procjenu (Lensvelt-Mulders, 2008: 472-474).

Metoda procjene pomoću društvene mreže (eng. *Network Scale-Up Method*) jedna je od tehnika, prema logici slična tzv. uzorkovanju metodom grude snijega, kojom se može procijeniti veličina manje vidljivih grupa. Obično je riječ o nekom socijalno nepoželjnom ponašanju, a ponekad i pripadnosti grupama koje su označene kao devijantne ili kriminalne. Primjerice, na ovaj način možemo pokušati utvrditi broj ovisnika o drogama ili broj osoba koje posjeduju oružje (uključujući i ono nelegalno). Ova je metoda neizravna i upotrebljava se tako da se od osoba traži da navedu broj osoba s određenim obilježjem koje poznaju. Prije toga se određenim pitanjem procijeni veličina njihove društvene mreže. Primjerice, može se navesti popis desetak zanimanja te se od ispitanika traži da navede koliko osoba koje se bave tim zanimanjem poznaju (primjerice, međusobno se znaju po imenu) ili navesti neko osobno ime te tražiti od ispitanika da navede jesu li s takvom osobom u nekoj vrsti kontakta (viđaju se, telefonski razgovaraju, komuniciraju na društvenim mrežama i sl.). Pretpostavimo da ovu metodu primijenimo kao metodu procjene broja osoba homoseksualne orijentacije u populaciji. Kao prvo, ispitanicima damo popis od 10 imena te zatražimo da navedu broj osoba s tim imenima s kojima su u kontaktu. S obzirom na to da znamo broj osoba u populaciji s ovim imenima (dobijemo ga iz podataka statističkog zavoda), možemo procijeniti da se veličina ukupne društvene mreže ispitanika može izračunati kao umnožak ukupne populacije u državi te udjela osoba s navedenim imenima koje ispitanik poznaje u ukupnom broju tih osoba u državi. Pojednostavljeno govoreći, ako osoba poznaje 5% od ukupnog broja osoba s tim imenima, može se pretpostaviti da poznaje 5% sveukupne populacije. Ovako procijenjena veličina društvene mreže pojedinca može se dalje upotrijebiti u procjeni veličine nepoznate populacije. Dakle, prema analogiji, ako osoba poznaje ukupno 1000 ljudi, a

navela je da poznaje 30 osoba homoseksualne orijentacije, može se prepostaviti da u populaciji ima oko 3% osoba homoseksualne orijentacije. Naravno, ova metoda pretpostavlja da osoba poznaje ravnomjeran broj ljudi u svim društvenim grupama, odnosno da zna obilježja osoba koje poznaje te da se može prisjetiti svih tih osoba. Sve ove pretpostavke u određenoj su mjeri nerealistične (Maltiel i sur., 2015). Tako postoji tzv. efekt barijere jer osobe uglavnom poznaju druge osobe koje su im slične. Nadalje, prema tzv. pristranosti transmisije, osoba ne mora znati oblilježja osoba koje poznaje. Tako u našem slučaju nije očekivano da osoba poznaje seksualnu orijentaciju svih osoba koje poznaje, osobito imajući u vidu seksualnu orijentaciju koja je donekle stigmatizirana. Nadalje, tzv. pristranost prisjećanja dovodi do toga da se ne sjećamo nekih osoba koje poznajemo, a ova će pristranost biti veća u većim grupama s češćim obilježjem. Primjerice, češće ćemo se sjetiti osobe s neobičnim imenom ili zanimanjem nego osobe čije su ime i zanimanje češći u populaciji.

## 8.4. POSTAVLJANJE „NEPRIJETEĆIH“ PITANJA O PONAŠANJU

„Neprijeteća“ pitanja o ponašanju odnose se na ona pitanja o ponašanju koja ispitanici ne procjenjuju osjetljivim i na koja daju slobodan odgovor, bez želje da se predstave u boljemu svjetlu ili da ne odgovore iskreno na pitanje zbog toga što smatraju da pitanje zadire u njihovu intimnost. Ta vrsta pitanja nije osjetljiva na formulaciju, ali mogući izvori pogreške kriju se osobito u nesavršenosti ljudske memorije i proteku vremena.

Budući da se od ispitanika često traži da kaže ne samo je li se ponašao na određeni način, nego da navede i učestalost ponašanja. Pri postavljanju pitanja o ponašanju vrlo je važno jasno definiranje vremenskih kategorija. Tako treba izbjegavati kategorije poput „ponekad“, „često“, „povremeno“ i sl., jer te kategorije nemaju isto značenje za sve ispitanike. Umjesto takvih kategorija bolje je upotrebljavati one potpuno jasne, poput „jedanput tjedno“, „dvaput mjesečno“ i sl. Izuzetak su ona pitanja kod kojih je razumno pretpostaviti da ispitanici nemaju jasno poimanje o tome koliko često nešto rade. Primjerice, pitanje „koliko često čitate kriminalističke romane“ vjerojatno je bolje postaviti s opcijama odgovora „nikad“, „povremeno“ i „često“, unatoč tome što te kategorije nisu jednoznačne. Naime, ispitanici vjerojatno ne broje koliko su kriminalističkih romana pročitali u nekom vremenskom razdoblju, nego samo imaju okvirno sjećanje o tome koliko ih često čitaju.

U slučajevima kada se pitanje postavlja u kondicionalnom obliku, uvjet bi trebalo iznijeti u prvom dijelu rečenice, a ključnu ideju u drugom (Leary, 1995). Primjerice, bolje je postaviti pitanje: „Ako bi ulaznice bile jeftinije, biste li češće išli u kazalište“, nego pitanje: „Biste li češće išli u kazalište ako bi ulaznice bile jeftinije.“ Naime, u drugom će slučaju jedan dio ispitanika površnije pročitati pitanje i zapravo odgovoriti na njegov prvi dio, odnosno odgovarat će na pitanje bi li češće išli u kazalište vjerojatno imajući u vidu druge motive (raspoloživo vrijeme, kvalitetu predstava, udaljenost od kazališta i sl.), a ne samo cijenu ulaznica.

Kada su u pitanju ponašanja koja se često ponavljaju, tada je bolje ispitanike pitati za što kraće razdoblje u kojemu se ponašanje odvijalo. Budući da sami ispitanici u tom slučaju najčešće ne pokušavaju izbrojati koliko se puta događaj dogodio u tom razdoblju, nego obično izbroje broj događaja u kraćem razdoblju. Primjerice, ako članove knjižnice želimo pitati koliko često podižu knjige, vjerojatno je najbolje da ih pitamo koliko to često rade u razdoblju od jednog ili dva tjedna („Koliko ste puta u prošla dva tjedna bili u knjižnici?“). Ako ih pitamo za duži vremenski period (mjesec dana ili duže), ispitanici će se vjerojatno pokušati sjetiti koliko su puta bili u knjižnici u posljednjih tjedan-dva, te će zatim množenjem procijeniti koliko su puta bili u knjižnici u posljednjih npr. šest mjeseci, što samo donosi dodatnu pogrešku mjerenja.

Samom formulacijom pitanja u ovom tipu pitanja ispitaniku treba pomoći da se prisjeti ponašanja o kojemu mu se postavljaju pitanja. Na primjer, pitanjem „Koliko ste puta u posljednjih tjedan dana bili na nekom kulturnom događaju – posjet galeriji, muzeju, kazališnoj predstavi, kinu i sl.?“, ispitanika podsjećamo na vrste kulturnih događaja i pomažemo mu da ne zaboravi neki od posjeta, tj. da ga se prisjeti. Stoga, neprijeteća pitanja o ponašanju mogu biti nešto duža.

Takva je pitanja također često dobro postaviti u formi otvorenog pitanja (bez ponuđenih kategorija). Naime, različito postavljene kategorije ispitanicima sugeriraju i različito shvaćanje pitanja. Npr. u pitanju o učestalosti dnevnog gledanja televizije pri primjeni kategorija „do 1 h“, „između 1 i 2 h“ itd., dobit ćemo veću frekventnost gledanja televizije nego kada kategorije postavimo „do 30 min“, „od 30 do 60 min“ itd. U drugom slučaju, užim kategorijama ispitaniku sugeriramo da primijeni strože kriterije pri procjeni što je to „gledanje televizije“ (npr., je li istovremeno čitanje knjige uz povremene poglede na ekran doista gledanje televizije?) Osim toga, na određeni se način i sugerira da je veći broj sati gledanja televizije neuobičajen, odnosno da se osoba ponaša na način koji odudara od većine drugih pojedinaca. U ovom drugom slučaju riječ je o tome da ispitanik prilikom procjene učestalosti ponašanja koja nisu osobito česta i važna ili njihovu

učestalost nije lako procijeniti. Ekstremni krajevi skale pritom se upotrebljavaju kao svojevrsni indikatori uobičajenosti određenog ponašanja, a nakon toga učestalost svojega ponašanja smješta na prikladno mjesto na ovako konstruiranoj mentalnoj skali. Primjerice, ako ispitaniku postavimo pitanje o tome koliko prosječno dnevno u medijima prati/čita političke teme i pri tome kao maksimum na skali stavimo „osam sati i više", tada će ispitanik koji smatra da političke teme prati kao prosječan građanin na takvoj skali označiti odgovor „četiri sata". S druge strane, ako je maksimum na skali „šest sati i više", ispitanik će svoju procjenu sniziti na sat. Naime, u ovom je slučaju vjerojatno da ispitaniku nije lako procijeniti prosječno dnevno vrijeme provedeno u praćenju političkih tema, unatoč tome što ova tema može biti važna za njega, no može procijeniti u kojoj mjeri prati politiku u usporedbi s ostalim građanima. Utjecaj kategorija kojima se mjeri učestalost ponašanja na skali manji je kada se mjeri važnija i češća ponašanja, kao i ponašanja koja imaju svoju ustaljenu dinamiku (primjerice, tjedni odlazak u crkvu) (Schwarz i sur., 2008: 26).

Neka istraživanja pokazuju da preciziranje razdoblja za koje se traži učestalost nekog ponašanja vodi do manjeg pretjerivanja navođenja učestalosti toga ponašanja u ispitanika. Naime, postoji tendencija da ispitanici događaje koji su se dogodili prije određenog razdoblja pomaknu „unaprijed", tj. da navedu da su se dogodili unutar traženog razdoblja (eng. *forward telescoping*).[72] Iako se nekada događa i da se događaji pomaknu unatrag u vremenu (eng. *backward telescoping*). Primjerice, ako se od ispitanika traži da navedu jesu li u zadnjih mjesec dana pročitali ijednu knjigu, vjerojatno je da će na ovo pitanje odgovoriti potvrdno i ispitanici koji su posljednju knjigu pročitali prije dva mjeseca. *Telescoping* se može smanjiti u određenoj mjeri tako da se preciznije odredi traženo razdoblje, tj. da se navede konkretan datum. Npr. u viktimizacijskom istraživanju[73] među mladima (Lucia i sur., 2007.) točniji rezultati dobiveni su kada se koristilo izrazom „od listopada 2004. do danas" umjesto „u posljednjih 12 mjeseci", iako je u oba slučaja bilo riječ o istom vremenskom razdoblju. Ovakav postupak obično se naziva *ograničavanje* (eng. *bounding* ili *bounded interview*), a koristan je ako se može pronaći javni ili privatni događaj koji za sudionika istraživanja ima veliko značenje. Primjerice, ako se u nekom gradu prije oko šest mjeseci dogodio veći potres, a to

[72] Objašnjenje se vjerojatno može pronaći u „zgušnjavanju" pamćenja, odnosno činjenici da se mnogi nevažni događaji koji su se dogodili jednostavno zaboravljaju te da se zbog toga stječe dojam da su se oni važni dogodili poslije. Zgušnjavanje pamćenja može objasniti i čest dojam da se vrijeme u djetinjstvu (kada je bilo mnogo novih događaja i impresija) odvijalo sporije nego što je to slučaj u naknadnim životnim razdobljima.

[73] Istraživanje koje se bavi time jesu li osobe bile žrtve nekog kaznenog djela (kriminala).

je događaj koji su svi zapamtili i ima određeno značenje za sudionike istraživanja, tada se u istraživanju kulturne participacije pitanje može formulirati na način da osobu pitamo koliko je puta bila u kazalištu nakon što se dogodio potres. Tako važni događaji sudionicimaa istraživanja stvaraju vremensku orijentaciju koja omogućava da se događaji pravilnije smjeste u vremenskom smislu.

## 8.5. NAJČEŠĆE POGREŠKE U FORMULACIJI ANKETNIH PITANJA

S obzirom na to da ispravan način postavljanja pitanja ujedno implicira i načine na koje ga ne treba postaviti, neke od mogućih pogrešaka u formulaciji anketnih pitanja naveli smo u prethodnim poglavljima. Ovdje ćemo detaljnije objasniti ostale pogreške, koje se mogu sustavno podijeliti (podjela je preuzeta i djelomično prerađena prema Fowleru i Cosenzi, 2008) na: (a) pogreške koje uključuju pristranost u mjerenju konstrukta (b) pogreške koje proizlaze iz nekonzistentnog razumijevanja pitanja, (c) pogreške koje su rezultat nepostojanja odgovarajućih informacija, (d) pogreške koje su rezultat neodgovarajuće forme odgovora.

### 8.5.1. Pogreške koje uključuju pristranost u mjerenju konstrukta

U ovakvim je slučajevima riječ o tome da istraživač, svjesno ili nesvjesno, pitanje postavlja tako da ispitanika usmjerava prema određenim odgovorima uslijed socijalne poželjnosti osobine slaganja ili davanjem više ili manje suptilnog signala o većinskom/poželjnom/ispravnom stavu o određenom pitanju. Dakle, na ovaj način sklonost prema konformizmu ili kognitivne pristranosti dovode do toga da se uz mjerenje uključuje pogreška, odnosno da odgovori na pitanje na manje kvalitetan način odražavaju posjedovanje određenog obilježja.

*Sugestivna pitanja*

Kako kaže sâmo ime, ovdje je riječ o pitanjima koja ispitaniku sugeriraju poželjan i „ispravan“ odgovor. Primjerice: „Većina ljudi smatra da se u Hrvatskoj premalo ulaže u kulturu. Dijelite li i Vi to mišljenje?“ Pitanje je očigledno sugestivno jer ispitaniku sugerira da je mišljenje većine već stvoreno, a time na neki način i ispravno. Nije ni potrebno napominjati da takvo korištenje socijalnog pritiska ne donosi valjane rezultate i da bi ga trebalo izbjegavati. Stoga se primjeri sugestivnih pitanja najčešće susreću u političkim i medijskim „istraživanjima“ u kojima provoditelji istraživanja žele postići rezultat koji odgovara njihovim željama i interesima. Sugestivna pitanja ne moraju nužno biti rezultat svjesne namjere,

nego mogu biti posljedica nepromišljenosti, a njihova sugestivnost ne mora biti posve očita. Postavljanjem pitanja – „Čitate li često knjige? Koliko knjiga pročitate godišnje?“ – vjerojatno ćemo dobiti veću učestalost čitanja knjiga u usporedbi s pitanjem: „Čitate li ponekad knjige? Koliko knjiga pročitate godišnje?“ Upotreba priloga „često“ i „ponekad“ utjecala bi na procjenu samih ispitanika i na njihovo precjenjivanje ili podcjenjivanje vlastitog čitanja knjiga.[74]

***U upitniku treba izbjegavati sugestivna pitanja, odnosno pitanja koja sudioniku istraživanja sugeriraju neki odgovor koji se može smatrati poželjnim.***

*Neuravnotežena pitanja*

Neuravnotežena pitanja ona su pitanja u kojima u opcijama odgovora nisu navedene sve alternative. Na primjer, pitanje – „Ulaže li se u Hrvatskoj premalo u kulturu?“ – nije uravnoteženo, dok je pitanje – „Ulaže li se u Hrvatskoj premalo, previše ili sasvim dovoljno u kulturu?“ – uravnoteženo. Iako je u neuravnoteženim pitanjima riječ o blažem obliku sugestivnosti, a eksperimentalna istraživanja pokazuju da neuravnoteženost ne dovodi do većih pogrešaka u rezultatima, pitanja bi ipak trebalo postavljati u uravnoteženom obliku.

Znatno teži oblik neuravnoteženosti pojavljuje se ako se u jednoj opciji odgovora navode, a u drugoj ne navode dodatni argumenti (Milas, 2005: 450). Naime, u usporedbi s uravnoteženom tvrdnjom – „Slažete li se ili ne slažete s ograničavanjem radnog vremena diskoteka?“ – neuravnotežena tvrdnja s dodatnim argumentima bila bi – “Slažete li se s ograničavanjem radnog vremena diskoteka ili smatrate da bi to nepotrebno osiromašilo život mladih?“ Pri takvoj neuravnoteženosti ispitanici češće biraju one opcije u kojima su navedeni dodatni argumenti.

### 8.5.2. Pogreške koje proizlaze iz nekonzistentnog razumijevanja pitanja

U ovu vrstu pogrešaka mogu se ubrojiti sve one situacije koje dovode do toga da jedan ispitanik pitanje shvati na jedan, a drugi na drugi način. Slično tome, to su i one situacije u kojima će jedan ispitanik u više navrata možda isto pitanje shva-

[74] Shaughnessy i sur. (2003: 155) navode primjer dvaju marketinških istraživanja koje je provela tvrtka koja proizvodi lijekove za glavobolju, a u kojima su dvije navedene formulacije dovele do bitno različitih rezultata pri procjeni sudionika istraživanja o učestalosti glavobolje.

titi na različite načine, čime će se u dva navrata zapravo mjeriti donekle slična, ali ipak različita obilježja (konstrukti).

*Dvostruko pitanje* (eng. *double-barreled question*)

Pogrešno je unutar jednog pitanja postaviti zapravo dva odvojena pitanja, odnosno mjeriti dvije različite stvari, jer će odgovori biti neupotrebljivi. Npr., pitanje – „Sviđa li Vam se režija i scenarij ovoga filma?" – predstavlja dvostruko pitanje zbog toga što niti odgovor „da" niti odgovor „ne" ne pružaju jasnu informaciju. Naime, nismo sigurni sviđa li se ispitaniku režija, scenarij ili oboje. U nekim situacijama dvostruka pitanja nisu tako očita, a najčešće je riječ o tome da se u pitanju nalaze prešutno prihvaćene pretpostavke koje nisu provjerene. Primjerice, u istom se pitanju može mjeriti neko ponašanje i razlozi za to ponašanje. Primjer predstavlja pitanje: „Imate li vremena za čitanje novina svakoga dana?" (Lietz, 2010: 254). Kako se ovdje zapravo mjeri i ponašanje (čitanje novina) i razlozi za to ponašanje (dovoljna ili nedovoljna količina slobodnog vremena), nije jasno što bi trebala odgovoriti osoba koja ima dovoljno vremena, ali ne čita novine. U tom bi slučaju pitanje trebalo podijeliti na dva odvojena pitanja, u prvome bi se ispitanika pitalo čita li novine svaki dan, a u drugome razloge za (ne)čitanje novina. Sličan primjer navode Fowler i Cosenza (2008), a odnosi se na pitanje: „Smatrate li da bi zbog porasta maloljetničke delinkvencije trebalo produljiti vrijeme boravka u školama?" Naime, ovdje nije jasno što bi trebala, primjerice, odgovoriti osoba koja smatra da bi vrijeme u školama trebalo produljiti kako bi se postigli bolji obrazovni rezultati. Takva bi osoba mogla odgovoriti „da" jer smatra da vrijeme treba produljiti, no tada bi taj odgovor zapravo bio odgovor na drugo pitanje. Odgovor „ne" mogao bi joj biti neprirodan jer doista smatra da bi vrijeme trebalo produljiti. I u ovom bi slučaju pitanje trebalo razdvojiti na nekoliko jednostavnih pitanja u kojima ne postoje skrivene pretpostavke. Primjerice, ispitanika bi se moglo pitati smatra li da bi školsko vrijeme trebalo produljiti, a nakon toga i razloge za takav stav, tj. zalaže li se za to zbog povećanja obrazovnih uspjeha ili zbog smanjenja delinkvencije (ili oboje). Alternativno, mogli bi ga se pitati bi li produljenje školskog vremena dovelo do povećanja obrazovnog uspjeha, odnosno smanjenja delinkvencije.

*Pitanja koja uključuju negaciju ili dvostruku negaciju*

Pitanja koja uključuju negaciju ili dvostruku negaciju problematična su iz dvaju razloga: ponekad nisu jasna i nedvosmislena, a ponekad su jasna, no ispitanicima treba više vremena da shvate njihovo značenje. Primjerice, odgovori na pitanje – „Ne smatrate li da su društvene nejednakosti u Hrvatskoj prevelike?" – ili

– „Ne smatrate li da društvene nejednakosti u Hrvatskoj nisu prevelike?“ – ne nude jasnu i nedvosmislenu informaciju. S druge strane, pitanje – „Što mislite o tvrdnji da konzervatori ne bi trebali biti tako nekooperativni u odnosima s vladom?“ – prilično je jasno, no ispitanicima treba znatno više vremena da ga shvate u usporedbi s pitanjem – „Što mislite o tvrdnji da bi ispitanici trebali biti kooperativniji u odnosima s vladom?“ (Lietz, 2010: 254). Osnovni razlog zbog kojeg pitanja koja uključuju negaciju izazivaju je činjenica da smo u svakodnevnom iskustvu naviknuti na činjenicu da se obično slažemo s ili ne slažemo s afirmativnom tvrdnjom, a mnogo se rjeđe od nas traži da potvrdimo ili negiramo tvrdnju koja je i sam izražena u formi negacije nečega (stava, pojave i sl.). Pitanja koja uključuju dvostruku negaciju nekada su očita i istraživač neće lako počiniti grešku njihova postavljanja. No nekada se jedna negacija krije u samom pitanju, a druga u opcijama odgovora i tada je mogućnost greške nešto veća. Wolf (2008) daje primjer sljedećeg pitanja: „Kažite mi slažete li se ili ne slažete sa sljedećom tvrdnjom: ‚Imena članova porote u važnim suđenjima ne bi trebala biti uskraćena medijima.‘“ I u ovom slučaju, kako je obično riječ u pitanjima koja uključuju dvostruku negaciju, istraživači žele saznati slažu li se sudionici istraživanja s negacijom nečega. No i ovdje sudionici istraživanja mogu odgovoriti potvrdno s mišlju da time izražavaju slaganje s time da se imena uskrate, a ne s time da se ne uskrate. Dakle, jedan dio njih sasvim sigurno neće shvatiti da se pozitivnim odgovorom zapravo slažu s negacijom („ne uskrate“). Wolf (2008) donosi i primjer vjerojatno najpoznatijeg pitanja s dvostrukom negacijom koje je 1992. postavio Roper Organization, ugledna organizacija za istraživanje javnog mnijenja. U istraživanju stavova o holokaustu tako je postavljeno sljedeće pitanje:

> „Izraz ‚holokaust‘ obično se odnosi na ubijanje milijuna Židova u nacističkim logorima smrti tijekom Drugog svjetskog rata. Čini li Vam se mogućim ili nemogućim da se nacističko istrebljenje Židova nikada nije dogodilo?“

S obzirom na to da su rezultati upućivali na neuobičajeno veliki broj ljudi koji smatraju da je moguće da se holokaust nije dogodio, *debriefing* sudionika istraživanja pokazao je problematičnost dvostruke negacije – mnogi su od njih smatrali da afirmativan odgovor znači slaganje s time da se holokaust dogodio, a ne slaganje s onima koji ga negiraju. I ovaj slučaj pokazuje da treba biti osobito oprezan pri oblikovanju pitanja kojim pokušavamo utvrditi slaže li se netko s osobama ili organizacijama koje nešto negiraju jer se afirmativan (negativan) odgovor može shvatiti kao slaganje (neslaganje) s negacijom ili sa samim stanjem stvari koje se opisuje u tvrdnji.

*Nejasna ili dvosmislena pitanja*

Primjerice, pitanje – „Jeste li ekološki osviješteni?“ – vjerojatno je previše nejasno jer nije definiran sâm pojam ekološke osviještenosti. S druge strane, pitanje – „Koliko iznosi Vaš mjesečni dohodak?“ – dvosmisleno je jer će neki ispitanici imati na umu individualni, a neki obiteljski dohodak. Dvosmislenost se ponekad krije i u nedovoljno preciznom određenju pitanja, odnosno u situacijama kada ispitaniku nije jasno koliki se stupanj preciznosti od njega očekuje, odnosno koji je od mogućih formata odgovora očekivan istraživaču. Fowler i Cosenza (2008) navode primjer pitanja: „Kada ste se doselili u London?“ Ovo je pitanje samo naizgled jasno i nedvosmisleno, no problematično je što očekivani format/preciznost odgovora nije postavljen. Primjerice, na ovo je pitanje moguće odgovorit s „prije desetak godina“, „nakon dovršenja studija“, „kada sam imala 25 godina“ i sl. Stoga bi u samom pitanju, primjerice, trebalo jasno naglasiti da se od ispitanika očekuje točna godina doseljenja: „Koje ste se godine doselili u London?“ Kako bi se osigurala razumljivost pitanja, odnosno smanjile moguće nejasnoće i dvosmislenosti, preporučuje se da se kognitivni napor potreban za odgovaranje na pitanje svede na minimum. U tom je smislu poželjno da pitanja budu što je moguće kraća, da gramatička struktura bude što jednostavnija (izbjegavanje pasiva, ponavljanje imenica umjesto korištenja zamjenica i sl.), kao i to da se složena pitanja „razbiju“ na niz jednostavnijih specifičnih pitanja (Lietz, 2010: 251).

### 8.5.3. Pogreške koje su rezultat nepostojanja odgovarajućih informacija

Ove pogreške proizlaze iz neposjedovanja odgovarajuće informacije ili iz nemogućnosti da se informacije u trenutku davanja odgovora na kvalitetan način dozovu iz sjećanja. Već smo istaknuli potrebu da se ispitanicima u anketnom upitniku postavljaju samo ona pitanja na koja mogu odgovoriti, odnosno o kojima imaju odgovarajuće informacije. Također je istaknuta i potreba da se u samom pitanju ispitanicima daju dodatne informacije koje mogu olakšati prisjećanje, a time i kvalitetnije odgovore. Kao dvije dodatne pogreške ove vrste mogu se dodati neodgovarajući vremenski okvir odgovora i kognitivna kompleksnost pitanja (prema Fowleru i Cosenzi, 2008: 145-146).

*Neodgovarajući vremenski okvir odgovora*

Kad je riječ o ovoj pogrešci, potrebno je vremenski okvir odgovora prilagoditi važnosti samog pitanja/teme za ispitanika. Naime, kada su u pitanju manje važne teme, vjerojatnije je da će dulji vremenski okvir dovesti do velikog broja zabo-

ravljanja, odnosno iskazivanja manje učestalosti određenog događaja u odnosu na ono što je stvarno stanje stvari. Primjerice, sasvim je sigurno da u istraživanju čitanosti dnevnih novina nećemo postaviti pitanje o broju pročitanih primjeraka novina u posljednih godinu dana jer je riječ o ponašanju koje nije osobito važno za većinu ljudi. S druge strane, sasvim je prihvatljivo postaviti pitanje o broju promjena mjesta boravaka tijekom cijelog života jer je riječ o važnom događaju koji se teško može zaboraviti.

*Kognitivna kompleksnost pitanja*

Kognitivna kompleksnost pitanja odnosi se na postavljanje nepotrebno kognitivno zahtjevnih pitanja ako se isti cilj može postići s više jednostavnijih pitanja. Primjerice, ako bismo htjeli istražiti ukupan broj pročitanih knjiga u nekom razdoblju, bilo bi manje kognitivno kompleksno za ispitanike ako bismo knjige prvo podijelili na stručnu literaturu, publicistiku i beletristiku (ili nekako drukčije) pa ispitanike onda pitali koliko su knjiga iz ovih kategorija pročitali. To im omogućuje da se koncentriraju na jedan lakši zadatak u manjim vremenskim razdoboljima, umjesto jednog kompleksnijeg zadatka koji trebaju obaviti u duljem vremenu.

### 8.5.4. Pogreške koje su rezultat neodgovarajuće forme odgovora

*Neodgovarajuće ili međusobne neisključive kategorije odgovora*

U ovoj je vrsti pogreške riječ o tome da se prilikom navođenja kategorija odgovora na zatvorena pitanja ne navedu odgovarajuće i/ili nepotpune kategorije ili navedene kategorije nisu međusobno isključive. Često je tako slučaj da kategorija odgovora nije u potpunosti prikladna samom pitanju, što za ispitanika može biti zbunjujuće. Primjerice, pitanje – „Treba li gradsko središte obnovu ili ne?“ – s kategorijama odgovora – „Središte je grada zapušteno i treba veliku obnovu“; „Središte je grada zapušteno, ali ne treba veliku obnovu“; „Središte grada uopće nije zapušteno i ne treba obnovu“ – problematično je iz nekoliko razloga. Prije svega, u njemu se miješa pitanje zapuštenosti (namjerne ili nehotične nebrige) s pitanjem potrebe obnove gradskog središta. Nadalje, mogućnosti da gradsko središte nije zapušteno, ali da treba malu obnovu“, kao i mogućnost da netko tvrdi da je „središte grada zapušteno, ali da ne treba obnovu“ (jer postoje drugi prioriteti ili nije vrijedno obnove) uopće nisu navedene. Klasičan slučaj međusobno neisključivih kategorija navode Fowler i Cosenza (2008: 150-151), a odnosi se na pitanje: „Jeste li trenutno oženjeni/udani, razdvojeni, razvedeni, udovac/ica, ili

nikada niste bili udani/oženjeni?“ Naime, ovdje postoje dva kriterija klasifikacije, jedan je pravni status, a drugi stvarno življenje s partnerom. Primjerice, osoba može biti razvedena, no istovremeno i živjeti s drugim partnerom. Ovakvo bi pitanje imalo smisla postaviti ako nas baš zanimaju one osobe koje su razvedene ili udovci/ice, a ne žive s drugim partnerom, odnosno želimo ih usporediti s onim osobama istog pravnog statusa, ali koje žive s novim partnerom. No čak i tada je jednostavnije i potpunije pitati prvo za pravni status (prvih pet kategorija odgovora), a nakon toga pitati živi li osoba trenutno s bračnim ili izvanbračnim partnerom. Na taj će se način razdvojiti osobe koje žive s partnerom, a prethodno su bile u braku, od onih koji žive s partnerom, a nisu bile u braku.

*Preveliko oslanjanje na kategoriju „ostalo“*

Ova vrsta pogreške zapravo predstavlja specifični oblik prethodne pogreške, odnosno nepotpunog broja međusobno isključivih kategorija odgovora. U pitanjima koja uključuju jedan ili nekoliko kategorija odgovora (*multiple choice*), kao zadnja kategorija uvijek se stavi i kategorija „ostalo“ uz mogućnost dopisivanja odgovora. No, ako ne uključimo sve relevantne kategorije, kategorija „ostalo“ često neće moći previše pomoći. Uzmimo za primjer pitanje – „Koji je najvažniji razlog zbog kojeg kupujete novine A?“ – s odgovorima:

a. zbog kvalitete sadržaja,
b. zbog objektivnosti,
c. zbog toga što ih čitam godinama,
d. ostalo (navedite što:_____).

Ovo je pitanje vjerojatno loše postavljeno jer nismo naveli vrlo važan potencijalni razlog kupovine – cijenu u odnosu na konkurentske novine. Nije realno pretpostaviti da će svi ispitanici koji cijenu smatraju odlučujućom izabrati kategoriju „ostalo“ i dopuniti odgovor.

*Izostavljanje odgovora „ne znam“*

U istraživanja se uvijek događa da jedan dio sudionika nema stav o određenom pitanju. Ako izostavimo opciju „ne znam“ ili „nemam mišljenje/stav“, ti će ispitanici najčešće nasumično odgovarati na pitanje. Primjerice, Schuman i Presser (1996.) pokazali su da se uvođenjem kategorije „ne znam“ oko 20-25% ispitanika koji bi inače izrazili vlastito mišljenje (tj. dali odgovor na anketno pitanje) odlučuje za nju. Isti su autori također zaključili da se distribucija podataka najčešće ne mijenja, neovisno o tome je li opcija „ne znam“ uključena ili ne. Drukčije rečeno, izostavljanjem te opcije nasumični odgovori vjerojatno će ići u različi-

tim smjerovima podjednako pa će distribucija podataka (prosječna vrijednost i raspršenje) vjerojatno biti sačuvana. No pouzdanost tako dobivenih mjera bit će snižena, što će utjecati na statističku snagu pri testiranju hipoteza. Npr. ako ispitujemo stav ispitanika o određenom pitanju i izostavimo odgovor „ne znam", vjerojatno ćemo dobiti točne proporcije ispitanika koji su „za" i „protiv", ali ćemo puno teže utvrditi razlikuju li se npr. manje obrazovani i obrazovaniji ispitanici u stavu o tom pitanju.

Iz navedenih je razloga opciju „ne znam" najčešće dobro uključiti u anketno pitanje, uz dva izuzetka. Prvi predstavljaju socijalno osjetljiva pitanja u kojima opcija „ne znam" sudionicima istraživanja može pružiti alternativu iskazivanju vlastitog stava koji doista i postoji. Izostavljanjem opcije „ne znam" ispitanici se „prisiljavaju" na izjašnjavanje, iako se i tu može dogoditi da ovakva prisila unese nelagodu ispitanicima, a time i pokvari kvalitetu podataka koji slijede u istraživačkoj anketi. Drugi je izuzetak situacija u kojoj odgovori ispitanika koji će izabrati opciju „ne znam", kada je dostupna, nisu nasumično raspoređeni, odnosno ne odražavaju nasumično odgovaranje. U takvim slučajevima odgovori ispitanika odražavaju određenu tendenciju, čak i onda ako bi ti isti ispitanici izabrali opciju „ne znam" kad bi im bila ponuđena (Lietz, 2010: 260). To se može dogoditi onda kada ispitanik nije previše razmišljao o određenom pitanju ili mu stav o nekom pitanju nije previše važan (salijentan), odnosno nije povezan s nekom ispitanikovom vrijednošću. Uzmimo da, primjerice, učenike ili studente pitamo je li hrvatski porezni sustav socijalno pravedan ili ne. Iako će mnogi ispitanici o tome imati određeno mišljenje, vjerojatno će zbog nedovoljnog bavljenja tom temom i nepostajanja vlastitog izravnog iskustva znatan dio njih izabrati opciju „ne znam". Uvrštavanjem opcije neizjašnjavanja utvrđivanje tendencije u stavovima ispitanika bilo bi onemogućeno, a dodatno bi se i reducirao uzorak korišten u istraživanju. Zbog toga bi, ako bi se pilot-istraživanjem utvrdilo postojanje većeg broja takvih ispitanika, u takvoj situaciji vjerojatno bilo bolje izostaviti opciju „ne znam", pogotovo ako smo odlučili da su nam tendencije u stavovima ispitanika također važne, odnosno ako se nismo odlučili za mjerenje onih stavova koji su jasno formirani.

## 8.6. REDOSLIJED PITANJA U UPITNIKU

Redoslijed pitanja u upitniku važan je iz dvaju razloga:

1. Odvijanje samog procesa anketiranja,
2. Pouzdanosti rezultata.

Općenito se može reći da, s aspekta samog procesa anketiranja, postoje dvije strategije kada je u pitanju redoslijed pitanja u upitniku (Supek, 1981., prema Mejovšeku, 2008: 49):

1. Psihološka strategija,
2. Logička strategija.

*Psihološka strategija* odnosi se na uspostavljanje povoljnog odnosa s ispitanikom što ranije tijekom procesa anketiranja kako bi se osigurala daljnja suradnja te kvaliteta prikupljenih podataka. Primjerice, prema psihološkoj strategiji treba postavljati prvo lakša pa teža pitanja, upitnik treba započeti sa zanimljivim i nekonfliktnim pitanjima, osjetljiva pitanja treba postaviti na samom kraju upitnika kako bi se spriječila blokada ispitanika i sl. *Logička strategija* odnosi se na smisleno grupiranje pitanja, tako da se dijelovi upitnika slažu u smislene cjeline. Na taj način ispitanik ima osjećaj da se anketiranje odvija na logičan i predvidljiv način. Te dvije strategije često mogu biti u koliziji. Primjerice, osjetljivo pitanje može logički spadati u skupinu pitanja koja se postavlja na početku upitnika, ali osjetljiva pitanja bi u psihološkom smislu bilo bolje postaviti na kraju upitnika. Zbog toga se te dvije strategije kombiniraju, a izbor strategije ovisi o svakom pojedinačnom upitniku (istraživanju) i njegovim specifičnostima.

***Redoslijed pitanja u upitniku važan je i zbog utjecaja na način odgovaranja sudionika istraživanja i zbog što kvalitetnijeg odvijanja procesa anketiranja.***

Kombiniranjem psihološke i logičke strategije moguće je doći do nekoliko iskustvenih pravila o redoslijedu pitanja u upitniku:

1. Pitanja u upitniku trebaju biti grupirana u logične cjeline – ne treba skakati s teme na temu.
2. Na prijelazu između pojedinih logičnih cjelina korisno je prijelaz eksplicitno objasniti ispitanicima – najčešće se koriste izrazi poput „sada ćemo preći na pitanja o…“ ili „u ovom dijelu upitnika zanima nas Vaše mišljenje o…“
3. Upitnik je potrebno započeti s lakšim i zanimljivijim pitanjima kako bi se ispitanika potaknulo na sudjelovanje i stvorila dobra atmosfera.
4. Upitnik treba započeti s neutralnim pitanjima o ponašanju na koje je lako dati odgovor (npr. „Jeste li jučer koristili javni prijevoz?“).
5. Pitanja koja uključuje stavove postaviti što kasnije.
6. Sva pitanja koja se smatraju osjetljivim po mogućnosti ostaviti za kraj upitnika.

7. Demografska pitanja (obrazovanje, dohodak, mjesto stanovanja i sl.) ostaviti za kraj upitnika jer nisu previše zanimljiva, a ispitanici ih ponekad mogu smatrati i osjetljivim.
8. Pitanja otvorenog tipa bolje je postaviti naknadno u upitniku jer obično uključuju veći napor od ispitanika, pa ih treba postaviti poslije kada je odnos s ispitanikom već izgrađen i kad je ispitanik već dovoljno upućen u temu istraživanja.

Redoslijed pitanja u upitniku utječe i na pouzdanost rezultata s obzirom na to da odgovori na neko pitanje mogu biti pod utjecajem prethodno postavljenog pitanja. Npr. Schuman i Presser (1981., prema Milasu, 2005: 455) utvrdili su da na pitanje – „Mislite li da bi žena trebala imati pravo na legalan pobačaj ako je u braku i ne želi imati više djece?" – potvrdno odgovorilo 60% ispitanika. Međutim, kada je prethodno postavljeno pitanje o opravdanosti pobačaja u slučaju djece s nasljednim poremećajima, na to pitanje potvrdno je odgovorilo 48% ispitanika. U konkretnom slučaju, na ispitanike je vjerojatno djelovalo neizravno podsjećanje na mogućnost da bi se pobačaj mogao dogoditi zbog „rješavanja" djece s nasljednim poremećajima. Redoslijed pitanja najveći utjecaj ima u situacijama kada ispitanik nema jasno izražen stav o nečemu ili mu taj stav nije previše važan (istaknut), pa tada treba voditi računa da prethodno postavljena pitanja mogu imati utjecaj na odgovore na pitanje koje dolazi poslije. U istraživanju o akademskom varanju (prepisivanje, plagijat i sl.) Standing i Shearson (2010.) pronašli su znatan učinak redoslijeda pitanja na broj studenata koji su u anketnom upitniku priznali da su prakticirali neki oblik akademskog varanja. Naime, ispitanici su u tom istraživanju bili podijeljeni u dvije skupine: prvoj skupini prije postavljanja pitanja o varanju postavljeno je pitanje u kojoj mjeri akademsko varanje odobravaju nastavnici i drugi studenti. Drugoj skupini prvo je postavljeno pitanje o varanju, a zatim pitanje o odobravanju. Rezultati su pokazali da je broj ispitanika koji priznaju akademsko varanje znatno veći u prvoj skupini, vjerojatno zbog grižnje savjesti koja je uslijedila nakon pitanja o odobravanju.

Utjecaj na rezultate može imati i činjenica je li u upitniku prvo postavljeno općenito pa nakon toga specifična pitanja, ili su prvo postavljena specifična pitanja, a nakon toga općenito pitanje. Drukčije rečeno, upotreba *lijevka* (prvo općenito pitanje) ili *obrnutog lijevka* (prvo specifična pitanja) može znatno utjecati na rezultate. Najčešće se preporučuje korištenje strategije lijevka jer specifična pitanja mogu utjecati na naknadno zauzimanje općenitog stava, a obrnuti utjecaj nije izrazito jak (Schuman i Presser, 1981). Naime, uslijed efekta asimilacije, informacije koje se dozovu u memoriju ispitanika prije odgovora na pitanje utječu na sâm odgovor

(Schwarz i sur., 2008: 29-30). Primjerice, Schwarz, Strack i Mai (1991) utvrdili su da se korelacija između zadovoljstva brakom i zadovoljstva ukupnim životom mijenjala u ovisnosti o tome koje se pitanje postavi prvo. Kada se prvo postavi pitanje o braku, tada je korelacija iznosila 0,67, a u slučaju da je prvo postavljeno pitanje o braku općenito, korelacija je iznosila 0,32. Može se pretpostaviti da je korelacija bila jača u prvom slučaju zbog toga što su ispitanici dozvanu informaciju o kvaliteti braka upotrijebili prilikom kalkulacije ukupnog zadovoljstva brakom.

Slično tome, ponekad se odgovori na pitanja sličnoga smisla mogu biti pod utjecajem redoslijeda kojim su postavljena zato što ispitanik na pitanje koje je postavljeno poslije može dodati nove informacije, odnosno spriječiti davanje istih informacija (Dillman, 2008: 163). Primjerice, Mason, Carlson i Tourangeau (1994) dobili su različite odgovore na pitanja o ekonomskoj situaciji u državi i ekonomskoj situaciji u lokalnoj zajednici u ovisnosti o tome što je postavljeno prvo. Ako je pitanje o situaciji o zajednici slijedilo nakon pitanja o situaciji u državi, tada su ispitanici uspoređivali situaciju u zajednici s onom u državi te su je procjenjivali boljom ako je situacija bolja od državnog prosjeka. Ispitanici u anketnu situaciju unose pravila koja važe za svakodnevne konverzacijske situacije, a u njima se očekuje da se pitanja ne ponavljaju, tj. da se sa svakim novim pitanjem traži drukčija i nova informacija. Tako će ispitanici nakon što su odgovorili na pitanje o situaciji u državi, pitanje o situaciji u zajednici uokviriti u kontekstu nove informacije koju bi trebali pružiti, a to je na koji se način situacija u njihovoj zajednici može usporediti sa situacijom u državi. Stoga je slična pitanja dobro odvojiti u upitniku, tj. ne postavljati ih jedno nakon drugog.

Osim redoslijeda samih pitanja, na rezultate može utjecati i redoslijed kategorija odgovora u upitniku. Naime, uslijed kognitivnog zahtjeva koji postoji prilikom razmišljanja o ponuđenim alternativama, vjerojatnije je da će ispitanici detaljnije obraditi alternative koje dolazi prije te stoga pronaći više argumenata za njihovo usvajanje (Schwarz i sur., 2008: 33). Stoga se i ovdje nameće potreba randomizacije kategorija odgovora. Valja napomenuti da su utvrđene i dobne razlike u reakcijama na poredak kategorija odgovora u pitanju, kao i poredak pitanja u upitniku. Naime, starije će osobe zbog manjeg kapaciteta radne memorije biti podložnije efektu poretka kategorija odgovora u pitanju. S druge strane, zbog manjeg memorijskog kapaciteta starije će osobe biti manje podložne utjecaju prethodnih pitanja na odgovor na trenutno pitanje jer će jedan dio ranije dobivenih informacija zaboraviti, odnosno te će se informacije izgubiti iz radne memorije (Schwarz i sur., 2008: 33). Stoga prilikom istraživanja dobnih razlika treba voditi više računa o učinku poretka pitanja i kategorija odgovora unutar pitanja.

Kada se redoslijed općenitih i specifičnih pitanja uzme u obzir, može se napomenuti da strategija obrnutog lijevka može biti korisna u situacijama kada ispitanici o nečemu nemaju izgrađen jasan stav, odnosno taj stav nije dostupan u svijesti ispitanika. Odgovarajući na specifična pitanja, ispitanici induktivno stvaraju svoje mišljenje, tj. u njima se kristalizira stav koji ranije nisu osvijestili (Kukić i Markić, 2006: 164). Primjerice, ispitanici možda ne mogu pouzdano odgovoriti na općenito pitanje jesu li liberalnog svjetonazora, no ako im postavimo niz specifičnih pitanja o slobodi govora, slobodi biranja vlastitog svjetonazora i sl., tada će vjerojatno osvijestiti vlastiti stupanj liberalizma.

S obzirom na to da i druga istraživanja pokazuju raznolike situacije u kojima redoslijed pitanja, kao i redoslijed ponuđenih odgovora unutar samih pitanja, na nepredvidive načine utječe na rezultate istraživanja, u istraživanjima bi redoslijed pitanja u pravilu trebao biti randomiziran. Drukčije rečeno, upitnike bi trebalo raditi u nekoliko verzija, s različitim redoslijedima pitanja, a svaka od verzija trebala bi biti primijenjena na jednaki broj ispitanika. Na taj bi se način neutralizirao učinak redoslijeda. U praksi bi neutralizacija trebala biti primjenjivana što češće, iako se može dogoditi da neutralizacija utječe na psihološki i/ili logički slijed pitanja, tj. narušava normalno odvijanje upitnika. Stoga bi istraživač u svakoj konkretnoj situaciji trebao procijeniti kakve su koristi i štete od randomizacije, odnosno neutralizacije redoslijeda.

## 8.7. DEMOGRAFSKA PITANJA

Demografska se pitanja odnose na opća obilježja ispitanika poput dobi, dohotka, stupnja obrazovanja, zanimanja i slično. U većini je slučajeva način postavljanja tih pitanja jednostavan i samorazumljiv, no i tu je ponekad potrebno napraviti izbor između različitih mogućnosti koje stoje na raspolaganju istraživaču. Ovakva se pitanja obično stavljaju na kraj upitnika, ponajviše zbog socijalne osjetljivosti.

***Demografska pitanja odnose se na opća obilježja ljudi, kao što su spol, dob i mjesto stanovanja, a obično se stavljaju na kraj upitnika.***

### 8.7.1. Pitanja o dohotku

Najinformativnije pitanje o dohotku bilo bi ono kojim bi se pitalo za točan prosječni mjesečni iznos dohotka (individualnog ili obiteljskog). Međutim, ako se

pretpostavlja da će iz nekog razloga veći broj ispitanika smatrati da je takvo pitanje previše osjetljivo, mogu se navesti kategorije u koje se ispitanik treba svrstati (npr. do 2 000 kuna, od 2001 kune do 4 000 kuna itd.). U situacijama kada se smatra da je i pitanje s ponuđenim intervalima previše osjetljivo može se upotrijebiti tzv. ljestve-pitanje (eng. *step-ladder question*) u kojemu se numerički intervali nude jedan po jedan, najčešće u progresivnom slijedu, a koje obično dovodi do manjeg broja odbijenih odgovora na pitanje o dohotku (Lavrakas, 2008).[75] Primjerice, umjesto da sudionicu istraživanja pitamo o individualnom dohotku i odmah joj ponudimo intervale poput „do 3.000 kuna", „od 3.000 do 6.000 kuna", „od 6.000 do 9.000 kuna" i „više od 9.000 kuna", možemo prvo postaviti pitanje „je li Vaš individualni dohodak manji ili veći od 3.000 kuna". Ako je dohodak manji, ne postavljamo sljedeće pitanje, tj. pitanje o dohotku završava se u tom trenutku jer smo dobili informaciju koju smo tražili (dohodak iznosi manje od 3.000 kuna). Ako je dohodak veći od 3.000 kuna, tada postavljamo pitanje „je li Vaš individualni dohotak manji ili veći od 6.000 kuna", i tako dalje. Ovako postavljeno pitanje sudionici smatraju manje prijetećim vjerojatno zbog toga što odmah ne vide sve intervale pa imaju dojam da otkrivaju manje informacija o sebi nego što je to ustvari slučaj. Očito je da postavljanje više pitanja u ovakvom slijedu produljuje trajanje anketiranja, pa ljestve-pitanje treba upotrebljavati samo onda kada prednosti nadmašuju nedostatke, odnosno ako nam je jako važno da broj odbijenih odgovora bude što manji ili smatramo da će pitanje o dohotku za neku skupinu biti posebnu osjetljivo.

Ponekad se želi ispitati koliko je ispitanik zadovoljan imovinskim stanjem, a ne koliki je točan iznos dohotka, pa se pitanje može postaviti i na takav način: „Koliko ste zadovoljni svojim imovinskim stanjem?" U praksi se često susreće i pitanje u kojemu ispitanik svoje imovinsko stanje uspoređuje s drugima (s odgovorima „bolje od ostalih", „slično kao i kod ostalih" itd.), no u velikoj većini slučajeva ispitanici se svrstavaju u srednju kategoriju („slično kao i kod ostalih"), pa odgovori često nisu previše korisni. S druge strane, ispitanici tako postavljeno pitanje smatraju najmanje osjetljivim (intimnim).

Ako se pita točan iznos obiteljskog dohotka, taj se dohodak postupkom izjednačavanja (ekvivalizacije) pretvara u tzv. ekvivalentni dohodak, zbog toga što nije isto ima li određeni dohodak npr. obitelj s dva člana ili obitelj sa šest članova, kao što nije isto jesu li u pitanju odrasle osobe ili djeca. Osim toga, troškovi života povećavaju se sa svakim novim članom, ali prema različitoj dinamici. Primjeri-

[75] Ovaj tip pitanja može se upotrijebiti u bilo kojem slučaju u kojem se odgovori mogu smjestiti u numeričke intervale, a ne samo u slučaju postavljanja pitanja o dohotku.

ce, troškovi zajedničkog života dvije odrasle osobe neće biti jednaki dvostrukim troškovima života za jednu osobu jer neki troškovi postoje neovisno o broju osoba koje upotrebljavaju određenu uslugu (npr. fiksni troškovi režija, televizijska pretplata, registracija automobila i sl.). Postoji nekoliko pristupa izračunu ekvivalentnog dohotka koji se međusobno razlikuju prema načinu dodjeljivanja težinskih čimbenika (tzv. pondera), a svi su razvijeni unutar OECD-a.[76] Tako se ekvivalentna veličina kućanstva najčešće računa prema tri metodologije:

1. Stara OECD skala – Prvi odrasli član kućanstva dobije težinski faktor 1,0, svaki daljnji odrasli član 0,7, a dijete 0,5.
2. Modificirana (nova) OECD skala – Prvi odrasli član kućanstva dobije težinski faktor 1,0, svaki daljnji odrasli član 0,5, a dijete 0,3.
3. Skala drugo korijena – ekvivalentna veličina kućanstva dobiva se izračunom drugog korijena iz „obične" veličine kućanstva.

Ilustrirajmo ove različite načine izračuna na primjeru kućanstva koje se sastoji od bračnog para i dvoje male djece. Prema staroj OECD skali ekvivalentna veličina kućanstva bila bi 1,0 + 0,7 + 0,5 + 0,5 = 2,7. Prema modificiranoj OECD skali ekvivalentna veličina kućanstva bila bi 1,0 + 0,5+ 0,3 + 0,3 = 2,1. Prema skali drugog korijena ekvivalentna veličina kućanstva bila bi $\sqrt{4}$ = 2,0. Ekvivalentni dohodak po članu kućanstva ovakve obitelji, ako ona zarađuje 10.000 kuna, prema ovim metodama iznosio bi (1) $\frac{10000}{2,7}$ = 3.703,70 *kuna*, (2) $\frac{10000}{2,1}$ = 4.761,90 *kuna* te (3) $\frac{10000}{2,0}$ = 5.000,00 *kuna*.

## 8.7.2. PITANJA O DOBI

Pitanje o dobi najčešće se postavlja na tri načina:

1. Napunjene godine života,
2. Godina rođenja,
3. Dobni intervali (do 18 g., 19-25 g., itd.).

Budući da je mladost u pravilu socijalno poželjna osobina, taj tip pitanja neki ispitanici mogu smatrati osjetljivim i osjećati nelagodu prilikom postavljanja pitanja o dobi. Iskustva pokazuju da dobne intervale (od ispitanika se traži da se svrstaju u neki od intervala) ispitanici smatraju najmanje osjetljivim, no takav

[76] Organizacija za europsku suradnju i razvoj.

tip pitanja najmanje je kvalitetan jer se varijabla spušta na ordinalnu razinu. Pitanje kojim se traži godina rođenja ispitanici smatraju manje osjetljivim od onoga kojim se od njih traži da kažu koliko su godina napunili, pa je taj tip pitanja o dobi vjerojatno najbolji.

### 8.7.3. Pitanja o zanimanju

Pitanja o zanimanju uvijek treba postaviti u formi pitanja otvorenog tipa, tj. od ispitanika tražiti da navedu točan naziv zanimanja. Ako je riječ o anketiranju u kojemu postoji osobni kontakt, anketar može od ispitanika tražiti da pojasni čime se točno bavi. Nakon toga se navedeno zanimanje obično svrstava (kodira) u jedan od rodova zanimanja prema Nacionalnoj klasifikaciji zanimanja („zanimanja u trgovini i uslugama", „visokoobrazovani profesionalci", „inženjeri i tehničari", „radnici u obrtu i pojedinačnoj proizvodnji" i sl). Pri tome osoba koja kodira zanimanja mora biti vrlo dobro educirana o tome koje zanimanje spada u koji rod.

## 8.8. NAČINI PRIKUPLJANJA PODATAKA POMOĆU UPITNIKA

Postoji pet osnovnih vrsta prikupljanja podataka pomoću upitnika:

1. Terenske ankete prikupljene individualnim anketiranjem,
2. Terenske ankete sa skupnim anketiranjem,
3. Telefonske ankete,
4. *Online* ankete,
5. Poštanske ankete.

Svaki od načina prikupljanja podataka ima svoje prednosti i nedostatke navedene u donjoj tablici.

*Tablica 31. Prednosti i nedostaci načina prikupljanja anketnih podataka*

| **Način prikupljanja podataka** | **Prednosti** | **Nedostatci** |
|---|---|---|
| Terenske ankete prikupljene individualnim anketiranjem | Velika količina skupljenih podataka<br>Reprezentativni uzorak<br>Postoji interakcija s ispitanikom | Visoka cijena<br>Dugo trajanje istraživanja<br>Nepostojanje anonimnosti (loše za ankete s puno osjetljivih pitanja) |
| Terenske ankete prikupljenje skupnim anketiranjem | Umjerena cijena<br>Umjereno trajanje istraživanja<br>Postoji interakcija s ispitanikom<br>Anonimnost | Nije ju moguće uvijek provesti (ispitanici se moraju nalaziti na istom mjestu – npr. škole, fakulteti, poduzeća i sl.)<br>Reprezentativnost nije uvijek savršena (npr. anketiraju se studenti koji dođu na nastavu) |
| Telefonske ankete | Niska cijena<br>Veliki geografski obuhvat<br>Brzina istraživanja | Niska anonimnost<br>Reprezentativnost nije savršena (neki ljudi nemaju telefone, neki ih imaju više od jednog)<br>Nemogućnost korištenja vizualnih pomagala (slika, grafičkih skala itd.) |
| *Online* ankete | Vrlo niska cijena<br>Mogućnost korištenja vizualnih pomagala<br>Kratko trajanje istraživanja<br>Doseg specifičnih skupina | Upitna reprezentativnost (niska dostupnost interneta i autoselekcija)<br>Nepostojanje izravnog kontakta s ispitanikom |
| Poštanske ankete | Umjerena cijena<br>Mogućnost korištenja vizualnih pomagala<br>Ispitanici mogu ispuniti anketu kada im odgovara<br>Anonimnost | Mali odaziv (upitna reprezentativnost)<br>Zahtijeva veći napor od ispitanika |

***Različiti načini prikupljanja podataka imaju svoje prednosti i nedostatke, a odluka o tome koji ćemo način upotrijebiti prije svega ovisi o dopuštenom trošku i trajanju istraživanja, kao i o tome koji je način najbolje prilagođen specifičnim sudionicima istraživanja.***

Terenske ankete s individualnim anketiranjem najbolje su u većini situacija zbog reprezentativnosti uzorka i mogućnosti duljeg trajanja pojedinačne ankete, a

danas u pravilu anketari podatke odmah pri anketiranju unose u računala (tzv. CAPI – *computer-assisted personal interviewing*). Izuzetak predstavljaju istraživanja koja uključuju mnogo osjetljivih pitanja. Tako će u terenskim anketama ispitanici često davati socijalno poželjne odgovore, a pri mjerenju stavova neće biti skloni zauzeti ekstremne pozicije (smjestit će se u sredini skale). Stoga je u terenskim istraživanjima ponekad poželjno izostaviti srednji stupanj skale (npr., „Niti se slažem niti ne slažem" u Likertovoj skali). Dodatnu opasnost u terenskim anketama predstavlja nešto veći utjecaj anketara, tj. pogreška mjerenja koja se zbog toga događa. Najčešće su situacije u kojima anketar pitanje postavlja sugestivno (navodi ispitanika na određeni odgovor), ne postavlja pitanja pravim redoslijedom, izostavi pojedina pitanja i sl. Utjecaj anketara javlja se i u telefonskim anketama, ali je u terenskim istraživanjima stupanj kontrole rada anketara, a samim time i mogućnost ispravljanja pogrešaka znatno manji. S druge strane, upravo postojanje interakcije s ispitanikom anketaru omogućava da promatranjem mimike i govora tijela uoči moguće nesporazume i ispravi ih. Primjerice, anketar može uočiti da ispitanik nije dobro razumio pitanje i stoga ga ponovno postaviti. Međutim, ovakve je situacije dobro standardizirati prilikom edukacije anketara, odnosno dobro je da izrazi koji se upotrebljavaju prilikom sličnih situacija svi anketari upotrijebe na jednak način.

Dugo trajanje istraživanja i njegova visoka cijena također su nedostatci terenskih anketa. Naime, odlasci na teren zahtijevaju dodatne troškove, ali i vrijeme jer se svakoga potencijalnog ispitanika u slučaju nedostupnosti mora pokušati kontaktirati više puta. Stoga se terenske ankete u praksi upotrebljavaju za društveno ili komercijalno važna istraživanja kojima se svakako želi postići kvaliteta podataka unatoč visokoj cijeni njihova pribavljanja.

Neki od tih nedostataka mogu biti uklonjeni skupnim anketiranjem. U tom slučaju anonimnost je potpuno zajamčena jer se upitnici ispunjavaju samostalno, a ispunjeni upitnici ne potpisuju. Cijena istraživanja također je znatno manja, a istraživanje se može izvesti vrlo brzo jer se u jednom mahu prikupi veći broj upitnika. Skupno anketiranje nije uvijek moguće provesti, odnosno može ga se provesti samo onda kada su ispitanici grupirani u prirodne cjeline (škola, tvrtka...). Osim toga, reprezentativnost uzorka često je upitna zbog učinka samoselekcije. Primjerice, pri anketiranju studenata na fakultetima u uzorak će ući oni studenti koji su prisutni na predavanju, a oni se mogu znatno razlikovati od onih koji nisu prisutni i na predavanja dolaze rjeđe.

Velika je prednost telefonskog prikupljanja podataka brzina istraživanja i širok geografski obuhvat ispitanika, a danas se ova tehnika u pravilu kombinira s ra-

čunalnim unosom podataka koje prilikom anketiranja rade anketari (tzv. CATI – *computer-assisted telephone interviewing*). Iz tih se razloga telefonske ankete vrlo često koriste za istraživanja javnog mnijenja u kojima je potrebno brzo i uz manje troškove istražiti neku aktualnu temu, primjerice za potrebe medija. Važan je nedostatak telefonskih anketa nemogućnost dubljeg istraživanja određene teme, tj. činjenica da telefonsko istraživanje zbog zamora ispitanika ne bi trebalo trajati dulje od 15 minuta, kao i da u njemu ne mogu biti postavljena pitanja složenije forme ili pitanja koja uključuju neki oblik grafičke reprezentacije. Činjenica da telefonske ankete ne bi trebale trajati dugo dovodi i do toga da je u njima uobičajeno pokušati pitanja učiniti što kraćim, upotrebljavati brojeve kao stupnjeve skale umjesto verbalnih opisa, skratiti broj opcija odgovora i broj stupnjeva na skali i sl. Kao sve veći nedostatak telefonskih anketa ističe se i njihova upitna reprezentativnost jer jedan dio kućanstava nema fiksne telefonske priključke – u RH je to prema posljednjim podatcima oko 20% – što znatno smanjuje okvir uzorka koji se upotrebljava u istraživanju. Zbog većeg broja telemarketinških aktivnosti stope sudjelovanja u telefonskim anketama smanjile su se posljednjih desetljeća, a smanjenju sudjelovanja pridonosi i mogućnost prikazivanja telefonskog broja pozivatelja. Mogućoj pristranosti uzorkovanja pridonosi i činjenica da je jedan broj ljudi izrazito teško pronaći kod kuće (mlađi i zaposleni pojedinci), no to je problem koji postoji i u provođenju drugih vrsta anketnih istraživanja, primjerice onih terenskih. Svakako valja napomenuti da se u telefonskim istraživanjima prilikom izbora telefonskih brojeva treba koristiti generator slučajnih brojeva, a da je za stratifikaciju prema nekom geografskom načelu, primjerice prema veličini naselja, potrebno poznavati brojeve centrala tih naselja. Anonimnost istraživanja provedenog telefonskim putem veća je od individualnih terenskih anketa, ali i manja od poštanskih i internetskih anketa, kao i od terenskih anketa provedenih skupnim anketiranjem.

Danas se, zbog sve veće upotrebe interneta, sve više upotrebljavaju *online* ankete. S obzirom na to da je riječ o samostalnom popunjavanju upitnika koji se nalazi na internetu ili općenito na nekoj vrsti online izvora, za ove se ankete upotrebljava i naziv CAWI (*computer-assisted web interviewing*). Postoje tri osnovne vrste *online* anketa:

1. Ankete na internetskim stranicama,
2. E-mail i druge pozivne ankete,
3. *Online* paneli.

*Ankete na internetskim stranicama* služe za ispitivanje mišljenja posjetitelja te stranice i najčešće nisu reprezentativne u odnosu na cijelu populaciju. Iako se

ponekad može osigurati da jedna osoba upitnik ne popuni više puta, element samoselekcije ispitanika izrazito je velik te je u ovom slučaju riječ o prigodnom uzorku, a procjene dobivene pomoću njega najčešće nisu nepristrane upravo zbog nepoznate vjerojatnosti ulaska u uzorak. E-mail ankete koriste se na način da se ispitanicima e-mailom ili drugim putem (npr. pomoću društvenih mreža) dostavi anketni upitnik ili im se dostavi poveznica na kojoj mogu popuniti upitnik. Za kreiranje upitnika koji se koriste u ovakvim anketama koriste se ili programi za obradu teksta (npr. forme unutar MS Worda) ili, što je danas mnogo češći slučaj, specijalizirani softveri za izradu e-mail upitnika. Ovakve ankete najčešće se koriste u slučaju manjeg uzorka ljudi koje poznajemo i čije su nam e-mail adrese dostupne ili u slučaju kada želimo provesti istraživanje a svjesni smo da će ono uključivati visok stupanj samoselekcije sudionika istraživanja. Naime, izradom online upitnika i dijeljenje poveznice na njega istraživač gubi kontrolu nad time tko je popunio ovakav upitnik. Nije moguće reći ni koje su stope odaziva za pojedine skupine sudionika, a jedino je moguće usporediti demografsku strukturu uzorka te izraditi poststratifikaciju u slučaju da su neke skupine podzastupljene/nadzastupljene. Dugim riječima, kao i u slučaju upitnika postavljenih na mrežne stranice, na ovaj se način dobije prigodni uzorak u čija obilježja ne možemo biti sigurni, odnosno ne možemo reći jesu li procjenjivači dobiveni ovakvim uzorcima nepristrani i efikasni. *Online paneli* odnose se na ispitanike koji su pristali na sudjelovanje u anketnim istraživanjima i koji su najčešće za to i financijski nagrađeni. Ispitanici povremeno e-mailom dobivaju pozive za popunjavanjem anketnog upitnika ako ispunjavaju demografske ili druge kriterije za sudjelovanje u istraživanju. Općenito se može reći da je velika prednost *online* anketa njihova brzina provođenja i vrlo niska cijena, no reprezentativnost uzorka najčešće je vrlo upitna. Neki autori (Kleck i Roberts, 2012) sugeriraju i da online ankete daju dobre rezultate pri istraživanju socijalno osjetljvih tema jer su sudionici istraživanja rjeđe daju socijalno poželjne odgovore ako imaju osjećaj da odgovore daju računalu, a ne osobi. Velika je prednost *online* anketa i mogućnost dosezanja specifičnih skupina, odnosno ciljnih skupina do kojih je teško doći na ekonomičan način drugim metodama anketiranja. Tako se na internetskim stranicama, Facebook grupama, internetskim forumima i drugim mjestima na internetu, uz suglasnost njihovih administratora, može na jednostavan način doći do ljudi sa specifičnim obilježjima i interesima (npr., manjinske vjerske skupine, pratitelji nekoga sporta, oboljeli od rijetkih bolesti, osobe određenih političkih uvjerenja i sl.).

Poštanske ankete provode se tako da se ispitanicima poštom pošalje upitnik u kojemu je priložena omotnica s plaćenim povratnim odgovorom. Najveća je prednost poštanske ankete mogućnost da ispitanik upitnik ispuni u trenutku

kada mu/joj to najviše odgovara, kao i da upitnik ispunjava svojim tempom i da prikupi podatke koji se traže u istraživanju. Primjerice, u Hrvatskoj se neka istraživanja koja državne institucije provode na gospodarskim subjektima (npr. *Anketa poslodavaca* koju provodi HZZ) provode upravo poštanskim putem jer ispitanicima omogućavaju dulje razmišljanje i prikupljanje odgovarajućih podataka o vlastitom poduzeću. Osim toga, poštanske ankete nisu izrazito skupe, a uključuju i mogućnost korištenja vizualnih pomagala. Primjerice, u marketinškom istraživanju, kojim se želi istražiti koja je od etiketa nekog proizvoda ispitanicima najzanimljivija, u poštanski se anketni upitnik mogu uvrstiti grafički prikazi tih etiketa. Najveći je nedostatak poštanskih anketa upitna reprezentativnost jer je stopa odaziva često vrlo mala (oko 10%), osim kada su u pitanju ankete koje provode državne institucije.

## 8.9. IZVORI POGREŠKE U ANKETNOM ISTRAŽIVANJU

Izvori pogreške u anketnom istraživanju mogu se podijeliti na (Milas, 2005: 435):

1. pristranost uzorkovanja,
2. varijabilnost uzorka (statistička greška uzorka),
3. pristranost neovisnu o uzorkovanju.

*Pristranost uzorkovanja* obično se događa u neslučajnim uzorcima, a predstavlja situaciju u kojoj su neki segmenti populacije nadzastupljeni, a neki podzastupljeni. Primjerice, anketiranjem prolaznika na ulici vjerojatno ćemo imati podzastupljenost zaposlenih građana, a nadzastupljenost nezaposlenih. Dakle, pristranost uzorkovanja događa se u situacijama kada nemamo dobru pokrivenost uzorka, odnosno važna obilježja okvira uzorka znatnno nam se razlikuje od obilježja populacije. Pristranost uzorkovanja dovodi do pogrešnih i nepouzdanih rezultata istraživanja.

*Varijabilnost uzorka* normalna je posljedica činjenice da u istraživanju koristimo uzorak, tj. ne istražujemo cijelu populaciju. Naime, kada bismo umjesto izvučenog uzorka izvukli neki drugi, izračunani pokazatelji na njemu vjerojatno bi se razlikovali od pokazatelja prvog uzorka jer bi u uzorak ušli drugi članovi populacije. Dobra je stvar da se varijabilnost uzorka može izračunati, odnosno pravi rezultat u populaciji može se procijeniti pomoću statističkih tablica (distribucija) izračunom intervala pouzdanosti.

*Pristranost neovisna o uzorkovanju* odnosi se na pristranost vezanu uz opažanja (pogreške upitnika, pogrešku u anketiranju, obradi podataka i sl.) te pristranost nevezanu uz opažanje (neodaziv, nedovoljan pokrivenost i sl.). Drukčije rečeno, ova se pristranost (pogreška) može podijeliti na pogrešku mjerenja (nedostatci u upitniku i njegovoj primjeni koji dovode do nevaljanih rezultata), pogrešku pokrivenosti (nedostupnost) i pogrešku neodaziva.

Stopa nesudjelovanja u anketi utječe na pogrešku rezultata dobivenih anketom, iako to izrazito ovisi o razlici između onih članova uzorka koji su sudjelovali i onih koji iz raznih razloga nisu sudjelovali u anketi. Stopa nesudjelovanja dobije se tako da se broj onih članova uzorka koji su sudjelovali u anketi podijeli s ukupnim brojem članova uzorka koji su trebali sudjelovati u anketi. Dva su osnovna uzroka nesudjelovanja u anketama:

1. Nedostupnost,
2. Odbijanje sudjelovanja.

*Nedostupnost* se odnosi na nemogućnost kontaktiranja ispitanika zbog njihove odsutnosti, zauzetosti, bolesti i sl. Pogreška zbog nedostupnosti može se smanjiti ponovljenim kontaktima s potencijalnim ispitanicima i pokušajem obavljanja ankete. Tako se u terenskim istraživanjima više puta dolazi u kućanstva ako ispitanik nije bio prisutan, u telefonskim više puta se nazivaju brojevi u slučaju da se nitko ne javlja i sl. Jedna od tehnika kojima se može smanjiti pogreška koja nastaje zbog nepristupačnosti isptanika zamjena je nedostupnih ispitanika u sadašnjem istraživanju ispitanicima koji su bili nedostupni u prethodnom istraživanju (Milas, 2005: 441). Ta se tehnika zasniva na ideji da ispitanici koji su nedostupni mogu imati slična obilježja, pa se onda i čini logičnim da ispitanike do kojih trenutno ne možemo doći pokušamo zamijeniti onima do kojih nismo mogli doći u prethodnom istraživanju. Primjerice, u prvom istraživanju anketiramo 1 000 studenata, pri čemu nismo uspjeli doći do njih 300 (npr. nisu bili na nastavi u vrijeme anketiranja). Ako u drugom istraživanju od planiranih 1 000 studenata uspijemo doći do njih 700, a njih 300 su nam nedostupni (nisu na nastavi), pokušat ćemo ih zamijeniti s 300 studenata koji nisu bili dostupni u prvom istraživanju. Ta zamjena čini se logičnom jer studenti koji rjeđe dolaze na nastavu mogu imati slična obilježja (manja motivacija, nekontinuiran rad tijekom studija), što može biti povezano s onime što istražujemo.

*Odbijanje sudjelovanja* u anketama postaje sve veći problem s obzirom na to da je broj anketnih istraživanja sve veći (državna istraživanja, znanstvena istraživanja, komercijalna istraživanja i sl.). Odbijanje anketa povezano je s određenim

sociodemografskim obilježjima. Tako u Hrvatskoj ankete odbijaju češće stariji, manje obrazovani i ispitanici koji žive u velikim gradovima (Lamza-Posavec, 1997.). Kada su znanstvena istraživanja općenito u pitanju, istraživanja pokazuju da u njima dobrovoljno češće sudjeluju obrazovaniji pojedinci, višeg društvenog sloja i inteligencije, kao i društveniji ljudi, odnosno ljudi koji imaju veću potrebu za odobravanjem drugih ljudi (Milas, 2005: 407). Moguće je objašnjenje manje voljnosti za sudjelovanjem u istraživanjima koju pokazuju ljudi nižeg socijalnog statusa i obrazovanja činjenica da se govorenje osobi višeg socijalnog statusa o vlastitom životu može shvatiti kao prijeteća situacija (npr. pojedinac se može osjećati neugodno zbog vlastitog imovinskog statusa, zanimanja koje obavlja i sl.), a nedostatak obrazovanja može navesti osobu da pomisli da će u istraživanju pokazati svoje „neznanje".

Pogreška neodaziva ne mora uvijek imati utjecaj na kvalitetu istraživačkih podataka. Naime, neodaziv će smanjiti kvalitetu rezultata samo u situacijama kada se skupine koje imaju veći neodaziv znatno razlikuju prema parametrima koji se u istraživanju smatraju važnim, te kada je udio zainteresiranih u populaciji dovoljno velik. Primjerice, Groves i sur. (2004) nisu pronašli veći utjecaj različitog sudjelovanja zainteresiranih i nezainteresiranih dijelova populacije, ponajviše zbog malih udjela prvih u populaciji. Primjerice, iako će nastavnici u usporedbi s općom populacijom češće sudjelovati u istraživanjima koja se tiču školstva, te razlike u stopama sudjelovanja neće imati znatniji utjecaj na rezultate zbog toga što nastavnici čine vrlo mali dio ukupne populacije.

Determinante sudjelovanja u istraživanjima općenito se mogu objasniti tzv. *teorijom planiranog ponašanja* (Ajzen, 2002., navedeno prema Heerweghu i Loosveldtu, 2009.). Prema toj teoriji, svako je ponašanje određeno trima čimbenicima: stavovima prema tom ponašanju, subjektivnim normama i percipiranom kontrolom. Stavovi prema ponašanju odnose se na percipiranu korisnost ponašanja, tj. njegove pozitivne i negativne karakteristike. U kontekstu istraživanja to znači da će ispitanici češće sudjelovati u onim istraživanjima koja smatraju zanimljivijim, čije rezultate smatraju korisnim i ako su nagrađeni za to sudjelovanje. Sudjelovanje u istraživanjima obično je veće u situacijama kada iza istraživanja stoji neka poznata državna ili javna institucija (npr. sveučilište ili istraživački institut), no nije jednostavno reći u kojoj je to mjeri posljedica procjene veće korisnosti istraživanja od samog ispitanika, a u kojoj mjeri svojevrsni socijalni pritisak. Drugi čimbenik odnosi se na subjektivne norme, tj. procjenu odobravanja ili neodobravanja određenog ponašanja od strane društvene okoline. U kontekstu istraživanja to znači da će ispitanici češće sudjelovati u istraživanju ako

im se naglasi da svojim sudjelovanjem mogu pomoći istraživačima, s obzirom na to da je pomaganje osobina koja se pozitivno vrednuje. Treći čimbenik odnosi se na stupanj kontrole, tj. jednostavnost izvođenja nekog ponašanja, pri čemu će se pojedinac lakše i vjerojatnije odlučiti na određeno ponašanje ako vjeruje da je to ponašanje jednostavno izvesti. U kontekstu istraživanja to znači da je poželjno da ono bude kratko, razumljivo i da od ispitanika zahtijeva što manji napor bilo koje vrste.

***Teorija planiranog ponašanja sugerira da se bolji odziv na sudjelovanje u istraživanju može postići olakšavanjem sudjelovanja, zanimljivošću i korisnošću samog istraživanja, kao i apelom na altruizam sudionika istraživanja.***

Kako bi se stvorio pozitivan stav ispitanika prema istraživanju, naglasila poželjnost sudjelovanja ili ispitanicima jamčila kontrola, osobito je važan uvodni dio istraživanja, odnosno uspostavljanje prvoga kontakta. U njemu je ispitanicima potrebno ukratko protumačiti svrhu istraživanja, naglastiti njegovu korisnost te točno navesti njegovo trajanje i što se očekuje od ispitanika. Treba imati na umu da je bilo kakvo obmanjivanje ispitanika, osim u slučajevima kada bi otkrivanje svrhe istraživanja ugrozilo mogućnost njegova provođenja, ne samo neetično, nego i smanjuje vjerojatnost da će ispitanici sudjelovati u budućim istraživanjima. Time se onemogućava skupljanje podataka koji mogu biti znanstveno ili praktično korisni, odnosno onemogućava daljnji znanstveni napredak.

## 8.10. UPOTREBA UPITNIKA U MEĐUKULTURNIM ISTRAŽIVANJIMA

Istraživači često upotrebljavaju upitnike u istraživanjima koja se provode u više zemalja, pri čemu su neko obilježje zemlje ili kultura eksplanatorne varijable (Fife-Schaw, 2012: 126). Drukčije rečeno, razlike u stavovima, znanju ili ponašanju koje se utvrde u podatcima prikupljenim anketnim putem pokušavaju se protumačiti obilježjima zemlje. Pri tome se postavljaju dva vrlo važna pitanja: (1) jesu li upitnici korišteni u različitim zemljama ekvivalentni, odnosno je li osigurano jednako shvaćanje upitnika svim ispitanicima?, te (2) utječu li razlike u općenitim obrascima odgovora na anketna pitanja u pojedinim zemljama na rezultate istraživanja i njihovu interpretaciju? Prvo se pitanje, dakle, odnosi na kvalitetu, odnosno mogućnost prijevoda upitnika na druge jezike, pri čemu se obično ko-

risti strategija *povratnog prijevoda* (eng. *back-translation*). Ta se strategija sastoji od toga da jedan prevoditelj upitnik prevede s originalnog na ciljni jezik, a zatim drugi neovisni prevoditelj upitnik ponovno prevede na originalni jezik. Ako je završni prijevod vrlo sličan prvotnom, tada se može reći da su prijevodi ekvivalentni, tj. da se može govoriti o tome da su obje jezične verzije jednako shvatili govornici dvaju jezika. Onkvisit (2004: 229) spominje još dvije strategije osiguravanja jezične ekvivalentnosti: *paralelni prijevod* (eng. *parallel-blind translation*) te korištenje *odbora stručnjaka* (eng. *commitee approach*). U prvom slučaju dva neovisna prevoditelja rade na prijevodu iz originalnog jezika, nakon čega se njihovi prijevodi uspoređuju i korigiraju. U drugom slučaju, odbor stručnjaka u grupnoj raspravi dolazi do prijevoda koji se smatra najboljim. Niti jedna od spomenutih strategija ne može osigurati potpunu ekvivalentnost, ali može spriječiti grube pogreške u prijevodu koje mogu znatno umanjiti kvalitetu istraživanja.

Drugi se problem sastoji od činjenice da su pojedini obrasci odgovora na anketna pitanja, osobito sklonost zauzimanju srednjeg stupnja na skali ili sklonost davanju ekstremnih odgovora različite u pojedinim zemljama. Te razlike otežavaju usporedbe među pojedinim zemljama, pa bi u takvim istraživanjima uvijek trebalo utvrditi, po mogućnosti u pilot-istraživanju, postoje li različiti obrasci odgovaranja, a Fife-Schaw (2012.) preporučuje da se u tom slučaju izostavi srednji stupanj skale, odnosno da se broj stupnjeva na skali smanji. U prvome bi se slučaju uklonio učinak različitih sklonosti zauzimanja srednjeg stupnja, a u drugome različita sklonost davanju ekstremnih odgovora.

## 8.11. PREDTESTIRANJE UPITNIKA

Ranije su navedeni mnogobrojni izvori pogrešaka u anketnom istraživanju, odnosno situacije u kojima se događa komunikacijski nesporazum između anketara i ispitanika, pri čemu ispitanik i anketar (istraživač) nemaju isto razumijevanje anketnih pitanja. Jasno je da ovakva situacija dovodi do mjerne pogreške, umanjujući time metrijska obilježja mjernih instrumenata (valjanost, pouzdanost itd.). Stoga se, osobito kada su u pitanju važna istraživanja koja zahtijevaju ulaganje većih vremenskih, financijskih i drugih resursa, nameće potreba predtestiranja upitnika, odnosno provođenje pilot istraživanja.[77]

[77] Predtestiranje i pilot istraživanje uglavnom se shvaćaju kao sinonimi, iako se ponekad izraz „pilot istraživanje“ upotrebljava isključivo za provođenje istraživanja na manjem uzorku, a

Predtestiranje može uključivati primjenu neformalnih tehnika, kao što su konzultiranje s kolegama, čitanje pitanja naglas, samointervjuiranje ili anketiranje manjeg broja poznatih ljudi (kolega, prijatelja, rodbine i sl.), ali može se sastojati i od formaliziranih tehnika koje zahtijevaju dulje vrijeme i pomno planiranje. Campanelli (2008) tehnike provođenja predtestiranja dijeli na tradicionalne i nove. Tradicionalne tehnike odnose se na provođenje istraživanja na manjem uzorku, prema mogućnostima reprezentativnom u odnosu na ciljanu populaciju. Nakon što se anketiranje provede, pregledaju se odgovori i potraže problematični obrasci i situacije, poput većeg broja neodgovorenih pojedinih pitanja, pitanja vrlo male diskriminativnosti, nelagode koja se pojavljuje prilikom odgovora na neka pitanja, učestalo traženje pojašnjenja ispitanika i sl. U ovoj fazi moguće je provjeriti i dimenzionalnost pojedinih skala upotrijebljenih u istraživanju. Jedna je od opcija i promjena formulacije upitnika nakon što je proveden jedan dio istraživanja, kako bi se vidjelo hoće li nova formulacija dovesti do drukčijih rezultata, tj. ukloniti uočene probleme. Kao nove tehnike, Campanelli (2008) izdavaja (1) upotrebu eksperata, (2) sustavnu provjeru upitnika, (3) *debriefing* ispitanika, (4) bihejvioralno kodiranje, (5) kognitivno intervjuiranje i (6) fokus grupe. Upotreba eksperata odnosi se na sustavnu analizu upitnika pomoću eksperata iskusnih u konstrukciji anketnih pitanja i provođenju anketnih istraživanja. Organizacije pri tom mogu stvoriti i stalne panele koji će biti zaduženi za pregled svih upitnika i davanje sugestija za njihovo poboljšanje. Sustavna provjera upitnika odnosi se na primjenu formi u kojima se označe svi mogući problemi koji su se pojavili prilikom predtestiranja. Neki od mogućih problema odnose se na nejasne formulacije pitanja, dvostruka pitanja, poteškoće prilikom prisjećanja ispitanika, nedostupnost informacija, preklapajuće kategorije odgovora i sl. *Debriefingom* se od ispitanika koji su sudjelovali u istraživanju pokušava saznati na koji su način razumjeli pojedina pitanja i koje su poteškoće imali prilikom popunjavanja upitnika, odnosno odgovaranja na pojedina pitanja. Na ovaj se način može utvrditi i jesu li neka pitanja previše osjetljiva, pri čemu ispitanike to ne treba izravno pitati jer je takvo pitanje samo po sebi također osjetljivo. Umjesto toga najbolje je postaviti indirektno pitanje. Primjerice, umjesto pitanja: „Je li Vam bilo neugodno odgovoriti na ovo pitanje“ ili „Koja su pitanja bila previše osobna“, bolje je pitati: “Je li ovo pitanje za većinu ljudi neugodno“ ili „Koja bi od ovih pitanja većinu ljudi navela da se neugodno osjećaju?“ (prema Campanelli, 2008: 187). Kao opće načelo d*ebriefinga* može se istaknuti da je rijetko korisno ispitanike direktno pitati vide li neke probleme u upitniku i koja su im pitanja bila

predtestiranje može uključivati primjenu drugih tehnika na manjem broju pitanja iz upitnika koja se smatraju problematičnim.

manje razumljiva. Umjesto toga bolje je provjeriti kako su shvatili pojedine riječi i izraze, odnosno kojim su mentalnim procesom došli do odgovora na pitanje (Campanelli, 2008: 187). Bihejvioralno kodiranje odnosi se na standardizirani postupak u kojemu se bilježi koliko je puta u pojedinoj anketnoj situaciji došlo do poteškoća. Primjerice, koliko je puta anketar netočno pročitao odgovor, odnosno koliko je puta ispitanik zatražio pojašnjenje pitanja. Sve ove situacije upućuju na poteškoće u upitniku i potrebu njegova korigiranja. Kognitivno intervjuiranje predstavlja vrstu dubinskog intervjua u kojemu istraživač nastoji rekonstruirati misaone procese do kojih dolazi prilikom odgovora na neka pitanja. Primjerice, od ispitanika se može, nakon što je odgovorio na pitanje, zatražiti da ponovno da odgovor pri čemu treba naglas opisati proces razmišljanja, tj. dolaženja do odgovora. Od ispitanika se može zatražiti i da pojasni značenje pojedinih riječi, parafrazira pitanja i sl. I na kraju, moguće je i provođenje fokus grupa, odnosno grupnih rasprava čija je tema sam upitnik, odnosno neki njegovi dijelovi. Fokus grupe moguće je napraviti u dvije faze. U prvoj sudionici popunjavaju upitnik, a u drugoj, koja se provede nakon pauze i analize odgovora, moderator radi *debriefing* i moderira raspravu o pojednim pitanjima i dijelovima upitnika (Campanelli, 2008: 197).

## DODATNA LITERATURA UZ OSMO POGLAVLJE

Fowler, Floyd J. (2009). *Survey Research Methods*. London, Thousand Oaks: Sage Publications.

Knjiga pokriva sve faze anketnog istraživanja, od izbora uzorka, formulacije i redoslijeda anketnih pitanja, preko raznih načina prikupljanja podataka, procesa anketiranja te evaluacije mjernih instrumenata i izračuna pogreške neodziva.

Mardsen, Peter V.; Wright, James D. (ur.) (2010). *Handbook of Survey Research*. Bingley: Emerald Publishing.

Zbornik članaka koji se detaljno bave povijesnim razvojem anketnih istraživanja, teorijom i praksom uzorkovanja, konstrukcijom upitnika, načinima prikupljanja podataka te specifičnim pitanjima kao što su podatci koji nedostaju, neodziv, međukulturna istraživanja i longitudinalna anketna istraživanja.

## PITANJA UZ OSMO POGLAVLJE

1. Što su to anketna istraživanja?
2. Što treba definirati prije početka pisanja anketnog upitnika?
3. Na koje se sve načine formuliraju pitanja o dobi, dohotku i zanimanju?
4. Kako se anketna pitanja dijele prema formalnom kriteriju?
5. Kako se anketna pitanja dijele prema kriteriju sadržaja?
6. Što su to dihotomna pitanja?
7. Što su to pitanja višestrukog izbora?
8. Što su to pitanja koja uključuju rangiranje i što treba imati na umu prilikom njihova postavljanja?
9. Koje se sve tehnike koriste za postavljanje socijalno osjetljivih pitanja?
10. Koje su najčešće pogreške prilikom postavljanja anketnih pitanja?
11. Što su to dvostruka pitanja?
12. Što su to sugestivna, a što neuravnotežena pitanja?
13. Što je psihološka, a što logička strategija određivanja redoslijeda pitanja u upitniku?
14. Kojih se pravila treba pridržavati prilikom određivanja redoslijeda pitanja?
15. Što je to tehnika lijevka, a što tehnika obrnutog lijevka?
16. Na koje se sve načine prikupljaju podatci u anketnim istraživanjima? Koje su prednosti i nedostatci pojedinih načina?
17. Koji su osnovni izvori pogreške u anketnom istraživanju?
18. Što je teorija planiranog ponašanja i kako tumači determinante sudjelovanja u anketnim istraživanjima?
19. Kako se osigurava kvaliteta upitnika u međukulturnim istraživanjima?

# 9. KVALITATIVNE METODE

## 9.1. OSNOVNA OBILJEŽJA KVALITATIVNIH METODA

U ovoj je knjizi već bilo riječi o razlikama u kvantitativnom i kvalitativnom pristupu istraživanjima u društvenim i humanističkim znanostima. Standardizirani pristup koji je karakterističan za kvantitativnu metodologiju očituje se i u relativno standardiziranim metodama koje smo ranije opisali (eksperiment, anketno istraživanje). Kvalitativne metode specifične su u odnosu na kvantitativne metode jer se proces prikupljanja podataka, njihove analize i zaključaka često međusobno prepleću, a standardizacija istraživačkog postupka obično je znatno manja. Naime, uobičajena je privremena analiza kvalitativnih podataka, na osnovi koje se modificiraju mjerni instrumenti i prikupljaju dodatni podatci.

Isto tako, u slučaju kvalitativnih podataka, obično unaprijed ne znamo koliki će nam broj slučajeva (ispitanika) biti dovoljan za kvalitetno istraživanje. Uobičajeno je da se istraživanje radi sve dok se ne dostigne tzv. točka zasićenja (saturacije), tj. sve dok nam prikupljanje dodatnih podataka više ne donosi dodatne informacije (informacije različite od onih koje već imamo). Ova se vrsta uzorkovanja obično naziva teorijsko uzorkovanje (eng. theoretical sampling) i predstavlja posebnu vrstu prosudbenog uzorka. Kao i u prosudbenom uzorku, teorijsko uzorkovanje od istraživača zahtijeva promišljeni izbor jedinica uzorka, no u teorijskom uzorkovanju ovaj se proces ne događa prije samoga istraživanja, nego se nove jedinice uzorka biraju tijekom samog istraživanja, i to u ovisnosti o spoznajama i teorijskim konceptima koji su se pojavili tijekom istraživanja. Primjerice, ako tijekom istraživanja uzroka stresa na radnom mjestu i njegova utjecaja na zdravlje napravimo nekoliko intervjua i shvatimo da bi količina autonomije na radnom mjestu mogla biti važan čimbenik, naš plan uzorkovanja možemo prilagoditi tako da napravimo dodatne intervjue (ili primijenimo neku drugu metodu) s pojedincima koji na radnom mjestu imaju izuzetno niski stupanj autonomije (npr. radnici na tekućoj vrpci) i onima s visokim stupnjem autonomije (npr. menadžeri ili sveučilišni profesori). Ako u tom istraživanju shvatimo da stres ovisi o tome ima li radnik s niskim stupnjem autonomije socijalnu podršku na radnom mjestu, u uzorak možemo uvrstiti radnike iz organizacija za koje znamo da imaju narušene međuljudske odnose i one s izvrsnim međuljudskim odnosima, te usporedimo dobivene rezultate. Ako nas dodatni rezultati navedu na ideju da veličina plaće igra ulogu u tom smislu, možemo uzorkovanje usmjeriti prema radnicima s izuzetno niskim i onima s izuzetno visokim plaćama. Teorijsko uzor-

kovanje tako se kreće između podataka i novih teorijskih koncepata sve dok ne dođe do zastoja u kreiranju novih koncepata, odnosno dok se ne formira konačna teorija. Ovdje valja naglasiti da se prosudba o izboru jedinica uzorka odvija na razini kada je populacija već izabrana, a ne na razini izbora populacije. Naime, izbor populacije uvijek je stvar prosudbe, čak i u kvantitativnim istraživanjima i u probabilističkim uzorcima. Primjerice, ako istražujemo različite tipove religioznosti, tada nam populaciju čine samo religiozne osobe, no to ne znači da je uzorak prosudbenog tipa. Naime, nakon prosudbe o tome koje nam osobe čine ciljanu populaciju (u našem slučaju to su religiozne osobe), možemo izabrati bilo koju vrstu uzorka (npr. slučajni uzorak religioznih osoba). Prosudbeni uzorak birali bismo ako bismo, primjerice, izabrali osobe za koje predstavljamo da dobro reprezentiraju različite tipove religioznosti koje želimo proučavati (npr. religijski tradicionalisti, ultrakonzervativci, modernisti, New Age eklektici i sl.). Prilikom izbora uzorka i tumačenja rezultata istraživanja treba imati na umu da je u prosudbenim uzorcima i kvalitativnim istraživanjima općenito česta samoselekcija ispitanika, zbog čega rezultati istraživanja ne moraju biti reprezentativni za širu populaciju koju istražujemo (Daymon i Holloway, 2002). Razlog češćoj samoselekciji u kvalitativnim istraživanjima predstavlja činjenica da su sudionici istraživanja vrlo često dobro upoznati s temom istraživanja, odnosno sam ih istraživač s njom upoznaje prilikom poziva na sudjelovanje u istraživanju. U tom smislu na istraživanje češće mogu pristati ljudi koji su jače zainteresirani za određenu temu. Primjerice, ako želimo napraviti istraživanje o dobnoj diskriminaciji na radnom mjestu na intervjue nam mogu češće pristati osobe koje smatraju da su bile izložene takvoj diskriminaciji jer su zbog takvog iskustva i frustracija spremne izdvojiti dulje vrijeme za intervjuiranje. Osobe koje nisu bile izložene diskriminaciji rjeđe će pristati na izdvajanje vlastitog vremena jer im tema nije previše važna. Ako je cilj istraživanja utvrditi moguće razloge i iskustva dobne diskriminacije, odnosno posljedice koje izaziva, tada nam ovakva samoselekcija nužno ne predstavlja problem, a može čak i biti korisna jer ćemo dobiti informacije od osoba koje su ju iskusile. No čak i u takvom slučaju moramo biti svjesni da će najteži slučajevi diskriminacije možda ostati nedetektirani zbog nesklonosti ljudi da o njima govore te zbog neanonimnosti istraživanja koja je često prisutna u kvalitativnim istraživanjima (u intervjuima svakako).

***Uzorkovanje u kvalitativnim istraživanja specifično je po tome što se često unaprijed ne zna veličina uzorka, nego se istraživanje provodi sve dok se ne dostigne tzv. točka zasićenja, tj. sve dok novi članovi uzorka ne prestanu donositi nove informacije.***

Kada su u pitanju vrste uzoraka, i u kvalitativnom istraživanju moguće je upotrijebiti sve vrste probabilističkih i neprobabilističkih uzoraka koje se upotrebljavaju u kvantitativnim istraživanjima, osobito ako je riječ o metodama koje imaju i svoju kvantitativnu dimenziju (npr. analiza sadržaja). No u kvalitativnim se istraživanjima često upotrebljavaju i neprobabilistički uzorci koji se rijetko susreću u kvantitativnim istraživanjima, kao što je uzorak maksimalne varijacije i uzorak grude snijega. Kao što smo ranije naveli, u širem se smislu ovi uzorci mogu smatrati podvrstama prosudbenog uzorkovanja. Kada je veličina uzorka u pitanju, prvo što treba imati na umu je da kvalitativna istraživanja obično imaju za cilj dubinski istražiti neku temu i doći do novih, dubinskih spoznaja. U tom smislu veličina uzorka ne igra glavnu ulogu pa se kvalitativna istraživanja i ne prosuđuju prema tome. Dapače, veličina uzorka može smanjiti dostupno vrijeme potrebno za provođenje istraživanja i dublji uvid u pojave koje se proučavaju. Izuzetak predstavlja kvantitativno-kvalitativna analiza sadržaja jer se u takvoj vrsti analize obično nastoji generalizirati dobivene rezultate, pa onda veličina uzorka, kao i u kvantitativnim istraživanjima, predstavlja čimbenik koji utječe na veličinu pogreške uzorkovanja.

Kada je u pitanju etika istraživanja, i kvalitativna istraživanja moraju poštovati osnovno etičko načelo, a to je da istraživanje ne smije naštetiti njegovim sudionicima. U tom smislu valja poštovati načela informiranog pristanka, anonimnosti, privatnosti i povjerljivosti podataka. No u kvalitativnim istraživanjima češće se nego u kvantitativnim događa da su ova načela ugrožena te stoga prilikom njihova provođenja treba osobito voditi računa o etičkim smjernicama. Kao prvo, kvalitativna istraživanja uključuju jači osobni kontakt sa sudionikom i dublje ulaze u privatni život i intimu, pa stoga potencijalno mogu nanijeti veću psihološku štetu ispitaniku. Isto tako, kvalitativna istraživanja rijetko su anonimna jer u pravilu uključuju osobni kontakt sa sudionikom te je njegov identitet moguće prikriti samo pri pisanju istraživačkog izvještaja, no identitet ostaje poznat istraživaču.

***Kvalitativna istraživanja često su etički osjetljiva jer se u pravilu zasnivaju na osobnom kontaktu i nemaju posve standardizirani protokol istraživanja.***

Izuzetak predstavljaju online fokus grupe, u kojima je moguće zadržati potpunu anonimnost sudionika, kao i analiza sadržaja, u kojoj se obično analiziraju javno dostupni komunikacijski sadržaji pa anonimnost ionako ne postoji. Anonimnost se obično pokušava očuvati pomoću upotrebe pseudonima ili promjene imena sudionika, izmjene nevažnih informacija o sudionicima istraživanja (npr.

demografskih podataka), čuvanjem podataka na sigurnim mjestima i micanjem imena iz dokumenata u kojima se nalaze podatci (Daymon i Holloway, 2002: 80). Anonimnost je osobito ugrožena ako se istražuje manji broj jedinica uzorka ili se tijekom istraživanja prikuplja veliki broj detaljnih informacija o sudioniku na osnovi kojih se može rekonstruirati identitet jedinice uzorka/sudionika (npr. studije slučaja). Dodatni problem etike kvalitativnih istraživanja predstavlja i činjenica da se tijekom njihova provođenja pojavljuju nove teme koje mogu biti osjetljive za sudionike i o kojima istraživač nije mogao promisliti prije samoga istraživanja. Primjerice, tijekom intervjua istraživač može postaviti pitanja koja su teorijski zanimljiva, ali za koje tek poslije može shvatiti da su previše osjetljiva za sudionika i da su ga mogla dovesti u neugodnu situaciju.

Postoji nekoliko ključnih dimenzija pomoću kojih se čini izbor pojedinih kvalitativnih metoda i procjenjuje njihova kvaliteta (prilagođeno prema Brüggenu, 2009.): dubina, širina, efikasnost, grupna dinamika, neverbalni podatci i reakcija ispitanika. Svaka kvalitativna metoda može se procjenjivati na osnovi zastupljenosti pojedinih dimenzija, a o toj procjeni, uz čimbenike praktičnosti, ovisi i izbor pojedine metode. *Dubina* metode odnosi se na stupanj u kojem se pomoću nje može zahvatiti kompleksna logička struktura mišljenja ispitanika, kao i u kojoj se mjeri primjenom metode dobivaju supstantivni argumenti, tj. argumenti koji pridonose boljem razumijevanju istraživane teme. *Širina* se odnosi na spektar različitih mišljenja i stavova koji se dobiju istraživanjem. Mjeri se tako da se utvrdi koliki je broj istraživačkih tema pokriven samim istraživanjem. *Efikasnost* se odnosi na relevantnost podataka dobivenih upotrebom pojedine metode. Ako se podatci u velikoj mjeri odnose na istraživačka pitanja na koja se u istraživanju nastoji dati odgovor, tada je metoda efikasna. Ako se istraživanjem dobiju podatci koji nemaju veze sa samom temom, tada je i metoda neefikasna. Efikasnost se u praksi često mjeri brojem riječi koje dolaze na jedan supstantivni argument, tj. koje su bile potrebne da bi se došlo do njega (Brüggen, 2009.). *Grupna dinamika* odnosi se na broj interakcija unutar grupe, ako u samom istraživanju ispitanici sudjeluju kao grupa. Ako je ispitanik reagirao na mišljenje nekog člana grupe, tada se ova interakcija koristi kao pokazatelj grupne dinamike. Grupna dinamika može utjecati na veći broj ideja, ali se stvaranjem grupne kohezije ispitanici često osjećaju ugodnije te su skloniji dati veći broj kvalitetnijih odgovora. *Neverbalni podatci* odnose se na izraze lica, gestikulaciju, ton glasa, odjeću i druge indikatore koji mogu poslužiti u interpretaciji odgovora sudionika u istraživanju. *Reakcija ispitanika* odnosi se na voljnost za sudjelovanjem u istraživanju, kao i zadovoljstvo samih ispitanika nakon participacije u istraživanju.

Kvalitativne se metode mogu podijeliti na metode u kojima je naglasak na načinu prikupljanja podataka, koje imaju svoje epistemološke korijene te jake i slabe strane, i one u kojima je naglasak na obradi podataka (Wilkinson, 2004: 178). Primjerice, analiza sadržaja, kako samo ime i kaže, primarno je metoda analize podataka, iako i u njoj postoje pravila prikupljanja podataka, utvrđivanja njihove valjanosti, pouzdanosti i sl. S druge strane, fokus grupe primarno predstavljaju metode prikupljanja podataka koji se onda mogu analizirati različitim drugim metodama i tehnikama. Primjerice, analiza diskursa i konverzacijska analiza mogu se provoditi na podatcima prikupljenim pomoću fokus grupa, iako je uobičajenije da se upotrebljavaju na materijalima koji se prirodno pojavljuju u svakodnevnim konverzacijama (dakle, prikupljeni su metodom promatranja) ili na medijskom sadržaju (dakle, prikupljenom analizom medijskog sadržaja). Gledajući na taj način metoda intervjua također je primarno metoda prikupljanja podataka, a delfi metoda predstavlja kombinaciju i jednog i drugog. I na kraju, studija slučaja predstavlja općenitiji metodološki pristup unutar kojeg je moguće upotrijebiti druge kvalitativne i kvantitativne metode, iako je primjena kvantitativnih metoda unutar studija slučaja mnogo rjeđa.

Kvalitativna se istraživanja, zbog toga što često ne uključuju brojčane pokazatelje i generalizacije, često smatraju manje znanstvenim, odnosno često subjektivnim i impresionističkim od kvantitativnih istraživanja. Ponekad ih prati i optužba da njihovi zaključci proizlaze iz zdravog razuma i da samo prenose sliku svijeta i samopercepciju osoba koje istražuju. Kada su u pitanju mjerna obilježja kvalitativnih metoda, one obično ne teže sličnim ciljevima kojima teže kvantitativna istraživanja, iako je to ponekad slučaj (primjerice u analizi sadržaja). Procjena poželjnosti određenih mjernih obilježja ovisi o epistemološkim prepostavkama, odnosno o tome smatra li se da je moguće postići objektivnu spoznaju o društvenoj realnosti. Primjerice, istraživači koji upotrebljavaju analizu diskursa, osobito kritičku analizu diskursa, često ističu vlastitu subjektivnost i vrijednosnu angažiranost. No i u tom slučaju istraživači obično nastoje svoje zaključke učiniti transparentnim, odnosno nastoje pokazati na koji su način iz podataka došli do teorijskih zaključaka. Osim klasičnih mjernih oblilježja (osobito valjanost i pouzdanost, ali i osjetljivost i objektivnost), u kvalitativnim se istraživanjima često ističu i načela autentičnosti i istinitosti (Lincoln i Guba, 1985.; Erlandson i sur., 1993.). Autentičnost pretpostavlja da dobiveni podatci i rezultati istraživanja pomažu njegovim sudionicima da bolje shvatite vlastito okružje i ponašanje. Istinitost označava nekoliko odvojenih ideja. Prva je vjerodostojnost koja implicira da sudionici istraživanja prepoznaju točnost zaključaka u svojem društvenom kontekstu. Prenosivost označava mogućnost prenošenja teorijskih spoznaja u

druge kontekste i njihovu validaciju u tim novim situacijama, drugim riječima u pitanju je eksterna valjanost istraživanja. Ovisnost označava mogućnost da drugi istraživači slijedeći algoritam odlučivanja istraživača dođu do novih spoznaja, i u tom je smislu slična klasičnom poimanju pouzdanosti istraživanja. I na kraju, potvrdljivost označava povezanost zaključaka s podatcima, odnosno činjenicu da zaključci ne smiju biti proizvoljni i neuvjerljivi.

Daymon i Holloway (2002: 90-101) predlažu nekoliko strategija za poboljšavanje kvalitete istraživanja: (1) longitudinalni dizajn, (2) provjera sa sudionicima (eng. *member checking*), (3) *debriefing* s kolegama (4) demonstracija postupka zaključivanja (eng. *audit trail*), (5) detaljni opis (eng. *thick description*), (6) traženje negativnih slučaja i alternativnih objašnjenja i (7) triangulacija. Longitudinalni dizajn znači dulje vrijeme istraživanja koje omogućava dublji kontakt sa sudionicima i bolje razumijevanje situacije. Provjera sa sudionicima znači iznošenje svojih zaključaka sudionicima istraživanja i provjera njihova slaganja s njima. *Debriefing* omogućava da se s drugim kolegama provede provjera zaključaka, potencijalno donošenje novih zaključaka i nuđenje alternativnih objašnjenja. Demonstracija postupka zaključivanja omogućuje povezanost između zaključaka i podataka, a detaljni prikaz razumijevanje situacije svima onima koji naknadno čitaju istraživanja i dobivene podatke i zaključke. Negativni slučajevi i alternativna objašnjenja dio su refleksivnosti istraživača, koji u svakom trenutku mora u pitanje dovoditi vlastite zaključke. Triangulacija pretpostavlja provjeru rezultata u drugim situacijama, s drugim metodama, kao i s drugim istraživačima.

## 9.2. OPAŽANJE

Opažanje kao metoda može biti korisno jer istraživaču daje uvid u situaciju upravo onako kako se inače odvija, nasuprot intervjuima ili anketnim upitnicima koji u osnovi otkrivaju samo percepciju ispitanika. Drukčije rečeno, opažanjem možemo utvrditi što ljudi doista misle i kako se doista ponašaju, nasuprot onome što kažu o vlastitim razmišljanjima i ponašanju. Međutim, opažanje kao metoda ima i nekoliko važnih nedostataka (Kothari, 2004: 96). Prije svega, ta je metoda relativno skupa zbog toga što uključuje odlazak na teren koji obično traje dulje vrijeme. Zatim, informacije koje se dobiju opažanjem odnose se samo na ponašanje u nekoj situaciji, dok se na taj način ne mogu otkriti vrijednosti i stavovi sudionika istraživanja, odnosno motivi koji su ih naveli da se ponašaju na određeni način. Stoga je promatranje korisno kombinirati s metodama kojima se mogu prikupiti takve vrste podataka. I kao treće, nisu svi pojedinci i grupe dostupni za

istraživačko opažanje, a često su i najmanje skloni sudjelovati u istraživanjima u kojima se promatra njihova svakodnevica.

***Opažanje se kao metoda upotrebljava u situacijama koje je jako važno proučavati u prirodnom okruženju, odnosno onako kako se stvarno pojavljuju (npr. interakcija nastavnika i učenika u učionicama).***

Opažanje se najčešće primjenjuje u znanostima poput psihologije i kulturalne antropologije, a nešto manje u ostalim društvenim i humanističkim znanostima. U psihologiji se opažanje često primjenjuje u istraživanjima vezanim uz obrazovanje i školu te općenito u istraživanjima u kojima su uključena djeca. U oba je slučaja riječ o događajima koji se mogu opažati, odnosno subjektima koji su dostupni za opažanje, a u nekim slučajevima opažanje zamjenjuje eksperimente koji su neetični ili neizvodivi. Primjerice, istraživanja u kojima su se istraživali razlike u vrstama agresivnosti koju pokazuju dječaci i djevojčice (interpersonalna agresija ili instrumentalna agresija) predstavljaju zamjenu za eksperimente koji nisu etični jer uključuju namjerno izazivanje agresivnog ponašanja.[78] Kulturalna antropologija, s druge strane, do velikog dijela svojih spoznaja došla je upravo korištenjem metode promatranja svakodnevnog života pripadnika tradicionalnih društava. Primjerice, jedan od osnivača kulturne antropologije Bronislaw Malinowski proveo je nekoliko godina živeći sa stanovnicima Trobrijandskog otočja u Melaneziji kako bi bolje upoznao njihovo društvo i kulturu, ali i postavio hipoteze o nekim društvenim fenomenima (npr. darivanje i religija).

Opažanje se može podijeliti na osnovi kriterija strukturiranosti, kontroliranosti i uključenosti istraživača u život pojedinca ili grupe koja se promatra (Kothari, 2004: 96-97).

Prema stupnju strukturiranosti opažanje može biti:

1. Strukturirano,
2. Polustrukturirano,
3. Nestrukturirano.

U *strukturiranom opažanju* postoji jasan protokol opažanja, tj. jasne jedinice opažanja utemeljene na ranije postavljenim hipotezama, a cijela je istraživačka situacija posve standardizirana. *Polustrukturirano* opažanje podrazumijeva činjenicu da postoji plan opažanja, no podatci koji se prikupljaju nisu detaljno određeni,

[78] Shaughnessy, 2003: 89.

tj. njihova važnost određuje se tijekom samog promatranja. Dok u nestrukturiranom opažanju ne postoje unaprijed određene jasne hipoteze, pa samim time nisu jasno određene jedinice promatranja niti postoji detaljan protokol promatranja. Prednost je strukturiranih opažanja jasnoća i lakša obrada prikupljenih podataka, a nedostatak je potencijalni gubitak zanimljivih informacija koje se mogu pojaviti tijekom promatranja.

Jedan primjer jednostavnog protokola za strukturirano opažanje vrste interakcije u školskoj učionici (tko se kome obraća) prikazan je u donjoj tablici.

*Tablica 32. Primjer protokola za promatranje*

| | | | | | | |
|---|---|---|---|---|---|---|
| Učenik učeniku | + | | | | | |
| Učenik učenicima | | + | + | | | |
| Učenik nastavniku | | | | + | | |
| Učenici nastavniku | | | | | + | |
| Nastavnik učeniku | | | | | + | |
| Nastavnik učenicima | | | | | | + |

Postoji tri vrste bilježenja podataka u protokole za opažanje (Cohen i sur., 2007.):

1. Uzorkovanje događaja,
2. Uzimanje trenutačnih vremenskih uzoraka,
3. Ljestvice procjene.

Pri *uzorkovanju događaja* događaji se bilježe onako kako su se dogodili, bez bilježenja kronologije. U gornjem primjeru protokola događaji bi se bilježili počevši od prvog stupca nadalje, pri čemu ne bi bilo jasno koji se događaj dogodio prije kojega.

Kad je riječ o *uzimanju trenutačnih vremenskih uzoraka*, svaki stupac u protokolu promatranja označava jedan vremenski odsječak (npr. 30 sekundi). Događaji u gornjoj tablici bilježeni su upravo tako, pri čemu se u svaki stupac bilježi vrsta interakcije u učionici koja se dogodila u 30 sekundi.

*Ljestvice procjene* odnose se na različite vrste procjene koje donose promatrači. Npr., u gore navedenom primjeru od promatrača bi se zahtijevalo da na određenoj ljestvici procijene ponašanje nastavnika (npr. je li bilo hladno ili toplo, profesionalno ili neprofesionalno i sl.).

Prema stupnju kontroliranosti opažanje se dijeli na *kontrolirano i nekontrolirano*. Osnovna je razlika između tih dviju vrsta opažanja ta da se u prvom slučaju opa-

žanje odvija u uvjetima koji nisu prirodni, a to su najčešće eksperimentalne situacije. U drugom slučaju riječ je o opažanju u prirodnim uvjetima, odnosno opaža se normalno odvijanje događaja u životu pojedinca ili grupe koja se proučava. I kontrolirano i nekontrolirano opažanje može imati različite stupnjeve strukturiranosti, no kontrolirana opažanja obično su jače strukturirana jer je, kako je navedeno, najčešće riječ o eksperimentalnim situacijama u kojima su hipoteze već postavljene i istraživač ima jasne ideje o tome što želi mjeriti i na koji način.

Prema tome sudjeluje li istraživač u aktivnostima proučavane skupine ili pojedinca, opažanje se može podijeliti na *opažanje sa sudjelovanjem i opažanje bez sudjelovanja*. Prednost je promatranja sa sudjelovanjem mogućnost približavanja sudionicima istraživanja, odnosno dolaženje do spoznaja do kojih se ne bi moglo doći bez sudjelovanja u životu pojedinca/skupine. Tako je, primjerice, Lalić (1993) sudjelovanjem u aktivnostima jedne organizirane skupine nogometnih navijača došao do klasifikacije navijača u nekoliko skupina na osnovi toga što im je osnovni motiv za sudjelovanje u nogometnoj supkulturi („trendovski navijači", „nasilnici" itd.). Može se pretpostaviti da bi neka od metoda ispitivanja (npr. ankete ili intervjui) u tom slučaju dala slabije rezultate zbog nesklonosti nogometnih navijača da otkriju svoje stvarne motive za sudjelovanjem. Međutim, ta se prednost može pretvoriti u nedostatak ako se istraživač previše identificira sa sudionicima istraživanja, odnosno izgubi objektivnost. Prilikom opažanja, osobito opažanja sa sudjelovanjem, potrebno je neko vrijeme provesti s ispitanicima kako bi se oni navikli na istraživača i počeli se ponašati onako kako se inače ponašaju (tzv. habituacija). Stoga je i korisno sâmo prikupljanje podataka ne početi odmah nego s vremenskim odmakom.

I opažanje sa sudjelovanjem i opažanje bez sudjelovanja može se raditi tako da pojedinac ili grupa koji se promatraju znaju ili ne znaju da sudjeluju u istraživanju, odnosno da su bili promatrani. Zbog etičkih pitanja koji se tiču čuvanja privatnosti i informiranog pristanka, o kojima smo već govorili, opažanje bez znanja sudionika istraživanja trebalo bi načelno izbjegavati. Kao i u drugim situacijama obmane sudionika istraživanja, ovoj bi metodi trebalo pribjegavati samo u situacijama kada cilj istraživanja nije moguće postići na način koji ne uključuje obmanu, a i u takvim situacijama dobro je potražiti savjet iskusnijih kolega ili etičkih odbora institucije u kojoj je istraživač zaposlen. Primjer ovakvog istraživanja predstavljaju istraživanja u kojima su psiholozi ili psihijatri zatražili hospitalizaciju lažno se predstavljajući kao osobe s psihičkim problemima, a nakon hospitalizacije počeli su se ponašati „normalno". Cilj je ovakvih istraživanja obično bio utvrditi koliko će dugo hospitalizacija trajati unatoč nestanku simptoma,

odnosno postoji li ili ne postoji stigmatizacija duševnih bolesnika. Prikriveno sudjelovanje, tj. obmana zaposlenika psihijatrijskih ustanova, izabrano je pod točnom pretpostavkom da cilj istraživanja nije moguće postići bez obmane te da će istraživači osobno doživjeti situaciju hospitalizacije bolje shvatiti položaj duševnih bolesnika i odnos prema njima.[79]

Općenito se može reći da svi oblici opažanja ovise o subjektivnosti opažača (halo-efekt, sklonost zauzimanju srednjih pozicija, strogost ili blagost i sl.), kao i da procjena situacije ovisi o kontekstu. Zato je i potrebno provesti tzv. triangulaciju, tj. podatke je potrebno provjeriti pomoću više promatrača, kao što je i istu situaciju potrebno promotriti u drugom vremenskom i prostornom kontekstu. Primjerice, u gornjem bi primjeru trebalo anagažirati više opažača, a interakciju u učionici trebalo bi promotriti u različitim danima u tjednu, na različitim predmetima, nastavnicima i sl. Ako je to moguće, potrebno je podatke dobivene promatranjem usporediti s podatcima dobivenim iz drugih izvora. Posebnu opasnost predstavlja i pristranost promatrača koja se pojavljuje ako promatrač zna istraživačke ciljeve i hipoteze, što može dovesti do sustavnih pogrešaka prilikom bilježenja podataka. Primjerice, promatrač događaje može nesvjesno kodirati tako da potvrđuju prethodno postavljene istraživačke hipoteze. Ovakva se vrsta pristranosti može kontrolirati postojanjem osvješćivanja promatrača o potencijalnoj pristranosti te skrivanjem ciljeva i hipoteza od promatrača koji sudjeluju u istraživanju (Shaughnessy i sur., 2003: 117).

## 9.3. INTERVJU

Intervju se, slično kao i anketno istraživanje, sastoji od niza pitanja koja se postavljaju ispitanicima. Štoviše, nekad se individualno usmeno anketiranje upravo i naziva *intervju*. Međutim, obično se pravi razlika između ankete napravljene individualnim anketiranjem i dubinskog intervjua, a ta se razlika zasniva na standardiziranosti upitnika, odnosno omjeru otvorenih i zatvorenih pitanja. Dubinski intervjui većim se dijelom sastoje od otvorenih pitanja, a upravo se time postiže dubina intervjua, odnosno ustanovljavanje stavova i motiva za određeno ponašanje koji često ostaju skriveni u anketnom istraživanju kojim dominiraju zatvorena pitanja, a koja često zahvaćaju samo površinske slojeve svijesti ispitanika. Zatvorena se pitanja u intervjuima uglavnom odnose na temeljne demografske podatke (npr. spol, dob, zanimanje i sl.) ili mjerenje učestalosti nekoga

[79] O tome više u Shaughnessy i sur. (2003: 92-93).

ponašanja. Upravo zbog oblika pitanja, tj. standardiziranosti procesa odvijanja samog intervjuiranja, dubinski se intervjui mogu podijeliti na nestrukturirane i polustrukturirane, što ovisi o odnosu otvorenih i zatvorenih pitanja i postojanju standardiziranog seta pitanja koja se planiraju prije intervjua, a izraz „strukturirani intervjui" trebalo bi zadržati za opis osobnog ili online anketiranja.

***Intervju se, za razliku od ankete, zasniva na pitanjima koja nisu posve standardizirana, a cilj im je dubinski istražiti neku pojavu.***

Unatoč tim razlikama, mnoga već spomenuta pravila o postavljanju pitanja, njihovom formatu, redoslijedu i sl. važe i za proces dubinskog intervjuiranja. Naime, i intervju treba početi s laganijim pitanjima, stvoriti povoljnu psihološku atmosferu, primijeniti odgovarajuće tehnike za postavljanje socijalno osjetljivih pitanja itd. S obzirom na to da je riječ o tipu istraživanja u kojemu prilikom provođenja prikupljanja podataka ne postoji anonimnost, izuzetno je važno osobu koja se intervjuira upoznati s osnovnim ciljevima istraživanja, upoznati ju s pravom odustajanja od istraživanja i povjerljivošću prikupljenih podataka. Takvo započinjanje intervjua, osim što je u skladu s etičkim smjernicama, omogućava i početak stvaranja povoljnog odnosa sa sudionikom koji je ključan za uspješnost intervjua. Tijekom cijelog procesa intervjuiranja intervjuer mora pokazati interes za sudionika istraživanja, aktivno ga slušati, tj. razumjeti i interpretirati ono što sudionik govori te sâmog sudionika staviti u prvi plan. Naime, iako intervjuer ima ulogu usmjerivača tijekom intervjua, on sâm ne bi trebao previše govoriti, puštajući intervjuiranoj osobi da iznosi vlastito mišljenje, ograničavajući svoju ulogu na pružanje povratne informacije i poticanje sudionika na daljnju razradu mišljenja. Iz navedenog je vidljivo da kvalitetno intevjuiranje od intervjuera zahtijeva iskustvo i izražene komunikacijske vještine.

Trajanje i broj intervjua nisu zadani, odnosno u tom se smislu ne mogu dati standardne preporuke. Intervju treba trajati onoliko koliko je potrebno da se postignu ciljevi istraživanja, a da ispitanik ne pokaže preveliki zamor koji može utjecati na kvalitetu odgovora i nezadovoljstvo. Broj intervjua koje je potrebno provesti tijekom jednog istraživanja u pravilu ovisi o tome je li skupljena dovoljna količina informacija. Iako se prilikom planiranja istraživanja obično naveden traženi broj intervjua, moguće je napraviti i veći i manji broj od planiranog, u ovisnosti o potrebama istraživanja.

Kako je u intervjuu riječ o usmenoj komunikaciji između istraživača i ispitanika, a od ispitanika se zahtijeva opsežno izražavanje mišljenja vlastitim riječima, taj je

proces podložniji komunikacijskim poteškoćama i prekidima u usporedbi s individualnim anketiranjem koje od ispitanika obično zahtijeva manje napora. Stoga je i ispitanika u slučaju takvih prekida potrebno potaknuti na daljnje odgovaranje, tj. na razradu vlastitog mišljenja. Trochim (2012) tako napominje nekoliko tehnika koje mogu poslužiti u tu svrhu: tišina, otvoreno poticanje, traženje elaboracije, traženje pojašnjenja i ponavljanje. Tišina (eng. *silent probe*) djelujući kao signal i unoseći malu količinu neugode u komunikacijski proces, ispitanika potiče na daljnje odgovaranje i razradu vlastitog mišljenja. Otvoreno poticanje odnosi se na verbalno ili neverbalno pokazivanje razumijevanja prema ispitaniku, no bez otvorenog izražavanja slaganja s mišljenjem ispitanika. Pri traženju elaboracije ispitanika se potiče na daljnje odgovaranje frazama poput: „možete li reći još nešto više o tome?" Traženje pojašnjenja donekle je slično traženju elaboracije i odnosi se na fraze poput: „možete li dodatno pojasniti to što ste upravo rekli?" Ponavljanje se kao tehnika primjenjuje u situacijama kada ispitanik treba dodatno vrijeme za razmišljanje pa istraživačevo ponavljanje odgovora upravo pruža potrebno vrijeme. Važnu ulogu u poticanju odgovora ima i govor tijela, pri čemu intervjuirane osobe izravni kontakt očima i nagnutost tijela intervjuera prema naprijed najčešće tumače kao očekivanje daljnjeg odgovora, odnosno nastavka interakcije, te time potiču širi i detaljniji odgovor. Osobito je važno da se u slučaju da intervjuirana osoba nije pristala na snimanje razgovora, intervjuer ne piše bilješke u trenutcima kada je intervjuiranu osobu potrebno potaknuti na daljnje odgovaranje.

Kako je navedeno, većina pravila koja se odnose na pitanja u anketnim istraživanjima mogu se primijeniti i na intervjue. Tako treba izbjegavati sugestivna, dvosmislena i nejasna pitanja, odnosno pitanja valja postaviti jezikom koji intervjuirana osoba razumije. Kao i u anketnim istraživanjima, pitanja se mogu podijeliti na ona koja ispituju (1) stavove i emocije, (2) znanja i (3) ponašanja. S obzirom na nestrukturiranost i polustrukturiranost intervjuiranja postoje i vrste pitanja koja su češća u intervjuima nego u anketama jer zahtijevaju širu elaboraciju odgovora, a ne samo biranje određene opcije. Daymon i Holloway (2002: 174-177) spominju (1) idealizacijska pitanja, (2) kontrastna pitanja, (3) pitanja hipotetičke interakcije, (4) direktna i faktična pitanja i (5) strukturalna pitanja. Idealizacijska pitanja (Schatzman i Strauss, 1973.) uključuju pitanje o idealnom događaju, proizvodu, osobi i sl., prema mišljenju intervjuirane osobe. Primjerice, osobu se može pitati da opiše kako izgleda njezin idealan nastavnik, idealno ljetovanje i idealni automobil, te se nakon toga obično pita kako se konkretni nastavnik, ljetovanje i automobil mogu usporediti s idealnim. Na taj se način obilježja konkretnog objekta koji se želi istražiti mogu istražiti na dublji način, odnosno sama intervjuirana osoba može pomoću usporedbe bolje

opisati objekt. Kontrastna pitanja vode se sličnom logikom, logikom usporedbe, no u njima se obično uspoređuju dva objekta, odnosno od intervjuirane se osobe traži da pojasni razliku između njih. Primjerice, istražujući marku automobila A, istraživač može od osobe tražiti da ju usporedi s markom automobila B. Pitanja hipotetičke interakcije od ispitanika traže da se zamisli u nekoj interakcijskoj situaciji te da opiše kako bi reagirala u njoj. Primjerice, ako želimo istražiti stavove osobe o davanju mita službenim osobama, možemo od nje zatražiti da opiše što bi napravila ako bi liječnik, policajac i sl. od nje zatražio mito, pri čemu se interakcijska situacija opiše što detaljnije (primjerice, liječnik traži mito a osoba je teško bolesna). Direktna i faktična pitanja od osobe traže da opiše koji su razlozi za određeno ponašanje te osobe, kakav je njezin stav o nekom pitanju i sl. Strukturalna pitanja slična su direktnim i faktičnim, no u njima se od intervjuirane osobe traži da sustavno opiše svoje iskustvo u nekom području. Primjerice, osobu se može zatražiti da navede sve pozitivne i sve negativne načine na koje upotreba internetskih društvenih mreža utječe na njih.

U dubinskim se intervjuima koriste i tzv. *kontrolna pitanja* kako bi se ispitala logička struktura stavova ispitanika. To je osobito važno i korisno u situacijama u kojima je riječ o kompleksnim pitanjima s elementima moralnog zaključivanja. Moguće je izdvojiti dva tipa kontrole u dubinskim intervjuima: jednostavna i paralelna kontrola (Stylianou, 2008.). Cilj je jednostavne kontrole izoliranjem varijable utvrditi smatraju li ispitanici tu varijablu nužnim uvjetom neke druge pojave (varijable). Da bi varijabla X bila nužan uvjet varijable Y, mora se pojaviti uvijek kada se pojavi i varijabla Y (ako Y, tada X). Teoretski model jednostavne kontrole može se prikazati na sljedeći način (prema Stylianouu, 2008: 246).

SUDIONIK: Ako X = 1, tada Y = 1.
ISTRAŽIVAČ: Ako X = 0, tada Y = ?
AKO SUDIONIK: Y = 0, tada je X nuždan uvjet za Y.
AKO SUDIONIK: Y = 1, tada je X nije nuždan uvjet za Y.

Ilustracija ovoga postupka može biti intervju u kojemu istraživač od sudionika istraživanja traži navođenje razloga zbog kojih smatra da marihuana ne bi trebala biti legalna (prilagođeno prema Stylianouu, 2008: 249).

SUDIONIK: Marihuana izaziva ovisnost, zbog toga bi trebala biti nelegalna.
ISTRAŽIVAČ: Što ako bi znanstvenici utvrdili da marihuana ne izaziva ovisnost, biste li se i tada zalagali za njezinu zabranu?
SUDIONIK: Da, marihuana može navesti ljude da se ponašaju nekontrolirano, a nije ni zdrava.

U tom se slučaju utvrdilo da izazivanje ovisnosti nije nužan uzrok zalaganja za zabranu marihuane, tj. da postoje dodatni razlozi za takav stav.

Pri postupku paralelne kontrole istraživač varira kontekste u kojima se pojavljuje varijabla Y, te nastoji utvrditi je li varijabla X dovoljan uvjet za pojavu varijable Y. Varijabla X dovoljan je uvjet varijable Y ako se varijabla Y pojavi svaki put kad se pojavi i varijabla X (ako X, tada Y). Teoretski model paralelne kontrole može se prikazati na sljedeći način (prema Stylianouu, 2008: 250).

SUDIONIK: Ako X = 1, tada Y1 = 1.
ISTRAŽIVAČ: Ako X = 1, tada Y2 = ?
AKO SUDIONIK: Y2 = 1, tada je X dovoljan uvjet za Y.
AKO SUDIONIK: Y2 = 0, tada je X nije dovoljan uvjet za Y.

Ilustracija postupka paralelne kontrole može biti intervju u kojemu istraživač od sudionika istraživanja traži navođenje razloga zbog kojih se psihoaktivne supstance trebaju zabraniti, a ispitanik odgovara da je osnovni razlog činjenica da izazivaju ovisnost (prilagođeno prema Stylianouu, 2008: 253)

SUDIONIK: Sve psihoaktivne supstance treba zabraniti jer izazivaju ovisnost.
ISTRAŽIVAČ: Cigarete također izazivaju ovisnost, treba li i njih zabraniti?
SUDIONIK: Ne, cigarete ne mijenjaju ponašanje na način na koji to rade druge supstance.

U ovom se slučaju utvrdilo da ovisnost, prema ispitaniku, nije dovoljan razlog da se neka supstanca zabrani. Dubinski je razlog zapravo mijenjanje ponašanja do kojih dovodi konzumacija.

Podatci prikupljeni intervjuiranjem obično rezultiraju transkriptom u kojemu je navedena izvorna komunikacija tijekom intervjua, upravo onako kako se događala. Danas postoje i softveri za automatsku transkripciju (npr. *TranscribeMe*), no uglavnom su ograničeni na engleski i druge jezike s većim brojem govornika, a ni točnost transkripcije još uvijek nije na savršenoj razini. Nadalje, pojedina obilježja govora (npr. smijeh) ne mogu se automatski transkribirati. Naime, transkripti mogu biti isključivo tematski, odnosno većim dijelom zanemariti jezične i kontekstualne čimbenike u kojima se zbiva intervju. Moguć je i drukčiji pristup, u kojemu se prilikom transkripcije bilježe i ovi elementi, na sličan način kako se to radi u analizi konverzacije, pri čemu postoje ustaljeni simboli za pojedina obilježja razgovora/intervjua (vidjeti poglavlje o analizi konverzacije). Ako se za analizu upotrebljavaju softveri za analizu kvalitativnih podataka, poznatiji prema engleskom akronimu CAQDAS – Computer Assisted/Aided Qualitative Data

Analysis Software, tada postoje dodatne pravila za transkripciju koja omogućavaju i/ili olakšavaju naknadnu analizu podataka u određenom softveru. Primjerice, prilikom kodiranja podataka u softveru *Atlas.ti* intervjueri i intervjuirane osobe obično se označe specifičnim imenima kako se u naknadnoj pretrazi ne bi duplirali s drugim osobama ili pojmovima. Primjerice, kodiramo li intervjuiranu osobu njezinim imenom, u pretrazi i drugih vrsta analiza može se dogoditi da postoji još jedna osoba s istim imenom. Stoga se imenu može dodati još jedan znak kako bi se stvorila jedinstvena kombinacija. Ovakav postupak omogućuje i tzv. automatsko kodiranje u kojem softver paragrafe odmah označava kodom određene osobe. Primjerice, umjesto da svaki paragraf koji je izrekao neki sudionik intervjua ili fokus grupe moramo kodirati svaki put, dovoljno je stvoriti jedan kod (u kojemu su najčešće podatci o dobi, spolu, stupnju obrazovanja i sl.) te automatski pridružiti ovaj kod svakom paragrafu u kojemu se pojavljuje određeno (jedinstveno!) ime. Navedeni softveri također imaju svoje konvencije koje se tiču odvajanja pojedinih govornika i druge transkripcijske konvencije. Primjerice, *Atlas.ti* govornike odvaja tako da analitičar dva puta stisne tipku „enter".

Transkripti se kodiraju, pri čemu istraživač pokušava doći do dubljih uvida putem traženja obrazaca i pravilnosti koji predstavljaju nove spoznaje ili odgovor na postavljena istraživačka pitanja. Ako je cilj intervjua bio generiranje nove teorije, tada se podatci mogu obraditi i pomoću tzv. *utemeljene teorije* (eng. *Grounded Theory*). Taj pristup, koji su razvili Glaser i Strauss (1967.), bez prethodnih hipoteza i na osnovi kvalitativnih podataka (najčešće intervjua) želi doći do znanstvenih teorija na području društveno-humanističkih znanosti. Prikupljeni podatci obično se početno kodiraju (tzv. otvoreno ili incijalno kodiranje), pri čemu se istraživač služi nizom analitičkih pitanja koja mu omogućavaju daljnji uvid u to što podatci govore. Neka su od takvih pitanja: „Zašto se postupci i činovi koji se analiziraju u podatcima uzimaju zdravo za gotovo?", „Kakav je proces ovdje u pitanju i kako ga mogu definirati?", „Kako se ovaj proces razvija?", „Kako se sudionici istraživanja ponašaju, što tvrde da osjećaju i o čemu razmišljaju tijekom ovoga procesa?", „Što njegovo ili njezino ponašanje može značiti?", „Kako i kada se pod ovim okolnostima ovaj proces mijenja i kakve su mu posljedice?" (Charmaz, 2006: 51). Pri tome se preporučuje kodirati u obliku glagolske imenice (gerunda) kako bi se zadržala orijentacija na sam proces. Primjeri su takvog kodiranja: „Izbjegavanje odgovornosti", „Pokazivanje ponosa", „Razmatranje alternative", i sl., umjesto „Osoba A pokazuje odgovornost", „Osoba A pokazuje ponos" i „Osoba A razmatra alternativu". Ponekad otvoreno kodiranje čak može krenuti od konkretnih iskaza i izraza koje su upotrijebili sudionici istraživanja, a takvo se kodiranje obično naziva *in vivo* kodiranje. Neki istraživači (npr. Saldaña, 2011.)

preporučuju da se *in vivo* kodovi pišu s navodnicima kako bi se naznačila njihova najniža razina apstrakcije, no često je iz samog jezičnog oblika jasno da je riječ o iskazima ispitanika (najčešće pisanje u prvom licu). Primjerice, *in vivo* kôd kojim se označava protivljenje smanjenju plaća u nekoj organizaciji može se doslovno navesti kao „protivim se smanjenju plaća". Na temelju otvorenog kodiranja bira se manji broj kodova koji se najčešće spominju i povezani su s drugim kodovima (tzv. selektivno ili fokusirano kodiranje). Na kraju dolazi teorijsko kodiranje u kojemu se pronalaze načini povezivanja kodova koji imaju teorijskog smisla i mogu se provjeriti u daljnjim istraživanjima. Teorijsko se kodiranje oslanja na tzv. abdukciju, kao treći način zaključivanja, uz indukciju i dedukciju. Abdukcije se sastoje od stalnog provjeravanja alternativnih hipoteza sve dok ne dosegnemo onu koja nam se u konkretnom slučaju čini najprihvatljivijom u odnosu na dostupne podatke. Thornberg i Charmaz (2014: 161-162), oslanjajući se na jednog od osnivača semiotike, Charlesa Sandersa Peircea, upotrebljavaju primjer s vrećama graha kao ilustraciju razlika između indukcije, dedukcije i abdukcije. Ovdje navodimo skraćeni prikaz njihove ilustracije. Uzmimo situciju u kojoj iz jedne vreće uzastopno izvučemo pet zrna graha i ustanovimo da su sva bijele boje. Na temelju toga zaključimo da su sva zrna u ovoj vreći bijela, a takav je zaključak induktivan (od pojedinačnog prema općem). Ako nam neka osoba kaže da u ruci drži tri zrna graha izvučena iz vreće na kojoj piše „bijeli grah" i ako pouzdano vjerujemo da natpis odgovara stvarnom stanju stvari, tada možemo zaključiti da ta osoba u ruci drži tri zrna bijeloga graha. Takav je zaključak deduktivan (od općeg prema posebnom). I na kraju, ako imamo tri vreće graha na kojima piše „crni grah" (prva vreća), „bijeli grah" (druga vreća) i „sivi grah" (treća vreća) te na zemlji pored tih vreća nađemo tri zrna bijelog graha, naš abdukcijski zaključak bio bi da zrna dolaze iz vreće na kojoj piše „bijeli grah". Međutim, zaključak se mijenja ako ustanovimo da su vreće hermetički zatvorene, a da se pored zrna graha nalaze tragovi ljudskih stopa. Na osnovni ovih podataka zaključujemo da je grah vjerojatno ispao nekom prolazniku i da ne dolazi iz naših vreća. Dakle, abdukcijski se zaključak stalno mijenja u svjetlu novih relevantnih podataka.

Prilikom kodiranja uobičajeno je pisanje memoranduma (skraćeno: memo) u kojima se bilježe sve ideje do kojih se dolazi prilikom analize, a cijeli je postupak iterativan. Kodiranja i nove ideje vode do promjene postojećih kodova, njihovo grupiranje u općenitije kodove ili lomljenje u manje općenite kodove i sl. Opisani je proces zapravo tzv. hermeneutički krug u kojemu shvaćanje cjeline vodi do novoga shvaćanja dijelova, koji opet vode do novog shvaćanja cjeline itd. Prilikom procesa kodiranja osobito je važno tražiti negativne slučajeve, odnosno pokušati opovrgnuti početne ideje/kodove, kako ne bismo prerano došli do konačnih za-

ključaka, odnosno kako naši zaključci ne bi bili u skladu s našim ranijim uvjerenjima o tome što stoji iza podataka, odnosno kako je moguće objasniti fenomen koji istražujemo. Softveri za analizu kvalitativnih podataka omogućuju različita pomagala i vizualizacije (tzv. oblaci riječi, grafikoni, mreže pojmova i sl.) koji pomažu prilikom dolaženje do ideja o odnosima između pojedinih pojmova. Isto tako, moguće je raditi analize bliskosti pojavljivanja pojedinih pojmova/kodova, njihova zajedničkog pojavljivanja kod određenih sudionika, odnosno računanja razlika u frekvencijama pojavljivanja i sl. Ovi softveri omogućuju i importiranje podataka iz datoteka različitog tipa, odnosno analizu podataka s interneta i društvenih mreža. Trenutno se u većini softvera podatci s web stranica i društvenih mreža prebacuju u pdf formatu i dalje analiziraju u softveru. Neki softveri, kao što je *Nvivo*, omogućuju i „čišćenje" web stranica i stranica s društvenih mreža od reklama i drugog ometajućeg materijala, pri čemu se sačuva osnovni oblik stranice, odnosno teksta. Neki softveri imaju i dublju integraciju podataka s nekih društvenih mreža. Tako *Atlas.ti* automatski može importirati podatke s Twittera pretraživanjem prema riječima unutar *tweetova* ili pomoću *hashtagova*, pri čemu se autori *tweetova* i njihova lokacija, osobe koje se u njima spominju, jezik kojim je pisan tekst te *hashtagovi* mogu automatski kodirati, što istraživaču donosi znatnu uštedu vremena.

Kao primjer analize podataka iz intervjua pomoću pristupa tzv. utemeljene teorije, uzmimo da istražujemo u kojoj mjeri socijalni status roditelja utječe na odluku o nastavku školovanja (odlasku na fakultet) i da u tu svrhu napravimo intervjue sa srednjoškolskim učenicima. U prvoj fazi (otvoreno kodiranje) podatke bi kodirali tako da neselektivno izdvojimo sve moguće elemente koji su se pojavili tijekom intervjua (npr. aspiracije učenika, stupanj podrške roditelja, nedostatak novca za nastavak školovanja, školski uspjeh, želja za zapošljavanjem nakon završetka srednje škole itd.). Ovdje je bitno napomenuti da se otvoreno kodiranje radi nakon nekoliko napravljenih intervjua (privremena analiza), te se nakon toga dobivene spoznaje koriste u idućim intervjuima. Tako se, primjerice, može ispostaviti da je važan element za odluku o nastavku školovanja nesklonost da se ode iz mjesta trenutnog stanovanja, što u prvom trenutku možda nismo predvidjeli. Nakon otvorenog kodiranja radi se selektivno kodiranje. U tome slučaju možemo pretpostaviti da je nedostatak novca povezan s neodlaskom na fakultet, da je stupanj roditeljskih aspiracija povezan s aspiracijama učenika, da želja za zaspošljavanjem nakon škole onemogućava odlazak na fakultet i sl. Teorijskim kodiranjem odlučili bismo koja je od povezanosti utvrđena selektivnim kodiranjem najvažnija. Na primjer, možemo smatrati da podatci pokazuju da je želja za neposrednim zapošljavanjem nakon fakulteta najvažniji element zbog

kojega neki učenici ne žele nastaviti školovanje, te nakon toga tu teoriju možemo testirati i širim kvantitativnim istraživanjem.

## 9.4. STUDIJA SLUČAJA

Studija slučaja (eng. *case study*) odnosi se na dubinsko proučavanje jednog pojedinca, organizacije, situacije, procesa, društvene grupe i sl. Studija slučaja može se promatrati i kao općenita istraživačka stretegija koja je vođena određenim pretpostavkama, a u okviru koje je moguće upotrijebiti različite metode i tehnike. Te metode najčešće su kvalitativne, ali ponekad mogu biti i kvantitativne. Primjerice, u okviru neke studije slučaja možemo upotrijebiti istraživačku metodu promatranja, tj. istraživačku tehniku promatranja sa sudjelovanjem, pri čemu pod „metodom" podrazumijevamo općeniti pristup prikupljanju podataka u okviru nekog istraživanja, a pod „tehnikom" konkretnu realizaciju (varijantu) te metode.

***Studija slučaja istraživačka je metoda koja često kombinira druge metode kako bi dubinski istražila jednu organizaciju, pojedinca, proces, društvenu grupu i sl.***

Prema Veschurenu (2003.) studija slučaja može se definirati kao *holistički* pristup istraživanju, za razliku od kvantitativnog pristupa koji je redukcionistički. Na primjer, ako istraživač istražuje jednu tvrtku te u njoj pomoću anketnog upitnika izmjeri ukupno zadovoljstvo radnika, tada upotrebljava kvantitativni (redukcionistički) pristup jer istraživačku jedinicu (tvrtku) razbija na manje jedinice promatranja (radnike). Ako bi istraživač proučavao tvrtku kao cjelinu te pokušao ustanoviti koji specifičan splet okolnosti dovodi do toga da je zadovoljstvo u toj tvrtki visoko ili nisko, tada bi primijenio holistički pristup, tj. studiju slučaja (Verschuren, 2003: 126). Prema tome pristupu, svako proučavanje jednog određenog slučaja nije automatski i studija slučaja. S obzirom na vlastito holističko obilježje, studija slučaja ima i druga obilježja kvalitativnih metoda (prema Verschurenu 2003: 132). Tako npr. veličina i jedinice uzorka obično nisu unaprijed određeni, nego se stvaraju tijekom samog istraživanja. Često se upotrebljava uzorkovanje metodom grude snijega, s obzirom na to da proučavanje jedne jedinice uzorka često dovodi do zaključka da bi neka druga jednica bila zanimljiva za proučavanje. Primjerice, ako se istraživaču razmišljanje jednog čovjeka unutar organizacije učini zanimljivim, tada istraživač traži od te osobe da preporuči druge osobe unutar organizacije koje razmišljaju na isti (ili drukčiji)

način. Isto, tako istraživačke hipoteze nisu unaprijed pripremljene nego se stvaraju i modificiraju tijekom istraživanja. To istovremeno znači da se kao metode prikupljanja podataka češće koriste kvalitativne metode u kojima mjerni instrumenti nisu standardizirani i unaprijed pripremljeni, poput dubinskih intervjua ili polustrukturiranog i nestrukturiranog promatranja.

Studija slučaja najčešće se upotrebljava za (Yin, 1984.):

1. Izvor hipoteza za naknadno istraživanje,
2. Omogućavanje spoznaja o rijetkim pojavama,
3. Dovođenje teorije u pitanje,
4. Provizornu potporu teoriji.

Studija slučaja dubinskim ispitivanjem pojave koja se proučava može omogućiti niz plodnih hipoteza koje poslije mogu biti provjeravane kvantitativnim istraživanjem. Studija slučaja može biti jedini način proučavanja rijetkih pojava (npr. rijetke bolesti, kulturne institucije kojih ima samo nekoliko u cijeloj državi). Isto tako, studija slučaja može osporiti ili provizorno potvrditi neku postojeću teoriju, iako i tu valja imati na umu da je riječ o samo jednome slučaju.

U ovisnosti o tome na čemu je naglasak, studije slučaja se dijele na:

1. Eksploratorne,
2. Deskriptivne,
3. Eksplanatorne.

*Eksploratorne* studije slučaja imaju za cilj preliminarno istražiti neku pojavu kako bi se kreirale ideje i hipoteze za buduća, obično kvantitativna, istraživanja. *Deskriptivne* studije slučaja opisuju određeni slučaj bez većih teorijskih pretenzija. U *eksplanatornim* studijama slučaja testira se određena hipoteza ili teorija.

Prednosti su upotrebe studije slučaja kao metode sljedeće (Tkalac Verčič i sur., 2010: 97):

1. utvrđuje se međusobna povezanost niza čimbenika istodobno,
2. proučava se stvarni događaj, pa je vanjska valjanost istraživanja visoka,
3. dobiva se mnoštvo detaljnih podataka o proučavanoj pojavi.

Najčešći su nedostatci studije slučaja kao metode sljedeći:

1. Teškoće u uzročno-posljedičnom zaključivanju,
2. Pristranost (subjektivnost) istraživača,
3. Poteškoće u generalizaciji rezultata,
4. Studija slučaja traje relativno dugo.

Kako je riječ o samo jednom slučaju i prirodnoj, nekontroliranoj situaciji, ne možemo biti sigurni da smo osigurali kontrolu nad svim relevantnim čimbenicima, što znači da je na temelju jednog slučaja teško zaključivati o uzročno-posljedičnom odnosu. Pristranost istraživača odnosi se na činjenicu da pri dubinskom istraživanju sâm istraživač odlučuje koje će izvore podataka ili ispitanike koristiti, što dovodi u pitanje vjerodostojnost rezultata. Često je riječ o neformalnim razgovorima, odnosno primjeni nestandardiziranih instrumenata, pa to dodatno umanjuje valjanost i pouzdanost dobivenih podataka. Dakle, taj proces pod izrazitim je utjecajem samoga istraživača, koji odlučuje ne samo koje će podatke prikupiti, nego služi i kao „mjerni instrument", za razliku od kvantitativnih istraživanja u kojima postoje unaprijed određene mjerne skale. Verschuren (2003.) smatra da se mogu razlikovati konceptualni i tehnički dizajn prikupljanja podataka, te da su kvantitativna istraživanja manje ovisna o istraživaču (pouzdanija) u tehničkom, a kvalitativna u konceptualnom dijelu. Prema njemu, studija slučaja manje je pouzdana u tehničkom dijelu prikupljanja podataka, dok je u konceptualnom dijelu čak i pouzdanija od kvantitativnih istraživanja, jer se unaprijed ne ograničava na točno određene hipoteze, kako je slučaj u kvantitativnom istraživanju. Međutim, može se ipak reći da je izbor hipoteza i mjernih instrumenata i hipoteze, iako su ga istraživači unaprijed odredili na temelju njegovih/njezinih subjektivnih pogleda, jasan i podložan kritici drugih istraživača. S druge strane, subjektivnosti koje se pojavljuju tijekom formulacije hipoteza i obrade podataka u studiji slučaja znatno su manje transparentne. Tako, primjerice, ne znamo je li istraživač tijekom analize zanemario određene podatke jer ih je smatrao manje važnim, je li zanemario neka istraživačka pitanja i sl.

Poteškoće u utvrđivanju uzročno-posljedičnih odnosa i subjektivnost istraživača impliciraju da je unutrašnja valjanost studija slučaja često problematična, a smanjena unutrašnja valjanost, slično kao i kod eksperimenata, smanjuje i mogućnost vanjske valjanosti, odnosno mogućnost da se rezultati i zaključci dobiveni studijom slučaja generaliziraju na drugo vrijeme, mjesto, ljude ili situacije. Dodatne poteškoće u generalizaciji podataka odnose se i na činjenicu da je riječ o samo jednome slučaju, što statističko zaključivanje (generalizaciju) čini upitnom. S obzirom na to da je u studiji slučaja najčešće riječ o pokušaju ustanovljavanja uzročno-posljedičnih odnosa, uzorak veličina 1 (jedan slučaj) predstavlja manji problem kada je generalizacija u pitanju, nego što je to slučaj u ispitivanjima javnog mnijenja u kojima je riječ o pokušaju procjene nekog parametra populacije. Primjerice, proučavanja prilagođavanja neke tvrtke tržišnoj globalizaciji (otvorenosti tržišta) ne treba odbaciti samo zbog toga što je riječ o jednom slučaju, dok bi pokušaj procjenjivanja rezultata izbora na temelju ispitivanja samo jednog po-

jedinca bio vrlo nepouzdan. Dodatnu poteškoću za generalizaciju rezultata, odnosno vanjsku valjanost istraživanja, predstavlja i činjenica da se proučava slučaj koji može biti vrlo specifičan, tj. da može biti riječ o okolnostima koje se rijetko nalazi u drugim slučajevima.

Ilustrirajmo sve poteškoće studije slučaja na primjeru istraživanja stilova menadžmenta na uspješnost neke tvrtke. Pođimo od pretpostavke da je istraživač duže vrijeme dubinski proučavao tvrtku A terenskim prikupljanjem podataka putem promatranja te intervjua s menadžmentom i radnicima. Na temelju studije slučaja zaključio je da je tvrtka uspješna zahvaljujući participativnom stilu menadžmenta koji svim zaposlenim omogućava iznošenje mišljenja i problema, odnosno prijedloga za poboljšanje poslovanja tvrtke. Prva prijetnja unutrašnjoj, a time i vanjskoj valjanosti odnosila bi se na činjenicu da je istraživač na temelju svoje, donekle subjektivne procjene, donio zaključak da je stil menadžmenta u toj tvrtci participativan. Drugi bi istraživač istu situaciju možda procijenio drukčije; primjerice, možda bi zaključio da je izjašnjavanje i sudjelovanje radnika moguće samo u posve nevažnim pitanjima i odlukama. Druga bi se prijetnja unutrašnjoj valjanosti odnosila na postojanje alternativnih objašnjenja uspjeha te tvrtke. Naime, tvrtka je možda uspješna zbog svoje izgrađene tržišne pozicije, monopolske ili oligopolske situacije, ili zbog toga što ima pristup jedinstvenim resursima (npr. povoljna lokacija). Moguće je i da tvrtka posluje na tržištu koje se tek počelo razvijati i u kojem se još nije pojavila brojna i jaka konkurencija. Drukčije rečeno, možda stil menadžmenta, kakav god bio, nije izrazito važan za uspješnost tvrtke. Poteškoće u generalizaciji rezultata pojavile bi se ne samo zbog toga što je riječ o jednom slučaju, nego i zbog moguće specifičnosti te tvrtke. Primjerice, možda zaposlenici i vlasnici tvrtke A već generacijama žive u istoj zajednici i međusobno se jako dobro poznaju. Stoga u takvoj situaciji participaciju radnika omogućuje povjerenje koje postoji između svih zaposlenih, uključujući i vlasnike. U nekoj drugoj tvrtki s heterogenim zaposlenicima takav stil rukovođenja možda ne bi bio izvodiv, tj. možda bi bio manje uspješan. I naposljetku, provođenje takve studije slučaja vjerojatno bi zahtijevalo duže vrijeme, a time bi imalo veću cijenu, pogotovo ako istraživač ne živi u okolini slučaja koji se analizira.

Navedene nedostatke studije slučaja moguće je donekle ublažiti pomoću nekoliko strategija povećanja valjanosti i pouzdanosti. Kako bi se povećala vjerojatnost da su uzročno-posljedični odnosi točni, potrebno je razmotriti sve alternativne uzroke pojave (zavisne varijable) koja se proučava. U gornjem bi slučaju trebalo razmotriti sve moguće razloge zbog kojih bi tvrtka A mogla biti uspješna. Su-

bjektivnost i utjecaj istraživača može se smanjiti standardizacijom mjernih instrumenata ili sudjelovanjem više istraživača u studiji te usporedbom njihovih rezultata i zaključaka. Poteškoće u generalizaciji rezultata također je moguće donekle smanjiti razmatranjem alternativnih postavki i pokušajem da se utvrdi koliko su okolnosti vezane uz slučaj koji se proučava specifične za njega, tj. koliko se razlikuju od okolnosti prisutnih u drugim slučajevima. Eksternu valjanost istraživanja, tj. mogućnost generalizacije rezultata studije slučaja na druge slučajeve, može se pokušati obraniti pomoću holističke naravi same studije slučaja (Verschuren, 2003: 135). Naime, studija slučaja koristi vrlo male uzorke (jedan ili nekoliko slučaja), ali mali uzorci mogu biti prihvatljivi ako varijabilnost pojave nije velika. Kako se za analizu studije slučaja koriste cijele pojave, a ne njihovi pojedinačni elementi (ranije opisani holistički pristup), tako je i varijabilnost tih pojava često mala. Primjerice, proučavamo li obilježja suvremene obitelji, tj. odnose među njezinim članovima, vjerojatno nam neće trebati veliki uzorak jer tipovi suvremene obitelji nisu mnogobrojni (npr. nukleusna obitelj, jednoroditeljska obitelj, višegeneracijska obitelj...), pa bi možda bilo dovoljno napraviti studiju jednog slučaja svakoga od tih tipova.

Poseban problem prilikom provođenja studije slučaja predstavlja osiguravanje anonimnosti osoba ili organizacija koje su predmet istraživanja. Naime, u kvantitativnim studijama u kojima sudjeluje mnogo osoba ili organizacija, anonimnost prilikom prezentiranja rezultata sačuvana je u samoj činjenici da se rezultati prikazuju u agregiranom obliku iz kojega nije moguće iščitati rezultate pojedinih sudionika istraživanja, čak i ako je poznato tko je sve sudjelovao u njemu. U kvalitativnim istraživanjima, s obzirom na to da u njima obično sudjeluje manji broj ljudi/organizacija, statistička agregacija ne mora jamčiti potpunu anonimnost. U studiji slučaja taj je problem osobito izražen pa je često, ako to sudionici istraživanja zahtijevaju, potrebno primijeniti razne tehnike *anonimizacije* (Gomm, 2009: 14). Najčešće se u tu svrhu koristi označavanje sudionika istraživanja brojevima ili pseudonimima te brisanje svih kontekstualnih referenci koje mogu otkriti tko je sudjelovao u istraživanju. Primjena potonje tehnike nije bez poteškoća jer drugim znanstvenicima otežava kritiku sâmoga istraživanja, a potpuno onemogućava i repliciranje istog istraživanja radi provjere valjanosti istraživanja. Preporučuje se i da se već prilikom vođenja bilješki, odnosno prikupljanja podataka, koriste pseudonimi, tj. da se onemogući povezivanje podataka s određenim osobama ili organizacijama. Takvo postupanje, koje je poželjno i u kvantitativnim istraživanjima, onemogućava drugim ljudima naknadnu zloupotrebu podataka, a istraživača oslobađa i od zakonske obveze osiguravanja tajnosti osobnih podataka. Primjerice, prema trenutno važećem *Zakonu o zaštiti*

*osobnih podataka* (NN, 103/03) u Republici Hrvatskoj, posjedovanje podataka o osobama koje se mogu identificirati povlači obvezu vođenja zbirke osobnih podataka, osiguravanje njihove zaštite i druge obveze.

I u studiji slučaja, kao i u drugim istraživanjima koja uključuju promatranje i intervjuiranje, vrijedi nekoliko pravila za bilježenje podataka:

1. podatke treba zabilježiti vrlo brzo nakon što su nastali (kako bi se spriječilo zaboravljanje),
2. ne treba početi novo opažanje prije nego što su raniji podatci zabilježeni,
3. bilješke trebaju biti vrlo detaljne kako bi se budućem čitatelju dobro dočarao sâm slučaj.

Ako je to moguće i ne ometa normalno odvijanje situacije, pri prikupljanju podataka treba koristiti videokamere, magnetofone i sl. Ta tehnička pomagala ne treba koristiti ako su podatci koji se prikupljaju u nekoj mjeri osjetljivi jer će ispitanici postati znatno oprezniji i zatvoreniji.

## 9.5. FOKUS GRUPE

### 9.5.1. Osnovna obilježja, svrhe i organizacija fokus grupa

Povijesno gledajući, nastanak fokus grupa vezuje se uz istraživačku grupu okupljenu oko Paula Lazarsfelda na sveučilištu Columbia 1940-ih. Ova je grupa ispočetka provodila komercijalna marketinška istraživanja, ali je početkom 2. svjetskog rata uključena u istraživanja političke propagande, osobito testiranje američkih ratnih propagandnih poruka. Metodološki iskorak grupi daje sociolog Robert Merton, no čak su i njegove fokus grupe prije svega alat za grupno intervjuiranje, a manje specifična metoda pogodna za proučavanje grupne dinamike (Kamberelis i Dimitriadis, 2014: 317). Prva načela vezana za provođenje fokus grupa kodificirana su u knjizi *The focused interview* izdanoj 1956. godine, a koju je Merton izdao u suautorstvu s Marjorie Fiske i Patriciom Kendall. Fokus grupe se završetkom rata opet uključuju u standardni alat istraživača tržišta i ispitivača javnog mnijenja, kao i evaluatora javnih politika, a dvostruki život nastavljaju živjeti i u okviru akademskih znanstvenih istraživanja. Imajući u vidu ovu dvostrukost, moguće je reći da većina pravila i primjera dobre prakse za provođenje fokus grupa valjane su i za komercijalne i za znanstvene fokus grupe, no za ove potonje vrijede nešto strožiji metodološki standardi, osobito kada su u pitanju resursi uloženi u obradu i analizu prikupljenih podataka.

Fokus grupe predstavljaju skupine ljudi koje pod vodstvom moderatora raspravljaju o određenoj temi. Svrhe provođenja fokus grupa mogu se podijeliti na *sadržajne i logičke,* pri čemu pri sadržajnoj primjeni fokus grupa želimo doći do određenih spoznaja o nekoj istraživačkoj temi (npr. zašto ljudi vole ili ne vole neku TV-emisiju), dok u metodološkoj primjeni želimo unaprijediti metodologiju istraživanja (npr. vidjeti razumiju li ljudi pitanja iz anketnog upitnika koji želimo upotrijebiti) (Skoko i Benković, 2009: 220). U tom drugom slučaju, fokus grupe služe kao predistraživanje za buduće opsežnije, najčešće kvantitativno, istraživanje. Čest je slučaj da fokus grupe služe za osiguravanje sadržajne valjanosti upitnika. Fuller i sur. (1993) navode primjer upitnika o bračnim svađama čija se sadržajna valjanost može poboljšati fokus grupom u kojoj će sudionici navesti sve moguće načine na koji se svađaju s partnerima/supružnicima, a koji bi istraživači možda mogli previdjeti prilikom konstrukcije upitnika.

***Fokus grupe predstavljaju istraživačku metodu u kojoj se pomoću grupne diskusije i koristeći se grupnom dinamikom i sinergijskim učinkom nastoji generirati što već broj ideja, stavova i sl.***

Bloor i sur. (2001) upotrebe fokus grupa dijele na upotrebe u kojima je fokus grupa glavna metoda te one u kojima igra ulogu pomoćne metode. Kao glavna metoda fokus grupe se u znanstvenim istraživanjima u pravilu upotrebljavaju za proučavanje grupnih procesa, stvaranja grupnih normi i mišljenja. U tom smislu fokus grupe predstavljaju metode koja je najbolje prilagođena ovakvim istraživačkim situacijama i teško može biti zamijenjena pogodnijom metodom. S druge strane, fokus grupe nisu pogodne za istraživanje ponašanja jer će na sklonost sudionika da iznesu vlastito ponašanje i njegovu učestalost jako utjecati grupni kontekst, odnosno prisutnost drugih ljudi. Bloor i sur. fokus grupe vide i kao pomoćnu metodu, i to u nizu različitih situacija. Kao prvo, fokus grupe mogu biti eksplorativna metoda koja je osobito korisna u nepoznatim situacijama, odnosno u situacijama u kojima istraživač nema dublje uvide u temu koju želi proučavati. Osobito je važan i uvid koji istraživač dobije u jezik koji neka grupa ljudi upotrebljava i njezino razumijevanje pojedinih riječi i izraza, a što istraživaču može dati dragocjene podatke za konstruiranje anketnog upitnika. Kao drugo, fokus grupe mogu djelovati kao mehanizam razjašnjavanja i kontekstualizacije istraživačkih rezultata dobivenih kvantitativnim metodama. Pretpostavimo, primjerice, da se veći broj ljudi u anketnom istraživanju izjasni protiv izgradnje nekog industrijskog postrojenja u njihovu gradu. U naknadnim fokus grupama može biti utvrđeno da je takvo protivljenje rezultat medijskih napisa zasnovanih

na krivim činjenicama, a što teško može biti utvrđeno u anketnom istraživanju. Bloor i sur. (2001: 11) navode primjer studije koju su proveli Kitzinger i sur. (1994), a u kojoj je oko 4% sudionika anketnog istraživanja iznijelo mišljenje da se doniranjem krvi osoba može inficirati HIV-om. Ovakav podatak mogao je predstavljati ozbiljan javnozdravstveni problem, s obzirom na to da mnoge ljude može odvratiti od dobrovoljnog davanja krvi. No naknadne fokus grupe pokazale su da su ispitanici koji su izrazili takvu bojazan zapravo mislili da osoba koja prima krv može biti inficirana HIV-om, tj. da nisu jasno razlikovali davanje i primanje krvi. Upravo zbog ovih razloga fokus grupe prilikom multimetodoloških istraživanja ne treba gledati kao samo jednu od metoda koja treba poslužiti potvrdi istraživačkih rezultata putem triangulacije. Naime, svaka metoda ima svoje jake i slabe strane, te su fokus grupe više dopuna drugim metodama koja služi za kontekstualizaciju, dopunu, potvrdu ili osporavanje istraživačkih rezultata, a ne kao puku metodu potvrde (Bloor, 1997). I na kraju, Bloor i sur. ističu da fokus grupe mogu biti upotrijebljene za dijeljenje rezultata istraživanja s njegovim sudionicima. Ovakva se situacija obično pojavljuje onda kada istraživač smatra da je uloga istraživanja da osnaži lokalnu zajednicu ili onda kada se dijeljenje podataka smatra načinom validacije rezultata istraživanja (tzv. validacija pomoću sudionika ili provjera sa sudionicima). No naknadna rasprava rezultata pomoću fokus grupa može djelovati i kao način *debriefinga* te kao način da se poveća spremnost na sudjelovanje u istraživanju.

Fokus grupe obično se sastoje od 6 do 10 ljudi, a jedna fokus grupa traje oko 1,5 do 2 sata. Optimalan broj ljudi koji sudjeluju u fokus grupi upravo je takav jer bi broj manji od 6 obično značio da se ne može doći do većeg broja različitih mišljenja unutar grupe, što onemogućava važniju diskusiju i generiranje novih ideja, dok bi broj veći od 10 doveo do toga da grupna diskusija postane kaotičnija te teža za praćenje i moderiranje. Fokus grupe specifične su i zbog toga što se govori sudionika međusobno prekidaju i prepleću, pa bi u slučaju većeg broja sudionika bilo teško napraviti transkripciju zbog nemogućnosti identificiranja toga što je tko rekao. Isto tako, imajući u vidu trajanje fokus grupe, u većim fokus grupama neki sudionici mogli bi imati osjećaj da ih se previše prekidalo prilikom govora i da nisu stigli reći sve ono što su htjeli, odnosno sudjelovanje u grupi za njih bi moglo predstavljati negativno iskustvo. Broj je sudionika to veći što je pretpostavljena zainteresiranost sudionika za temu manja, pa se može očekivati da će proizvesti manje materijala, odnosno ideja. Stoga je u tim situacijama potrebno uzeti veći broj sudionika kako bi se došlo do dovoljno materijala. Valja napomenuti da točan broj ljudi u pojedinoj fokus grupi varira zbog toga što istraživači nikad nisu sigurni koliki će se broj dogovorenih sudionika doista i pojaviti. Iz

istoga je razloga broj pozvanih sudionika obično oko 20% veći od potrebnog broja. Uzorkovanje u fokus grupama ne mora biti probabilističkog tipa, zato što je u pitanju kvalitativna metoda čiji cilj nije generaliziranje rezultata nego dobivanje što šireg kruga mišljenja. Zbog toga se u stvaranju uzorka najčešće koristi uzorkovanje metodom grude snijega (*snowball sampling*).

Fokus grupe obično se audiovizualno snimaju te se snimke poslije analiziraju. Fokus grupe obično se odvijaju u prostorijama s dvostranim zrcalom (*one-way mirror*), kako bi se ponašanje sudionika moglo promatrati bez ometanja odvijanja fokus grupe. Poželjno je da sudionici sjede u kružnom rasporedu, kako bi mogli vidjeti jedni druge, pri čemu je isto tako poželjno da sjede za stolom kako bi se mogli nagnuti i nasloniti, ali i kako bi se manje pozornosti u interakciji obraćalo na tijelo sudionika. Organizacija fokus grupa obično uključuje i druge praktične detalje, kao što su hrana i piće za sudionike, pločice s imenima ako se sudionici ne poznaju i sl. Osobito je važno omogućiti identifikaciju sudionika prilikom naknadne transkripcije, čemu upravo služe pločice s imenima i kratko predstavljanje sudionika na početku grupe. Transkripcija postaje teža ako se upotrebljava samo audiosnimanje, pa u takvim situacijama moderator treba sažimati argumente sudionika i navoditi češće njihova imena, kako bi osobi koja sluša audiosnimku olakšala identifikaciju sudionika. S obzirom na to da su sociodemografska obilježja sudionika obično važan podatak za tumačenje podataka dobivenih istraživanjem, prije fokus grupe sudionici mogu popuniti kratki upitnik s osnovnim podatcima o sebi, ili te podatke mogu iznijeti prilikom upoznavanja odnosno na početku fokus grupe.

Grupe se obično sastoje od sličnih ispitanika (npr. samo žene, mlade osobe, obiteljski ljudi i sl.), kako bi se omogućilo slobodnije izražavanje mišljenja, kao i spriječili sukobi mišljenja i nepotrebne rasprave. Primjerice, manje obrazovani pojedinci često su manje skloni izražavati svoje mišljenje u prisutnosti obrazovanijih osoba, a žene i muškarci obično slobodnije iznose svoje mišljenje ako su u grupi prisutni samo pripadnici njihova spola. Isto tako, npr. ako unaprijed znamo da mladi vole određenu televizijsku emisiju, a stariji je ne vole, tada bi fokus grupa koja bi se sastojala od mlađih i starijih ljudi mogla puno vremena izgubiti na međusobna uvjeravanja i sukobe, što nije cilj fokus grupe. Pravi cilj bi bio dubinsko ispitivanje razloga zašto mladi vole, a stariji ne vole dotičnu emisiju. Iz sličnih je razloga bitno da u istu fokus grupu ne uđu pojedinci koji se poznaju od ranije, kao i da u fokus grupu ne ulaze pojedinci s različitih pozicija unutar neke hijerarhije (nadređeni i podređeni). Naime, prethodno poznavanje ili različite pozicije mogle bi utjecati na slobodno iznošenje mišljenja, dok pret-

hodno poznavanje također može dovesti do toga da je moderatoru teško pratiti diskusiju jer pojedinci koji se poznaju međusobno komuniciraju na implicitan, a ne eksplicitan način (Milas, 2005: 595). Drukčije rečeno, među poznanicima značenja se često prenose gestom, intonacijom glasa i sl., s obzirom na to da pojedinci ponekad već unaprijed znaju ili pretpostavljaju mišljenje druge osobe koju poznaju. Zbog svega navedenog preporučljivo je da moderator fokus grupe bude osoba što sličnija njezinim sudionicima. Primjerice, ako se rade fokus grupe razdvojene prema spolu, dobro je da ženski moderator vodi žensku, a muški mušku fokus grupu.

Kada je u pitanju prethodna upoznatost s drugim sudionicima fokus grupe, može se zaključiti da je ona nepotrebna, a čak i štetna, kada su u pitanju teme koje su izrazito individualne, odnosno interakcija između pojedinaca unutar fokus grupe nije sama po sebi zanimljiva, nego je njezina funkcija dolaženje do novih ideja. To je najčešće slučaj u marketinškim i medijskim istraživanjima u kojima se želi doći do novih ideja i stavova o nekom sadržaju (proizvodu, emisiji i sl.). U takvim bi situacijama prethodno poznavanje nekih osoba moglo dovesti do težeg izjašnjavanja o osjetljivijim temama. Primjerice, osoba će teže priznati da kupuje neki luksuzniji proizvod da bi zadovoljila potrebu za društvenim statusom ako se u fokus grupi nalaze i njezini prijatelji ili susjedi. S druge strane, ako je interakcija unutar grupe jedinica analize, odnosno ako će se podatci obrađivati pomoću konverzacijske analize i analize diskursa (vidjeti iduće poglavlje), tada je poznavanje osoba nužan preduvjet. Ranije spomenuta pogodnost fokus grupa za istraživanje grupnih procesa sasvim sigurno ide u prilog proučavanja postojećih društvenih grupa u njihovu prirodnom društvenom okruženju. Primjerice, želimo li proučavati proces donošenja odluka u poslovnim organizacijama, zasigurno je optimalno proučavati postojeći menadžment neke tvrtke u prostorima same tvrtke.

Kada je u pitanju primjena fokus grupa prilikom istraživanja osjetljivijih tema, sigurno je da je ova metoda manje pogodna za prikupljanje osjetljivih podataka od metoda koje jamče potpunu anonimnost prikupljenih podataka (npr. anketna istraživanja u kojima je osigurana anonimnost). S duge strane, fokus grupe mogu biti pogodnije za istraživanja osjetljivih tema od drugih kvalitativnih metoda, primjerice individualnih intervjua. Osobito je to slučaj kada je riječ o osjetljivim temama zajedničkim jednoj skupini ljudi, a u tim bi situacijama grupni razgovor mogao biti manje stresan za ispitanika od situacije individualnog intervjuiranja. Ilustrativno može biti, na primjer, istraživanje maloljetničke delinkvencije u kojemu želimo utvrditi zašto je netko započeo s kršenjem zakonskih normi. Mlada

bi osoba vjerojatno bila sklonija slobodnije razgovarati o ovoj temi u skupini drugih mladih osoba sa sličnom prošlošću i problemima sa zakonom, nego u situaciji kada osobno razgovara s jednim intervjuerom. U prvoj situaciji zasigurno postoji veća razina socijalne podrške nego u drugoj. No u takvim situacijama treba uzeti u obzir etičku osjetljivost situacije, odnosno mogućnost da sudionici iznesu osjetljive podatke pred osobama koje poznaju, a zbog čega mogu poslije zažaliti. Fokus grupe uključuju dinamiku zbog koje sudionik može iznijeti one podatke koje nije htio i planirao iznijeti, a moderator ne može posve kontrolirati grupnu dinamiku i ne može posve spriječiti takvu situaciju. Imajući u vidu da se istraživač ne može ispitanike spriječiti u naknadnom širenju informacija dobivenih putem fokus grupe, ovakvu mogućnost treba imati na umu prilikom planiranja istraživanja i odlučivanja o sastavu fokus grupe.

Poželjno je da fokus grupa započne neobveznim razgovorom o svakodnevnim temama kako bi se sudionici upoznali i opustili. Pri tome treba obvezno izbjeći sve kontroverzne teme (religija, politika i sl.), odnosno teme koje će se pokriti u fokus grupe. Krueger (1994: 108-109) čak predlaže da se ovaj neobvezni dio iskoristi kako bi se identificirali sudionici koji će biti više ili manje aktivni/razgovorljivi tijekom fokus grupe, pri čemu se manje aktivni trebaju smjestiti nasuprot moderatoru radi kontakta očima i poticanja reakcije, a aktivniji što više postrani moderatoru. Važno je napomenuti da se sudionicima, iako im okvirno treba reći o čemu je u studiji riječ, ne otkrije stvarni istraživački/praktični problem, a osobito da se ne istakne da sudionici trebaju pronaći rješenje za taj problem i da je to njihova primarna uloga. Naime, sudionici bi tijekom fokus grupe trebali iznijeti svoja iskustva i razmišljanja i ne bi se trebali staviti u poziciju „eksperta" jer to može u potpunosti iskriviti njihovu perspektivu. Umjesto da razmišljaju o vlastitim iskustvima, sudionici ih mogu početi apstrahirati i razmišljati o teorijskim načinima kako riješiti problem. S obzirom na to da sudionici često nisu stručnjaci za taj problem, ovakva perspektiva nije ono što je poželjno u fokus grupama. Primjerice, pretpostavimo da radimo fokus grupu o problemu vandalizma i maloljetničke delinkvencije u nekom gradu ili naselju. Primarna uloga sudionika fokus grupe nije da nam ponude rješenje za taj problem, nego da nam iznesu svoja iskustva s vandalizmom/delinkvencijom, spoznaje o mladima koji rade takve stvari i razloge zbog kojih ih rade. Njihove ideje o načinu rješavanja problema također mogu biti dobrodošle, ali tek na kraju fokus grupe, nakon što su iznijeli svoja neposredna iskustva koja su mnogo važnija od teorijskih zamisli o delinkvenciji koje imaju.

Službeni dio fokus grupe obično počinje nekim poticajem koji omogućuje „zagrijavanje" sudionika, odnosno pokretanje grupne dinamike. Često je to neka

videosnimka, fotografija ili tekst. Bloor i sur. (2001) sugeriraju četiri mogućnosti za ono što nazivaju *fokusirane vježbe*, odnosno zagrijavanje za početak fokus grupe: (1) vježbe rangiranja, (2) stvaranje vinjeta, (3) stvaranje vijesti (eng. *news bulletin*) i (4) komentiranje fotografija. U vježbama rangiranja sudionicima se da nekoliko tvrdnji te imaju zadatak da ih poslože prema redoslijedu važnosti ili točnosti. Primjerice, sudionicima se može dati nekoliko tvrdnji koje govore o cijeni, kvaliteti i dostupnosti nekog proizvoda te ih oni trebaju zajednički rangirati prema točnosti. Na ovaj će se način već u uvodu početi raspravljati o nekim aspektima proizvoda koji zanimaju istraživača, u ovom slučaju istraživača tržišta. Stvaranje vinjeta odnosi se na hipotetičke situacije slične stvarnim životnim situacijama, a sudionici trebaju objasniti moguće aktivnosti koje treba poduzeti u takvim situacijama. Primjerice, ispitanicima se može navesti primjer televizijske serije koja je imala veliku početnu gledanost, ali joj je ona odjednom počela naglo opadati, te se od njih može zatražiti objašnjenje zašto se to dogodilo i što producenti serije trebaju poduzeti. U slučaju stvaranja vijesti sudionici dobiju niz nepovezanih fotografija te od njih trebaju stvoriti vijest. Primjerice, u fokus grupi čija je svrha istražiti strah od kriminala sudionicima se može dati niz fotografija koje uključuju različite osobe, kriminalne činove i policiju te oni od njih trebaju kreirati medijski izvještaj o događaju prikazanom na fotografijama. I na kraju, slično prethodnoj vježbi, komentiranje fotografija (a i videosnimaka) može poslužiti za uvod u temu jer će sudionicima poslužiti kao povod za prve komentare. Primjerice, u fokus grupi o novom obiteljskom zakonu sudionicima se može prikazati medijski izvještaj o zakonu, videosnimka svakodnevnog života obitelji ili obiteljske fotografije.

Druga pravila vezana za postavljanje pitanje relativno su slična onima koja postoje pri provođenju drugih vrsta istraživanja (ponajviše anketa i intervjua). Krueger (1994: 57-65) tako izdvaja sedam pravila vezana za postavljanje pitanja u fokus grupama:

1. Fokus grupe upotrebljavaju otvorena pitanja,
2. Prvo se postavljaju pitanja bez podsjetnika (pomoći), a nakon toga s podsjetnikom,
3. Fokus grupe izbjegavaju dihotomna pitanja,
4. „Zašto“ je pitanje koje se rijetko postavlja u fokus grupama,
5. Fokus grupe mogu upotrebljavati standardizirane strategije postavljanja pitanja,
6. Pitanja u fokus grupama pozorno su pripremljena,
7. Pitanja iz fokus grupa jasna su.

Otvorena pitanja u fokus grupama češća su od zatvorenih jer je cilj fokus grupa promotriti stvarnost iz pozicije sudionika istraživanja. Ponekad su neka otvorena pitanja zapravo prikrivena djelomično otvorena pitanja – primjerice, pitanja koja uključuju izraze poput „koliko", „do koje mjere", „koliko ste zadovoljni" uključuju implicitnu ljestvicu na kojoj bi ispitanik trebao odgovarati.

Dihotomna pitanja izbjegavaju se jer su odgovori na njih u pravilu kratki i ne potiču grupnu diskusiju. Stoga ih u pravilu treba upotrebljavati samo u strukturiranim istraživanjima, odnosno u anketama.

Pitanja koja uključuju riječ „zašto", odnosno pitanja koja su usmjerena na traženje uzroka/razloga ponašanja putem direktnog pitanja izbjegavaju se iz dva razloga. Prije svega, direktno pitanje podrazumjeva da ljudi znaju razloge za svoje ponašanje, a što nije uvijek slučaj. Nadalje, samo pitanje o uzroku/razlogu nejasno je, neki će ljudi navoditi direktne, a neki indirektne uzroke ponašanja. Drukčije rečeno, neki će navoditi atribute same pojave, a neki okruženje koje je utjecalo na odluku. Primjerice, na pitanje zašto je pojedinac kupio baš automobil koji je kupio on/ona može odgovoriti navođenjem neposrednog uzroka, tj. reći da ga je kupio jer je imao dovoljno novca (automobil nije bio preskup). Drugi će pojedinac istaknuti indirektne uzroke, tj. navodit će kvalitetu automobila, nisku potrošnju i sl. Treći će pojedinac istaknuti socijalne razloge, odnosno da se s kupovinom složila njegova supruga i sl. Stoga je mnogo bolji način istraživanja važnosti pojedinih razloga njihovo razdvajanje, odnosno specifikacija. Tako pojedinca u prethodnom primjeru možemo pitati što mu se sviđa/ne sviđa na automobilu, jesu li se njegovi ukućani složili s kupovinom, je li cijena bila prihvatljiva i u kojoj mjeri i sl. Pitamo li za izravni uzrok, vjerojatno je da će neki od ovih razloga ostati nepokriveni/neistraženi.

Prvo se postavljaju pitanja koja su posve otvorena i koja ne uključuju podsjećanje. Primjerice, od pojedinca možemo zatražiti da navede razloge zbog kojih smatra da je škola koju pohađa njegovo dijete dobra ili loša, bez navođenja mogućih razloga. Nakon što pojedinci navedu svoje mišljenje, pomaže im se sugestijama o mogućim razlozima. Na ovaj se način osigurava da sudionici mogu navesti sve moguće razloge, pa i one kojih se moderator/istraživač nije sjetio u pripremi istraživanja, ali i da svi mogući razlozi budu pokriveni.

Pitanja u fokus grupama mogu uključivati standardizirane formate. Primjerice, Krueger navodi dovršavanje rečenica i konceptualne mape kao neke od mogućnosti. Sudionicima grupe mogu se dati rečenice koje trebaju dovršiti (npr. „ova škola dobra je zbog..."), pri čemu trebaju skicirati kratke odgovore i iznijeti ih

grupi. Konceptualne mape znače grafički prikaz pojedinih objekata prema njihovoj bliskosti. Npr. pojedincima se može dati popis škola u njihovu gradu i od njih se može zatražiti da ih grupiraju prema kvaliteti i da objasne svoje odluke. Oba ova, a i drugi standardizirani formati pitanja, služe za pripremu diskusije, tj. pojedincima daju mogućnost da promisle o pitanjima i da ih šire elaboriraju.

I na kraju, pitanja trebaju biti jasna i unaprijed promišljena. Ovo pravilo vrijedi za bilo koje drugo istraživanje, no u kvalitativnim istraživanjima istraživač može počiniti pogrešku i ne pripremiti se za samo istraživanje računajući da će improvizirati i pitanja smisliti na licu mjesta. No i kvalitativno istraživanje zahtijeva visoku razinu priprema i promišljenosti.

Osim pravila koje donosi Krueger, može se dodati i da bi pitanja koja se koriste u fokus grupama trebala na početku diskusije biti općenitija, a nakon toga sve specifičnija (Del Rio-Roberts, 2011). Na taj se način ispitanicima omogućava „zagrijavanje" prije nego što se od njih traži mišljenje o konkretnijim temama.

Može se izdvojiti dvije ključne kvalitete fokus grupa kao metode:

1. *Dobivanje dubinskih mišljenja* o određenim temama,
2. *Upotreba socijalne dinamike* – pojedinac će često pomoću komentara drugih jasnije osvijestiti i prezentirati svoje mišljenje.

Nedostatci su fokus grupa sljedeći:

1. *Nedovoljna generalizacija* – mali broj ispitanika onemogućava pouzdanu generalizaciju,
2. *Mogućnost da pojedinci preuzmu većinsko mišljenje grupe*,
3. *Mogućnost da aktivniji pojedinci zauzmu većinu vremena* i onemoguće druge da kažu svoje mišljenje i stavove,
4. *Rezultate je teško kodirati* budući da u fokus grupama pitanja nisu standarizirana.

Osobito je ozbiljna opasnost grupnog mišljenja i konformizma, odnosno situacija u kojoj se u fokus grupi stvori mišljenje koje pojedinci u grupi iz konformističkih razloga ne žele osporavati. Ranije opisan eksperiment Solomona Ascha pokazao je da se konformizam izrazito smanjuje ako u grupi postoji bar jedan pojedinac različitog mišljenja (Asch, 1956). Stoga bi moderator uvijek trebao poticati alternativno mišljenje, a ponekad se može odrediti i dodatni moderator čija će uloga biti poticati divergentno mišljenje i na neki način osporavati preovladavajuće mišljenje u grupi. Drugim riječima, ovaj moderator treba igrati ulogu „vražjeg odvjetnika" odnosno suprotstavljati se onome što fokus grupa (prebrzo)

utvrdi kao konsenzualan stav. Dodatni moderator može imati i ulogu zapisivanja mišljenja i stavova koji su se pojavili na *flipchart* ploči ili papiru koji svi sudionici mogu vidjeti. Ovaj način omogućuje sudionicima da lakše prate temu, no istovremeno može oduzimati i dragocjeno vrijeme jer će sudionici obično čekati da moderator završi pisanje. Osim toga, pisanje zahtijeva ustajanje, čime se moderator stavlja u poziciju iznad sudionika, što može smanjiti njihovu aktivnost (Krueger, 1994: 106)

Kvaliteta rezultata fokus grupa izrazito ovisi o kvaliteti i uvježbanosti moderatora (facilitatora), a loše je moderiranje najčešći uzrok neuspjeha istraživanja provedenih pomoću fokus grupa. Dobar moderator trebao bi (navedeno prema Milasu, 2005: 594-596.):

1. *voditi tijek razgovora na način da se pokriju sve važne teme*,
2. *omogućiti svima iznošenje mišljenja* (motivirati za iznošenje mišljenja i šutljivije sudionike),
3. *naglasiti da u fokus grupi ne postoje točna i netočna mišljenja*,
4. *izbjegavati izražavanje slaganja ili neslaganja s pojedinim sudionicima* (jer se drugi sudionici tada mogu sustezati od davanja drukčijeg ili istog mišljenja),
5. *poticati na dodatnu razradu iznesenih stavova* (npr. postavljanjem potpitanja ili kratkom stankom nakon svakog mišljenja, koja omogućava drugima da izraze svoj stav).

Iz navedenih pravila o postupanju kvalitetnog moderatora vidljivo je da je riječ o (1) kombinaciji poznavanja teme istraživanja i usmjeravanju aktivnosti fokus grupe u smjeru ostvarenja istraživačkih ciljeva, te (2) pravilnog upravljanja grupnom dinamikom. U prvom je slučaju riječ o tome da moderator uspije ostvariti optimalnu specifičnost, opseg i dubinu podataka. Specifičnost se odnosi na traženje preciznosti i detalja u odgovorima ispitanika – primjerice, ponekad je dovoljno od ispitanika zatražiti da kažu sviđa li im se nešto ili ne, a ponekad se želi istražiti i stupanj sviđanja. Opseg se odnosi na pokrivanje svih važnih pitanja, a dubina na detaljniju elaboraciju vlastitog mišljenja ili stavova sudionika fokus grupe. Kada je grupna dinamika u pitanju, ključno je održati usredotočenost grupe na temu istraživanja, spriječiti sukobljavanja unutar grupe koja smanjuju navedenu usredotočenost te osigurati da svi sudionici daju doprinos grupnoj raspravi. Kao jedna od tehnika osiguravanja ravnomjernog sudjelovanja i zastupljenosti manjinskih mišljenja često se koristi tzv. produžena fokus grupa (eng. *extended focus group*) u kojoj sudionici prije sudjelovanja popunjavaju formalizirani upitnik. Njime su pokrivene upravo one teme o kojima će se

raspravljati unutar fokus grupe, a time se osigurava da sudionici razmisle o temi i kristaliziraju vlastito mišljenje o njoj. Rezultati istraživačima mogu donijeti i dragocjeni uvid o manjinskim mišljenjima koja možda nisu došla do izražaja u fokus grupi, tj. sudionici ih možda nisu izrazili zbog grupnog pritiska. Kada je moderiranje grupe u pitanju, na kraju valja reći da stupanj intervencije moderatora ovisi i o tome što su istraživački ciljevi. Ako se žele proučavati grupni procesi, tada je stupanj intervencije sigurno manje poželjan od upotrebe fokus grupa za predtestiranje upitnika ili za testiranje novog proizvoda. Nije posve jasno treba li moderator „glumiti" da temu dovoljno ne poznaje kako bi sudionike potaknuo na opširnije odgovaranje. Naime, ovakav pristup može razljutiti sudionike koji smatraju da se moderator mogao bolje pripremiti, a kod onih sudionika koji shvate da moderator primjenjuje ovakvu strategiju može doći do ljutnje zbog podcjenjivanja sudionika.

Uobičajeni je način završavanja fokus grupe kratko sažimanje rezultata grupe i upućivanje pitanja sudionicima slažu li se s zaključcima, nedostaje li nešto važno u sažetku te jesu li možda neke važne teme za razgovor ostale nepokrivene tijekom fokus grupe. Pri tome se pozorno prati govor tijela sudionika, odnosno pokušavaju detektirati svi znakovi neslaganja sa zaključcima (Krueger, 1994: 120). Ponekad se sažimanje rezultata napravi nakon isključenja audio-vizualne snimke kako bi se omogućilo onima koji su zbog snimanja fokus grupe bili suzdržani da neometano kažu svoje mišljenje.

Rezultati dobiveni fokus grupama obično se analiziraju pomoću analize sadržaja, pri čemu je, za razliku od uobičajene analize sadržaja, proces stvaranja kategorija izrazito dinamičan i odvija se tijekom same analize. Naime, u analizi se sadržaja kategorije analize obično stvaraju prije analize podataka – kvantifikacije. U analizi sadržaja podataka iz fokus grupa, imajući u vidu eksplorativnu narav fokus grupa, te se kategorije obično definiraju i redefiniraju tijekom analize podataka. Kada je u pitanju transkripcija podataka, moguće je samo prepisati razgovore onako kako su se dogodili ili je moguće napraviti transkripciju kakva se radi u konverzacijskoj analizi, a koja uključuje niz lingvističkih i drugih obilježja komunikacije (pauze u govoru, intonacija, glasnoća, naglašavanje pojedinih riječi, gestikulacija, mimika i sl.). Izbor ovisi o tome koja se vrsta analize podataka želi izabrati. Valja svakako imati na umu da jedna minuta fokus grupe može generirati i jednu stranicu transkripta, odnosno da fokus grupa uobičajenog trajanja može donijeti transkript s više od 100 stranica. Samo transkribiranje fokus grupe oduzme i do 10 puta više vremena od vremena potrebnog za provođenje fokus grupe, ponajviše zbog kognitivnog napora potrebnog da se identificiraju sudio-

nici prilikom simultanog govorenja i prekidanja drugih sudionika, kao i potrebe da se zabilježe svi verbalni i neverbalni znakovi relevantni za istraživanje.

Wilkinson (2004) razlikuje dvije opće vrste analize podataka iz fokus grupa koje se temelje na samom epistemološkom shvaćanju ove metode: analiza sadržaja i etnografska metoda. U analizi sadržaja riječ je o epistemološkom pristupu pri kojem se u fokus grupama otkrivaju postojeći stavovi, vrijednosti, ideje, ponašanja i sl., odnosno elementi društvenog svijeta koji su postojali prije same fokus grupe i koji se izvlače na „površinu". Podatci se obično analiziraju na kvantitativan način, navodeći elemente koji su se pojavili u fokus grupi i brojeći učestalost njihova pojavljivanja ili njihov intenzitet. Drukčije rečeno, analiza slijedi proceduru koja postoji u analizi sadržaja (analitička matrica, kodna knjiga i sl.). Primjerice, u fokus grupi koja se bavi političkim orijentacijama mogli bi istražiti koji elementi razlikuju ljude liberalne i konzervativne političke orijentacije te koliko su pojedini elementi važni ljudima. Etnografski pristup analizu koncentrira na samu interakciju unutar grupe, odnosno na načine na koje se društveni svijet stvara u navedenoj interakciji. Primjerice, u prethodno navedenoj fokus grupi mogli bismo istražiti poštuju li sudionici pravila dobre konverzacije (vidjeti poglavlje o konverzacijskoj analizi) na isti način kada razgovaraju s osobama iste i različite političke orijentacije, odnosno na koje načine krše ova pravila. Dakle, temeljna je razlika ovih dvaju pristupa usmjerenost na interakciju koja postoji u etnografskom pristupu, odnosno svojevrsna apstrakcija od interakcije koja se dogodila u fokus grupi prvoga pristupa, odnosno analize sadržaja. I u etnografskom pristupu mogu se dobiti kvantitativni podatci, to bi bio slučaj i u našem primjeru koji se odnosi na fokus grupu vezanu za političke orijentacije. No češće je slučaj da etnografski pristup nudi analizu koja je usmjerena na tekst i citiranje pojedinih tema koji se u njemu pojavljuju, pri čemu se implicira da je društvena grupa koja se proučava vrlo specifična, odnosno da se kontekst u kojemu se događaju određeni procesi društvene interakcije ne može lako generalizirati.

### 9.5.2. *ONLINE* FOKUS GRUPE

*Online* fokus grupe predstavljaju varijantu fokus grupa u kojoj se sudionici i moderator ne nalaze na fizički istome mjestu, nego se rasprava odigrava nekom vrstom računalno posredovane komunikacije. Osnovna prednost takvog načina provođenja fokus grupa sigurno je uklanjanje vremensko-prostornih barijera (praktičnost), jer sudionici ne moraju dolaziti na isto mjesto kako bi sudjelovali u fokus grupi. Stoga je lakše regrutirati sudionike koji ne žive na istom području,

a teorijski je u fokus grupu moguće okupiti sudionike iz različitih društava, kultura i međusobno udaljenih država, što je teško izvodivo u klasičnim licem-u-lice fokus grupama.

***Online fokus grupe predstavljaju varijantu fokus grupa u kojoj se sudionici ne nalaze na fizički istom mjestu, nego je komunikacija računalno posredovana.***

Komunikacija u online fokus grupama može biti (1) tekstualna, (2) audio ili (3) audio-vizualna. U tekstualnim fokus grupama komunikacija se odvija pomoću nekog od postojećih softvera za razmjenu poruka (npr. MSN Messagenger, Trillian, Google Hangouts i sl.), a moguće je upotrebljavati i platforme za VOIP komunikaciju (npr. WhatsApp i Viber), što postaje važno novijim generacijama koje su se navikle na komunikaciju putem mobilnih telefona. Tekstualna fokus grupa može biti sinkrona (sudjelovanje u realnom vremenu) i asinkrona (sudjelovanje i davanje doprinosa u različitim vremenskim trenutcima). Kada su u pitanju asinkrone fokus grupe, moguće je upotrijebiti klasične platforme kao što su e-mail, internetski forumi, blogovi i sl.

Prednost je tekstualnih fokus grupa anonimnost, a ovakav tip fokus grupa ne zahtijeva pisanje transkripta jer pisana komunikacija ostaje zabilježena na komunikacijskom softveru koji se upotrebljava za provođenje fokus grupe. No ovakav zapis donosi i izazov u pogledu privatnosti prikupljenih podataka, s obzirom na to da komunikacija ostaje vidljiva svim sudionicima grupe. Stoga je prije provođenja grupe potrebno sudionike obvezati da ne dijele komunikaciju, odnosno prikupljene podatke. Imajući u vidu da tekstualna komunikacija nosi mogućnost istovremene komunikacije sudionika fokus grupe, često je pravilo tekstualnih online fokus grupa da se od sudionika grupe traži da ne pišu svoje odgovore u trenutku kada drugi član grupe piše svoj odgovor (Lobe, 2017: 231), a što se u softverima obično može vidjeti pomoću odgovarajućeg znaka/ikone. S druge strane, takvo pravilo izrazito smanjuje brzinu odvijanja fokus grupe. Osim prednosti nadilaženja prostorno-vremenskih barijera koja vrijedi za sve online fokus grupe, važna prednost tekstualnih fokus grupa trebala bi biti anonimnost koja ispitanicima omogućava veću slobodu izražavanja mišljenja i smanjuje neugodu zbog rasprave s dotad nepoznatim ljudima. Ta anonimnost obično dovodi do većeg broja različitih ideja nego u F2F grupama jer su ispitanici manje skloni konformizmu, kao i tome da se manje vremena potroši na izražavanje slaganja s drugim sudionicima. Prednost bi mogla biti i smanjivanje nejednakosti u doprinosu pojedinih sudionika, jer sudionici mogu promišljati vlastite odgovore

istovremeno kada neki sudionik fokus grupe piše svoj odgovor. Na taj je način teže ostvariti dominaciju jednog sudionika, što može biti slučaj u F2F grupama. K tome, ispitanici koji su manje skloni iznositi vlastito mišljenje, zbog anonimnosti bi mogli pridonositi više nego u F2F grupama. No ovdje valja imati na umu da u tekstualnim online fokus grupama dominaciju mogu ostvariti sudionici koji pišu, odnosno tipkaju brže. Zanimljivo je i da bi tekstualne grupe mogle biti pogodne za istraživanje socijalno osjetljivih (intimnih) tema ne samo zbog anonimnosti, nego i zbog toga što nepostojanje potrebe da se razmišlja o tome kakav vizualni dojam ostavljamo na druge ljude, odnosno nepostojanje vizualnih podataka o drugim sudionicima tesktualne fokus grupe, dovodi do toga da sudionici postaju introspektivniji, tj. da se više fokusiraju na vlastite misli i emocije pa su ih i skloniji otkriti. Na ovakav zaključak upućuju istraživanja koja se bave usporedbom računalno posredovane komunikacije i one licem-u-lice (za pregled istraživanja i daljnje implikacije za online fokus grupe vidjeti Lobe, 2017: 237-238). Asinkrone tekstualne fokus grupe daju više vremena sudionicima, s obzirom na to da mogu davati odgovore kada im to odgovara, pa su pogodnije za kompleksnije teme.

Najvažniji je nedostatak tekstualnih *online* fokus grupa smanjenje ukupne kvantitete diskusije (npr. mjerene brojem riječi) zbog toga što je tipkanje znatno sporije od ljudskog govora u *face-to-face* fokus grupama. No, moguće je da *online* fokus grupe ljude prisiljavaju na veću konciznost, pa manja kvantiteta ne mora značiti i manju kvalitetu doprinosa u *online* fokus grupama, što neka istraživanja opovrgavaju (Straus, 1997), a neka potvrđuju (Reid i sur., 2005). Neka istraživanja (Brüggen, 2009) pokazuju da *online* fokus grupe daju manje irelevantnih informacija u usporedbi s F2F fokus grupama, kao i delfi metodom. Nadalje, većina ljudi preferira *face-to-face* sudjelovanje jer smatra da je takvu komunikaciju znatno lakše pratiti i općenito su zadovoljniji rezultatima takvih grupa i ostvarenom bliskošću s drugim sudionicima (Reid i sur., 2005). Jedan od nedostataka *online* grupa mogao bi biti i međusobno vrijeđanje i oštrije izražavanje neslaganja (eng. *flaming*), jer je kršenje pravila pristojnog ponašanja (vrijeđanje) znatno češće u situacijama visoke anonimnosti, tj. tamo gdje ne postoji komunikacija licem u lice. Oštrije neslaganje može postojati i zbog toga što u elektroničkoj komunikaciji neverbalni znakovi neslaganja nisu dostupni, pa se stoga nadomještaju verbalizacijom neslaganja. Npr. umjesto laganog odmahivanja glavom u F2F grupi, pojedinac će svoje neslaganje u *online* grupi izraziti riječima, što može izazvati daljnje reakcije i sukobe. Iako istraživanja nisu jedinstvena u pogledu povećane sklonosti *online* grupa prema *flamingu* (prema Reid i sur., 2005), *online* grupe vjerojatno su nepogodne za diskusije u kojima se, zbog osjetljivosti

teme, mogu očekivati jača neslaganja i povišene emocije (političke teme, etička pitanja i sl.). Potencijalni nedostatak *online* grupa mogao bi biti i činjenica da je u elektroničkoj komunikaciji mnogo teže postići dogovor i slaganje između ispitanika, a diskusija je obično više upućena prema zadatku (instrumentalna je), a manje prema poboljšavanju socioemotivne atmosfere unutar grupe. Naime, istraživanja pokazuju da je za grupni učinak potrebna određena ravnoteža između usmjerenosti na cilj grupnog rada (zadatak) i usmjerenosti na međuljudske odnose unutar grupe, tj. odobravanje, slaganje i sl. (prema Reid, 2005). S druge strane, prevelika upućenost na poboljšavanje međuljudskih odnosa u klasičnim F2F grupama može utjecati na smanjenu koncentraciju na zadatak (diskusiju). Uloga moderatora u obje situacije trebala bi biti uravnoteženje tih dviju komponenti grupne dinamike.

U tekstualnim fokus grupama obično ne sudjeluje veliki broj ispitanika, odnosno preporučeni je broj obično 3-4 sudionika (Lobe, 2008), a temeljni je razlog sporija komunikacija, odnosno dulje čekanje na vlastiti red u pisanju tekstualnih poruka. Može se postaviti i donekle slično pitanje jesu li tekstualne *online* grupe pogodnije za manje ili veće fokus grupe, odnosno trebamo li upotrijebiti ovakav tip fokus grupe ako iz nekoga razloga moramo imati veće fokus grupe (npr. želimo imati što veći uzorak, odnosno prikupiti što više podataka). Kako je navedeno, u većim je grupama teže pratiti sinkronu elektroničku komunikaciju, no pojedinac se u većim fokus grupama osjeća neugodnije, pa bi sudjelovanje u *online* grupama moglo smanjiti navedenu neugodu i trebalo povećati izražavanje mišljenja, odnosno iznošenje vlastitih iskustava i stavova (Reid i sur., 2005).

Audio i audio-vizualne fokus grupe slične su klasičnim fokus grupama, osobito kada je riječ o potonjim. Naime, u audio grupama sudionici komuniciraju u realnom vremenu, pri čemu se čuje samo njihov glas, a u audio-vizualnim grupama prisutan je i audio-vizualni kontakt, odnosno sudionici vide jedni druge. Audio i audio-vizualne fokus grupe tehnički se izvode na isti način, razlika je samo u tome hoće li pri primjeni nekog komunikacijskog softvera biti zabilježen samo zvuk ili i zvuk i slika. Za ovakav tip fokus grupe obično se upotrebljavaju softveri za audio-vizualnu komunikaciju putem interneta (npr. Skype ili Google Hangouts) koji nude mogućnost snimanja komunikacije ili softveri za konferencijsku komunikaciju (npr. Zoom), također s opcijom snimanja. Razlika između ovih dvaju tipova softvera je u tome što prvi obično zahtijevaju da svi sudionici imaju snimljen softver, a drugi omogućuju primjenu softvera i onda kada ga nismo instalirali. Drugim riječima, u prvom slučaju svi sudionici fokus grupe moraju instalirati softver, a voditelj inicira komunikaciju pozivom, odno-

sno otvaranjem razgovora u dogovoreno vrijeme. U konferencijskim softverima voditelj grupe mora imati instaliran softver te ostalim sudionicima može poslati internetski link pomoću kojega mogu pristupiti komunikaciji u dogovoreno vrijeme. Prilikom izbora softvera svakako treba voditi računa o najvećem broju sudionika u komunikaciji koji određeni softver dopušta odnosno omogućuje, a koji mora biti veći od predviđenog broja sudionika fokus grupe. I jedan i drugi tip softvera ubrzano se razvijaju i očekuje se da će u budućnosti ponuditi još bolju funkcionalnost.

Audio i audio-vizualne fokus grupe dijele sve prednosti online fokus grupa, odnosno jednostavnost organizacije i mogućnost regrutiranja širokog kruga sudionika. Iako je u ovom tipu fokus grupa prisutna audio i vizualna komunikacija, sasvim je sigurno da ona nije onoliko ekstenzivna kao u offline fokus grupama. S jedne strane ovo je nedostatak jer osiromašuje interakciju i vjerojatno smanjuje grupni, odnosno sinergijski učinak fokus grupe. S druge strane, vidjeli smo da upravo manji broj vizualnih podataka o drugim osobama, i vlastitih podataka koje vide druge osobe koje sudjeluju u fokus grupi, može potaknuti osobe da budu otvorenije i podijele stvari koje ne bi podijelile u licem-u-lice komunikaciji, pa tako ni u *offline* fokus grupama.

Prilikom organizacije audio i audio-vizualnih fokus grupa najvažniji je zadatak provjera imaju li svi sudionici potrebni softver te je li internetska veza pojedinih sudionika dovoljno dobra za prihvatljivu kvalitetu zvuka i slike. Isto tako, sudionici bi trebali biti u prostoru koji minimalizira vanjske zvukove i u koji ne ulaze druge osobe te bi trebali stišati mikrofon kada ne govore kako mogući zvukovi ne bi ometali druge sudionike. Kada je u pitanju broj sudionika, on može biti nešto veći od broja sudionika u tekstualnim fokus grupama, no svakako bi trebao biti manji od onih u *offline* fokus grupama jer je grupnu komunikaciju na monitoru računala sigurno teže pratiti nego grupnu komunikaciju licem-u-lice. Stoga Lobe (2017: 242) preporučuje od četiri do šest sudionika. Možemo dodati da manje iskusan moderator neće pogriješiti ako iz opreznosti izabere svega tri ili četiri sudionika jer je komunikaciju osim sudionicima teže pratiti i samome moderatoru. Obrada podataka prikupljenih audio ili audio-vizualnim fokus grupama radi se na isti način kao u klasičnim fokus grupama, tj. kao prvi je korak potrebno napraviti transkript prikupljenih podataka. Kako je navedeno, softveri koji se upotrebljavaju za ove tipove online fokus grupa obično imaju funkciju snimanja, a čak i kada to nije slučaj za snimanje je moguće upotrijebiti neki od postojećih *screen recordera*, odnosno softvera koji snimaju sadržaj računalnog zaslona.

## 9.6. DELFI METODA

Delfi metoda predstavlja metodu koja se koristi panelom stručnjaka kako bi se pronašla rješenja ili donijele odluke u nekoj problemskoj situaciji. Metoda se sastoji od nekoliko sukcesivnih krugova. U prvom krugu ispitanicima (stručnjacima) objasni se situacija i od njih se traži određena prognoza (npr. kakva će biti poslovna situacija u zemlji, čiju javnu politiku bi trebalo primijeniti kako bi se riješio neki problem i sl.). Nakon toga moderator pravi sažetak predloženih rješenja i šalje ih ispitanicima, a ispitanici nakon pročitanog sažetka revidiraju svoje prognoze i/ili nude dodatne argumente. Delfi se nastavlja sve dok se ne postigne konsenzus, koji onda predstavlja predloženo rješenje, ili ispitanici više ne mijenjaju mišljenje ili ne nude nove argumente, nakon čega se izračunava prosječna vrijednost prognoze ili se navodi rješenje koje su ispitanici najčešće zastupali. Delfi metoda slična je fokus grupama po tome što uključuje neki oblik interakcije između ispitanika (grupnu dinamiku), no u delfi metodi ta je interakcija posredovana (ispitanici međusobno izravno ne komuniciraju), čime se izbjegavaju moguće negativne posljedice interakcije, poput grupnog mišljenja koje onemogućava alternativne poglede i mišljenja. Može se reći da se delfi metoda zasniva na kompromisu između dvaju pristupa odlučivanju, odnosno kolektivnom donošenju odluka. Prema prvom pristupu, neposredna grupna interakcija dovodi do razmjene argumenata, ispravljanja pogrešnih mišljenja i konsenzusa. Prema drugom pristupu, neposredna interakcija može dovesti do emocionalnog donošenja odluka pod utjecajem pojedinaca koji dominiraju grupom. Stoga je neovisno donošenje odluka, pod uvjetom da su dostupne informacije raznolike i dostupne svim članovima grupe, bolje od neposrednog grupnog odlučivanja. Prema tom pristupu, mase su „mudrije" i od pojedinaca i od društvenih grupa budući da će neovisno donošenje odluka, tj. statistički prosjeci koji se izračunaju u većini slučajeva, biti točniji od rezultata do kojih dođu pojedinci ili grupe putem konsenzusa (Surowiecki, 2004). Delfi metoda spaja elemente oba pristupa jer omogućuje interakciju, ali istovremeno onemogućava i njezine negativne posljedice. Naime, interakcija je anonimna[80] i odvija se preko moderatora, pa ne postoji pritisak konformizma ili tvrdoglavog ostajanja pri vlastitom mišljenju kako bi se očuvalo samopoštovanje. S obzirom na to da u delfi metodi svi ispitanici imaju jednaku mogućnost doprinosa, ne postoji opasnost dominacije od najglasnijih članova grupe, kako je to slučaj u primjeni fokus grupa.

[80] Ispitanici ostaju anonimni čak i nakon završetka delfija.

***Delfi metoda slična je metodi fokus grupa, no u pravilu se upotrebljava za rješavanje problema i donošenje prognoza te stoga uključuje stručnjake za određeno područje.***

Delfi metodom dobiva se izrazito velika dubina podataka jer ispitanici odgovore daju promišljeno i onda kada imaju vremena za njih (bez vremenskog pritiska). Međutim, delfi metoda obično je neefikasna, jer istraživanja (npr. Brüggen, 2009) pokazuju da se ispitanici često ne drže teme i daju veliki broj podataka koji nisu relevantni. S druge strane, zbog mogućnosti obuhvata velikog broja ispitanika, delfi se metoda može smatrati kvantitativno-kvalitativnom metodom. Iako ispitanici mogu davati odgovore kada god to žele, istraživanja (Brüggen, 2009) pokazuju da ih ispitanici smatraju nešto napornijim u usporedbi s *online* fokus grupama, ponajviše zbog toga što se u delfi metodi od ispitanika očekuju nešto duži i razrađeniji odgovori. U *online* fokus grupama odgovori su kraći i sažetiji.

## 9.7. ANALIZA SADRŽAJA

### 9.7.1. Definicija i vrste analize sadržaja

Analiza sadržaja odnosi se na proučavanje sadržaja različitih vrsta komunikacije, pri čemu se najčešće upotrebljava analiza masovnih medija. Sadržaji komunikacije obično se odnose na učestalost pojavljivanja nekih sadržaja, način na koji je određeni sadržaj prikazan (pozitivno, negativno, neutralno), kome je sadržaj (poruka) namijenjen, što se komunikacijom želi postići i sl. S obzirom na to da se analizirani sadržaj obično kvantificira te da se dobiveni podatci obično statistički analiziraju, kao i da su hipoteze obično unaprijed određene, a valjanost i pouzdanost također se mogu egzaktnije odrediti, ta metoda može se uvrstiti i u kvantitativne metode. To je osobito slučaj kada se upotrebljava posve automatska analiza sadržaja pomoću računala s unaprijed pripremljenim rječnicima. Klasična Berelsonova (1952: 18) definicija analize sadržaja kao „istraživačke tehnike za objektivnu, sustavnu i kvantitativnu deskripciju manifestnog sadržaja komunikacije“ upravo se odnosi na kvantitativnu analizu sadržaja, ne samo naglašavanjem njezine metodičnosti nego i time da se kao predmet analize određuuje manifestni sadržaj komunikacije. S druge strane, u analizi sadržaja često je riječ o interpretaciji stavova, vrijednosti, ponašanja i sl., pa ta metoda nosi i obilježje kvalitativnih istraživanja. Kao primjer možemo uzeti Shannonovu (1954, na-

vedeno prema Schreier, 2014: 171-172) analizu novinskog stripa *Little Orphan Annie*. Naime, Shannon je nastojao utvrditi za koje se vrijednosti zalaže strip te je razvio pet glavnih kategorija analize: (1) Tko su prijatelji i neprijatelji glavnog lika, tko je među neprijateljima ozlijeđen ili ubijen, (2) Koje ciljeve glavni lik i njegovi prijatelji odobravaju, (3) Kakve su sugestije o načinu postizanja tih ciljeva, (4) Koje simbole glavni lik i prijatelji pozitivno ocjenjuju i (5) Koje simbole ocjenjuju negativno. Analizom pojavnosti ovih kategorija Shannon je utvrdio da strip naglašava vrijednosti američke srednje klase (težak rad, novac, poštivanje zakona, pristojnost), a da osuđuje lijenost, neprijatelje američke vanjske politike (komuniste, Sovjetski Savez) i političke radikale općenito.

Kada je u pitanju analiza sadržaja koja upotrebljava ljude kao procjenjivače (kodere) koji određeni sadržaj procjenjuju prema ranije utvrđenoj analitičkoj matrici, pitanje subjektivnosti osobito je važno. S obzirom na to da se, unatoč što preciznijoj definiciji kategorija iz analitičke matrice i jasnim uputama procjenjivačima, element subjektivnosti ne može izbjeći, u ovakvoj analizi sadržaja nije moguće postići potpunu objektivnost. Stoga je naglasak na intersubjektivnosti, odnosno na jasnoj proceduri i ponovljivosti istraživanja u sličnim okolnostima u kojima je napravljeno originalno istraživanje. Drugim riječima, osim precizne analitičke matrice, izvještaj o istraživanju trebao bi sadržavati i opis procjenjivača i njihovih obilježja (dob, spol, socijalni status, profesionalni profil i sve ono što može utjecati na procjene kategorija u matrici). Jedino takav postupak omogućava ranije navedenu intersubjektivnost i ponovljivost (Krippendorff, 2004). U tom smislu procjenjivači ne moraju biti slučajno izabrani iz opće populacije, odnosno reprezentirati „običnog čovjeka". Procjenjivače je moguće izabrati upravo na temelju stručnosti, ali u opisu istraživanja treba opisati koje su njihove kvalifikacije i zašto su izabrani za analizu. Sadržajno gledajući, analiza sadržaja može se podijeliti na konceptualnu i relacijsku. Konceptualna analiza sadržaja mjeri pojavljivanje ili nepojavljivanje određenih pojmova. U relacijskoj analizi u pitanju je mjerenje odnosa među pojmovima. Takav se tip analize razvio unutar lingvistike i kognitivne znanosti, pri čemu odnosi među pojmovima mogu biti logička pravila, kauzalni odnosi i sl. Primjer relacijske analize sadržaja bila bi analiza govora nekoga političara kojom se želi utvrditi koliko često taj političar tvrdi da bi povećanje socijalnih prava ljudi smanjilo motivaciju za pronalaženjem posla. U tom se primjeru analizira jednostavna kauzalna shema: veća socijalna prava > manja motivacija.

Iz svega navedenog proizlazi da se analiza sadržaja može kretati od one koja je posve automatizirana i koja se radi pomoću računala (eng. *computer-coded con-*

*tent analysis*) do posve kvalitativne analize koja stremi dubinskom uvidu bez pretjerane kvantifikacije i uključuje izraziti kognitivni angažman istraživača, a obično se odvija bez unaprijed detaljno određene matrice (mjernog instrumenta). U sredini se nalazi analiza sadržaja koja ima unaprijed definiranu matricu i varijable, ali kodiranje prikuplja sam čovjek (eng. *human-coded content analysis*). U nastavku ćemo prikazati osnovne elemente analize sadržaja koji se u najvećoj mjeri odnose na „klasičnu" analizu sadržaja, odnosno kvalitativno-kvantitativnu analizu u kojoj su ljudi procjenjivači, a procjenu vrše na osnovi unaprijed definirane analitičke matrice. Automatska (kvantitativna) analiza sadržaja te specifične kvalitativne analize sadržaja bit će objašnjene u idućim poglavljima.

### 9.7.2. Osnovni elementi analize sadržaja

Kako smo naveli, sve vrste analize sadržaja imaju neke zajedničke elemente koje strukturiraju. Kad je riječ o analizi sadržaja, potrebno je razlikovati sljedeće elemente (prema Tkalac Verčič i sur., 2010: 91-94):

1. Izvor analize,
2. Kategorije analize,
3. Uzorak analize,
4. Jedinica analize.

Većina navedenih elemenata odnosi se na sve vrste analize sadržaja: od onih strogo kvantitativnih koje se u potpunosti rade pomoću računala do onih posve kvalitativnih koje ne rezultiraju kvantifikacijom.

Izvor analize sadržaja odnosi se na komunikacijski medij čiji sadržaj želimo analizirati, npr. novine, televizija i sl. Dakle, u pitanju je medij koji nas zanima i za kojeg pretpostavljamo da će nam pomoći prilikom otkrivanja nekih komunikacijskih obrazaca koji nas teorijski zanimaju.

Kategorije analize odnose se na obilježja komunikacije koja želimo analizirati. Na primjer, ako želimo analizirati koje se vrste umjetnosti spominju i koliko su istaknute u kulturnoj rubrici određenih novina, tada će nam kategorije analize biti književnost, klasična glazba, slikarstvo i sl., odnosno učestalost njihova spominjanja u novinskim člancima. Kategorije analize proizlaze iz nekoga više ili manje apstraktnog koncepta koji se operacionalizira upravo kategorijama analize. U gore spomenutom slučaju potrebno je definirati i operacionalizirati pojmove „umjetnosti" i pojam „istaknutosti". Dok je u prvom slučaju operacionalizacija relativno jednoznačna, u drugom su moguće različite operacionalizacije koje ovise

o odlukama istraživača, odnosno o tome koji ga/ju aspekt apstraktnog koncepta zanima i što smatra važnim. Primjerice, istaknutost pojedine umjetnosti moguće je mjeriti brojem pojavljivanja/članaka, opseg članaka, mjesto na stranici i sl.

Kategorije analize na kraju se kvantificiraju. Postoje četiri osnovna načina kvantifikacije kategorija koji se koriste u analizi sadržaja (Milas, 2005: 512):

1. binarno određivanje – pojavljivanje i nepojavljivanje,
2. učestalost pojavljivanja kategorije,
3. količina prostora posvećena kategoriji,
4. snaga ili intenzitet kojim je kategorija zastupljena.

Binarnim određivanjem utvrđujemo pojavljivanje kategorije – npr. je li u članku iz kulturne rubrike spomenuto kazalište. Učestalost pojavljivanja određujemo brojem pojavljivanja unutar jedinice analize – npr. koliko puta se spominje kazalište u člancima iz kulturne rubrike. Količinu prostora određujemo fizičkom količinom koja je posvećena određenoj kategoriji – npr. broj minuta u televizijskoj emisiji, površina u novinama i sl. Pri mjerenju snage ili intenziteta zastupljenosti kategorije pokušavamo utvrditi intenzitet stava koji je iznesen u komunikaciji. Primjerice, je li pisanje o nekom političaru ili zemlji negativno, neutralno ili pozitivno intonirano i u kojoj mjeri (npr. na ljestvici od 1 do 10). U slučaju mjerenja intenziteta pojave, u igru ulazi kvalitativni aspekt analize sadržaja. Primjerice, u Shannonovoj analizi stripa *Little Orphan Annie* neke se vrijednosti nisu morale tako često pojavljivati, ali su se kada su se pojavile mogle vrlo često naglašavati. Drugim riječima, frekvencija pojavljivanja ponekad treba biti dopunjena intenzitetom pojavljivanja. Ponekad je ovaj odnos moguće prikazati i kvantitativno, tako da se učestalost pojavljivanja množi s intenzitetom pojavljivanja kako bi se dobila ukupna mjera zastupljenosti neke pojave. Tako će, primjerice, neka vrijednost u analizi dobiti veću ukupnu vrijednost zbog visokog intenziteta iako se pojavljuje rjeđe od neke vrijednosti za koju se autor teksta zalaže s manjim intenzitetom.

Budući da često ne možemo analizirati sve izvore sadržaja, biramo uzorak. Pri uzorkovanju primjenjuju se pravila kao i u drugim vrstama istraživanja. Primjerice, u analizi novina možemo izabrati jednostavni slučajni uzorak ili sistematski uzorak (npr. analizirati svaki drugi broj novina). Kao i u drugim situacijama, pri izboru sistematskog uzorka treba paziti da se korak uzorka ne poklapa s nekom važnom pravilnošću (npr. ako nam je korak uzorka 7, tada ćemo izabrati samo novine koje izlaze određenim danom, što će vjerojatno rezultirati pristranim uzorkom). Imajući u vidu cikličke varijacije u sadržaju (dani u tjednu, tjedne ili mjesečne specifičnosti), u analizi sadržaja često se primjenjuju i stratificirani uzorci. Za analizu

medijskog sadržaja osobito je pogodan tzv. *umjetni (konstruirani) tjedan* kao jedna od varijanti stratificiranog uzorka. Uzmimo, primjerice, da želimo analizirati sadržaj nekih novina u šestomjesečnom razdoblju. Jednostavni slučajni uzorak mogao bi nam donijeti neravnomjernu zastupljenost pojedinih dana, a time i manju valjanost. Ako se odlučimo za slučajan izbor jednog tjedna u tom razdoblju, tada dobivamo ravnomjernu zastupljenost pojedinih dana, ali se može dogoditi da je tjedan koji smo izabrali po nečemu specifičan i drukčiji od ostalih tjedana. *Umjetni tjedan* izabrali bi tako da s popisa svih ponedjeljaka u tom razdoblju slučajno izaberemo jedan od njih, s popisa svih utoraka slučajno izaberemo jedan utorak, i tako nastavimo sve dok ne izaberemo predstavnika svakog od dana u tjednu. Ako nam jedan tjedan nije dovoljan, najčešće zbog rijetke zastupljenosti pojave koju istražujemo, tada možemo izabrati dva ili više umjetnih tjedana. Ovdje se postavlja važno pitanje: koliki nam je broj umjetnih tjedana dovoljan za dovoljno dobru analizu, a kako ne bismo potrošili previše vremena i resursa izabirući previše veliki uzorak? Odgovor na to pitanje ovisi o mediju koji proučavamo, duljini razdoblja proučavanja i varijacijama te učestalosti onoga što proučavamo. Primjerice, Riffe i sur. (1993.) utvrdili su da je za proučavanje udjela lokalnih vijesti u nacionalnim novinama u šestomjesečnom razdoblju dovoljno uzeti uzorak od jednog umjetnog tjedna, a Lacy i sur. (2001.) da je za proučavanje vrste priloga u novinama u razdoblju od pet godina dovoljno uzeti devet umjetnih tjedana.

Jedinica analize odnosi se na one elemente sadržaja koje koristimo kako bismo istražili pojavljivanje kategorija analize. Na primjer, u slučaju novina to mogu biti novinski članci, naslovnica i sl.

Kako je navedeno, kategorije analize moraju biti navedene u *analitičkoj matrici* (*kodnom planu*), pri čemu se podatci iz svake jedinice analize (npr. novinskog članka ili televizijske emisije) bilježe u matricu. Kategorije iz analitičke matrice detaljnije se definiraju u *kodnoj knjizi* kao bi se uklonile moguće nejasnoće i dvosmislenosti, odnosno poboljšala valjanost i pouzdanost istraživanja. Kao primjer uzimamo istraživanje čiji je cilj bio utvrditi kako različiti elementi novinskog reklamnog oglasa utječu na uočljivost oglasa i čitateljevo zapamćivanje oglasa (prilagođeno prema Naccaratu, 1990). Iz određenih teorijskih postavki proizlazi da bi važna obilježja reklamnog oglasa kada su u pitanju uočljivost i zapamćivanje mogli biti pozicija unutar publikacije, korištenje vizualnih pomagala, ... Skraćena analitička matrica iz ovoga istraživanja prikazana je u donjoj tablici, a vidljivo je da počinje s općenitim podatcima čiji je cilj identifikacija oglasa i procjenjivača, kako bi se poslije analiza mogla ponoviti, izračunati koeficijente pouzdanosti i sl. Zatim slijede supstantivne kategorije koje proizlaze iz ciljeva istraživanja i postavljenih hipoteza.

*Tablica 33. Primjer analitičke matrice*

| **Općeniti podatci o oglasu** |
|---|
| 1. Procjenjivač (upisati broj procjenjivača)<br>_____<br><br>2. Redni broj oglasa (upisati redni broj napisan na oglasu)<br><br>_____ |
| **Pozicija u publikaciji** |
| 3. Pozicija (zaokružiti jedno)<br>a. prednji dio novina<br>b. stražnji dio novina<br>c. sredina (duplerica) |
| **Vizualna pomagala** |
| 4. Korištenje vizualnih pomagala (zaokružiti jedno)<br>a. da<br>b. ne |
| 5. Vrsta korištenog pomagala (zaokružiti sve što se pojavljuje)<br>a. fotografija<br>b. ilustracija<br>c. grafikon<br>d. tablica<br>e. bez vizualnog pomagala |
| **Korištena tehnika** |
| 6. Tehnika korištena u oglasu (zaokruži sve što se pojavljuje)<br>a. tehničko objašnjenje d. analogija/alegorija<br>b. kompetitivna usporedba e. korištenje eksperta/glasnogovornika<br>c. svjedočenje f. naracija |
| **Pristup** |
| 7. Temeljni pristup ili „ton“ oglasa<br>a. pitanje b. humor c. strah d. altruizam e. samopromocija<br>f. status g. apel na biološke porive h. logički argument i. problem/rješenje |

Izvor: Naccarato, 1990: 137-148.

Kako bi se semantički razjasnile pojedine kategorije, svaku analitičku matricu trebala bi pratiti kodna knjiga. Primjer kodne knjige za prethodnu analitičku matricu prikazujemo u sljedećoj tablici (prilagođeno prema Naccaratu, 1990).

*Tablica 34. Primjer kodne knjige*

| **Općeniti podatci o oglasu** |
|---|
| 1. Procjenjivač – svaki procjenjivač ima unaprijed određeni identifikacijski broj.<br>2. Redni broj oglasa – oglasi su prije analize numerirani. |
| **Pozicija u publikaciji** |
| 3. Pozicija<br>a. prednji dio novina – ako se oglas pojavljuje prije duplerice,<br>b. stražnji dio novina – ako se oglas pojavljuje nakon duplerice,<br>c. sredina (duplerica) – ako se oglas pojavulje na duplerici (središnjem dijelu novina). |
| **Vizualna pomagala** |
| 4. Korištenje vizualnih pomagala<br>Kao vizualna pomagala računaju se grafikoni, tablice, fotografije i svi drugi netipizirani vizualni prikazi. Logotip tvrtke i bilo koji druga vrsta njezine identifikacije ne računaju se kao vizualno pomagalo. |
| 5. Vrsta korištenog pomagala<br>Objašnjeno u prethodnom retku. |
| **Korištena tehnika** |
| 6. Tehnika korištena u oglasu (zaokruži sve što se pojavljuje)<br>a. tehničko objašnjenje – koriste se tehnički podatci koji se odnose na proizvod,<br>b. kompetitivna usporedba – u oglasu se direktno ili indirektno spominje konkurencija ili konkurentski proizvod,<br>c. svjedočenje – korisnik proizovoda/klijent koji govori o proizvodu,<br>d. analogija/alegorija – metaforičko opisivanje subjekta, usporedba s nečim drugim,<br>e. korištenje eksperta/glasnogovornika – korištenje eksperta iz tvrtke, vanjskog eksperta ili javne osobe kako bi se promovirao proizvod. Osoba mora biti prepoznatljiva (ime i prezime ili općepoznata javna osoba), inače se ne računa kao ekspert/glasnogovornik,<br>f. naracija – proizvod se opisuje, ali bez tehničkih detalja. |
| **Pristup** |
| 7. Temeljni pristup ili „ton“ oglasa<br>a. pitanje – postavlja se pitanje na kojeg se najčešće daje odgovor,<br>b. humor – nastoji se nasmijati čitatelja,<br>c. strah – izazivanje straha kako bi se pridobila pozornost,<br>d. altruizam – u oglasu se čitatelju objašnjava kako će kupovinom proizvoda pomoći drugim ljudima,<br>e. samopromocija – tvrdnja o superiornosti („naš proizvod je najbolji“),<br>f. status – čitatelju se objašnjava zašto će mu kupovinom proizvoda narasti ugled,<br>g. apel na biološke porive – uklanjanja boli, gladi, žeđi i sl.,<br>h. logički argument – uvjeravanje pomoću logike, bez poziva na emocije,<br>i. problem/rješenje – identificira se problem i čitatelju se pokazuje kako će ga riješiti kupovinom proizvoda. |

Izvor: Naccarato, 1990: 123-131.

Mogući se različiti pristupi specifikaciji analitičke matrice, odnosno davanju upute procjenjivačima kako da kodiraju komunikacijski materijal. Krippendorff (2004: 132-140) navodi (1) verbalne opise, (2) ekstenzijske liste, (3) sheme odlučivanja, (4) skale, (5) simulacija testiranja hipoteza i (6) simulacija intervjua. Verbalni opisi u pravilu se odnose na vrijednosti pojedinih varijabli. Primjerice, za varijablu spol navodimo dvije vrijednosti – žene i muškarci. Verbalni se opis može svesti na binarno određivanje neke pojave, odnosno pretpostavlja se da procjenjivači znaju što znače pojedine vrijednosti i da ih stoga nije potrebno detaljnije opisivati/objašnjavati. U ekstenzijskim listama u pravilu je riječ o snazi ili intenzitetu zastupljenosti neke kategorije (varijable), ali su njezine vrijednosti detaljno opisane. Primjerice, ako bismo htjeli utvrditi ima li autor nekoga novinskog članka pozitivan ili negativan stav prema nekoj pojavi, možemo konstruirati ljestvicu od pet stupnjeva i dati stupnjevima ljestvice verbalne opise. Primjerice:

1 – navodi isključivo negativne stvari o pojavi,

2 – navodi uglavnom negativne stvari o pojavi, navodi i pozitivne stvari, ali samo kao izuzetak,

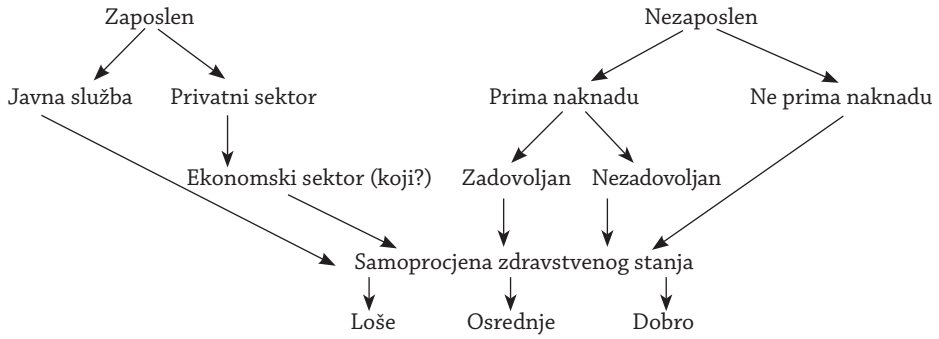
3 – u sličnoj mjeri navodi pozitivne i negativne stvari o pojavi,

4 – navodi uglavnom pozitivne stvari o pojavi, navodi i negativne stvari, ali samo kao izuzetak,

5 – navodi isključivo pozitivne stvari o pojavi.

Sheme odlučivanja odnose se na shematski (grafički) prikaz kategorija, odnosno analitičke matrice. Kako navodi Krippendorff, ovakav prikaz procjenjivačima omogućuje lakše kodiranje, a također onemogućava da se dogode pogreške prilikom kodiranja, odnosno da procjenjivač kodira i materijal koji ne treba kodirati. Primjerice, pretpostavimo da je riječ o analizi sadržaja intervjua u kojem su sudjelovale nezaposlene i zaposlene osobe. U tom slučaju zaposlene osobe može se procjenjivati na osnovi kategorija koje postoje samo za njih, a ne i za nezaposlene osobe, i obrnuto. Primjer jednostavne sheme odlučivanja od nekoliko kategorija navodimo u nastavku.

*Slika 2. Shema odlučivanja u analizi sadržaja*




Dakle, ovakva shema djeluje kao pomoć prilikom popunjavanja analitičke matrice, odnosno procjenjivač slijedi niz koraka prilikom popunjavanja koji omogućuju lakše snalaženje prilikom grananja koja postoje u određenim kategorijama.

***Analiza sadržaja provodi se pomoću standardizirane matrice u kojoj su navedene kategorije koje se analiziraju u komunikacijskom sadržaju koji se proučava.***

Prilikom analize sadržaja u analitičkoj je matrici moguće primijeniti i druge skale koje su inače upotrebljavaju u anketnim upitnicima. Osnovna je razlika da se za razliku od postavljanja pitanja ispitaniku u upitniku pitanja postavljaju samome sadržaju. Primjerice, umjesto skale semantičkog diferencijala u kojemu se od ispitanika traži da se izjasni sâm procjenjivač procjenjuje smatra li autor određenog teksta ili drugog komunikacijskog materijala da je neka pojava dobra ili loša, jaka ili slaba, aktivna ili pasivna.

Simulacija testiranja hipoteza odnosi se na situaciju kada analitičar želi vidjeti potvrđuje li se ili negira neka unaprijed postavljena hipoteza u nekome tekstu. Valja napomenuti da ta hipoteza nije hipoteza samoga analitičara, odnosno ne predstavlja stanje stvari koje on ili ona smatraju točnim. Primjerice, analitičar želi provjeriti smatraju li novinari da su imigranti odgovorni za porast kriminala u zemlji. Ovu se hipotezu može provjeravati tako da se svaki tekst ocjenjuje na nekoj ljestvici (npr. od 1 do 5) po tome u kojoj mjeri smatra da je to točno, odnosno tvrdi li pisac toga teksta da je takva hipoteza točna (da imigranti doista povećavaju stope kriminala). Dakle, ovakva vrsta analize ide iznad obične kvantifikacije sadržaja i od procjenjivača zahtijeva dublju prosudbu o tome što se u nekom tekstu tvrdi ili ne tvrdi.

Simulacija intervjua slično je heurističko sredstvo kao i simulacija testiranja hipoteza, no u ovom slučaju procjenjivač pokušava utvrditi što bi autor odgovorio na određena pitanja kada bi ga procjenjivač bio u mogućnosti intervjuirati. Simulacija intervjua pretpostavlja da procjenjivač može interpretirati manifestne, ali i latentne ideje prisutne u određenom tekstu, odnosno da se može uživiti u poziciju autora teksta. Jasno je da ovakav pristup analizi sadržaja donosi određenu dubinu, ali i da se njime gubi na objektivnosti same analize. Drukčije rečeno, primjena simulacije intervjua, kao i simulacije testiranja hipoteza, graniči s analizom diskursa.

### 9.7.3. Mjerna obilježja analize sadržaja

Kvalitetna analiza sadržaja trebala bi imati sljedeća obilježja (prerađeno na temelju Milas, 2005: 501-502):

1. pouzdanost (objektivnost),
2. valjanost,
3. sustavnost,
4. općenitost.

Da bi rezultati analize sadržaja bili pouzdani, analizu mora provoditi više istraživača, nakon čega je potrebno izračunati u kojoj se mjeri istraživači slažu u procjenama. Kada su u pitanju koeficijenti pouzdanosti, odnosno slaganja procjenjivača, u analizi sadržaja primjenjuju se koeficijenti koji mjere slaganje bilo kakvih procjenjivača, odnosno analiza sadržaja u tom smislu nije na bilo koji način specifična u odnosu na, primjerice, mjerenje slažu li se dva nastavnika oko ocjena koje treba dati učenicima. Kao i pri bilo kojoj procjeni slaganja, koeficijent koji će se upotrijebiti prije svega ovisi o razini mjerenja varijable čija se pouzdanost utvrđuje (nominalna, ordinalna, intervalna, omjerna), iako i nakon utvrđivanja ove razine istraživaču često na raspolaganju stoji nekoliko mogućnosti, odnosno moguće je birati između različitih koeficijenata koji imaju različitu matematičku pozadinu. Kada su u pitanju nominalne varijable, najčešće se upotrebljava postotak slaganja (iako ga, kako ćemo vidjeti, valja izbjegavati), Cohenov kappa koeficijent te Krippendorffov alfa koeficijent (odnosno njegova varijanta za nominalne varijable). Za ordinalne varijable postoje posebne verzije Cohenova kappa koeficijenta i Krippendorffova alfa koeficijenta, a za intervalne varijable, osim intervalne varijante Krippendorffova alfa koeficijenta, najčešće se upotrebljava tzv. koeficijent unutarklasne korelacije (ICC – *intraclass correlation coefficient*).

***Ako analiza sadržaja nije posve automatizirana, tj. ako je provodi čovjek kao procjenjivač/mjerni instrument, tada je poželjno da analizu provodi više procjenjivača te da se izračunaju odgovarajući koeficijenti pouzdanosti (slaganja procjenjivača).***

Postotak slaganja, kako sâmo ime kaže, označava udio slaganja prilikom procjene u ukupnom broju procjena. Primjerice, uzmimo da smo analizirali izvještava li se o nekoj političkoj stranci pozitivno, negativno ili neutralno u medijima i da smo rezultate dvaju procjenjivača prikazali u sljedećoj tablici.

*Tablica 35. Primjer slaganja procjenjivača prilikom analize sadržaja*

| | **Pozitivno** | **Neutralno** | **Negativno** | **Ukupno** |
|---|---|---|---|---|
| Pozitivno | 51 | 24 | 19 | 94 |
| Neutralno | 16 | 43 | 12 | 71 |
| Negativno | 24 | 17 | 49 | 90 |
| Ukupno | 91 | 84 | 80 | 255 |

U ovome bi slučaju ukupni broj slaganja bio 51 + 43 + 49 = 143. Budući da je ukupan broj procjena jednak 255, slaganje bi iznosilo oko 56%.

Nedostatak postotka slaganja kao mjere objektivnosti je da se određeno slaganje može očekivati sasvim slučajno, tj. pojavljivalo bi se čak i kada bi procjenjivači svoje procjene donosili potpuno nasumično. Upravo zbog toga se koristi Cohenov kappa koeficijent, koji uvažava činjenicu slučajnog slaganja. Formula za Cohenov kappa koeficijent glasi:

$$K = \frac{P(o)-P(e)}{1-P(e)} \qquad (3.1.)$$

Pri tome je P(o) empirijska vjerojatnost slaganja između procjenjivača, a P(e) slaganje koje se može očekivati na osnovi slučajnosti. U gore navedenom primjeru već je izračunato da je slaganje 0,56. Vjerojatnost da će i jedan i drugi procjenjivač slučajno dati pozitivnu ocjenu je 94/255*91/255 = 0,37*0,36 = 0,13. Analogno tome, može se izračunati da vjerojatnost da će i jedan i drugi procjenjivač slučajno dati neutralnu ocjenu jednaka 0,09, a vjerojatnost da će oba dati negativnu ocjenu jednaka 0,11. To znači da vjerojatnost slučajnog slaganja iznosi 0,33 (0,13 + 0,09 + 0,11). U skladu s tim izračunom, kappa će iznositi:

$$\kappa = \frac{0{,}56 - 0{,}33}{0{,}67}$$

$$\kappa = 0{,}34$$

Ova formula se, uz malo algebarske manipulacije, može jednostavno izraziti i kao:

$$\kappa = 1 - \frac{1-P(o)}{1-P(e)} \tag{3.2.}$$

Kako ćemo poslije vidjeti, ovaj se oblik formule upotrebljava pri izračunu vaganog Cohenova kappa koeficijenta, a vidljivo je da se u formuli od jedinice oduzima omjer dobivene vjerojatnosti neslaganja i očekivane vjerojatnosti neslaganja. S obzirom na to da je u drugom dijelu formule riječ o omjeru dviju vjerojatnosti, ovaj će omjer ostati isti ako umjesto vjerojatnosti upotrijebimo frekvencije neslaganja. Drugim riječima, imamo vjerojatnost neslaganja koja iznosi $\frac{N_o}{N_u}$, pri čemu brojnik znači frekvenciju neslaganja, a nazivnik ukupan broj slučajeva. Vjerojatnost očekivanog neslaganja iznosi $\frac{N_e}{N_u}$, pri čemu brojnik označava očekivanu frekvenciju neslaganja, a nazivnik već navedeni ukupan broj slučajeva. Vidljivo je da ćemo dijeljenjem ovih dviju vjerojatnosti dobiti $\frac{N_o}{N_e}$, odnosno da je omjer vjerojatnosti neslaganja i očekivane vjerojatnosti neslaganja jednak omjeru frekvencije neslaganja i očekivane frekvencije neslaganja.

Iz formule za izračun Cohenova kappa koeficijenta vidi se da on može imati negativne vrijednosti, a to se događa kada je slaganje između procjenjivača čak i manje od onoga što bi se moglo očekivati na temelju slučajnosti. Uz razumnu pretpostavku da postoji nezavisnost procjenjivača, odnosno da jedan i drugi nisu znali za procjene onoga drugoga i da nisu svoje procjene namjerno učinili drukčijima, negativni je koeficijent rezultat slučajnosti. Iako se rijetko pojavljuje u praksi, negativni rezultat može značiti i da procjenivači imaju posve suprotna shvaćanja neke kategorije iz analitičke matrice. Stoga njegov iznos nema supstancijalno značenje i u interpretaciji je dovoljno navesti da nije postojalo slaganje između procjenjivača, tj. da je pouzdanost istraživanja niska/nepostojeća.

Prihvatljivom se veličinom Cohenova kappa koeficijenta smatraju iznosi veći od 0,70 (za skale do tri stupnja), tj. iznad 0,60 (za skale od četiri i više stupnjeva). Budući da je u ovome slučaju kappa znatno manji od 0,70, provedena analiza sadržaja vrlo je nepouzdana. U ovom bi se slučaju analiza trebala provesti ponovno, pri čemu bi ponovno trebalo provesti edukaciju procjenjivača ili jasnije definirati kategorije analize.

S obzirom na navedena ograničenja Cohenova kapa koeficijenta, u slučaju potrebe izračuna slaganja više od dvaju ocjenjivača, odnosno upotrebe intervalnih ili omjernih varijabli, upotrebljavaju se i drugi koeficijenti, najčešće tzv. Krippendorffov alfa i koeficijent unutarklasne korelacije (ICC).

Krippendorff (2004, prvo izdanje 1980) predložio je alfa koeficijent, nazvan po njemu, pri čemu postoje različiti koeficijenti za različite razine mjerenja varijabli. Opća formula za izračun alfa koeficijenta glasi:

$$\alpha = 1 - \frac{D_o}{D_e} \quad (3.3.)$$

pri čemu je $D_o$ izmjereno neslaganje, a $D_e$ neslaganje koje se moglo očekivati na temelju slučajnosti. Minimalnom prihvatljivom vrijednošću ovoga koeficijenta Krippendorff smatra 0,67, a vrijednosti između 0,67 i 0,80 smatra uvjetno prihvatljivima. Iznos koeficijenta iznad 0,80 donosi pouzdanu analizu sadržaja (Krippendorff, 2004: 241-242).

Kao ilustraciju logike izračuna ovoga koeficijenta prikazat ćemo najjednostavniji slučaj, onaj s binarnom varijablom i dva procjenjivača. Uzmimo da dva procjenjivača procjenjuju pet novinskih članaka te trebaju procijeniti piše li se o nekome u njima povoljno (taj slučaj označe s 1) ili nepovoljno (oznaka 0). Pretpostavimo da su navedene članke procjenjivači ocijenili na sljedeći način.

*Tablica 36. Matrica frekvencija ocjena procjenjivača*

| | **Članak 1** | **Članak 2** | **Članak 3** | **Članak 4** | **Članak 5** |
|---|---|---|---|---|---|
| Procjenjivač A | 1 | 1 | 1 | 0 | 0 |
| Procjenjivač B | 1 | 0 | 1 | 0 | 1 |

Ovi se podatci zatim prikažu u tzv. matrici koincidencije, a ova je matrica ponešto različita od kontingencijske tablice koja se upotrebljava u Cohenovu kappa koeficijenta. Naime, kontingencijska tablica prikazuje broj analiziranih slučajeva, a koincidencijska tablica prikazuje broj procjena. Primjerice, kućica u koincidencijskoj tablici za prethodne podatke koja odgovara slučaju (0,0) ima frekvenciju 2 jer uključuje dvije procjene, a u kontingencijskoj tablici imala bi frekvenciju 1 jer uključuje jedan par procjena.

*Tablica 37. Empirijska koincidencijska matrica*

| | 0 | 1 | Ukupno |
|---|---|---|---|
| 0 | 2 | 2 | 4 |
| 1 | 2 | 4 | 6 |
| Ukupno | 4 | 6 | 10 |

Na temelju ove matrice izračuna se matrica očekivanih koincidencija, a njezina logika uključuje primjenu množenja uvjetnih vjerojatnosti. Polazimo od toga da u ukupno 10 procjena imamo 6 jedinica i 4 nule, odnosno pretpostavimo da je to dobra procjena povoljnih i nepovoljnih procjena o nekoj osobi u svim člancima no-

vina koje analiziramo. Krippendorffov alfa također pretpostavlja da je vjerojatnost da će osoba donijeti neku procjenu sukladna udjelu tih obilježja u populaciji. Stoga vjerojatnost da će prvi procjenjivač slučajno izabrati povoljnu procjenu iznosi 60% (6 jedinica od ukupno 10 procjena), a vjerojatnost da će drugi procjenjivač izabrati također jedinicu iznosi 55% (pet preostalih jedinica od ukupno 9 preostalih procjena). Umnoškom ovih vjerojatnosti dođe se do očekivane vjerojatnosti da će se dogoditi slučaj (1,1), a očekivani broj takvih slučajeva dobije se umnoškom ovoga broja s ukupnim brojem procjena. Dakle, $e_{11}$ = 0,6*0,55*10 = 3,33. Ostale se vjerojatnosti i očekivane frekvencije dobiju analognim izračunima uz primjenu uvjetnih vjerojatnosti, a matrica očekivanih koincidencija za ovaj slučaj prikazana je u sljedećoj tablici.

*Tablica 38. Matrica očekivanih koncidencija*

| | 0 | 1 | Ukupno |
|---|---|---|---|
| 0 | 1,33 | 2,67 | 4 |
| 1 | 2,67 | 3,33 | 6 |
| Ukupno | 4 | 6 | 10 |

I na kraju, primjenom formule dođemo do izračuna ovoga koeficijenta pouzdanosti:

$$\alpha = 1 - \frac{D_o}{D_e} = 1 - \frac{2+2}{2{,}67+2{,}67} = 1 - \frac{4}{5{,}34} = 0{,}25$$

Cohenov kappa koeficijent za ordinalne varijable i Krippendorffov alfa koeficijent za ordinalne, intervalne i omjerne varijable računaju se pomoću matrice pondera s kojom se množe vjerojatnosti u odgovarajućim matricama. Primjerice, udaljenost od jednog stupnja na ordinalnoj ljestvici može se množiti s 1, udaljenost od dva stupnja s 2 itd. Drugim riječima, očekivane vjerojatnosti ili frekvencije množe se s određenim ponderima koji će dati veću vrijednost neslaganjima što je udaljenost među stupnjevima na ljestvici veća. Krenimo od pretpostavke da smo imali ljestvicu „dobro, srednje, loše" koju su primjenjivala dva procjenjivača. Sasvim je sigurno da je neslaganje između dvaju procjenjivača veće ako je jedan nešto ocijenio kao dobro, a drugi kao loše, nego ako je prvi pojavu ocijenio kao dobru, a drugi kao osrednju. U prvom ih slučaju dijele dva stupnja ljestvice, a u drugom samo jedan. Koeficijenti pomoću pondera upravo uzimaju u obzir ovu činjenicu.

Prikažimo na jednom primjeru izračun Cohenova kappa koeficijenta za ordinalne varijable. Uzmimo da su dva procjenjivača procjenjivali neko obilježje na ljestvici sa stupnjevima „dobro", „osrednje" i „loše". Frekvencije njihova slaganja i neslaganja prikazane su u kontingencijskoj tablici koja slijedi, pri čemu stupci označavaju jednog, a retci drugog procjenjivača.

*Tablica 39. Izračun vaganog Cohenova koeficijenta – empirijske frekvencije.*

| | **Dobro** | **Osrednje** | **Loše** | **Ukupno** |
|---|---|---|---|---|
| **Dobro** | 5 | 4 | 3 | 12 |
| **Osrednje** | 1 | 5 | 1 | 7 |
| **Loše** | 2 | 3 | 8 | 13 |
| **Ukupno** | 8 | 12 | 12 | 32 |

Na temelju podataka iz tablice prikazujemo i očekivane frekvencije na temelju slučajnog slučajnosti i prikazujemo ih u sljedećoj tablici.

*Tablica 40. Izračun vaganog Cohenova koeficijenta – očekivane frekvencije*

| | **Dobro** | **Osrednje** | **Loše** | **Ukupno** |
|---|---|---|---|---|
| **Dobro** | 3 | 4,5 | 4,5 | 12 |
| **Osrednje** | 1,75 | 2,62 | 2,62 | 7 |
| **Loše** | 3,25 | 4,88 | 4,88 | 13 |
| **Ukupno** | 8 | 12 | 12 | 32 |

S obzirom na to da trebamo ponderirati frekvencije neslaganja i očekivane frekvencije neslaganja, tablicu pondera dobivamo tako da slaganjima damo ponder nula, parovima neslaganja koje dijeli jedan rezultat na ljestvici (npr. dobro i osrednje) dajemo ponder 1, a onima koje dijele dva stupnja (dobro i loše) dajemo ponder 2. Za izračun vaganog Cohenova kappa koeficijenta upotrebljavamo ranije navedenu formulu 3.2.:

$$\kappa = 1 - \frac{1 - P(o)}{1 - P\,(e)}$$

odnosno njoj ekvivalentnu formulu:

$$\kappa = 1 - \frac{N_o}{N_e} \tag{3.4.}$$

pri čemu frekvencije pomnožimo s odgovarajućim ponderima (w). U našem slučaju izračun bi glasio:

$$\kappa_w = 1 - \frac{\sum w_{ij}\, N_{o.ij}}{\sum w_{ij}\, N_{e.ij}} =$$

$$1 - \frac{0*5 + 1*4 + 2*3 + 1*1 + 0*5 + 1*1 + 2*2 + 3*1 + 0*8}{0*3 + 1*4{,}5 + 2*4{,}5 + 1*1{,}75 + 0*2{,}62 + 1*2{,}62 + 2*3{,}25 + 1*4{,}88 + 0*4{,}88}$$

$$= 1 - \frac{0 + 4 + 6 + 1 + 0 + 1 + 4 + 3 + 0}{0 + 4{,}5 + 9 + 1{,}75 + 0 + 2{,}62 + 6{,}50 + 4{,}88 + 0} = 1 - \frac{19}{29{,}25} = 0{,}35$$

Postavlja se logično pitanje može li se Pearsonov koeficijent korelacije (r) upotrijebiti za izračun slaganja procjenjivača kada su u pitanju intervalne varijable? Odgovor glasi da načelno može, no ovaj koeficijent ne mjeri apsolutno slaganje nego koherentnost procjena procjenjivača, pa stoga nije ono što želimo kada mjerimo pouzdanost analize sadržaja. Primjerice, ako bi jedan procjenjivač tri analitičke jedinice procijenio s ocjenama 1, 2 i 3, a drugi procjenjivač s 5, 6, i 7, tada bi Pearsonova korelacija bila maksimalno pozitivna (iznosila bi +1), no vidljivo je da apsolutno slaganje procjenjivača ne postoji. Drugim riječima, prvi i drugi procjenjivač slažu se da mjereno svojstvo u najmanjoj mjeri postoji u prvoj jedinici te da zatim slijede druga i treća jedinica, no navedeno svojstvo (varijablu) mjere drukčijim metrom jer dugi procjenjivač sustavno daje veće ocjene od prvoga. Stoga umjesto ovoga koeficijenta upotrebljavamo koeficijent unutarklasne korelacije (ICC).

Ovaj se koeficijent zasniva na analizi varijance, ali ovdje nećemo prikazivati tehničke detalje njegova izračuna jer bi zauzeli previše prostora, a ovaj se koeficijent lako dobiva pomoću statističkih softvera. Dovoljno je reći da ICC mjeri udio varijance među rezultatima koja otpada na razliku među analiziranim jedinicama u ukupnoj varijanci, odnosno mjeri onaj dio varijance koji ne proizlazi iz razlike među procjenjivačima. Primjerice, uzmimo da imamo tri učenika i tri nastavnika, pri čemu je prvom učeniku svaki od nastavnika dao ocjenu 1, drugome ocjenu 2, a trećemu ocjenu 3. Sukladno tome, sva varijanca, odnosno sve razlike u rezultatima proizlaze iz toga da su učenici različiti, odnosno imaju različitu količinu znanja, odnosno razlike u rezultatima nisu plod razlika među nastavnicima. U ovom bi slučaju ICC iznosio 1. Međutim, prilikom upotrebe ICC-a moguće je izabrati različite modele, i to ga razlikuje od Krippendorffova alfa koeficijenta. Prvo, s obzirom na to da imamo procjenjivače i jedinice koje analiziramo (dvije varijable), moguće je birati između jednostranog (*one-way*) i dvostranog (*two-way*) modela. Jednostrani model upotrebljava se kada za svaku jedinicu koju analiziramo imamo različite procjenjivače. Primjer ovakve situacije bi bio kada bi istog učenika ocjenjivala tri nastavnika, sljedećeg učenika druga tri nastavnika itd. Ovo je također u praksi vrlo rijetko jer pri analizi saržaja u pravilu sve jedinice analiziraju isti procjenjivači, a tada je riječ o dvostranom modelu jer nam variraju i jedinice koje analiziramo (npr. novinski članci u analizi sadržaja) i procjenjivači, tj. i jedni i drugi dio su veće populacije. Isto tako, može nas zanimati slaganje između procjenjivača koji rade analizu, pri čemu nas zanimaju baš oni i ne želimo generalizirati na druge procjenjivače. Drugim riječima, procjenjivači su fiksni i ne predstavljaju uzorak, a ovaj se model zove fiksni model. Ako su naši procjenjivači dio veće populacije procjenjivača, tada je riječ o slučajnom modelu (eng. *random*

*model*). Kada su nam jedinice koje analiziramo dio veće populacije, jedinice analize su slučajne, a procjenjivači su fiksni, u pitanju je tzv. dvosmjerni mješoviti model (eng. *two-way mixed model*). Mnogo je češći slučaj kada su naši procjenjivači samo uzorak iz skupine svih mogućih procjenjivača (tzv. slučajni model, eng. *random model*). Tada je riječ o dvostranom slučajnom modelu jer imamo jedinice i procjenjivače, a oba su dio veće populacije na koju želimo generalizirati (eng. *two-way random model*).

Kada su u pitanju računalni izračuni Cohenova kappa koeficijenta i Krippendorffova alfa koeficijenta, valja napomenuti da su oni dostupni u nekim softverima za statističku obradu podataka, a u nekima nisu. Kada je u pitanju SPSS, najčešće upotrebljavani softverski paket za statističku analizu u društvenim znanostima, Cohenov kappa koeficijent može se izračunati pomoću postojećih menija, a vagani Cohenov kappa za ordinalne varijable nije moguće izračunati u SPSS-u. S druge strane, Krippendorffov alfa nije dostupan u standardnim menijima, ali ga je moguće izračunati pomoću makro naredbe zvane kalpha, odnosno programa koji se može besplatno skinuti sa stranice njezina suautora Andrewa Hayesa i koji se nakon toga upotrijebi pomoću SPSS sintakse (Hayes i Krippendorff, 2007). Softverski paketi osim izračuna iznosa koeficijenata obično izračunavaju i njegove granice pouzdanosti. Na internetu se trenutačno mogu pronaći i drugi online alati za izračun ovih koeficijenata. S druge strane, ICC dostupan je za izračun u menijima u SPSS-u.

Što učiniti ako napravimo analizu sadržaja, izračunamo pouzdanost i utvrdimo da je ona ispod granica prihvatljivosti? Dvije su mogućnosti. Najčešća je ona da ponovno napišemo instrukcije za procjenjivače, odnosno kodnu knjigu, odnosno napravimo intenzivniji trening procjenjivača, te ponovno napravimo analizu s novim procjenjivačima. Druga je mogućnost da ponovno operacionaliziramo naše teorijske koncepte te operacionalizaciju učinimo konkretnijom, odnosno egzaktnijom, čak i onda kada to djelomično narušava teorijske ambicije naše analize. Primjerice, umjesto subjektivne procjene je li autor nekog članka pristran prema nekim političkim strankama ili političarima, možemo od procjenjivača zatražiti da izbroji broj spominjanja tih stranaka i političara (ili to može napraviti računalo). Na taj način povećavamo pouzdanost, no ugrožavamo valjanost analize jer ne možemo biti sigurni da je broj spominjanja posve valjana mjera pristranosti. Krippendorff (2004: 218-219) s pravom upozorava da druge opcije kojima se naizgled povećava valjanost nisu opravdane. Primjerice, upitno je hoćemo li povećati pouzdanost tako da od procjenjivača zatražimo da rasprave oko čega se nisu složili te da ponovno naprave kodiranje. Kako Krippendor-

ff ističe, ovakvo slaganje dobrim je dijelom lažno i do njega može doći tako da agresivniji procjenjivači ili procjenjivači višeg socijalnog statusa nametnu svoju definiciju kategorija analize sadržaja, a samim time analiza postaje nepouzdana jer je ne mogu ponoviti drugi procjenjivači, odnosno postaje nejasno koje su upute i definicije slijedili procjenjivači. Drugim riječima, nedokazana je postavka da će grupa bolje protumačiti upute, pa je najbolji postupak jasnija definicija kategorija u kodnoj knjizi i ponovna analiza s drugim procjenjivačima sve dok ne dobijemo upute prema kojima će različite osobe u različitim okolnostima doći do vrlo sličnih rezultata, a što je i sama definicija pouzdanosti istraživanja. Potreba da procjenjivači rasprave i dođu do konsenzusa oko kategorija poražavajuća je za analizu sadržaja i unosi nemogućnost njezine ponovljivosti.

Kao i u slučaju primjene drugih metoda, valjana analiza sadržaja je ona analiza kojom se mjeri ono što se željelo mjeriti. Odnos pouzdanosti i valjanosti analize sadržaja isti je kao i u bilo kojem drugom mjerenju – pouzdanost je preduvjet valjanosti, ali nije njezino jamstvo. Drukčije rečeno, moguće su vrlo pouzdane analize koje nisu valjane. Primjerice, dva procjenjivača mogu se složiti da u televizijskim reklamama postoji seksizam (rodni stereotipi), odnosno takva analiza može biti vrlo pouzdana. Međutim, osim što možda oba procjenjivača imaju vrlo specifična shvaćanja što su rodni stereotipi koja ljudi drukčijih stavova i svjetonazora ne moraju dijeliti, odnosno njihova operacionalizacija pojma „rodni stereotip" odražava njihove vrijednosti i stavove, sami procjenjivači mogi biti sustavno pristrani u mjerenju neke pojave. Primjerice, dva muškarca mogu se u velikoj mjeri slagati oko izgleda likova u reklamama i mogu žene procjenjivati zgodnijim od muškaraca, no to je moža posljedica njihove opće sklonosti da žene smatraju zgodnijim od muškaraca. Iako je u ovom konkretnom primjeru moguća pristranost jasno utvrdiva i može se provjeriti angažiranjem i žena kao procjenjivača te izračunom nove, ukupne pouzdanosti, to ne mora biti tako jasno u svim situacijama, odnosno izvori pristranosti mogu ostati skriveni. U tom smislu čak i angažman većeg broja procjenjivača ne može izbrisati mogućnost da svi oni imaju iste, možda i pristrane, poglede na neku pojavu. Slično tome, načelno govoreći, višestruko mjerenje jednog procjenjivača iste pojave, odnosno test-retest metoda, također bi se mogla upotrebljavati za izračun pouzdanosti analize sadržaja, no to s razlogom u pravilu nije slučaj. Naime, test-retest metoda ne uklanja sustavnu pogrešku, tj. pristranost procjenjivača, odnosno ne uzima kao mogućnost da se različiti procjenjivači razlikuju u svojim procjenama. Nadalje, procjenjivač može zapamtiti svoju procjenu te je ponovno primijeniti u ponovnoj analizi, tj. dvije procjene u različitim vremenskim razdobljima ne moraju biti međusobno neovisne.

Vrste valjanosti sadržaja, uz neke specifičnosti, slične su općenitim vrstama valjanosti koje vrijede za druge mjerne instrumente. Krippendorff (1980) razlikuje semantičku valjanost, valjanost uzorkovanja, pragmatičku valjanost i konstruktnu valjanost.

*Semantička se valjanost* odnosi na ispravno shvaćanje kategorija analize, odnosno na ispravno klasificiranje podataka koji se analiziraju. Drukčije rečeno, pravilno shvaćen opseg nekog pojma mora odgovarati skupu podataka koji su u istraživanju klasificirani kao instance toga pojma. Krippendorff predlaže da se kao strategija poboljšanja semantičke valjanosti analize koristi navođenje svih mogućih kontraprimjera, odnosno načina klasifikacije za koje znamo da su pogrešni. Ako, primjerice, želimo izbrojati koliko puta se u nekom članku pojavljuje pojam „kultura", shvaćen kao ljudska duhovna djelatnost, tada ćemo kao kontraprimjer navesti pojam „poljoprivredna kultura", na taj način dajući uputu procjenjivačima da ovakav podatak ne ulazi u opseg pojma kultura, tj. da je riječ o pogrešnoj klasifikaciji. Želimo li analizom sadržaja izmjeriti količinu nasilja u televizijskim emisijama, a pod nasiljem podrazumijevamo isključivo tjelesno nasilje, tada ćemo vikanje i sve druge primjere verbalnog nasilja navesti kao kontraprimjere.

*Valjanost uzorkovanja* u analizi sadržaja može se shvatiti na dva načina (Krippendorff, 1980: 90-91). Prema prvome, valjanost uzorkovanja definira se na isti način kao i u drugim vrstama istraživanja. I ovdje je, naime, riječ o reprezentativnosti uzorka, tj. o sigurnosti da podatci prikupljeni uzorkom predstavljaju nepristrani izbor iz univerzuma svih mogućih uzoraka. Drukčije rečeno, riječ je o mogućnosti nepristrane statističke generalizacije s uzorka podataka na univerzum svih podataka. Drugi pristup valjanosti uzorkovanja polazi od činjenice samoselekcije, odnosno nadzastupljenosti ili podzastupljenosti nekih koncepata u podatcima. Naime, komunikacijska zbilja koja se mjeri analizom sadržaja često predstavlja pristran prikaz same realnosti jer su komunikacijski mediji otvoreniji za određene segmente populacije ili za određena mišljenja. Stoga Krippendorff preporučuje da se prilikom uzorkovanja nadzastupljenošću određenih podataka ispravlja ta vrsta nepodudarnosti između zbilje i njezine medijske reprezentacije. Primjerice, istražujemo li mišljenje svih političara o nekoj temi preko analize njihovih medijskih nastupa, trebamo voditi računa o tome da će nekim političarima pristup u neke medije biti otvoreniji, a nekima manje otvoren. Stoga bi, u svrhu nepristrane statističke generalizacije, trebalo uzeti više jedinica analize u kojima se izražava mišljenje podzastupljenih političara.

*Pragmatička valjanost* odnosi se na korelaciju rezultata analize sadržaja s drugim fenomenima ili mogućnost predikcije događaja na osnovi provedene analize

sadržaja. Uzmimo, primjerice, da analiziramo na koji se način o nekoj državi A piše u medijima neke druge države B. Ako na osnovi provedene analize sadržaja možemo precizno predvidjeti promjene vanjske politike države B prema državi A, tada naša analiza ima visoku pragmatičku (prediktivnu) valjanost.

*Konstruktna se valjanost* odnosi na stupanj u kojemu je analiza povezana s nekom dobro provjerenom teorijom. Uzmimo, na primjer, da imamo teoriju prema kojoj medijske najave važnih zakonskih promjena ili drugih političkih odluka služe njihovim donositeljima, jer novinari koji se pozivaju na neimenovane izvore obavještavaju javnost o njima te time svjesno ispituju javno mnijenje o tim političkim odlukama („probni baloni"). Drukčije rečeno, postavimo teoriju da će najave promjena biti pretočene u djelo ako dožive pozitivnu reakciju javnosti, te tu teoriju provjerimo kombinacijom primjene analize sadržaja i rezultata ispitivanja javnog mnijenja. Ako je ta teorija doista točna, tada njome vršimo validaciju upotrebe kategorije vijesti iz neimenovanih i imenovanih izvora.

*Objektivnost* se odnosi na nezavisnost rezultata od istraživača koji rade analizu. Drukčije rečeno, ako bi više istraživača radilo analizu, svi bi trebali dobiti iste ili vrlo slične rezultate. Objektivnost se u analizi sadržaja povećava ako analizu obavlja veći broj istraživača, budući da se time smanjuju subjektivni stavovi pojedinaca. Ako rezultati jednog istraživača u znatnoj mjeri odstupaju od ostalih, tada se njegovi/njezini rezultati obično dodatno kontroliraju te se čini ponovna analiza tog dijela sadržaja. Objektivnost se povećava i jasnim određenjem kategorija analize i njihovim jasnim razgraničenjem. Npr. ukoliko želimo utvrditi je li količina oglašavanja neke tvrke u pojedinom mediju povezana s pozitivnim ili negativnim pisanjem tog medija o oglašivaču, trebamo jasno odrediti što znači pozitivno i negativno pisanje. Pozitivno pisanje može označavati iznošenje priznanja koje je dobila tvrtka, iznošenje pozitivnih poslovnih rezultata, društvene odgovornosti i sl. Negativno pisanje može se odnositi na probleme u poslovanju, lošu kvalitetu proizvoda, kršenje radničkih prava i sl. Što su ove kategorije jasnije, to je i objektivnost rezultata u pravilu veća.

*Sustavnost* analize sadržaja odnosi se na jasna pravila i procedure koje se moraju slijediti. Drukčije rečeno, analiza sadržaja ne smije predstavljati subjektivne dojmove jednog istraživača koji selektivno pokušava dokazati svoje hipoteze, nego iza nje moraju stajati jasno određene jedinice analize, kategorije itd. (jasan kodni plan).

*Općenitost* analize sadržaja označava teorijsku utemeljenost njezinih rezultata, tj. ti rezultati trebali bi se koristiti za formuliranje ili testiranje određene teorije.

Međutim, analiza sadržaja često se koristi za praktične i pragmatične svrhe, bez većih teorijskih aspiracija. Primjerice, ako analiziramo zastupljenost pojedinih političkih stranaka u medijima s ciljem utvrđivanja političke neutralnosti medija, analiza sadržaja u tom slučaju vjerojatno ima praktičnu, a ne znanstvenu svrhu. Ako, primjerice, pretpostavimo da se medijski sadržaji nalaze pod velikim utjecajem oglašivača (zbog izravnog pritiska ili autocenzure) i tu hipotezu pokušamo provjeriti analizom sadržaja pisanja medija o tvrtkama koje su njihovi vlastiti oglašivači, tada analiza sadržaja ima znanstveni cilj.

## 9.8. ANALIZA DISKURSA I ANALIZA KONVERZACIJE

Paltridge (2006: 2) analizu diskursa definira kao analizu jezika i njegove upotrebe, ali ne u usko lingvističkom smislu, nego u odgovarajućem društvenom i kulturnom kontekstu. Drugim riječima, pojam diskursa podrazumijeva povezanost jezika s odgovarajućom društvenom situacijom, akterima koji se u njoj pojavljuju te njihovim ciljevima i interesima. Osnovna je pretpostavka analize diskursa tako da se društveni svijet može razumjeti pomoću jezičnih situacija u kojima se stvaraju društveni odnosi i identiteti. Diskurs se tako povezuje sa stvaranjem značenja koje je povezano s društvenim ideologijama i institucijama. Analiza diskursa polazi od postavke da tekst nikad nije neutralna reprezentacija stvarnosti, nego u određenoj mjeri predstavlja odraz ideoloških, ekonomskih ili političkih uvjerenja ili interesa kreatora teksta, odnosno da je ukorijenjen u određenom društvenom kontekstu u kojemu se jezični ili, općenitije govoreći, komunikacijski čin odvija. Analiza diskursa nastoji otkriti kako se ovi konteksti, interesi i uvjerenja manifestiraju u tekstu posredstvom izborom riječi, simbola ili retoričkih elemenata.

***Analiza diskursa istraživačka je metoda koja proučava upotrebu jezika, ali i drugih vrsta komunikacije, u njihovom društvenom i kulturnom kontekstu.***

Kao jedna od najčešćih podvrsta analize diskursa u društvenim se znanostima često upotrebljava tzv. kritička analiza diskursa. Njezin je zadatak analizirati na koji se način u jeziku stvaraju i reproduciraju društvene nejednakosti i odnosi moći. Kritička analiza diskursa eksplicitno je društveno angažirana, odnosno cilj joj je razotkriti društvenu nepravdu i na taj način dati svoj doprinos poboljšavanju društva, tj. postizanju društvene pravednosti. Jedan od njezinih najčešćih zastupnika, Norman Fairclough (2012), drži da kritička analiza diskursa pro-

izlazi iz dijalektičkog odnosa između proizvodnje značenja i materijalnih društvenih struktura. Fairclough za primjer uzima diskurs o javnim financijama kao ekstenziji financija kućanstva koji implicira da i za jedan i za drugi vrijedi isti skup pravila. Kritička analiza diskursa ovakav bi diskurs razotkrila kao ideološki jer zastupa interese financijskog kapitala, odnosno one vrste kapitala kojemu su primarni cilj uravnotežene javne financije. Na diskurzivnoj razini pokazuju se upotrebe netočne analogije koja složeni svijet javnih financija i njegovu ulogu u ekonomskom razvoju neopravdano izjednačuje s financijama jednog običnog kućanstva. Fairclough razlikuje tri razine društvene realnosti: socijalne strukture, prakse i događaje, pri čemu su prakse posredujuća razina između konkretnih događaja i apstraktnih socijalnih struktura. Svi ovi elementi imaju elemente stvaranja značenja/semioze, pri čemu naglasak može biti na aktivnosti, značenju ili identitetu. Semiozu koja je vezana uz određenu aktivnost Fairclough naziva *žanrom* (npr. davanje intervjua, način političkog djelovanja, obavljanje određenog posla i sl.), onu koja je vezana za osmišljavanje društvenog svijeta naziva *diskursom*, a onu vezanu za identitete *stilom*.

Već sama definicija analize diskursa upućuje na njezinu povezanost s jezičnom pragmatikom, odnosno s komunikacijskim ciljevima koji se ostvaruju u jezičnoj praksi. Jezični se činovi, prema poznatoj klasifikaciji Johna Austina (1962), mogu podijeli na lokucijske, ilokucijske i perlokucijske. U prvom je slučaju riječ o supstancijalnom značenju koje prenosi neki izraz, određenom govorenju o stanju stvari u svijetu. Na primjer, izraz „u ovom uredu je bučno" predstavlja lokuciju. Ilokucija se odnosi na jezični izraz kojim se nešto želi postići, kojim se nešto predlaže, naređuje, zahtijeva i sl. Drugim riječima, cilj je unijeti promjenu u svijet, a ne samo ga opisati. Izraz „zatvori prozor" predstavlja tako ilokuciju. Perlokucijski jezični čin odnosi se na promjenu koja se dogodila u svijetu na temelju nekoga ilokucijskog čina. Primjerice, netko na prethodni zahtjev može reći „u redu" i zatvoriti prozor ili se može pobuniti riječima: „Zatvori ga sam!" Pri tome valja imati na umu da ilokucijski i perlokucijski činovi mogu biti izraženi s različitim stupnjevima indirektnosti, odnosno ne moraju odmah biti jasno prepoznati kao takvi. U prethodnom primjeru tako se ilokucija mogla izraziti tako da osoba kaže – „Ovdje je užasno bučno" – te da pogleda osobu koja se nalazi bliže prozoru nego što je to osoba koja izriče ilokuciju. Drugim riječima, osoba svoj zahtjev izražava na nešto indirektniji način, odnosno način koji se obično smatra pristojnijim i manje narušava komunikacijsko načelo autonomije osobe s kojom se komunicira. Austin je definirao i pojam sretnih okolnosti (eng. *felicity conditions*) koje moraju biti ostvarene da bi se određeni jezični čin mogao ostvariti, odnosno smatrati uspješnim. Naime, određeni jezični čin mora ostvariti osoba

koja na to ima pravo, odnosno njezin je čin u skladu s društvenim konvencijama, a čin se mora ostvariti u odgovarajućem prostornom i vremenskom kontekstu.

Ilokucijski se činovi prema Searleu (1976, navedeno prema Živkoviću, 2014: 82-83) mogu nadalje podijeliti na pet vrsta: asertivi, direktivi, ekspresivi, deklaracije, komisivi. Asertivi se odnose na iskaze u kojima se navodi nešto činjenično o vanjskom svijetu, odnosno nešto što govornik smatra istinitim, a s ciljem uvjeravanja druge osobe da je takvo stanje stvari doista istinito. Direktivi se, kako samo ime kaže, odnose na činove kojima se daju naredbe, instrukcije, savjeti, upozorenja. Pomoću ekspresiva govornik izražava svoje osjećaje, odnosno emocionalna stanja, pa u njih spadaju čestitke, zahvale, isprike, izražavanje sreće, nezadovoljstva i sl. Deklaracije se odnose na izraze posebne snage u kojima govornik donosi određenu promjenu, najčešće pomoću institucionalne moći koju posjeduje. U takve činove spadala bi sva određivanja pravila koja se nalaze u zakonima, pravilnicima i drugim propisima. I na kraju, komisivi se odnose na činove u kojima se obećava da će se određena radnja izvršiti ili se ne želi izvršiti u budućnosti (obećanja, garancije, odbijanja i sl.).

Fairclough (1995) analizu diskursa dijeli na mikroanalizu i makroanalizu, pri čemu se prva bavi temeljnim dijelovima teksta (rečenicama) i njihovim strukturiranjem, a druga kombiniranjem tih dijelova. No tome se može dodati i mezorazina, pri čemu bismo makrorazinu zadržali za analizu teksta kao cjeline i načina njegovoga strukturiranja, a mezorazina odnosila bi se na razinu rečenica, odnosno njihova kombiniranja na razini dijelova teksta. Richardson (2007) mikroanalizu povezuje s izborom riječi/leksikom, sintaksom, tranzitivnošću i modalnošću rečenica te pretpostavkama koje su dio rečenica, a makroanalizu s retorikom i analizom naracije/narativa. Na prvoj razini mikroanalize analiza diskursa proučava izbor riječi/leksika, odnosno tzv. referencijalnih strategija. Primjerice, riječi mogu imati različite konotacije, a njihov izbor može ovisiti o ideološkim preferencijama i ciljevima onoga koji ih upotrebljava. Richardson navodi primjer riječi „neutralizirati" i „eliminirati" koje predstavljaju hladniju alternativu riječi „ubiti" prilikom opisivanja vlastitih ratnih postignuća. Hladnije varijante ove riječi postupak svrstavaju u okvire strateških ratnih ciljeva, a izvlače ga iz konteksta oduzimanja ljudskih života, što je samo po sebi društveno nepoželjan postupak. Ratne aktivnosti i oduzimanje ljudskih života tako postaju legitimirani. Jedna od vrsta ideološkog imenovanja pojavljuje se onda kada se neke od mogućih kategorija koja se može pripisati određenoj osobi, društvenoj grupi ili pojavi izabere za označavanje te osobe, a druge se zanemare. Dobar primjer za takvu vrstu imenovanja predstavlja naglašavanje da osoba pripada nekoj manjinskoj skupini

u slučaju njezina smještanja u negativni kontekst. Primjerice, Google pretraga „Romi ukrali" daje veći broj rezultata u kojima se izvještavajući o krađi naglašava da su ju počinili pripadnici romske manjine. Jedan od primjera glasi: „Maloljetni Romi u Međimurju provalili u spremište, napili se, ukrali vatrogasno vozilo i demolirali ga za ‚staro željezo'."[81] S druge strane, pretraga „Hrvati ukrali" daje samo rezultate koji govore o krađama Hrvata izvan Hrvatske. Iz ovakvog načina izvještavanja može se dogoditi da javnost stekne pojačani dojam o učestalosti romskih krađa zbog toga što se prilikom krađa koje u Hrvatskoj počine Hrvati nikada ne navodi činjenica da su u pitanju Hrvati. Ovakav način izvještavanja ne proizlazi nužno iz novinarske ksenofobije, nego iz shvaćanja da bi navođenje etničke pripadnosti u slučaju Hrvata bilo suvišno jer se takvo što pretpostavlja, no učinak koji ovakav postupak može imati svejedno ostaje isti, odnosno može pojačati predrasude o Romima. Sličan se učinak dobije i kada se prilikom izvještavanja o nekom kriminalnom činu navede da ga je počinio imigrant, a nikada se ne navede da ga je počinila osoba koja je rođena u zemlji.

Nadalje, analiza diskursa proučava i konstrukciju rečenica, odnosno tranzitivnost i modalnost. Tranzitivnost se odnosi na to tko čini određenu radnju, a tko je objekt takve radnje. Pri tome je osobito važno je li radnja prikazana u aktivu ili pasivu, odnosno je li subjekt radnje izravno naveden ili je ispušten iz rečenice. Primjerice, jedan od najčešćih oblika lažne isprike predstavlja rečenica: „Pogreške su počinjene." (eng. *Mistakes were made*) Na ovaj se način pomoću pasiva izbjegava direktno navođenje tko je počinio pogreške te se cijeli postupak predstavlja kao gotovo automatski proces za koji nijedan pojedinac nije odgovoran. Dakle, transformacija rečenice u pasiv i ispuštanje pravog subjekta konotira da je u pitanju proces koji je automatski, impersonalan i neupravljan, a tim često i neizbježan. Richardson (2007: 56) navodi primjer rečenice: „U sve jače globaliziranoj ekonomiji današnjice ne možemo biti kompetitivni na stari način. Kapital je mobilan, tehnologija se može hitno preseliti i roba može biti proizvedena u zemljama s niskim troškovima i prebačena u razvijena tržišta." U toj se rečenici procesi prikazuju na impersonalan način, pa se tako navodi da je kapital mobilan, a ne da menadžeri multinacionalnih korporacija odlučuju preseliti kapital u potrazi za nižim troškovima i većim profitom. Drugim riječima, gubi se subjektivitet i uklanja moguća odgovornost za navedeni proces. Sličan se učinak postiže i tzv. nominalizacijom u kojoj se aktivni procesi, obično prikazani glagolima, zamje-

[81] https://www.index.hr/vijesti/clanak/Maloljetni-Romi-u-Medimurju-provalili-u-spremiste-napili-se-ukralivatrogasno-vozilo-i-demolirali-ga-za-staro-zeljezo/655365.aspx (vijest 4. 1. 2013., pristupljeno 7. 6. 2018.)

njuju stvarima, odnosno imenicama te apstraktnim glagolima kao što su „biti", „postojati" i sl. Primjerice, rečenica – „Moramo napraviti nešto" – može se nominalizirati u – „Postoji potreba da se nešto napravi" – pri čemu je glagol „morati" pretvoren u imenicu „potreba". I u ovom slučaju subjekt se stavlja u drugi plan, a cijeli opis postaje apstraktan i neživ. Izostavljanje subjekta, upotreba pasiva i nominalizacija mogu biti i strategije čiji je cilj diskurzivno isključivanje pojedinih subjekata (ljudi i društvenih grupa). Van Leeuwen (1996: 38-41) razlikuje dvije vrste isključivanja: supresiju i stavljanje u drugi plan (eng. *backgrounding*). U supresiji se subjekt u potpunosti izostavlja te nije jasno o kome je riječ, a diskurzivni je cilj često umanjiti njegovu važnost, odnosno minorizirati ga. Primjerice, izrazi „neki tvrde da..." ili „postoje tvrdnje da..." posve isključuju subjekt implicitno poručujući da nije vrijedan spomena. Stavljanjem u drugi plan, subjekt se spominje ili se može zaključiti o kome je riječ, no u cijelom diskursu spominje se rijetko i podzastupljen je u odnosu na druge aktere.

Modalnost se odnosi na odnos govornika prema izrečenom, u smislu sigurnosti u istinitost ili poželjnost onoga što se izriče. Modalnost se izražava modalnim glagolima poput „može", „treba", „mora" i njihovim negacijama (Richardson, 2007: 57). Jači glagoli, odnosno veći stupanj sigurnosti, obično je obilježje senzacionalističkih medija, a oni „ozbiljniji" češće upotrebljavaju modalne glagole koji izražavaju sumnju i oprez. S druge strane, ponekad i izražavanje mogućnosti može imati ozbiljne posljedice, odnosno služiti za poticanje straha i panike u javnosti. Richardson navodi primjer rečenice: „London bi mogao pretrpjeti terorističke napade slične onima u Madridu." Takva rečenica ne iznosi vjerojatnost da će se takvi napadi dogoditi, no samo podsjećanje na mogućnost da se napadi dogode izaziva nelagodu.

Jednu od čestih elemenata mikrorazine diskursa predstavlja i tzv. asimilacija, tj. predstavljanje pojedinaca isključivo kao članova grupe (van Leeuwen, 1996: 48-50). Van Leeuwen asimilaciju dijeli na dvije temeljne vrste: agregaciju i kolektivizaciju. Agregacija predstavlja postupak u kojemu se pojedinci reprezentiraju grupom tako da se navode konkretne brojke ili riječi poput „neki", „svi", „većina" „određeni" i sl., s namjerom impliciranja konsenzusa oko neke stvari, odnosno promoviranja neke teze. Primjerice, iskaz: „Većina građana ove zemlje zalaže se za pravo na pobačaj" stav o pobačaju nastoji argumentirati pozivanjem na mišljenje većine. Kolektivizacija uključuje intenzivnu upotrebu riječi koje označavaju kolektivni identitet, kao što su „mi", „zajednica", „država", „nacija", „narod" i sl. Kolektivizacija obično diskurzivno potiskuje alternativna mišljenja, odnosno mišljenja koja odstupaju od stvarnog ili pretpostavljenog mišljenja većine.

Figure riječi (tropi) predstavljaju upotrebu riječi koja odudara od njihove uobičajene, „rječničke" definicije. Postoji mnogo vrsta tropa, a Richardson (2007) kao posebno važne za analizu diskursa izdvaja hiperbolu, metaforu, metonimiju, neologizam i igre riječima. Hiperbola predstavlja upotrebu riječi koje su pretjerane i pojačane u odnosu na pojavu koju označavaju. Primjerice, nazivanje političkih prosvjeda „kaotičnim neredom" predstavlja primjer hiperbole s jasnim ideološkim funkcijama. Metafora predstavlja upotrebu određene riječi za pojave koje se obično ne označavaju tom riječju. Primjer predstavlja upotreba izraza „pregrijavanje ekonomije" za situaciju ubrzanog ekonomskog rasta koji može dovesti do inflacije ili izraza „rat" ili „bitka" za sportsko nadmetanje (Richardson, 2007: 67). Iako je slična metafori metonimija je takva figura u kojoj su riječ koja se upotrebljava i pojava koju označava u bližem semantičkom odnosu, obično u nekom odnosu prostorne ili vremenske blizine ili uzročno-posljedičnim odnosima. Primjer metonimije predstavlja i situacija u kojoj objekt zamjenjuje njegova korisnika („udario ga je automobil") ili vlastitog kreatora („zakon zabranjuje takvo ponašanje"). Neologizmi su novostvorene riječi koje često predstavljaju kombinaciju postojećih riječi, a posebno su važne jer određenu pojavu svrstavaju u određeni kontekst. Primjerice, u engleskom se jeziku nakon afere Watergate posebno važne afere označavaju neologizmima sa sufiksom „gate" (Irangate, Lewinskygate) (Richardson, 2007: 69). I na kraju, Richardson kao trope izdvaja i igre riječima (eng. *puns*) u kojima se iskorištavaju homofoni i homografi ili sličnost u značenju pojedinih riječi, najčešće kako bi se postigao komičan učinak. Primjerice, tabloidski naslov na engleskom jeziku: „Midget sues grocer, cites belittling remarks" (Chicago Sun-Times, 16. 12. 2003) igra se etimologijom glagola *belittle* i stavlja je u kontekst sudske tužbe koju je pokrenula niska osoba.

Kao primjer mezorazine analize mogu se navesti različite vrste argumentiranja, odnosno argumentacijski postupci. Tako npr. kritička analiza diskursa često za predmet ima i različite logički nevaljane argumentacijske strategije koje se upotrebljavaju kako bi se diskurzivno promovirali vlastiti ideologijski interesi. Primjerice, Reisigl i Wodak (2001: 70-74) ističu nekoliko takvih strategija koje krše pravila dobre argumentacije: *argumentum ad hominem*, *argumentum ad misericordiam*, *argumentum ad populum*, *argumentum ad ignorantiam*, *argumentum ad verecundiam*, *secundum quid*, *post hoc ergo propter hoc*, *petitio principii*, argumenti koji uključuju nedokazane prepostavke, *ignoratio elenchi*, argument koji uključuje zamjenu teza (argument strašila, eng. *straw man fallacy*) i *argumenti in dictione*. *Argumentum ad hominem* uključuje napad na čovjeka koji iznosi argument, a ne na sam argument. Time se krši pravilo argumentacije koje kaže da se argumentacija mora odnositi na činjenice o kojima se raspravlja, a ne na druge

irelevantne stvari. *Argumentum ad misericordiam* uključuje pozivanje na emocije, umjesto na činjenice, osobito na predstavljanje sebe kao žrtve. Ovakav argument također krši pravilo o relevantnosti argumenata. *Argumentum ad populum* uključuje pozivanje na većinu, tj. na mišljenje i emocije (navodne) većine ljudi. I ovdje je u pitanju kršenje pravila relevantnosti. *Argumentum ad ignorantiam* implicira tvrdnju da je nešto točno samo zbog toga što nije opovrgnuto ili se čak i načelno ne može opovrgnuti. Ovakva argumentacija krši pravilo prema kojemu osoba treba povući svoj stav ako za njega nije pružila valjane argumente. *Argumentum ad verecundiam* uključuje pozivanje na poštovanje prema autoritetima, čak i onda kada njihovo mišljenje nije u skladu s činjenicama, odnosno kada autoriteti nisu općeprihvaćeni. Riječ je o kršenju pravila po kojemu su u argumentiranju prihvatljive samo formalne sheme argumentacije prihvatljive za sve sudionike. *Secundum quid* uključuje prebrzu generalizaciju utemeljenu na nekoliko slučajeva ili na slučajevima koji se ne mogu smatrati tipičnim ili reprezentativnim. Time osoba koja argumentira nedokazano pretpostavlja mogućnost generalizacije. *Post hoc ergo propter hoc* uključuje tvrdnju da postoji uzročno-posljedična veza samo zato što postoji vremenska koincidencija. Primjerice, stopa nezaposlenosti može se povećati dolaskom imigranata, no to ne znači da su ju oni svojim dolaskom povećali jer je mogla narasti zbog promjene ekonomskih ili političkih okolnosti (Reisigl i Wodak, 2001: 73). *Petitio principii* znači kružno zaključivanje u kojemu se dvije tvrdnje potvrđuju jedna drugom, pri čemu druga tvrdnja zapravo može biti samo drukčije formulirana prva tvrdnja. Primjerice, političke se neprijatelje može optužiti za korupciju navodeći da su skloni primati mito, pri čemu ova stvar nije dokazana drugim argumentima. Pri tome se krši argumentacijsko pravilo prema kojemu polazne pretpostavke u argumentiranju moraju biti prihvatljive svima. *Argumenti koji uključuju nedokazane prepostavke* također krše navedeno pravilo, a uključuje tvrdnje poput: „Kada će Ministarstvo unutarnjih poslova prestati favorizirati strance u odnosu na domaće državljane?“ (Reisigl i Wodak, 2001: 73). *Ignoratio elenchi* odnosi se na dokazivanje teze koja zapravo nije teza o kojoj je riječ o argumentaciji, čime se krše pravila koja govore da treba napadati one teze koje protivnik zapravo iznosi te da se treba držati teme diskusije. *Argument koji uključuje zamjenu teza* odnosi se na izvrtanje protivnikovih teza te njihovo lažno opovrgavanje putem opovrgavanja teza koje protivnik zapravo i ne iznosi. Primjerice, političke se protivnike može optužiti da tvrde da su apsolutno nekorumpirani, tj. da u njihovoj stranci nema korumpiranih ljudi (iako oni to ne tvrde). Takva se teza može opovrgnuti upućujući na političara iz suprotnog tabora koji je osuđena za korupciju. Ovaj argument može uključivati i napada na neki stav napadom na argumente osobe koja taj stav brani izuzetno

loše i neargumentirano. I na kraju, *argumenti in dictione* uključuju igranje s različitim značenjima neke riječi, nejasnoćama što one zapravo znače, odnosno s konotacijama koje imaju neke riječi. Reisigl i Wodak (2001: 194) navode primjer pozivanja pojedinih političara na kršćanske vrijednosti, pri čemu isti političari ne navode što bi točno bile kršćanske vrijednosti koje zagovaraju.

Posebnu vrstu mezorazine razine analize diskursa čini analiza tzv. pretpostavki (eng. *presupposition*). U pitanju su istinosne izreke koje se impliciraju određenom rečeničnom konstrukcijom te mogu imati ideološku funkciju jer se pretpostavlja nešto što bi zapravo tek trebalo dokazati. Postoje određene riječi, izrazi ili rečenične konstrukcije koje impliciraju pretpostavke, odnosno tzv. okidači pretpostavki (eng. *presupposition triggers*). U jezicima u kojima postoje to su često određeni članovi. Primjerice, rečenica u engleskom jeziku – „The person responsible for the securitiy did not do his/her job" – pretpostavlja da takva osoba postoji, odnosno da je netko bio zadužen za sigurnost. Tzv. implikativni glagoli „izbjeći" i „zaboraviti" povlače određene pretpostavke, glagol „izbjeći" tako pretpostavlja da je osoba trebala napraviti to što je izbjegla, a glagol „zaboraviti" da je osoba nešto znala. Primjerice, ako kažemo da je netko izbjegao obaviti svoju dužnost, pretpostavljamo da je ta osoba bila dužna nešto napraviti i da je toga bila svjesna. Nadalje, glagoli poput „prestati" i „nastaviti" pretpostavljaju da je netko nešto radio prije određenog trenutka, a sličnu pretpostavku povlače i izrazi repeticije, kao što su „ponovno", „opet" i „vratiti se". Ponekad se pretpostavka krije i u samom pitanju koje nudi samo određene mogućnosti, a druge izostavlja. Primjerice, pitanje: „Treba li ulaganja u socijalnu skrb povećati za 10% ili za 15%?" – pretpostavlja da ulaganja treba povećati. Tzv. rascijepljene rečenice (eng. *cleft sentences*) u kojima se rečenica naglašeno dijeli na dva dijela s vlastitim glagolima, iako bi se ista informacija mogla prenijeti i s jednim, također povlače pretpostavke. Primjerice, rečenica – "Nismo mi ti koji smo odgovorni za ovolike probleme" – pretpostavlja da postoji netko tko je odgovoran, a slična rečenica – „Mi nismo odgovorni za ovolike probleme" – ne povlači nužno takvu pretpostavku.

Postupak sličan pretpostavkama obično se naziva intertekstualnost. No ona podrazumijeva eksplicitno uvođenje drugih tekstova u diskurs, odnosno intertekstualnost obično uvodi druge perspektive i dijalog/konflikt, a pretpostavke se temelje na jednom glasu i homogenosti (Fairclough, 2003: 40). Fairclough (2003: 41-42) razlikuje pet mogućih scenarija intertekstualnosti: (a) otvorenost i dijaloško prihvaćanje razlika, (b) naglašavanje različitosti i konflikta, (c) pokušaj da se razlike razriješe, (d) inzistiranje na sličnosti, negiranje različitosti i (e) konsenzus koji suzbija svaku razliku. Fairclough (1992) navodi i važnost smje-

štaja pojedinih „glasova“, odnosno perspektiva u tekstu. Naime, nije nevažno na kojem se mjestu nalaze alternativne perspektive, navode li se na prvom ili posljednjem mjestu, jesu li ugniježđene između dominantnog diskursa i sl. Isto tako, Fairclough ističe razliku između manifestne intertekstualnosti (direktnog ili indirektnog navođenja drugih tekstova) i konstitutivne intertekstualnosti (interdiskurzivnosti) u kojoj se struktura jednog diskursa upotrebljava u drugom diskursu (primjerice, neka vjerska zajednica može usvojiti diskurs pozitivne psihologije, odnosno diskurs kojim se promovira psihološka dobrobit).

I na kraju, na makrorazini rečenice se u diskursu mogu oblikovati na mnogo različitih načina, odnosno naracija. Dva su od najčešćih medijskih naracija obrnuta piramida (eng. *inverted pyramid*) i pješčani sat (eng. *hourglass*). U obrnutoj piramidi cilj je u prvih nekoliko rečenica dati najvažnije informacije koje korisniku omogućuju da shvati što se dogodilo, tko je to napravio, gdje, kada i zašto (tzv. 5 W – *What*, *Who*, *When*, *Where* i *Why*). Ovakav način naracije čest je u tabloidskim izdanjima, a potječe iz vremena kada se uredniku novina radi uštede prostora skraćivao tekst od kraja prema početku. Pješčani sat počinje tako da se prvih nekoliko rečenica oblikuje u formi obrnute piramide, nakon čega slijedi uobičajena naracija koja slijedi događaj onako kako se vremenski dogodio, a ponekad i opis dijelova dramske radnje koji potiče još od Aristotela (uvod, zaplet, kulminacija, peripetija, rasplet). Pješčani je sat čest oblik naracije prilikom izvještavanja o dramatičnim događajima, poput onih o pljačkama ili razbojstvima, zbog toga što one imaju jasan početak i kraj, aktere i ishode.

Analiza konverzacije (konverzacijska analiza) bavi se proučavanjem interakcije u njezinu svakodnevnom društvenom kontekstu, odnosno proučava način na koji ljudi svakodnevnom interakcijom osmišljavaju i stvaraju svakodnevne društvene aktivnosti i društveni poredak (Psathas, 1995: 1-2). Njezin se nastanak izvodi iz nekoliko teorijskih tradicija, ponajprije etnometodologije, i vezuje uz imena poput Erwinga Goffmana i Harolda Garfinkela.

Analiza konverzacije bavi se osnovnim jedinicama razgovora/interakcije koji se obično sastoje od konverzacijskih parova. Drugim riječima, iskaz jedne osobe obično izaziva neku vrstu simetrije i sličnog odgovora, odnosno razgovori su strukturirani oko ovakvih dijada. Primjerice, navođenje vlastitog imena na početku razgovora potiče drugu osobu da i sama kaže svoje ime. Ovakve se strukture obično nazivaju susjedni parovi (eng. *adjacency pairs*), a drugi primjeri uključuje parove žalba/isprika ili opravdanje, pozdrav-povratni pozdrav, ponuda/prihvaćanje ili odbijanje, poziv/prihvaćanje ili odbijanje, optužba/odbrana i sl. Skladna interakcija uključuje laganu i neprimjetnu izmjenu ovakvih parova, a ko-

munikacijski nesporazumi događaju se kada druga osoba ne prepozna prvi iskaz u susjednom paru i ne odgovori adekvatno na njega. Ponekad se susjedni parovi grupiraju u skupine po dva, pri čemu prvi par vrši svojevrsnu pripremu za drugi. Uzimo za primjer sljedeću interakciju:

Osoba A: Jeste li Vi osoba za izdavanje vozačkih dozvola?
Osoba B: Da.
Osoba A: Mogu li vozačku dozvolu dobiti danas?
Osoba B: Ne, došli ste prekasno.

Konverzacija se zasniva na različitim vrstama prešutnih pretpostavki koje omogućuju njezino započinjanje i neometano odvijanje. Grice (1975) je definirao tzv. načelo kooperativnosti konverzacije, a to načelo pretpostavlja da određena osoba s kojom stupamo u interakciju ima određene namjere i da komunicira na način koji omogućuje međusobno razumijevanje, tj. da u komunikacijsku situaciju stupa s namjerom međusobnog razumijevanja, a ne nesporazuma ili obmane. Grice je izdvojio četiri sastavnica (on ih naziva maksimama) koje čine načelo kooperativnosti: količina, kvaliteta, relacija i način. Maksima kvantitete kaže da ćemo prenijeti optimalnu količinu informacija, a ne preveliku ili premalenu. Kada bismo na upit o tome kakvo će sutra biti vrijeme od prijatelja dobili odgovor „osrednje", vjerojatno ne bismo dobili onu količinu informacija koju smo htjeli, a to ne bi vjerojatno bio slučaj ni ako bi nam prijatelj iznio mnoštvo tehničkih meteoroloških detalja jer nas samo zanima kakva će biti temperatura i hoće li padati kiša. Maksima kvalitete govori o tome da ljudi govore ono što smatraju da je istinito, odnosno da djeluju u najboljoj namjeri želeći nam prenijeti stanje stvari kako ono stvarno jeste. Komunicirajući s ljudima moramo pretpostaviti da nas ne obmanjuju. Maksima odnosa ističe da u komunikaciji iznosimo samo stvari koje su relevantne ili da istaknemo zašto ističemo informaciju koja nije naočigled relevantna. U razgovoru o vremenu tako ne moramo objašnjavati na kojoj smo televizijskoj postaji vidjeli prognozu jer je teško pretpostaviti zašto bi to bilo relevantno za odgovor na pitanje o tome kako će vrijeme biti sutra. Maksima načina govori da informaciju trebamo prezentirati na što jasniji način, izbjegavajući izraze nejasnog značenja i dvosmislenosti. U našem primjeru tako od prijatelja koji je školovani meteorolog očekujemo da ne upotrebljava izraze koje mi, kao laici, ne razumijemo.

Načela kooperativnosti u konverzaciji mogu se prekršiti, što namjerno, što slučajno. Ponekad je kršenje načela rezultat slabih komunikacijskih sposobnosti ili nepoznavanja jezika, a kršenje također ponekad može biti motivirano željom da nas se ne razumije, odnosno potrebom skrivanja istine. Tako je govor javnih

osoba, glasnogovornika i drugih stručnjaka za odnose s javnošću često ispunjen kršenjima pojedinih maksima. Primjerice, tzv. lažna isprika (eng. *non-apology apology*) kao komunikacijska strategija kršenje bar dviju maksima – kvalitete i načina. Kada neka javna osoba uputi grube i uvredljive riječi nekome drugome i naknadno kaže da „joj je žao ako su njezine riječi mogle nekoga povrijediti", tada nije jasno ispričava li se doista ta osoba i preuzima li odgornost za ono što je učinila, odnosno ta osoba sigurno ne želi prenijeti stvarno stanje stvari (najčešći je razlog izbjegavanje mogućih sudskih tužbi i sličnih posljedica).

Kako bi se osigurala međusobna komunikacija istraživača koji se bave analizom konverzacije, usvojen je relativno standardizirani transkripcijski sustav, poznat pod nazivom Jeffersonov transkripcijski sustav (tvorac je Gail Jefferson, trenutna verzija može se naći u Jefferson, 2002), prikazan u sljedećoj tablici.

*Tablica 41. Transkripcijski simboli – analiza konverzacije*

| **Simbol** | **Objašnjenje** |
|---|---|
| Ivana: | Atribucija govora određenom govorniku |
| (.) | Kratka, gotovo neprimjetna pauza u govoru |
| (0.5) | Broj u zagradi označava trajanje pauze, u ovom slučaju to je 0,5 sekundi. |
| = | Spajanje govora dviju osoba, nema pauze između govora dviju osoba, prva osoba prestaje, a druga odmah počinje govoriti |
| GOVOR | Iznimno glasan govor (velika slova) |
| :: | Duža pauza između ili unutar riječi |
| <u>On</u> to hoće | Naglašeni dio riječi ili rečenice (podvlačenje) |
| £ | Smijeh |
| ~ | Drhtavi glas |
| - | Naglo prekinut govor |
| >< | Ubrzani govor |
| <> | Usporeni govor |
| ( ) | Nerazumljivi dio govora |
| [ | Od ovoga mjesta govor prve osobe počinje se miješati s govorom druge osobe (traju istovremeno) |
| ] | U ovom trenutku prestaje istovremenost dvaju govora. |

## 9.9. PROJEKTIVNE TEHNIKE

Projektivne tehnike razvijene su uglavnom unutar psihologije, a predstavljaju alternativu eksplicitnom traženju izražavanja stavova ili navođenju vlastitog ponašanja ispitanika. Drugim riječima, klasične kvantitativne i kvalitativne meto-

de u pravilu podrazumijevaju da je ispitanik svjestan vlastitog stava, ponašanja, mišljenja i osjećaja te da ih može verbalno izraziti i prenijeti istraživaču u nekom obliku. Projektivne se tehnike u pravilu sastoje od višeznačnih, nejasnih objekata (riječi, slika...) kojima sam ispitanik treba dati značenje projicirajući tako vlastite stavove, želje i emocije. Kako navodi Rook (2006),u klasičnim se neprojektivnim metodama često od ispitanika očekuje da pokaže memoriju koja zapravo ne postoji. Prednost je projektivnih tehnika u takvim situacijama mogućnost da se pomoću stimulansa poput slika ili opisa realnih situacija iz dubljih slojeva memorije dozovu sjećanja koja se ne mogu dozvati eksplicitno. Primjerice, tražimo li od ispitanika da zamisli i opiše ili nacrta svoju posljednju kupovinu nekoga proizvoda tada ovakve asocijacije mogu dozvati u sjećanje situaciju posljednje kupovine na mnogo bolji način od klasičnog anketnog ispitivanja. Nadalje, neprojektivne tehnike od sudionika istraživanja uključuju visoku razinu introspekcije i poznavanje samoga sebe, kao i visoku sposobnost verbalizacije vlastitih unutrašnjih stanja, što je kod mnogih ljudi zasigurno nerealna pretpostavka.

***Projektivne metode sastoje se od nestrukturiranog materijala kojemu sâm sudionik istraživanja treba dati značenje, projicirajući tako vlastite stavove, želje i emocije.***

Neke su od najčešće upotrebljavanih projektivnih tehnika sljedeće:

- Asocijacija riječi,
- Dopunjavanje rečenica,
- Test tematske apercepcije,
- Personifikacija objekata.

Asocijacija riječi odnosi se na situaciju u kojoj se ispitaniku ponudi riječ, a on treba navesti riječ koja mu prva pada na pamet u odnosu na ponuđenu. Ova se tehnika osobito često upotrebljava u istraživanjima tržišta, posebice pri istraživanju asocijacija na pojedino ime proizvod/brand. Dopunjavanje rečenica predstavlja sličnu tehniku, pri kojoj se ispitanicima ponudi započeta rečenica koju trebaju završiti tako da navedu svoju prvu zamisao/asocijaciju. Test tematske apercepcije sastoji se od slike na kojoj se obično nalazi prikaz interakcije dviju ili više osoba, a ispitanik treba ponuditi priču/objašnjenje koje stoji u pozadini događaja prikazanog na slici. Personifikacija također je često upotrebljavana tehnika u istraživanjima tržišta, osobito prilikom istraživanja pozicioniranja brandova. Primjerice, ispitaniku se ponudi sljedeća mogućnost/pitanje: „Kada bi automobil X bio osoba, kakvim biste ga opisali?“

Unatoč početnom oduševljenju s projektivnim tehnikama u društvenim znanostima i, osobito, unutar marketinških i drugih primijenjenih istraživanja, danas se uglavnom smatra da projektivne tehnike imaju upitna mjerna obilježja (ponajviše valjanost, pouzdanost i objektivnost). Naime, tumačenje dobivenih rezultata pod jakim je utjecajem subjektivnog dojma istraživača pa nije jasno u kojoj su mjeri rezultati valjani, a teško ih je i replicirati u drugim istraživanjima. Međutim, kako ističe Rook (2006), opravdanost primjene projektivnih tehnika ovisi o tome u kakve ih se svrhe upotrebljava. Njihova mjerna obilježja sasvim sigurno nisu dovoljno dobra za psihodijagnostiku ili bilo koju drugu primjenu koja bi imala veće posljedice na osobu koja se istražuje pomoću projektivnih tehnika. S druge strane, sama narav projektivnih tehnika koja, strogo govoreći, predstavlja slabost u znanstvenom smislu, može imati korisne primjene u nekim drugim tipovima istraživanja. Primjerice, istraživanje brandova upravo za cilj ima utvrditi klijentov vizualni i estetski doživljaj branda, a ne nužno utvrđivanje eksplicitnih stavova o brandu jer ih sam ispitanik/klijent možda i nije svjestan. Drugim riječima, fluidna i emotivna narav potrošnje može biti bolje istražena pomoću ovakvih tehnika, nego pomoću strožijih znanstvenih metoda koje su jače upućene na kognitivni dio čovjekove osobnosti. Važna je prednost projektivnih tehnika i njihova spontanost, odnosno moguće zaobilaženje socijalno poželjnih odgovora koji se javljaju u situacijama kada se od ispitanika traži da navede vlastite stavove u eksplicitnom obliku.

## DODATNA LITERATURA UZ DEVETO POGLAVLJE

Silverman, David (2010). *Qualitative Research*. London, Thousand Oaks: Sage Publications.

Knjiga objašnjava osnovna obilježja kvalitativnih metoda te načine analize i vizualizacije podataka dobivenih ovim metodama. Od konkretnih metoda, u knjizi su obrađeni promatranje (etnografija), analiza teksta, intervjui i fokus grupe te analiza konverzacije.

Lapan, Stephen D.; Quartaroli, Marylynn, T.; Riemer, Frances J. (ur.) (2012). *Qualitative Research*. San Francisco: Jossey-Bass.

Dublji pregled dijela kvalitativnih metoda koji obuhvaća osnovne kvalitativne pristupe i etiku kvalitativnih istraživanja, kao i detaljniju obradu etnografskih istraživanja, studije slučaja i feminističkih istraživanja. Knjiga daje pregled tzv. utemeljene teorije, kao načina upotrebe kvalitativnih istraživanja, odnosno načina analize podataka dobivenih pomoću njih.

## PITANJA UZ DEVETO POGLAVLJE

1. Po čemu se kvalitativne metode razlikuju od kvantitativnih metoda?
2. Na osnovi kojih dimenzija procjenjujemo obilježja kvalitativnih metoda?
3. Kako dijelimo promatranje prema stupnju strukturiranosti?
4. Kako dijelimo promatranje prema stupnju kontroliranosti?
5. Kako dijelimo promatranje prema stupnju uključenosti promatrača?
6. Na koji se način intervju razlikuje od ankete?
7. Koje se tehnike koriste za poticanje razrade mišljenja u intervjuima?
8. Što su to fokus grupe i kada ih koristimo?
9. Koliko se sudionika obično nalazi u fokus grupama i kako ih biramo?
10. Od čega se sastoji uloga moderatora u fokus grupama?
11. Kako se analiziraju podatci dobiveni u fokus grupama?
12. Po čemu se *online* fokus grupe razlikuju od *face-to-face* grupa?
13. Što je to analiza sadržaja i od kojih se elemenata sastoji?
14. Koja obilježja treba imati kvalitetna analiza sadržaja?
15. Što je to analitička matrica, a što kodna knjiga analize sadržaja?
16. Kako mjerimo pouzdanost analize sadržaja?
17. Koje sve tipove valjanosti analize sadržaja razlikujemo?
18. Što je delfi metoda i kako se upotrebljava?
19. Što je studija slučaja i koje vrste studije slučaja razlikujemo?
20. Koje su prednosti i nedostatci upotrebe studije slučaja kao metode?

# 10. PRIMIJENJENA ISTRAŽIVANJA

## 10.1. MEDIJSKA ISTRAŽIVANJA – ISTRAŽIVANJA MEDIJSKE PUBLIKE

Medijska istraživanja uključuju razna istraživanja koja mogu imati teorijsku i primijenjenu svrhu. Ako ciljevi istraživanja uključuju utvrđivanje medijskih učinaka (na koji način mediji utječu na stavove, vrijednosti i ponašanja ljudi), ili načina na koji društvene okolnosti utječu na medijske sadržaje, tada medijska istraživanja obično imaju teorijsku (znanstvenu) svrhu. U ovom poglavlju dat ćemo pregled medijskih primijenjenih istraživanja, a ona se u pravilu odnose na istraživanja medijske publike, odnosno istraživanja posjećenosti (čitanosti, gledanosti, slušanosti) medija.

Svrha ovakvih medijskih istraživanja obično je dvostruka. S jedne strane, njihova je namjera utvrditi utjecaj koji pojedini mediji imaju, a s druge strane identifikacija medijske publike ima jasne marketinške (oglašivačke) primjene. U prvom slučaju istraživanja mogućuju procjenu utjecaja pojedinog medija, a time i procjenu (ne)postojanja medijskog pluralizma. Iz tih razloga objava ovih podataka u medijima u mnogim državama predstavlja i zakonsku obvezu. Tako u Republici Hrvatskoj prema članku 14. Zakona o medijima nakladnik ima obvezu u vlastitom mediju bar jednom godišnje javnost obavijestiti ne samo o programskoj osnovi, vlasničkoj strukturi i poslovnim rezultatima, nego i o prosječnoj nakladi, odnosno prosječnoj slušanosti ili gledanosti. Kada je u pitanju čitanost tiska, ovaj podatak predstavlja i osnovu za sprječavanje nedopuštene koncentracije. Primjerice, prema hrvatskim zakonima nijedan nakladnik općeinformativnih dnevnih ili tjednih novina ne smije imati udio u prodanoj nakladi veći od 40% (članak 33. Zakona o medijima).

S druge strane, istraživanja medijske publike važna su i zbog toga što predstavljaju osnovu za oglašavanje. Naime, oglašivači mogu bolje fokusirati oglašavanje, tj. usmjeriti ga na ciljanu publiku (tržišni segment). Bez istraživačkih podataka, većina oglašivačkih planova bila bi zasnovana na nagađanju, a time bi se i povećala vjerojatnost pogrešnog oglašavanja, tj. nepotrebnog trošenja novca oglašavanjem u medijima koje prate osobe koje ne predstavljaju ciljani segment koji kupuje određeni proizvod ili uslugu.

***Važnost istraživanja medijske publike sastoji se od potrebe procjene društvenog utjecaja pojedinih medija, kao i od marketinških koristi koje se odnose na mogućnost fokusiranog oglašavanja.***

### 10.1.1. Čitanost tiskanih medija

Postoje dva osnovna indikatora čitanosti tiskanih medija: prodana naklada i istraživanja čitatelja. Oba indikatora imaju svoje prednosti i nedostatke te ih stoga valja upotrebljavati promišljeno i u kombinaciji.

***Čitanost tiskanih medija istražuje se pomoću prodane naklade te direktnog istraživanja čitatelja.***

Naklada se odnosi na broj tiskanih primjeraka novina, a prodana naklada mjeri se na način da se od broja tiskanih primjeraka koji su prodani putem pretplate, direktnom prodajom ili koji su besplatno podijeljeni oduzme remitenda, tj. broj neprodanih primjeraka koje je vratio distributer. Naklada je važan pokazatelj čitanosti osobito za oglašivačke agencije koje uz primjerke novina plasiraju svoje kataloge, reklamne letke i sl. jer im podatak o nakladi točno govori koliki broj reklamnih materijala trebaju tiskati. Zbog očite potencijalne pristranosti oglašivača u iskazivanju naklade u većim zemljama postoje nezavisna tijela (agencije) koja vrše reviziju naklade. Obično su u pitanju tripartitna tijela (nakladnici, oglašivači i marketinške agencije), a agencije provjeravaju sve relevantne podatke (broj prodanih primjeraka, broj podijeljenih primjeraka, remitendu) i donose nezavisne procjene.

Međutim, naklada nije savršena mjera čitanosti s obzirom na to da jedan primjerak novina obično pročita veći broj osoba jer je prema dosadašnjim istraživanjima broj čitatelja obično 5-6 puta veći od naklade. Stoga se kao komplementaran podatak nakladi koriste anketna (terenska ili telefonska) istraživanja kojima se nastoji procijeniti stvaran broj čitatelja. Ove ankete, za razliku od naklade, otkrivaju i sociodemografski profil čitatelja, što je ključan podatak za reklamne agencije kojima su segmentacija tržišta i fokusirano oglašavanje najvažniji. S druge strane, naklada ne omogućava izbor ciljne skupine.

Istraživanja čitanosti obično se organiziraju na tri načina te stoga u organizacijskom smislu postoje sljedeće tri vrste istraživanja čitanosti: sindicirana istraživanja, Joint Industry Research te Ad-hoc istraživanja. Sindicirana istraživanja agencija za istraživanje tržišta samoinicijativno provedu istraživanje čitanosti, čije rezultate onda prodaju većem broju korisnika (nakladnicima, reklamnim agencijama i sl.). Prednost sindiciranih istraživanja je ušteda koja se može ostvariti, jer istraživačke agencije mogu ponuditi niže cijene ako podatke prodaju većem broju korisnika (klijenata). Joint Industry Research koristi sličan postupak, no istraživanje inicira udruga nakladnika i oglašivača, koja zatim putem natje-

čaja bira agenciju koja će provesti istraživanje. Najpoznatiji je primjer ovakvog istraživanja britanska National Readership Study. Treća su vrsta istraživanja Ad-hoc istraživanja koja naručuju pojedini nakladnici kako bi detaljnije proučili profil svojih čitatelja. Ovakva su istraživanja skuplja, ali su prilagođena pojedinačnom korisniku. U Hrvatskoj trenutačno postoje objektivni podatci o prodanoj nakladi. Kada su u pitanju istraživanja čitanosti, prisutan je veći broj sindiciranih istraživanja, pojedini nakladnici rade i svoja Ad-hoc istraživanja, a Joint Industry Research ne postoji.

Postoji nekoliko metoda kojima se čitanost mjeri te nekolicina indikatora čitanosti:

1. Prosječna čitanost primjerka (eng. *average issue readership*),
2. Doseg (eng. *reach*),
3. Frekvencija.

Prosječna čitanost primjerka može se mjeriti na nekoliko načina: metoda nedavnog čitanja, metoda jučerašnjog čitanja, čitateljski dnevnici i metoda kataloga.

Prvi je način tzv. metoda nedavnog čitanja (eng. *recent reading method*), kojom se čitatelje pita kada su posljednji put pročitali primjerak nekih novina. Prosječna čitanost predstavlja broj ljudi koji su rekli da su čitali novine u relevantnom intervalu. Primjerice, za tjednik je to broj ljudi koji su rekli da su ga pročitali u nekom od posljednjih sedam dana, a za dnevnike kao puni čitatelj računa se osoba koja je novine pročitala jučer, kao pola čitatelja osoba koja je rekla da je posljednji put novine pročitala prekjučer itd. Ova metoda prikladna je i za tjednike i mjesečnike, tj. izdanja rjeđa od dnevnih. Niže je naveden primjer izračuna.

*Tablica 42. Izračun novinske čitanosti*

| **Osoba** | **Posljednje čitanje** | **Prosječno čitanje** |
|---|---|---|
| Osoba 1 | Prije 2 dana | 1/2 |
| Osoba 2 | Jučer | 1 |
| Osoba 3 | Prije 7 dana | 1/7 |
| Osoba 4 | Prije 3 dana | 1/3 |
| Osoba 5 | Nikad ne čita | 0 |

Prosječna čitanost u ovom slučaju iznosi 1,98/5 = 39,5%.

Nedostatak je ove metode pogreška prisjećanja, budući da ljudi najčešće ne mogu točno odrediti kada su posljednji put čitali novine. Kako smo ranije naveli, u slučaju odgovora na pitanja o događajima iz prošlosti događa se tzv. *telescoping*, pri čemu se davni događaji u sjećanju ispitanika obično smještaju u bližu prošlost

(eng. *forward telescoping),* a zbog takvog telescopinga prosječna se čitanost može precijeniti. U tom smislu može se reći da se dva se izvora pogreške – zaboravljanje i *telescoping* – često međusobno poništavaju jer imaju suprotne učinke.

Tzv. metodom jučerašnjeg čitanja (eng. *first read yesterday*) ispitanike se pita koje su novine prvi put čitali jučer. Metoda jučerašnjeg čitanja osigurava bolje prisjećanje jer se sudionike pita samo za jučerašnji dan. Neprikladna je za tjednike, mjesečnike i rjeđa izdanja jer zahtijeva velike uzorke. Primjerice, čitateljstvo mjesečnika raspoređuje se na 30 dana pa "hvatamo" samo 1/30 dio njih. Broj čitatelja u ovoj metodi odnosi se na postotak ljudi koji su novine čitali jučer. Primjerice, ako je 20% ljudi reklo da su neke novine posljednji put čitali jučer, tada čitanost iznosi 20%.

Treća su metoda čitateljski dnevnici, koje čitatelji vode i u koje upisuju koje su novine čitali, gdje su ih nabavili, tko ih je sve čitao, kakav je dojam o njima i sl. Stavovi o novinama i sociodemografske informacije o čitateljima nisu nužan dio dnevnika, ali se obično prikupljaju.

Tzv. metoda kataloga (eng. *through the book*) radi se tako da se čitateljima pokaže primjerak novina ili naslovne stranice, te da se od njih traži da se prisjete jesu li čitali taj primjerak novina. Ova metoda preciznija je od uobičajenih terenskih ili telefonskih istraživanja, ali je također vrlo skupa jer se mora provesti terenskim putem.

Druga je važna mjera čitanosti tzv. doseg (eng. *reach*). Mjerenje čitanosti dosega kao i u slučaju drugih medija predstavlja broj ili omjer (postotak) ljudi koji su u određenom vremenskom razdoblju barem jednom pročitali određene novine. Ovaj se broj razlikuje od prosječne čitanosti, odnosno obično je puno veći. Npr. ako su osoba A i osoba B neke novine čitali u ponedjeljak, a osoba C i osoba D u utorak, prosječna čitanost iznosi 2, ali je doseg 4 jer je ukupan broj osoba koji su novine pročitali u ova dva dana 4. Doseg i prosječna čitanost bili bi isti samo kad bi potpuno iste osobe čitale određene novine svaki dan.

*Tablica 43. Ilustracija dosega i prosječne čitanosti*

| **Dan** | **Osobe koje su čitale** | **Prosječna čitanost** | **Ukupan doseg** |
|---|---|---|---|
| Ponedjeljak | A i B | 2 osobe | 4 osobe (osobe A, B, C i D) |
| Utorak | C i D | 2 osobe | |

I na kraju, frekvencija predstavlja mjeru broja čitanja novina prosječnog čitatelja u određenom vremenskom razdoblju. Drugim riječima:

Frekvencija = prosječna čitanost X broj izdanja / doseg

Frekvencija se dobiva kada se prosječna čitanost i broj izdanja pomnože, pri čemu se dobiva broj čitanja (impresije, eng. *impressions*) te se ovaj broj podijeli s dosegom, tj. ukupnim brojem čitatelja u tom razdoblju. Za gornji bi primjer frekvencija iznosila 2X2/4 = 1, budući da je svaki čitatelj novine u prosjeku pročitao samo jednom u istraživana dva dana.

Poseban je problem u istraživanjima tiskanih medija potrebni uzorak, koji mora biti prilično velik. Naime, mnoge tiskovine imaju relativno malu nakladu pa bi u slučaju malog uzorka bilo nemoguće procijeniti njihovu čitanost. Uzmimo da neki magazin u Hrvatskoj u prosjeku čita 5 000 ljudi tj. da ga čita otprilike 0,1% svih punoljetnih stanovnika. Tada ćemo u uzorku od 1 000 sudionika istraživanja vjerojatno naići na samo jednog čitatelja tog magazina te tako procjena čitanosti postaje vrlo nepouzdana. Rješenje je da se rezultati mjesečnih istraživanja obično prikazuju u šestomjesečnom ili godišnjem obliku. Ovakav postupak povećava uzorak, ali podatci postaju nešto manje aktualni (tj. stariji). Treba postići kompromis između potrebe preciznosti i potrebe aktualnosti, što ovisi o parametrima konkretne situacije (koliki je broj tiskovina s malom nakladom, mijenja li se čitanost brzo i sl.).

### 10.1.2. Posjećenost interneta

Mogu se izdvojiti četiri načina mjerenja posjećenosti interneta: podatci koji su automatski generirani pomoću skripti na mrežnim stranicama, online (pop-up) ankete na mrežnim stranicama, offline istraživanja te internetski paneli koji se služe programima instaliranim na računala korisnika.

***Posjećenost interneta najčešće se mjeri automatskim metodama, no upotrebljavaju se i anketa na mrežnim stranicama, offlina istraživanja te internetski paneli.***

Skripte na mrežnim stranicama automatski, odnosno bez znanja i aktivnosti posjetitelja bilježe određene podatke poput broja posjetitelja, broja posjećenih stranica, vremena provedenog na određenoj stranici i sl. Svaki put kada računalo pošalje zahtjev za stranicom, server zabilježi određene podatke. Online (pop-up) ankete zahtijevaju suradnju posjetitelja, kojemu se prilikom posjeta određene stranice pojavi zahtjev za sudjelovanjem u istraživanju. Ova vrsta istraživanja omogućuje prikupljanje sociodemografskih podataka o posjetiteljima (dob, spol,

imovinski status, mjesto stanovanja, interesi i sl.), pa predstavlja važnu dopunu automatski generiranih podataka. Offline ankete obično se rade terenskim i telefonskim putem, prilikom čega se ispitanicima postavljaju pitanja o korištenju interneta. Ove ankete izbjegavaju poteškoće vezane uz online mjerenje, ali su problematične zbog pogrešaka prilikom prisjećenja ispitanika tj. ispitanici precizno ne mogu odrediti vrijeme i načine vremena provedenog na internetu. Internetski paneli rade se na način da korisnici pristanu na instalaciju programa koji mjere posjećenost stranica na svome računalu. Nedostatak je internetskih panela njihova visoka cijena, jer je korisnike potrebno financijski motivirati za sudjelovanje u istraživanju. Zbog toga se ova metoda primjenjuje samo na većim tržištima.

Najčešći su indikatori internetske posjećenosti:

1. Doseg (eng. *reach*),
2. Broj posjeta stranici (eng. *page view*),
3. Broj zahtjeva upućenih web-serveru (eng. *hits*),
4. Prosječno trajanje posjeta web-stranicama,
5. Vremenski udjel (eng. *time share*),
6. Indeks afiniteta (eng. *affinity indeks*).

Doseg (eng. *reach*) predstavlja broj ljudi koji su barem jednom posjetili određenu web-stranicu u nekom razdoblju podijeljen s ukupnim brojem ljudi koji su koristili internet u tom razdoblju.

Drukčije rečeno, doseg predstavlja udio posjetitelja neke stranice u ukupnom broju korisnika interneta u nekom razdoblju. Doseg se često računa i kao omjer ukupnog broja posjetitelja i ciljane populacije. Dakle, broj posjetitelja ne dijeli se samo s posjetiteljima interneta, nego s općom populacijom.

Broj posjeta stranici (eng. *page view*) odnosi se na posjećenost svih stranica unutar neke lokacije. Web-lokacije obično se sastoje od više stranica (www dokumenata), a ovaj indikator mjeri koliko je tih stranica posjećeno na web-lokaciji. Ovaj indikator obično se mjeri skriptama smještenim na web-stranicama.

Broj zahtjeva upućenih web serveru (eng. *hit*) odnosi se na svaki zahtjev, neovisno o njegovoj vrsti. Naime, mjeri se svaki zahtjev upućen serveru prilikom posjeta jednoj stranici. Primjerice, ako na jednoj stranici s koje se šalje email korisnik napiše poruku i pošalje ju, u pitanju su dva hita. Prvi se zahtjev odnosio na pisanje poruke (gumb „compose"), a drugi na slanje (gumb „send").

Prosječno trajanje posjeta web-stranicama označava prosječno trajanje vremena posjeta stranicama unutar neke web-lokacije.

Vremenski udjel (eng. *time share*) predstavlja vrijeme provedeno na nekoj stranici podijeljeno s ukupnim vremenom provedenom na internetu u nekom razdoblju.

Indeks afiniteta predstavlja vjerojatnost da će posjetitelj jedne stranice posjetiti drugu stranicu u usporedbi s prosječnim korisnikom interneta. Primjerice, indeks afiniteta 2X kaže da je dva puta vjerojatnije da će posjetitelj neke stranice A posjetiti stranicu B u usporedbi s vjerojatnošću da će posjetitelji drugih stranica posjetiti stranicu B. Dakle, ovaj indeks označava sličnost publike dviju stranica.

Tumačenje odnosa posjećenosti pojedinih stranica nije jednostavno. Tako će stranice čiji su osnovni sadržaj dnevne vijesti imati veći broj posjeta, ali će korisnici prilikom posjeta otvoriti manji broj stranica (nove vijesti koje ih zanimaju). Stranice koje imaju analitički usmjerene sadržaje često će imati manji broj posjetitelja, ali će oni otvoriti veći broj stranica i duže se zadržati na njima.

### 10.1.3. Televizijska gledanost

Mjerenje televizijske gledanosti (eng. TAM – *television audience measurement*) danas se najpreciznije radi pomoću uređaja koji se naziva *peoplemeter*. Ovaj se uređaj instalira u kućanstvima i automatski mjeri gledanost televizijskih kanala. Prije stvaranja panela i instaliranja uređaja napravi se terenska anketa koja donosi pregled sociodemografskih obilježja populacije (veličina kućanstva, broj TV-prijemnika, mjesto stanovanja, regionalna pripadnost i sl.). Na temelju ove ankete stvara se panel kućanstava koji su reprezentativni za cijelu populaciju, odnosno predstavljaju stratificirani uzorak populacije. Nakon određivanja kućanstava koja sudjeluju u panelu, na svaki TV-prijemnik u kućanstvima instalira se *peoplemeter*, koji podatke o gledanosti šalje najčešće noću putem telefonske linije. Zadatak kućanstava koja sudjeluju u panelu je da prilikom gledanja TV-programa označe koje od osoba u kućanstvu ga gledaju. Najpoznatija je agencija u svijetu kada su u pitanju istraživanja televizijske gledanosti AGB Nielsen. Prednost je peoplemetra brzina prikupljanja podataka i njihova točnost.

***Televizijska se gledanost u pravilu mjeri pomoću automatiziranih uređaja.***

Veliki nedostatak automatskog mjerenja predstavlja činjenica da će peoplemeter bilježiti gledanje čak i onda kada je osoba prisutna, ali ne obraća pozornost na televizijski program.

Drukčije rečeno, osoba može spavati, čitati knjigu..., no svejedno će biti zabilježena kao gledatelj.

Kao indikatori televizijske gledanosti mogu se izdvojiti:

1. Rejting (eng. *rating*),
2. Doseg (eng. *reach*),
3. Udio (eng. *share*).

Rejting predstavlja udio ljudi koji su gledali određenu televizijsku emisiju u ukupnom broju ljudi na određenom području. Primjerice, ako je neku emisiju gledalo 250 000 ljudi, a ukupan broj ljudi (koji najčešće isključuje malu djecu) na nekom području iznosi 1 000 000, tada rejting iznosi 25%. Rejting se danas računa na način koji je precizniji od prethodno opisanog jer se ne uzima u obzir samo koliko je ljudi gledalo neki program, nego i koliko dugo su ga gledali. Izračuna se prosječni broj gledatelja po minuti, pri čemu se gledatelj koji je program gledao sve vrijeme računa kao 1 gledatelj, onaj koji je gledao pola vremena kao 0,5 gledatelja itd. Slijedi primjer ovakvog izračuna.

*Tablica 44. Primjer izračuna televizijske gledanosti*

| **Gledatelj** | **Početak** | **Kraj** | **Ukupno minuta** |
|---|---|---|---|
| A | 8:30 | 8:40 | 10 |
| B | 8:46 | 8:50 | 4 |
| C | 8:30 | 8:35 | 5 |
| D | 8:33 | 8:58 | 25 |
| E, F, G, H, I, J | - | - | - |

U ovom primjeru prosječan broj gledatelja po minuti iznosi 10/30 + 4/30 + 5/30 + 25/30 = 1,47, a rejting je (1,47/10)*100 = 14,7%.

Udio (eng. *share*) predstavlja postotak ljudi koji su u određenom intervalu gledali neku emisiju u ukupnom broju ljudi koji su u tom intervalu gledali televiziju. Preciznije ga se može izraziti, ako takvi podatci postoje, kao udio vremena koje su gledatelji posvetili gledanju neke postaje u ukupnom vremenu posvećenom gledanju televizije.

Doseg (eng. *reach*) predstavlja ukupan broj ljudi koji su gledali neki program ili TV-postaju u nekom vremenskom intervalu, pri čemu se svaki gledatelj računa samo jedanput. Predstavlja važan element procjene javnih medija zbog toga što je njihova uloga „pokrivanje" svih slojeva populacije, a zbog toga se izrađuje sociodemografska segmentacija dosega.

### 10.1.4. Radijska slušanost

Najbolji podatci o radijskoj slušanosti dobiju se ispunjavanjem dnevnika. Dnevnici se sastoje od tablica u kojima su radijske postaje prikazane u stupcima, a vremenski intervali u redcima, pri čemu vremenski intervali mogu ići od 15 minuta do cijeloga dana. Slušatelj ima zadatak označiti vremenske intervale u kojima je slušao/la određenu radijsku postaju.

„Slušanje" se definira na vrlo različite načine, pa tako može uključivati slušanje kao najvažniju djelatnost u nekom trenutku ili običnu prisutnost u prostoriji kada je radio uključen. Različite definicije dat će vrlo različite procjene slušanosti, a u praksi se obično koriste vrlo ekstenzivne definicije slušanja, koje upravo uključuju prisutnost u prostoriji (ili automobilu) u trenutku kada je radio uključen.

Nedostatci su metode dnevnika sporost prikupljanja i obrade podataka te podcjenjivanje udjela manjih postaja. Prikupljanje podataka traje dugo te radijske postaje podatke o slušanosti dobivaju s većim vremenskim odmakom. Manje se postaje podcjenjuju jer se ljudi koji popunjavaju dnevnike lakše prisjete poznatijih postaja koje češće slušaju od malih postaja koje slušaju usputno. Naime, kada nisu sigurni koju su postaju slušali, ljudi češće unesu veću i poznatiju postaju. Druge metode nude manju preciznost od metode dnevnika, ali znatno manje koštaju, pa se uglavnom upotrebljavaju za istraživanja na manjim tržištima (poput npr. Hrvatske). Tako se npr. u telefonskim, terenskim ili online istraživanjima radijska slušanost obično procjenjuje postavljanjem pitanja: „Jeste li proteklog dana slušali neku od ovih radijskih postaja?" Ili: „Koju radijsku postaju najčešće slušate?" U novije se vrijeme počinje primjenjivati i uređaj koji slušanost mjeri automatski – tzv. audiometer. Predstavlja napravu, obično sličnu ručnom satu, koja automatski mjeri slušanost radijskih postaja. Zabilježeni audio signal pretvara se u digitalni signal i elektronički se uspoređuje sa snimljenim signalima pojedinih postaja. Prema drugoj verziji, postaje koje sudjeluju u istraživanju u emitirani signal ugrade i signal koji audiometer prepoznaje (npr. Arbitronov Portable People Meter). Ovaj je uređaj vjerojatno precizniji od metode dnevnika, ali je i znatno skuplji. Usporedbe podataka iz dnevnika i audiometara pokazuju da dnevnici podcjenjuju doseg, ali i precjenjuju rejting postaja. Drukčije rečeno, ljudi koji popunjavaju dnevnike ponekad zaboravljaju postaje koje su slušali, ali znatno uvećaju vrijeme u kojem su ih slušali. Doseg je obično manji za oko 5%, a rejting je veći od onoga zabilježenog audiometrom čak i do 50%. Kao i pri automatskom mjerenju televizijske gledanosti, i audiometri imaju nedostatak da ne mjere stvarnu uključenost osobe koja sluša radio, nego samo prisutnost u prostoriji. Stoga bi metoda dnevnika mogla u tom smislu biti točnija jer ljudi bilježe

u dnevnik samo one postaje koje su slušali s višom razinom pozornosti pa su ih stoga i zapamtili. S druge strane, izrazito precjenjivanje broja minuta slušanja programa pokazuje da ovaj argument vjerojatno nije točan. Nadalje, audiometri točnije prepoznaju glas s radija nego radijsku glazbu. Stoga postaje s puno govora u programu imaju nešto bolje rezultate od postaje s manje govora, a više glazbe. Dakle, točnost automatskog bilježenja slušanosti još nije posve dokazana u istraživanjima. Dodatni je nedostatak da ljudi ne nose audiometre sve vrijeme tj. ne stavljaju ih odmah ujutro nakon buđenja, kao i da bilježenje svih zvukova uključuje i kršenje privatnosti.

***Radijska slušanost najčešće se mjeri automatiziranim uređajima ili dnevnicima.***

Kada su u pitanju indikatori radijske slušanosti, mogu se izdvojiti: prosječna slušanost (rejting), doseg, frekvencija i udio.

Prosječna slušanost radija (rejting) definira se kao omjer broja ljudi koji su slušali neku postaju u određenom vremenskom intervalu i ukupnog broja ljudi na tom području. Npr. ako je u vremenskom intervalu u od 6 do 7 sati ujutro neku postaju slušalo 10 000 ljudi, a ukupni je broj ljudi na tom području 100 000, tad je prosječna slušanost 10%. Doseg (eng. *reach*) se definira kao broj ljudi koji je slušao neku postaju u nekom vremenskom intervalu, pri čemu se svaki pojedinac računa samo jedanput. Primjerice, ako je od 6 do 7 sati neku postaju slušalo 10 000 ljudi, a od 7 do 8 sati također 10 000 ljudi, tada je prosječna slušanost po satu 10 000 ljudi. Međutim, ako su svi pojedinci koji su postaju slušali od 6 do 7 sati prestali je slušati u drugom intervalu (7 do 8 sati), tj. od 7 do 8 sati postaju je slušalo potpuno drugih 10 000 ljudi, tada doseg iznosi 20 000 ljudi. Drugim riječima, u razdoblju od 6 do 8 sati tu postaju slušalo je 20 000 različitih ljudi. Različiti dosezi mogu predstavljati vrlo važan podatak za oglašivače jer u osnovi određuju koliki će broj različitih ljudi čuti određenu reklamnu poruku u nekom vremenskom intervalu. Veći će doseg, uz istu prosječnu slušanost, značiti da će veći broj ljudi čuti poruku manje puta, dok će manji doseg značiti da će manji broj ljudi čuti poruku, ali više puta. Frekvencija se izračuna na sličan način kako je to opisano u istraživanju čitanosti, tj. predstavlja omjer broja prikazivanja (impresija) i dosega. Ova je mjera osobito važna u marketinškom smislu jer označava koliko je puta prosječni slušatelj čuo neku reklamnu poruku.

Udio (eng. *share*) mjeri se kao broj sati u kojima slušatelji u nekom intervalu slušaju neku postaju podijeljen s ukupnim brojem sati koje ljudi na nekom području provedu slušajući radio.

Primjerice, ako su na nekom području u određenom tjednu ljudi slušali radio ukupno 100 000 sati (npr. 100 000 ljudi slušali su u prosjeku po jedan sat tjedno), a neku postaju ukupno 10 000 sati, tad udio te postaje iznosi 10% ukupne slušanosti.

S obzirom na to da mnoge postaje imaju ograničeni broj slušatelja, kao i da su geografski koncentrirane, i pri istraživanju radijske slušanosti veličina uzorka može biti otežavajući čimbenik. Mnoge male postaje mogu biti obuhvaćene malim brojem ispitanika u uzorku, pa varijacije u podatcima o njihovoj slušanosti mogu biti izrazito velike. Ovakvi nedostatci mogu se izbjeći većim uzorkom, no na manjim tržištima ovo je često neisplativo.

### 10.1.5. Marketinški medijski indikatori

Temeljni indikator iz kojeg se izvode mnogi drugi predstavlja tzv. prikazivanje. Prikazivanje (eng. *impression*, *impact*) predstavlja indikator koji pokazuje marketinšku učinkovitost prikazane poruke, a označava koliko je puta neka reklamna poruka primijećena. Npr., ako je u nekom intervalu u kojemu je slušanost postaje iznosila 10 000 ljudi poruka emitirana jedanput, a u intervalu u kojemu je slušanost iznosila 15 000 dvaput, tada je ukupan broj prikazivanja 40 000 (10 000 * 1 + 15 000 * 2).

Iz ove se mjere obično računa tzv. trošak po tisući (eng. *cost per thousand*). Ova se mjera definira kao omjer ukupnog troška i ukupnog broja prikazivanja, pomnožen s tisuću, a označava trošak 1 000 prikazivanja (impresija). Npr. ako je broj prikazivanja 40 000, kao u gornjem primjeru, a ukupni je trošak plaćenih reklama 40 000 kuna, tada trošak po tisući iznosi 1 000 kuna (40 000/40 000*1 000). Trošak po tisući može se računati i s dosegom u nazivniku. Drukčije rečeno, u tom slučaju predstavlja trošak dostizanja tisuću ljudi. Primjerice, ako je ukupan trošak kampanje bio 100 000 kuna, a dosegnuto je 10 000 ljudi (barem jednom su vidjeli reklamu), trošak po tisući iznosi 10 000 kuna.

Trošak po tisući obično se koristi kao standard za usporedbu isplativosti promidžbe u različitim postajama, koje imaju različitu gledanost/slušanost/čitanost, ali i različite troškove oglašavanja. Pri tome se biraju oni mediji koji imaju manji trošak po tisući. Obično se uspoređuju različiti nakladnici istog medija (npr. dviju TV-postaja), dok je usporedba različitih medija znatno manje pouzdana. Primjerice, teško je pretpostaviti da jedno prikazivanje ima isti marketinški učinak na televiziji i internetu, s obzirom na to da su reklamne poruke na internetu najčešće manje uočljive, tj. imaju manji učinak od televizijskog oglašavanja.

Sljedeći se indikator izvodi iz rejtinga i frekvencije, a naziva se bruto rejting-bod. Ovaj se indikator u marketingu također koristi za usporedbu različitih medija, a predstavlja sumu svih rejting bodova koju je dobio neki sadržaj tijekom nekog vremena (*media schedule*). Računa se množenjem rejtinga i frekvencije emitiranja. Primjerice poruka koja je emitirana četiri puta, a svaki put ju je vidjelo 25% ukupne populacije, nosi 100 bruto rejting bodova. Bruto rejting-bodove ciljne skupine računamo množenjem rejtinga publike iz ciljne skupine i frekvencije emitiranja. Primjerice, poruka koja je emitirana četiri puta, a svaki put ju je vidjelo 25% populacije između 20 i 30 godina, nosi 100 bruto rejting bodova u ovoj ciljnoj skupini. Trošak po bruto rejting-bodu, kako sâmo ime kaže, računa se kao trošak kupovine jednog bruto rejting boda. Na primjer, ako smo za kampanju potrošili 100 000 kuna, a postignuto je 10 bruto rejting bodova, trošak jednog boda iznosi 10 000 kuna.

Planirani doseg predstavlja doseg koji se želi ostvariti nekom kampanjom (eng. *plan reach*). Obično se računa postotak ostvarenosti planiranog dosega. Primjerice, neku je reklamu na jednoj postaji vidjelo 1 000, a na drugoj 2 000 ljudi, pri čemu je 500 ljudi vidjelo reklamu i na jednoj i na drugoj postaji. U tom slučaju doseg iznosi 2 500 ljudi. Ako je planirani doseg 10 000 ljudi, ostavreno je 25% plana.

Efektivna frekvencija predstavlja prosječan broj puta gledanja reklame da bi ona bila učinkovita, a procjenjuje se na osnovi parametara koji se tiču samog brenda, medijskih parametara te komunikacijskih parametara. Svakom parametru daje se određena težina.

Indeks afiniteta računa se kao omjer rejtinga u našoj ciljnoj skupini i ukupnog rejtinga.

Npr. ako neku reklamu u nekom tjednu vidi 5% populacije, ali i 10% populacije koja nas zanima (npr. mlađi od 30 godina), tada indeks afiniteta iznosi 2. Dakle, ovaj indikator označava prilagođenost medija našoj ciljnoj skupini.

## 10.2. ISTRAŽIVANJA TRŽIŠTA

Istraživanja tržišta odnose se na primjenu znanstvenih spoznaja prilikom donošenja odluka vezanih za elemente tzv. marketinškog spleta (miksa). U tom smislu, sve faze istraživačkog procesa koje objašnjavamo u ovoj knjizi odnose se i na ovu vrstu istraživanja. Stoga ćemo samo navesti kratki pregled sadržajnih

specifičnosti primjene istraživanja tržišta, kao i objašnjenje specifičnih načina prikupljanja podataka koji se primjenjuju u istraživanjima tržišta.

***Istraživanja tržišta odnose se na primjenu znanstvenih spoznaja prilikom donošenja odluka vezanih za elemente tzv. marketinškog spleta.***

Istraživanja tržišta ponekad se razlikuju od marketinških istraživanja u širem smislu te riječi, pri čemu se ova prva prije svega bave tržištem, a ova druga procesom marketinškog odlučivanja, odnosno samim marketingom u cjelini. U tom smislu sva su istraživanja tržišta istovremeno i marketinška istraživanja jer imaju za cilj bolje marketinško odlučivanje, no ne odnose se sva marketinška istraživanja na istraživanje tržišta. Kao primjer se može uzeti istraživanje razlika u uspješnosti pojedinih prodavača ili prodajnih tehnika, pri čemu bi u tom slučaju bilo riječ o marketinškim istraživanjima, a ne o istraživanjima tržišta. No oba su ova procesa međusobno vrlo povezana i u konačnici za cilj imaju prilagodbu pojedinih elemenata marketinškog spleta kako bi se ostvarili što bolji rezultati na tržištu. Upravo zbgo toga ovdje za obje vrste istraživanja upotrebljavamo izraz „istraživanje tržišta", imajući u vidu i da se ovaj izraz u Hrvatskoj uobičajeno upotrebljava u ovakvom semantičkom dosegu.Marketinški se splet obično dijeli na četiri elementa: proizvod, cijena, distribucija, promocija, koji se obično označavaju kraticom 4 P (eng. *product, price, place, promotion*). U skladu s time, i istraživanja se tržišta mogu podijeliti na istraživanja koja se bavi pojedinim elementima marketinškog spleta (Proctor, 2005). Tako će se istraživanja proizvoda najčešće baviti načinom kako potencijalni potrošači vide upotrebu proizvoda (jednostavnost i praktičnost), njegove dobre i loše strane (npr. okus, kvaliteta, pakiranje i sl.), a ovaj je tip istraživanja osobito koristan kada se testira koncept proizvoda prilikom namjere uvođenja novog proizvoda na tržište. Istraživanja koja se odnose na cijenu u pravilu se bave prihvatljivom cijenom koju su potrošači spremni platiti za neki proizvod, koliko su spremni platiti za pojedine varijante nekog proizvoda, odnosno cjenovnom elastičnošću – koliko će se smanjiti potrošnja nekog poizvoda ako mu se cijena poveća za određeni iznos. Istraživanja koja se bave distribucijom uglavnom nastoje utvrditi najbolji prodajni kanal nekoga proizovda, odnosno na koji će način najlakše doći do potrošača (gdje i zašto potrošači kupuju određeni proizvod). Istraživanja koja se bave promocijom povezana su s medijskim istraživanjima te nastoje naći najbolji način promocije određenog proizvoda, pri čemu se najčešće testiraju pogodnost nekog medija za

promociju proizvoda ili sama promotivna poruka, odnosno njezina učinkovitost u stvaranju pozitivnog dojma i namjere kupovine proizvoda.

Kako je navedeno, istraživanja tržišta uključuju i neke specifične vrste prikupljanja podataka, kao što su testovi na centralnoj lokaciji, testovi u kućanstvima, simulirana tržišta te paneli. Testovi na centralnoj lokaciji (eng. *hall test*) obično se primjenjuju u trgovačkim centrima i sličnim komercijalnim objektima, pri čemu se sudionicima predloži da sudjeluju u istraživanju u kojem obično isprobavaju neku novu vrstu proizvoda te o njemu iznose vlastito mišljenje. S obzirom na to da se ovakva istraživanja upotrebljavaju za utvrđivanje brzog dojma o proizvodu (npr. okus ili pakiranje), za utvrđivanje dojma koji nastaje dugotrajnijom upotrebom stoga se obično upotrebljavaju testovi u kućanstvima (eng. *placement test*). U njima se sudionicima daje neki proizvod na dugotrajniji upotrebu te se nakon toga istraži njihove dojmove i iskustva. Simulirana tržište (eng. *simulation markets*) mogu se primijeniti u dva načina. u jednom je slučaju riječ o eksperimentalnoj situaciji u kojoj se na stvarnim tržištima mijenjaju pojedini elementi marketinškog spleta te se utvrđuju promjene u tržišnim rezultatima. Jednostavan bi primjer bio primjena dvaju različitih cijena istog proizvoda na dvama usporedivim tržištima kako bi se utvrdilo kako će različite cijene utjecati na prodaju, odnosno koja od tih cijena dovodi do profitabilnijeg poslovanja. Drugi način primjene simuliranih tržišta bio bi laboratorijski eksperiment u kojemu bi se varirale osobine proizvoda te se na temelju odluke o simuliranoj kupnji utvrdilo koliko su pojedine osobine proizvoda važne za kupnju. I na kraju, paneli su također specifična vrsta prikupljanja podataka koja se često upotrebljava u istraživanjima tržišta. Najčešći su tzv. paneli kućanstava u kojima kućanstva koja sudjeluju u istraživanju popunjavaju dnevnike u koje unose detalje o kupovini svih članova kućanstva. Danas se takva istraživanja sve češće pomoću specijaliziranih uređaja, pri čemu se kupljene namirnice mogu skenirati pomoću barkodova ili na druge načine, a što znatno olakšava sudjelovanje u ovakvim istraživanjima. Imajući u vidu zahtjevnost sudjelovanja, u panelima i drugim ranije navedenim istraživanjima tržišta sudionici istraživanja vrlo se često nagrađuju za sudjelovanje na odgovarajući način (novčano ili davanjem kupona za kupovinu određenih proizvoda).

## DODATNA LITERATURA UZ DESETO POGLAVLJE

Malhotra, Naresh K.; Birks, David F. (2006). *Marketing Research: An Applied Approach*. Harlow: Pearson Education.

Knjiga donosi sveobuhvatan pregled svih faza istraživanja, s osobitim naglaskom na tehnike mjerenja u kvantitativnim i kvalitativnim istraživanjima. Sve tehnike ilustriraju se većim brojem primjera iz istraživanja tržišta. Završni dio knjige sadrži multivarijatne tehnike analize podataka iz istraživanja tržišta, kao što su faktorska i klasterska analiza.

Mytton, Graham; Diem, Peter; van Dam, Piet Hein (2016). *Media Audience Research*. Los Angeles: Sage Publications.

Knjiga obuhvaća sve faze istraživačkog procesa u istraživanjima medija, osobito kada su u pitanju istraživanja medijske publike, kao i nove online tehnologije koje se upotrebljavaju prilikom istraživanja upotrebe medija.

Proctor, Tony (2005). *Essentials of Marketing Research (Fourth Edition)*. Harlow: Pearson Education.

Knjiga povezuje sve etape istraživačkog procesa (istraživačke nacrte, uzorkovanje, mjerenje, analiza podataka) ilustrirajući ih pomoću primijenjenih istraživanja tržišta te pokazujući njihovu ulogu u sustavu podrške prilikom marketinškog odlučivanja.

## PITANJA UZ DESETO POGLAVLJE

1. Čemu sve služe istraživanja medijske publike?
2. Kako se mjeri televizijska gledanost i koji se indikatori upotrebljavaju pri tome?
3. Kako se mjeri radijska slušanost i koji se indikatori upotrebljavaju pri tome?
4. Kako se mjeri posjećenost interneta i koji se indikatori upotrebljavaju pri tome?
5. Kako se mjeri novinska čitanost i koji se indikatori upotrebljavaju pri tome?
6. Što su to istraživanja tržišta i čemu služe?

# 11. KLASIFIKACIJA ZNANSTVENIH RADOVA

Rezultati znanstvenih projekata u okviru kojih se poduzimaju različita znanstvena istraživanja jesu znanstveni i stručni radovi. Iako se završetak nekog znanstvenog istraživanja podrazumijeva kao pisanje izvještaja o samom istraživanju, njegovim fazama i konačnim rezultatima, kako bi se zadovoljila obveza prema naručitelju istraživanja ipak se očekuje za širu znanstveno i stručnu javnost objavljivanje znanstvenih potignuća u obliku pisanih radova. To mogu biti radovi objavljeni kao cjelovite *knjige*, kao *poglavlja u knjizi* (zborniku radova vezanom uz temu istraživanja) ili kao *članci* objavljeni u znanstvenim i stručnim časopisima. Također postoji potreba znanstvene i stručne javnosti i za *znanstveno-stručnim priručnicima* koji će poslužiti lakšem snalaženju u obilju znanstvene građe koja je danas dostupna. Svaki od spomenutih oblika pisanih djela koristi *znanstvenu metodologiju istraživanja*, te *ima ili nema znanstveni doprinos*. Prema razlici u znanstvenom doprinosu dijele se znanstvena od stručnih djela.

***Postoje razne vrste znanstvenih radova, a od stručnih ih radova odvajamo zbog razlike u znanstvenom doprinosu.***

## 11.1. ZNANSTVENE KNJIGE

Znanstvenici, bilo kao pojedinci ili u suradnji s drugim znanstvenicima, nakon višegodišnjeg istraživačkog rada na određenom predmetu najčešće objedinjuju postignute spoznaje u obliku znanstvene studije. Također, vezani istim predmetom istraživanja (u okviru znanstvenih projekata), a okupljeni na znanstvenim skupovima, znanstvenici svoja istraživanja objavljuju i kao zasebna poglavlja u knjigama-zbornicima koji su rezultat izlaganja i rasprava na znanstvenim skupovima.

**Znanstvena monografija** cjelovita je znanstvena studija ili znanstveni rad koji je rezultat višegodišnjeg znanstvenog bavljenja autora, ili skupine autora, određenim predmetom istraživanja. Predmeti koji se istražuju i predočavaju javnosti u znanstvenim monografijama mogu biti različiti: neki *događaji* (iz dalje i bliže prošlosti, iz suvremenosti, događaj vezan uz znanost, umjetnost, politiku i sl.), *osobe* (iz znanosti, filozofije, umjetnosti, književnosti, povijesnih previranja, sporta i sl.), *mjesta* (grad, selo, regija, stjecište ključnih prometnica, povijesna lokacija i sl.), *procesi i promjene* (kemijski, fizikalni, astronomski i sl.), *običaji* (folkloristika nekog kraja, etnološka građa i sl.) i sve drugo što može biti predmet

znanstvenog istraživanja, a prema kojemu se razlikuju znanstvena područja, polja, grane i ogranci. Znanstvena monografija, kao i svaki drugi znanstveni članak, studija ili izvještaj, poštuje sva znanstveno-istraživačka i metodološka pravila znanstvenog rada.

**Znanstveni zbornici** jesu knjige sastavljene od više zasebnih radova različitih autora koji su povezani istim predmetom istraživanja ili problematikom vezanom uz isti predmet. Znanstveni zbornici najčešće nastaju poslije tematski planiranog i održanog znanstvenog skupa, ali mogu biti i rezultat rada više znanstvenika na nekom znanstvenom projektu, ili na više projekata koje povezuje problematika vezana uz isti predmet istraživanja. Kako se u njima iznesene znanstvene spoznaje daju prvi put na uvid znanstvenoj i stručnoj javnosti, takvi zbornici, kao i znanstvene monografije, spadaju u *primarne izvore* informacija.

**Doktorski rad** (disertacija) posebna je vrsta znanstvenog djela koje je nastalo samostalnim istraživanjem kandidata uz stalnu stručnu pomoć i vođenje mentora. Doktorski rad treba imati obilježja izvornog znanstvenog rada kada je riječ o odabiru predmeta i cilja istraživanja, primjeni znanstvenih metoda i tehnika, korištenju izvora informacija (primarnih, sekundarnih i tercijarnih) te dolaženja do novih znanja koja predstavljaju znanstveni doprinos disertacije. Vrlo često se doktorski radovi objavljuju kao znanstvene monografije.

## 11.2. ZNANSTVENI ČLANCI

Najčešći oblik izvještavanja javnosti (znanstvene i stručne, ali i ostale) o rezultatima nekog znanstvenog istraživanja jesu *znanstveni članci*. Oni se uglavnom objavljuju u znanstvenoj periodici,[82] ali i u specijaliziranim zbornicima radova koji su povezani s istraživanom temom. Kako su znanstveni članci pisani s različitim ciljevima – da izvjeste javnost o završnim rezultatima istraživanja, ili o početnim rezultatima, ili da prikažu postojeće spoznaje o određenoj temi, ili da stručno opišu neku pojavu i sl. – tako se i međusobno razlikuju prema *znanstvenom doprinosu*. Slijedeći taj kriterij postoji vrlo raširena UNESCO-va klasifikacija

[82] Znanstvena (ili stručna) periodika jesu časopisi koji se tiskaju periodično (mjesečno, tromjesečno, polugodišnje ili godišnje). Svaki svezak časopisa ima broj godišta izlaženja (volumen) i broj u godištu. Najčešće su pokretači i izdavači znanstvene i stručne periodike znanstveni instituti i fakulteti (npr. časopis „Društvena istraživanja" izdaje Institut društvenih znanosti Ivo Pilar u Zagrebu, časopis „Socijalna ekologija" izdaje Odsjek za sociologiju Filozofskog fakulteta u Zagrebu, časopis „Ekonomski vjesnik" izdaje Ekonomski fakultet u Osijeku).

znanstvenih radova – izvorni znanstveni rad, prethodno priopćenje, pregledni rad – koju ćemo proširiti dodajući joj izlaganje sa znanstvenog skupa i stručni rad.

**1. Izvorni znanstveni rad** (ili originalni)[83] je onaj znanstveni članak ili studija koja prezentira *nova* (*izvorna, originalna*) *znanja* o predmetu koji je istraživan u okviru fundamentalnih, primijenjenih ili razvojnih znanstvenih istraživanja. Neki će rad dobiti klasifikaciju izvornosti ako se u njemu prikazani rezultati mogu ponoviti u približnim uvjetima s istim ili približno istim rezultatima, tj. ako se mogu ponoviti eksperimentalni uvjeti i primijeniti iste istraživačke metode i tehnike. Treba napomenuti da postoje razlike u odstupanjima pri provjeri točnosti dobivenih rezultata između npr. prirodnih i društvenih znanosti. Naime, u prirodnim je znanostima lakše ponoviti i kontrolirati eksperimentalne uvjete (npr. u fizici ili kemiji) nego u društvenim znanostima (npr. u ekonomiji ili sociologiji).

2. **Prethodno priopćenje**[84] znanstveni je rad kojim se u okviru znanstvenih istraživanja, fundamentalnih, primijenjenih ili razvojnih, dolazi do *novih spoznaja* koje se prezentiraju znanstvenoj i stručnoj javnosti, ali koje još nisu konačne, završene, zbog nepostojanja dovoljno argumenata za njihovu provjeru. Prethodno priopćenje najčešće predstavlja znanstveno međustepenicu za završno istraživanje koje se onda prezentira kao izvorni znanstveni rad.

3. **Pregledni rad** je članak u kojemu znanstvenik/ci donose pregled već postojećih znanstvenih spoznaja o nekom predmetu istraživanja na svoj, izvorni način. Tu je posrijedi autorova diskusija i interpretacija postojećih spoznaja i eventualno ukazivanje na nove korake u istraživanju. Po tome i pregledni rad ima određeni znanstveni doprinos pa spada također u znanstvene radove.

4. **Izlaganje sa znanstvenog skupa** ili konferencijsko priopćenje je rad koji autor izlaže na nekom znanstvenom skupu, te kao takav rad bude objavljen u zborniku sa znanstvenog skupa. Ako izlagani rad ima sve dijelove znanstvenog članka i daje određeni znanstveni doprinos, tada može biti kategoriziran kao izvorni, prethodno priopćenje ili pregledni rad. U protivnom bit će recenziran kao stručni članak.

5. **Stručni rad** je rad stručnjaka ili znanstvenika koji nema pretenziju otkriti nova znanja o istraživanom predmetu, već mu je zadatak stručno prikazati odre-

---

83 Često se u časopisima označava kao „članak" (*paper*).

84 Prethodno se priopćenje još naziva „znanstvenom bilješkom".

đeni problem o istraživanom predmetu koristeći znanstvenu metodologiju istraživanja. Dakle, razlika stručnog rada u odnosu na znanstvene je u tome što on ne daje znanstveni doprinos.

## 11.3. ZNANSTVENI I STRUČNI PRIRUČNICI

Svi navedeni članci, kao i prethodno prikazane znanstvene knjige, spadaju u *primarne izvore* informacija. Za razliku od njih, znanstveni i stručni priručnici jesu *sekundarni izvori* informacija. Ovdje ćemo navesti samo neke, one s kojima se koriste i najčešće susreću i studenti i znanstvena te ostala javnost.

**Udžbenik** se može definirati kao nastavno sredstvo (djelo) koje izlaže gradivo utvrđeno nastavnim planom i programom. Ako govorimo o sveučilišnom udžbeniku, zahtijeva se da udžbenik daje cjelovit prikaz predmeta, što uključuje i teoretske pretpostavke, te da ima trajniji karakter. Ulogu se udžbenika najčešće vezuje za pospješenje realizacije nastavnog programa određenog predmeta (kolegija). Umjesto udžbenika tu ulogu često preuzima *skripta* koju je pripremio nastavnik za lakše savladavanje dijelova predmetnog gradiva. Skripta najčešće ima interni karakter uporabe (samo u instituciji u kojoj određeni nastavnik predaje). Skripta ne mora pokrivati nastavni program cijelog predmeta. Kao i udžbenik, i skriptu odobrava *Povjerenstvo za znanstveno-nastavnu literaturu Sveučilišta* na temelju triju recenzija (www.carnet.hr). Kao takvi, udžbenici i skripte ne predstavljaju primarne izvore informacija, već sekundarne, jer njihova je zadaća sakupiti i razložno predstaviti učenicima i studentima relevantna znanja o određenom predmetu učenja. Udžbeničku funkciju često preuzimaju *hrestomatije* (izabrani stručni ili znanstveni tekstovi s komentarima pisca/urednika hrestomatije), *autorizirana predavanja* nastavnika, *zbirke zadataka* i *praktikumi* (radne bilježnice).

**Enciklopedija** je stručno djelo koje donosi (1) opće ili (2) specijalizirane informacije o znanju u cjelini ili iz pojedinih područja. Znanja se odnose na znanstvena postignuća, umjetnička ostvarenja, povijesne događaje i osobe, tehnička otkrića i sve ono što je plod čovjekove povijesne aktivnosti. U prvom slučaju riječ je o *općoj enciklopediji*, u drugom o *specijaliziranim, posebnim enciklopedijama* kao što su medicinska enciklopedija, tehnička enciklopedija, muzička enciklopedija, filmska enciklopedija, enciklopedija ptica i druge. U enciklopedijama se *natuknice* donose abecednim redom. Opseg natuknice ovisi o predmetu o kojemu se piše. U pravilu natuknice trebaju sažeto i smisleno donijeti najvažnije informacije o prikazanom predmetu. Svojom objektivnošću, preciznošću i točnim informira-

njem enciklopedije mogu poslužiti kao *znanstveni*, a ne samo stručni, izvor informacija za znanstvenike koji ih koriste. Važno je osuvremenjivanje enciklopedija kako podatci koje donose ne bi bili zastarjeli. Danas je u tome velika pomoć postojanje *online enciklopedija*.[85] Najpoznatija među enciklopedijama je *Encyclopedia Britanica*.

**Leksikon** je posebna vrsta enciklopedijskog rječnika. On predstavlja zbirku pojmova koji se odnose na osobe i događaje, mjesta i krajeve, predmete i živa bića, stanja i procese, dakle na sve što donose i enciklopedije, samo što su informacije leksikona kraće i uopćenije te predstavljaju *stručnu* pomoć. Natuknice su poredane abecednim redom. Leksikoni, kao i enciklopedije, mogu biti opći i specijalizirani za određena područja (zdravlje, biljke, sisavce, imena, ekonomiju, sociologiju i dr.).

**Rječnik** je knjiga koja predstavlja *stručni* priručnik. Njime se mogu koristiti svi, od običnih ljudi do učenika, studenata, stručnjaka i znanstvenika uvijek kada trebaju preciznije i jasnije tumačenje riječi koje susrećU i koje koriste. Naviknuli smo na postojanje jednojezičnih rječnika (rječnik hrvatskog književnog jezika, npr.), kao i na dvo- i višejezične rječnike (npr. hrvatsko-njemački i njemačko-hrvatski rječnik, ili englesko-njemačko-francusko-španjolsko-talijanski rječnik koji predstavlja svojevrsni europski rječnik).

**Bibliografija** predstavlja *stručno-znanstveni* priručnik kojim se znanstvenici i istraživači koriste kada žele steći uvid u objavljene knjige, zbornike radova, članke i druga pisana djela o određenom predmetu. Bibliografije mogu imati različite namjene pa se prema tome i ustrojavaju. Na primjer, ako želimo steći uvid koliko se autora bavi nekom temom i koji su to autori, tada posežemo za autorskim kazalom bibliografije. Ako želimo vidjeti preko teme (naslova, predmeta) koliko je radova o temi objavljeno, tada koristimo predmetno kazalo (ili ključnu riječ).[86]

---

[85] Od 8. travnja 2009. svim članovima obrazovne i akademske zajednice dostupna je prva hrvatska *online* enciklopedija – *Proleksis enciklopedija*, razvijena u suradnji Pro Leksisa i CARNeta, uz potporu Ministarstva znanosti, obrazovanja i športa. Enciklopedija trenutno (zadnja izmjena 14. 3. 2012.) sadrži više od 62 000 članaka (uključujući članke unutar sintetskih natuknica) te više od 17 000 ilustracija. Uže uredništvo enciklopedije čini 9 ljudi, a ukupno je na enciklopediji radilo više od 50 urednika, suradnika i autora članaka. (www.carnet.hr, pristup 3. 5. 2012.)

[86] Kao primjer uzmimo *Hrvatsku znanstvenu bibliografiju* koja daje mogućnosti pretraživanja na više načina: *pregledavanje radova* (prema znanstvenim područjima istraživanja, u određenim godinama), *jednostavno pretraživanje* (predmetno, autorsko), *napredno pretraživanje* (autor, naslov rada, ključna riječ, naslov na engleskom, ključna riječ na engleskom), *skupni podaci* (statistički podaci prema godinama broj objavljenih autorskih knjiga, uredničkih knjiga,

Danas je sve manje *općih* bibliografija, zbog mnoštva tiskanih radova, a sve su češće *specijalizirane* bibliografije vezane uz znanstvena područja, polja, grane i ogranke (discipline). Također, pojedine biblioteke objavljuju svoje bibliografije (tiskane radove u pojedinoj biblioteci), znanstveni i stručni časopisi to čine isto (npr. časopis *Socijalna ekologija* ima bibliografiju radova u 20 godina izlaženja časopisa). Znanstvenici vode svoju *osobnu bibliografiju* koja im povremeno služi i kao preporuka za dobivanje istraživačkih projekata i slično.

## 11.4. ZNANSTVENI I STRUČNI RADOVI PREMA SADRŽAJU

Osim navedene klasifikacije prema znanstvenom doprinosu i primjeni znanstvene metodologije, postoje brojne druge klasifikacije. Jedna od njih je i klasifikacija znanstvenih i stručnih radova *prema sadržaju*, koju navodi **M. Žugaj** (1997: 181-185):

a) **Apologija** je djelo u kojemu autor *brani* neko djelo, autora, sustav, običaje, religiju i slično.

b) **Anotacija** donosi u sažetoj formi obavijest o sadržaju djela, sud o njegovoj aktualnosti i idejnoj usmjerenosti.

c) **Bibliografija** donosi popis knjiga, članaka i studija za određeno područje. U širem smislu to može biti i sakupljanje i sistematiziranje djela prema određenim kriterijima uz znanstvenu analizu.

d) **Diskusija** je usmena razmjena mišljenja, rasprava oko neke teme.

e) **Članak** se još naziva „problemski članak", a obilježava ga problemski pristup i rješavanje određenog problema. Najčešće ima formu sinteze.

f) **Elaborat** je pismeni sastav u kojemu se iscrpno izvještava o rezultatima nekog znanstvenog ili stručnog istraživanja.

g) **Esej** je znanstvena rasprava (argumentirano raspravlja o određenom problemu) koja se stilom približava beletrističkom pristupu (često donošenje emocionalnih stanja autora, osobnih stavova i sl.).

h) **Interpretacija** predstavlja tumačenje nekog djela, njegovih teza i zaključaka.

---

poglavlja u knjizi, udžbenici i skripte, izvorni znanstveni i pregledni radovi u CC časopisima itd.). (www.mzos.hr, pristup 4. 5. 2012.)

i) **Kritika** je ocjena, prosudba o pozitivnim i negativnim stranama nekog djela. Kritiku ne treba shvaćati kao negiranje, obezvrjeđivanje ili odbacivanje nekog djela ili autora, već kao stručnu analizu doprinosa (znanstvenog ili estetskog) nekog djela.

j) **Meditacija** predstavlja neznanstveno, emocionalno udubljivanje u neki problem koji se želi promisliti i doživjeti, a bez ozbiljne znanstvene vrijednosti.

k) **Monografija** iscrpno razmatra život i rad neke osobe (znanstvenika, umjetnika, sportaša, političara i sl.), tijek nekog događaja (iz prošlosti ili suvremenosti), povijest nekog mjesta (grada ili sela) i slično. Monografija može imati formu znanstvenog djela ili popularno-znanstvenog namijenjenog široj javnosti.

l) **Polemika** je usmena ili pismena prepirka između suprotstavljenih strana. Može biti književna, znanstvena, sportska, politička i slično.

m) **Prikaz** predstavlja stručno ili znanstveno priopćenje o pojavi nove knjige, zbornika, članka i slično. Cilj mu je predstaviti javnosti novo djelo, a ne kritički ga analizirati. Najčešće se objavljuju u dnevnim i tjednim novinama, ali i u znanstvenim i stručnim časopisima.

n) **Projekt** je nacrt, skica, prijedlog za rad na nečemu. Znanstveni projekt uglavnom okuplja više znanstvenika koji zajedničkim radom u određenom vremenu nastoje znanstvenim metodama i tehnikama doći do otkrića zakonitosti neke pojave, odnosno do rješenja problema. Rezultat toga je znanstvena studija koja se često poistovjećuje sa znanstvenim projektom.

o) **Recenzija** je ocjena znanstvenog ili stručnog rada. Recenziju obavljaju kvalificirani stručnjaci za područja iz kojih je recenzirano djelo. Recenzija se sastoji od više elemenata: uvodno se prikazuje struktura rada, relevantnost teme, ocjenjuje se metodologija rada, jasnoća i argumentiranost teza, korišteni izvori informacija (literatura), organizacija i raspored građe, rezultati istraživanja. Recenzija daje ocjenu rada i preporuku za objavljivanje ili dodatne korekcije rada.

p) **Rasprava ili traktat** ima znanstveni karakter jer obuhvaća postavljanje teze, njenu razradu te potvrđivanje ili odbacivanje. Rasprava u pristupu može biti analitička (od rezultata prema dijelovima) ili sintetička (od dijelova prema rezultatu).

r) **Referat** je javno predavanje kojim je obuhvaćena neka znanstvena ili stručna tema. Najčešće je u pisanom obliku i predstavlja polazište za raspravu na znanstvenim i stručnim skupovima.

s) **Teza** je čest naziv za znanstvenu radnju poput disertacije, ili magistarskog rada. Teza u pravilu treba biti originalna glede znanstvenog pristupa i doprinosa.

## 11.5. ZNANSTVENI I STRUČNI RADOVI KAO PUBLIKACIJE

Pored do sada navedenih, moguća je i klasifikacija pisanih radova kao *publikacija*, koju nam daje **R. Zelenika** (1998: 181-184):

1. **Primarne** publikacije jesu sva tiskana znanstvena djela koja imaju znanstveni doprinos. Te su publikacije uglavnom nastale kao rezultat fundamentalnih i primijenjenih znanstvenih istraživanja. To mogu biti knjige, časopisi, novine, znanstveni i tehnički izvještaji, magistarski i doktorski radovi i druge publikacije.

2. **Sekundarne** publikacije nastaju obradom informacija koje donose primarne publikacije pa predstavljaju pomoć u otkrivanju sadržaja primarnih publikacija. To su bibliografije, indeksi, bibliotečni katalozi, enciklopedije, biografski rječnici, rječnici pojmova, pregledi, vodiči i druge publikacije.

3. **Tercijarne** publikacije čine razni priručnici, monografije, bibliografski indeksi, adresari, katalozi biblioteka i druge publikacije koje predstavljaju svojevrsne baze podataka o primarnim i sekundarnim publikacijama.

4. **Periodične** publikacije ili tekuće publikacije jesu one koje izlaze u određenim vremenskim razmacima (mjesečno, tromjesečno godišnje i sl.). Ovdje spadaju publikacije poput časopisa, novina, almanaha, zbornika, godišnjaka, periodične statistike i slične publikacije.

5. **Knjiga** je, prema preporuci UNESCO-a, tiskana publikacija koja izlazi povremeno i koja sadrži najmanje 49 tiskanih stranica bez korica. Ako neka publikacija ima najmanje 5 a najviše 48 stranica, tada je to *brošura*. Postoje brojne vrste knjiga kao što su: tehnička i znanstvena knjiga, umjetnička knjiga, školska knjiga, dječja knjiga, knjiga dramskih djela, knjiga pjesama i druge.

## DODATNA LITERATURA UZ JEDANAESTO POGLAVLJE

Oraić Tolić, Dubravka (2011). *Akademsko pismo. Strategije i tehnike klasične retorike za suvremene studente i studentice*. Zagreb: Naklada Ljevak.

Iako prije svega usmjerena na akademske konvencije u humanističkim znanostima, knjiga se bavi specifičnostima znanstvenog diskursa i načelima kvalitetne prezentacije znanstvenih istraživanja.

## PITANJA UZ JEDANAESTO POGLAVLJE

1. Kakvi sve mogu biti (u kojoj su formi) pisani znanstveni i stručni radovi?
2. Po čemu se može prepoznati (odrediti) znanstveni rad?
3. Koje tri vrste znanstvenih knjiga razlikujemo?
4. Koja je klasifikacija znanstvenih radova prema kriterijima UNESCO-a?
5. Koji su to *sekundarni izvori* informacija? Nabrojite ih.
6. Koja su osnovna obilježja udžbenika, enciklopedije, leksikona, rječnika i bibliografije?
7. Kakva je to klasifikacija znanstvenih i stručnih radova prema sadržaju?
8. Što je esej, a što elaborat?
9. Što je kritika, a što interpretacija?
10. Što je polemika, a što prikaz?
11. Što je rasprava, a što referat?
12. Koje vrste radova razlikuje klasifikacija pisanih radova kao *publikacija*?

# 12. STRUKTURA ZNANSTVENOG I STRUČNOG DJELA

U prethodnom je poglavlju prikazano nekoliko klasifikacija znanstvenih i stručnih djela. One se, međutim, ne razlikuju samo prema znanstvenom doprinosu i primjeni znanstvenih metoda i tehnika u istraživanju, prema svojoj namjeni i sl., već i prema *strukturi* ili *kompoziciji*. Složenost strukture nekog djela ovisi o tome je li riječ o knjizi ili članku, o udžbeniku ili stručnom prikazu, o znanstvenoj recenziji ili o kritici i slično. O strukturi znanstvenog i stručnog djela postoje brojni radovi kojima se, s malim razlikama, ukazuje na bitne i manje bitne dijelove razvrstane u skupine dijelova koje ukazuju na njihovu veću ili manju važnost.[87]

Bez namjere „otkrivanja" nečeg novoga, ovdje ćemo prikazati strukturu pisanog znanstvenog i stručnog djela u kojoj mogu, ali ne moraju, biti svi spomenuti dijelovi. Naime, nije za očekivati da će znanstveni članak imati jednako dijelova u strukturi kao i znanstvena knjiga. Uzimajući u obzir kriterij bitnosti (važnosti, nezaobilaznosti, nužnosti) nekog dijela, postoje tri skupine dijelova: *glavni, pomoćni* i *orijentacijski*.[88]

***Znanstveno i stručno djelo sastoji se od glavnih, pomoćnih i orijentacijskih dijelova.***

## 12.1. GLAVNI DIJELOVI

**Glavni dijelovi** znanstvenog i stručnog djela jesu oni koje susrećemo u gotovo svakom od njih. Dakle, to su oni dijelovi koje nalazimo u strukturi svakog znanstvenog i većeg dijela stručnih radova. Riječ je o sljedećim dijelovima:

**Naslov** je nezaobilazni dio svakog rada. Odlike mu trebaju biti *kratkoća* i *jasnoća*, ali i dovoljna *informativnost* kako bi se prepoznalo o kakvom se djelu radi. Česta je praksa da autor naslovu dodaje *podnaslov* kako bi što preciznije odredio predmet kojim se djelo bavi.[89] Postoje razlike u shvaćanju odnosa *naslova i*

---

87 Različite pristupe strukturi znanstvenog i stručnog djela vidjeti kod: Baban, 2000: 123-149; Ivanović, 1996: 171-197; Kukić – Markić, 2006: 270-309; Žugaj, 1997: 190-208; Zelenika, 1998: 453-469.

88 Neki autori razlikuju 1. *tehničke dijelove znanstvenih i stručnih radova* i 2. *sadržajne dijelove znanstvenih i stručnih radova*, vidi: Tkalac Verčić, Sinčić Ćorić, Pološki Vokić, 2010: 198-208.

89 Ulrich Beck, npr., svoju knjigu naslova *Moć protiv moći u doba globalizacije* dopunjuje podnaslovom *Nova svjetskopolitička ekonomija*, te time jasnije određuje temu na koju se naslov odnosi.

*teme*: za jedne vrijedi naslov ili tema rada, za druge tema je istraživačko područje na koje se naslov odnosi. Naslov može odrediti sam autor (istraživača), mentor (disertacije, magisterija ili znanstvenog projekta), recenzent (prijedlog korekcije naslova), ali i izdavač knjige ili naručitelj istraživanja. Naslov može naglašavati *teorijski, praktički ili kombinirani* pristup istraživanja. Također može usmjeravati na istraživanje *prošlosti, sadašnjosti, budućnosti* ili na *kombinirano* istraživanje.

**Uvod** je dio kojim nas autor(i) uvodi/uvode u temu, daje opis problema, obrazlaže potrebu za istraživanjem, njezinu opravdanost i aktualnost. U uvodu se također daje prikaz postojećih znanja o temi, određena (ne)slaganja s njima, kao i smjer u kojemu će istraživanje ići. Uvod nalazimo u svakom znanstvenom i stručnom djelu i uvijek mu je zadaća pobuditi interes čitatelja za ostali dio koji slijedi.

**Metodologija istraživanja i hipoteze** važan je dio koji se nalazi samo u stručnim i znanstvenim djelima (ne u beletristici ili esejistici). U njoj se istraživanje precizira predmetno, vremenski, područno; navode se izvori podataka, metode i tehnike kao i instrumenti koji se koriste, teškoće na koje se nailazilo. U metodološkom dijelu se također postavljaju hipoteze (jedna ili više, radne, nulte, glavna, pomoćne), odabire uzorak i precizira cilj koji se želi istraživanjem postići.

U **rezultatima istraživanja** tekstualno i/ili grafički navode se rezultati do kojih se došlo istraživanjem. U tom se dijelu rada rezultati ne komentiraju jer je komentar rezerviran za sljedeći dio – raspravu.

**Rasprava** se još naziva glavni dio ili razrada teme. Sve ono što je u uvodnom i metodološkom dijelu naznačeno, ovdje se realizira pa je taj dio prema broju stranica najopsežniji. U raspravi se diskutira o predmetu i problemu istraživanja (otuda neki ovaj dio nazivaju „diskusija“) analizirajući postojeće informacije i njihove izvore, provjeravajući postavljene hipoteze na dobivenim rezultatima provedenih istraživanja (teorijskih i/ili empirijskih). Dakle, sustavnost i argumentiranost u propitivanju istraživanjem dobivenih rezultata bitno je obilježje rasprave. Važno je naglasiti da se u raspravi ne ponavljaju rezultati istraživanja, nego se samo naznačavaju implikacije rezultata s obzirom na postavljene hipoteze i ciljeve istraživanja.

Zbog jasnoće i preglednosti u ovom dijelu autor najčešće poseže za podjelom na više dijelova (poglavlja i potpoglavlja) kojima čitatelja vodi kroz temu od njezinog teorijskog postavljanja, empirijskog potvrđivanja i provjeravanja, do sinteze postignutih znanja i verifikacije hipoteza.

**Zaključak** predstavlja sintezu rezultata istraživanja. Prema Zeleniki (1998: 466): „zaključak je na sustavan, koncizan i jezgrovit način izložena sinteza svih relevantnih spoznaja, informacija, stavova, znanstvenih činjenica, teorija i zakona koji su izneseni u analitičkom dijelu znanstvenog djela." U zaključku se, dakle, ne donosi ništa novo, nego se zaključno potvrđuje, naglašava, podvlači ono što se na prethodnim stranicama istražilo, spoznalo i dokazalo. Opseg zaključka treba biti primjeren opsegu djela, dakle, nije propisano koliko stranica treba biti ostavljeno za zaključak. Također, treba spomenuti da neki autori za zaključak upotrebljavaju različite nazive: umjesto zaključka, zaključne teze, završne teze, zaključna riječ i druge. Zaključak trebaju imati svi znanstveni i stručni radovi (knjige i članci), ne i stručni i znanstveni priručnici (enciklopedije, udžbenici i sl.).

**Literatura ili bibliografija** spada također u glavne dijelove. Svaka znanstvena knjiga, kao i znanstveni članak, ali i znanstveni i stručni priručnici sadrže popis korištene, predmetne i preporučene literature. Dakle, popis literature može biti dvovrstan: a) navođenje samo korištene literature (tj. citiranih, parafraziranih i interpretiranih djela), b) navođenje korištene i predmetne literature (tj. uz korištena se navode i djela koja su poznata i na određeni način vezana uz temu, a nije korištena). Najčešće se popis pravi abecednim redom prezimena autora, odnosno naslova nekog dokumenta. Neki autori i urednici zbornika i priručnika literaturu navode prema skupinama, npr.: a) znanstvene knjige, b) članci u časopisima, c) priručnici, d) dokumenti, e) internet. Također postoje i drugi kriteriji razvrstavanja kao što su: prema znanstvenom području i polju, prema povijesnom razdoblju nastajanja djela, prema zemljama porijekla autora i slično. Uobičajeno je literaturu stavljati poslije zaključka.

## 12.2. ORIJENTACIJSKI DIJELOVI

**Orijentacijski dijelovi** znanstvenog i stručnog djela služe za lakše snalaženje čitatelja u više ili manje opsežnom materijalu knjige, zbornika radova, znanstvenog i stručnog priručnika, a rjeđe se koriste u znanstvenim člancima.

**Sadržaj ili kazalo** dio je koji nalazimo u svakoj znanstvenoj knjizi. Zadatak mu je *pregledno* i *jasno* donijeti prikaz cjelina i dijelova cjeline u knjizi. U europskoj je tradiciji sadržaj uglavnom na kraju knjige. Danas je sve prisutniji američki pristup prema kojemu se sadržaj stavlja na početak knjige. Sadržaj bi trebao imati onakvu formu kakav je raspored označavanja dijelova u knjizi. Često se, međutim, događa nepreglednost sadržaja, a što se dalje i u samoj knjizi potvrđuje kao

teškoća u snalaženju i praćenju razrade teme, različitosti pristupa, važnosti pojedinih poglavlja i slično. Za primjer preglednosti sadržaja Kukić i Markić (2006: 273) navode *linijski princip* i *princip stupnjevanja* u označavanju dijelova sadržaja:

| Linijski princip | Princip stupnjevanja |
|---|---|
| 1. | 1. |
| 2. | 2. |
| 2.1. | 2.1. |
| 2.1.1. | 2.1.1. |
| 2.2. | 2.2. |
| 2.2.1. | 2.2.1. |
| 2.2.1.1. | 2.2.1.1. |
| 2.2.1.1.1. | 2.2.1.1.1. |
| 2.2.1.1.2. | 2.2.1.1.2. |
| 2.2.1.2. | 2.2.1.2. |
| 2.2.2. | 2.2.2. |
| 2.3. | 2.3. |
| 2.4. | 2.4. |
| 3. | 3. |
| 4. | 4. |

**Popis kratica i simbola** orijentacijski je dio koji se najčešće stavlja na početku knjige ili priručnika, odmah poslije sadržaja. Autori su skloni često korištene pojmove i simbole pisati u skraćenom obliku, pa je stoga preporučljivo abecednim redom sakupiti sve korištene kratice. Na primjer:

| Kratice: | Simboli: |
|---|---|
| BDP = bruto društveni proizvod | > = manje |
| DHK = Društvo hrvatskih književnika | < = više |
| HAZU = Hrvatska akademija znanosti i umjetnosti | ≠ = različito |
| HBK = Hrvatska biskupska konferencija | ∞ = beskonačno |
| ICT = informacijsko komunikacijska tehnologija | € = euro |
| pc = per capita (po glavi stanovnika) | % = postotak |
| UN = Ujedinjeni narodi | § = paragraf |

**Popis tablica, slika i grafikona** nalazi se kao orijentacijski dio u svakoj ozbiljnijoj znanstvenoj i stručnoj knjizi, kao i u priručnicima (ako se u njima koriste tablični, slikovni i grafički prikazi). To je posebice potrebno u ekonomskim, statističkim, demografskim, sociološkim i drugim znanstvenim djelima koja koriste kvantitativne prikaze istraživanih predmeta. Iz popisa tablica, grafikona i slika čitatelj može vidjeti njihov broj, naziv i stranicu na kojoj se nalazi. Na primjer:

Popis tablica:


| Red. broj | Naziv tablice | Stranica |
|---|---|---|
| 1. | Stanovništvo prema mjestu stanovanja (u %) | 26 |
| 2. | Stanovništvo prema obrazovanju i spolu (u %) | 31 |


**Kazalo imena** važan je orijentacijski dio, posebice koristan u opsežnijim znanstvenim i stručnim djelima i priručnicima. Iz njega se čitatelj može brzo informirati o tome koji su i kako autori ili druge osobe spominjani u djelu. Kazalo se ustrojava abecednim redom prezimena tako da se uz prezime i ime navedu stranice na kojima se autori ili druge osobe spominju. Na primjer:

*Cifrić, I.* 26, 63, 127
*Morin, E.* 16, 83
*Napoleon,* 8
*Rifkin, J.* 42, 143, 216

**Kazalo pojmova**, kao i kazalo imena, zaseban je dio znanstvenog i stručnog djela koji olakšava snalaženje čitatelju kada ga zanima određeni pojam, njegovo značenje i autorovo korištenje pojma. Kao i imena, i pojmovi se navode abecednim redom s navođenjem brojeva stranica na kojima se nalaze. Na primjer:

*Metafizika*, 8, 36
*Metoda*, 12, 45, 129
*Utilitarizam*, 22, 131
*Znanstveno istraživanje*, 16, 63, 189, 212

## 12.3. POMOĆNI DIJELOVI

**Pomoćni dijelovi** znanstvenog i stručnog djela postoje kako bi pomogli autoru što potpunije izložiti, prikazati i predstaviti rezultate znanstvenog ili stručnog istraživanja, diskusije i promišljanja o nekom predmetu i problemu. Mogu biti uključeni u znanstvena i stručna djela, no nisu obvezni poput glavnih dijelova.

**Predgovor** najčešće donosi autorovo ukazivanje na razloge, poticaje i motive pisanja znanstvenog ili stručnog djela te kratku, nepotpunu strukturu djela. Osim autora predgovor mogu pisati i recenzenti istog djela. Ustaljeno je pravilo da se predgovor piše kada je djelo završeno. Ako se isto djelo tiska u više izdanja, može se dodati novi predgovor svakom novom izdanju. Predgovor je dio koji se stavlja na početku djela, prije uvoda, često i prije sadržaja.

**Pogovor** je pomoćni dio koji se pojavljuje u nekim znanstvenim i stručnim djelima. Ne treba ga shvaćati kao „završni" dio nekog djela, već kao posebnu cjelinu o samom djelu. Najčešće ga piše recenzent ili neka treća osoba. Autor pogovora najčešće se trudi prikazati *okolnosti* nastajanja djela (povijesno vrijeme, sociokulturni prostor), te samo *djelo* (njegovu važnost u odnosu na postojeća znanja, važnost znanstvenog doprinosa i sl.) i *autora* (dosadašnjem radu autora, njegovim postignućima i sl.).

**Sažetak** je kratki, sažeti prikaz sadržaja znanstvenog i stručnog djela koji obično sadrži između 150 i 250 riječi. Svrha mu je, navodi Žugaj (1998: 467), pružiti javnosti informaciju o djelu, te pobuditi interes pojedinaca ili ustanova za djelo. U knjigama se sažetak dodaje na kraju, poslije literature. Uglavnom se prevodi na neki, jedan ili više, svjetski jezik na kojemu djelo nije pisano (npr. djela na hrvatskom najčešće imaju sažetke na engleskom i/ili njemačkom). Uvriježena je praksa tiskati *knjige sažetaka* referata na znanstvenim skupovima, ali i u *bibliografijama* davati kratke sažetke djela. Časopis radova koji se objavljuju u znanstvenim časopisima obično slijede strukturu samoga rada, donose osnovna istraživačka pitanja i/ili hipoteze, metodologiju i druge podatke o istraživanju, kao i temeljne nalaze istraživanja. Ovakav se sažetak obično naziva *informativni sažetak*, a sažetak u kojem je samo kratko skicirana struktura rada, bez ulaženja u njegove rezultate i zaključke, često se naziva *indikativni sažetak*. U knjigama ili radovima u časopisima može postojati i duži sažetak (eng. *summary*, za razliku od kraćeg sažetka koji se naziva *abstract*) koji se obično fokusira na iscrpnije izlaganje osnovnih ideja i nalaza rada, bez ulaženja u metodološke i druge tehničke pojedinosti. Dakle, ovakav sažetak onda više ima ulogu duljeg zaključka, koji se onda može izostaviti u samom radu. U većini današnjih časopisa iz područja društvenih znanosti najčešći je tip sažetka informativni sažetak.

**Kontrolna pitanja** spadaju u neobvezne, pomoćne dijelove znanstvenog i stručnog djela. Najčešće se nalaze u sveučilišnim udžbenicima i imaju edukativnu svrhu za čitatelja. Zadaća im je voditi učenika/studenta kroz izloženu građu, tako da se učenjem dijelova ne izgubi cjelina. Mogu se staviti na kraju svakog poglavlja ili na kraju djela.

**Rječnik** ili glosarij pomoćni je dio koji mogu imati opsežnija znanstvena i stručna djela. Autor dodaje rječnik kao zasebni dio kada smatra da će time olakšati snalaženje čitatelja s manje poznatim pojmovima koji se u djelu često koriste. Rječnik sadrži autorovo tumačenje značenja pojmova i broj stranica na kojima se pojam nalazi.

**Prilozi** su dodaci na kraju knjige koji donose korištenu građu ili sredstva pomoću kojih se dolazilo do informacija bitnih za znanstveno ili stručno djelo (npr. povijesni dokumenti, zemljovidi, statističke tablice, anketni upitnici i sl.).

**Biografija autora** zadnji je dodatak znanstvenog i stručnog djela. Osnovni mu je cilj kratko predstaviti autora: biografski, bibliografski te profesionalno.

**Moto** je kratka, smislena, duhovita rečenica koja se stavlja na početak nekog znanstvenog ili stručnog djela, a svrha mu je poticajno i usmjeravajuće djelovati na čitatelja. Moto na neki način predstavlja i autorov smjer u pristupu temi. Najčešće se za moto uzimaju misli poznatih autora, povijesnih veličina, mudraca i slično. Na primjer:

*„Mislim, dakle ja jesam!"* (Descartes)

**Zahvale i posvete** pišu se na početku knjige, prije stranice sadržaja. U *zahvali* autor se zahvaljuje osobama i ustanovama, koji su na bilo koji način pozitivno pridonijeli završetku djela. Autor također može djelo *posvetiti* nekoj osobi, obitelji, narodu, ustanovi, mjestu, kraju i slično.

## DODATNA LITERATURA UZ DVANAESTO POGLAVLJE

Oraić Tolić, Dubravka (2011). *Akademsko pismo. Strategije i tehnike klasične retorike za suvremene studente i studentice*. Zagreb: Naklada Ljevak.

Iako prije svega usmjerena na akademske konvencije u humanističkim znanostima, knjiga se bavi specifičnostima znanstvenog diskursa i načelima kvalitetne prezentacije znanstvenih istraživanja.

## PITANJA UZ DVANAESTO POGLAVLJE

1. Prema kriteriju bitnosti (važnosti, nezaobilaznosti, nužnosti), koje tri skupine dijelova postoje u nekom znanstvenom ili stručnom djelu?
2. Koji su to glavni dijelovi u strukturi znanstvenog ili stručnog djela?
3. Koji su to orijentacijski dijelovi u strukturi znanstvenog ili stručnog djela?
4. Koji su pomoćni dijelovi u strukturi znanstvenog ili stručnog djela?
5. Koje su bitne odlike „naslova"?
6. Što je bitno u dijelu „metodologija istraživanja"?
7. Koji je zadatak „rasprave" u svakom znanstvenom i stručnom djelu?

8. Što predstavlja „zaključak“ u svakom znanstvenom i stručnom djelu?
9. Koja je svrha „literature ili bibliografije“?
10. Koja je svrha „kazala ili sadržaja“ i prema koja dva principa se mogu označavati dijelovi sadržaja?
11. Koja je svrha „sažetka“ u strukturi znanstvenog ili stručnog djela?
12. Koja je svrha „kontrolnih pitanja“ u strukturi znanstvenog ili stručnog djela?
13. Koja je svrha „predgovora“ u strukturi znanstvenog ili stručnog djela?
14. Koja je svrha „pogovora“ u strukturi znanstvenog ili stručnog djela?

# 13. PISANJE ZNANSTVENOG I STRUČNOG DJELA

Svako se znanstveno i stručno istraživanje, često nazvano znanstveni i stručni rad, prezentira kao pisano djelo. To može biti završni izvještaj, studija, članak, poglavlje u knjizi ili knjiga (znanstvena ili stručna monografija). Neovisno o vrsti pisanog djela, u pravilu se od autora traži poštivanje važećih normi (1) u transparentnosti korištenja drugih izvora informacija o istraživanom predmetu, (2) u načinu korištenja drugih izvora, (3) u načinu navođenja korištenih izvora (literature) i njihovu prikazivanju, kao i (4) u svrsi uporabe pozivnih bilježaka.[90] Tu tzv. „dokumentacijsku osnovu rukopisa" autor mora strogo primjenjivati kada tijekom vremena istraživanja prikuplja informacije i znanstvenu građu iz različitih izvora prije pisanja vlastitog djela.

(1) Kada je riječ o *transparentnosti korištenja drugih izvora informacija* o istraživanom predmetu, autor mora svaku preuzetu pisanu ili izgovorenu riječ označiti kao nevlastitu, tj. ukazati na izvor iz kojega je preuzeta.

(2) Kada je riječ o *načinu korištenja* drugih izvora, autor se može odlučiti za doslovno preuzimanje tuđe misli, tj. *citiranje*, za skraćeno prepričavanje tuđe misli, tj. *parafraziranje* ili za vlastito razumijevanje osnovne ideje nekog djela, tj. *interpretiranje*.

(3) Kada je riječ o *načinu navođenja korištenih izvora*, dakle o pisanju literature ili bibliografije, autor mora biti *dosljedan u odabranom načinu navođenja*, a što znači da se izvori navođeni u tekstu i u konačnom popisu izvora (literaturi) moraju navoditi na isti način (o načinima navođenja u poglavlju 9.4.).

(4) Kada je riječ o *svrsi uporabe pozivnih bilježaka*, autor se mora opredijeliti *što* u bilješkama želi donositi i *gdje* ih želi stavljati, na kraju stranice ili poglavlja (o bilješkama u poglavlju 9.2.).

## 13.1. CITIRANJE, PARAFRAZIRANJE, INTERPRETIRANJE

Gotovo je nemoguće zamisliti nekog znanstvenika koji bi se u svom istraživanju oslanjao samo na sebe, a da ne posegne za argumentacijom drugih znanstvenika i istraživača iste ili slične problematike. Uvriježena je navika i potreba istraživača

[90] Neki autori govore o „dokumentacijskoj osnovi rukopisa" koju čine sastavnice: citiranje, pozivna bilješka i ilustracije. Tome se dodaje i literatura ili bibliografija (vidi Zelenika, 1998: 481, Kukić – Markić, 2006: 291).

koristiti već postojeća znanja, istraživačke metode i tehnike, stilove pisanja i sl. u svom znanstvenom i stručnom radu. Kako to korištenje ne bi izložilo autora falsificiranju i plagiranju,[91] autor mora svaku preuzetu pisanu ili izgovorenu riječ označiti kao nevlastitu, tj. ukazati na izvor iz kojega je preuzeta. Time je zadovoljeno *etičko načelo* znanstvenog poštenja i zakonsko pravo *zaštićenosti autorskog djela*. Dakle, autor uvijek mora voditi računa o *transparentnosti korištenja drugih izvora bilo* da je riječ o citiranju, parafraziranju ili interpretiranju tuđih riječi, ideja ili stavova.

***Svako preuzimanje tuđeg autorskog teksta mora se posebno označiti, a može se napraviti citiranjem, parafraziranjem ili interpretiranjem.***

**Citiranje** je doslovno preuzimanje teksta (ili izgovorenih riječi) iz drugih izvora, dakle prenošenje od riječi do riječi dijela tuđeg rada. Pri tome je bitno preuzeti tekst ili izgovorene riječi označiti navodnim znakovima kako bi se jasno izdvojili od autorova teksta. Niže navodimo primjer jednog fiktivnog citata.

> *Prema mišljenju ovoga autora, „na području tumačenja razlika u kvaliteti javnih i privatnih škola nedostaje konkluzivnih istraživanja." (Smith, 2010: 28)*

Ako se iz preuzetog teksta ispuste neke riječi ili rečenice zbog dužine ili nevezanosti uz temu, to treba označiti tako da se stavi na ispušteni dio oznaka „(...)". Također je važno istaknuti da ako autor unosi bilo kakve tehničke promjene u tekst poput pisanja u kurzivu pojedinih riječi, ili podvlačenje pojedinih dijelova citata, tada je nužno na to ukazati (npr. podv. autor, ili kurziv je naš). Za citirani dio je obvezno navođenje izvora, bilo u tekstu ili u bilješci.

**Parafraziranje** je vrlo često prisutan način korištenja tuđih riječi, ideja ili stavova. Riječ je o autorovu skraćenom prikazivanju (prepričavanju) većih dionica tuđeg teksta, čak cijelih članaka ili knjige. Osim što je obvezan navesti izvor djela koji parafrazira, autor je obvezan voditi računa da parafraziranjem vjerno prikaže izvorno djelo. Prethodno navedeni citat u parafraziranoj verziji izgledao bi ovako:

> *Smith (2010.) smatra da na području tumačenja razlika u kvaliteti javnih i privatnih škola nedostaje konkluzivnih istraživanja.*

---

[91] *Plagijat* je svako književno, znanstveno ili drugo djelo nastalo prisvajanjem tuđeg rada prepisivanjem u cjelini, u bitnim ili u prepoznatljivim dijelovima, a *plagiranje* je prisvajanje tuđeg autorskog djela (Tkalac Verčić, Sinčić Ćorić, Pološki Vokić, 2010: 170).

Kako ističe Oraić Tolić (2011: 447), prilikom parafraziranja važno je da ne počinimo pogrešku „simulacije parafraziranja" koja se odnosi na mogućnost da prilikom parafraziranja zapravo preuzimamo doslovne riječi autora kojeg parafraziramo. Ovakva simulacija parafraziranja može se često susresti u studentskim radovima u kojima nakon pravilno obilježenog citata slijedi doslovno preuzimanje izraza istog autora, a da to nije označeno navodnicima. Naravno, valja reći da nije uvijek jednostavno izbjeći određene sličnosti u našem i parafraziranom tekstu, inače bi bilo riječ o interpretiranju, a ne o parafraziranju.

**Interpretiranje** je prikazivanje autorova razumijevanja tuđeg pisanog djela, predstavljene ideje ili održanog govora. Iako u interpretaciji autor dodaje vlastite ideje, vlastito razumijevanje značenja tuđeg djela, ipak je obvezan pozvati se na izvor. Jedna od mogućih interpretacija navedenog citata izgledala bi ovako:

> *Smith (2010.) smatra da na području tumačenja razlika u kvaliteti javnih i privatnih škola nedostaje konkluzivnih istraživanja. Razlog za ovakvo mišljenje vjerojatno se može pronaći u činjenici da sva dosadašnja istraživanja sadrže metodološke nedostatke ili se temelje na nepotpunim podatcima.*

Iako je plagijat ponekad rezultat namjere, često se pojavljuje i kao posljedica nemara ili neznanja. Osobito je važno naglastiti da se plagirati može i nesvjesno, kada istraživač preuzme tuđe misli a da toga nije ni svjestan, pa treba osobito paziti da se pri čitanju tuđih radova rade vlastite zabilješke kako bi se mogle rekonstruirati vlastite ideje i odvojiti ih od ideja autora kojega smo čitali. Također treba naglasiti da se plagirati mogu i vlastiti radovi, tj. prijašnje vlastite radove ili njihove dijelove autor ne smije ponovno objavljivati bez izričitog pozivanja na njih. Iz navedenog proizlazi da se može dati nekoliko savjeta čijim se pridržavanjem smanjuje vjerojatnost plagijata (prema Tkalac Verčič i sur., 2010: 172):

1. *Odmah zabilježiti izvor prilikom pravljenja bilješki.*
2. *Prilikom bilježaka odmah koristiti navodnike pri preuzimanju tuđeg teksta* (kako poslije ne bismo mislili da su u pitanju naše vlastite rečenice).
3. *Nikad ne navoditi da smo nešto čitali u originalu ako to nismo učinili*. Naime, ako smo do ideja jednog autora došli čitajući prikaz nekog trećeg autora, tada to treba i navesti (najčešće pomoću izraza „navedeno prema"). Na ovaj način čitatelja upozoravamo da je riječ o prenošenju interpretacije nečijih ideja, a ne o prenošenju izvornih ideja. Na taj se način čitatelja upućuje na originalni izvor i smanjuje vjerojatnost da se izvorne ideje iskrive u cijelom nizu sukcesivnih interpretacija.

4. *Ograničiti dužinu citata na 5 redova*. Duže citiranje može navesti na dojam da autor ne dodaje ništa originalno.

Može se napomenuti i da se istraživački nacrti ili upitnici mogu preuzeti od drugih istraživača, a često je dapače i poželjno preuzeti tuđi nacrt ili mjerne instrumente ako imaju dokazane metrijske karakteristike. Međutim, i u ovakvim preuzimanjima mora biti naveden izvor, inače je riječ o plagijatu.

Bilo da je riječ o citiranju, parafraziranju ili interpretiranju, autor mora voditi računa da preuzeti dio dobro uklopi u svoj tekst kako on ne bi odudarao od stila, teme i slično. Također je važno kako označiti preuzeti dio. Kukić i Markić (2006: 294-297) navode tri načina ili sustava citiranja: harvardski sustav, numerički sustav i abecedno-numerički sustav. Zelenika (1998: 484-498) navodi dva: europski sustav i američki ili harvardski sustav. Iz ovih primjera vidimo da postoji različiti pristupi klasifikaciji sustava citiranja, ovisno o kriteriju klasifikacije koji se uzima kao važan. Uzmemo li kao kriteriji mjesto na kojemu se pojavljuje informacija o autoru djela, sustave citiranja moguće je podijeliti na: (1) sustave u kojima se autor navodi u tekstu, odnosno zagradama u tekstu (eng. *in-text citations*). (2) sustave u kojima se informacija o autoru pojavljuje u fusnotama (eng. *footnotes citations*) i (3) sustave u kojima se informacija u autoru pojavljuje tek u bibliografiji na kraju rada (numerički i abecedno-numerički sustav). Pri tome se svaki citatni sustav može realizirati u nizu konkretnih citatnih stilova, a neki citatni stilovi čak mogu kombinirati i dva ili više sustava citiranja. Primjerice, tzv. Chicago Manual of Style dopušta dva pristupa: citiranje u tekstu i citiranje u fusnotama.

***Postoji veliki broj sustava citiranja i citatnih stilova koji proizlaze iz njih, ono što je važno dosljedna je upotreba izabranog stila.***

**Citiranje u tekstu (još se naziva i američki ili harvardski sustav[92])** sustav je citiranja prema kojemu se citat, parafraza ili interpretacija označava u tekstu tako da se na kraju rečenice u zagradi navede prezime autora djela, godina izdanja i prema mogućnosti stranica(e) s koje se citira, parafrazira ili interpretira tekst, npr. (Milas, 2009: 563). Potpunu informaciju o djelu iz kojega se uzima citat autor daje u dijelu *Literatura* pa će tamo biti ovako navedeno djelo:

[92] Ne treba ga pomiješati s konkretnom realizacijom ovog sustava citiranja, odnosno harvardskim citatnim stilom. Naime, harvardski citatni stil tek je jedna od, iako najčešće upotrebljavanih, mogućih realizacija ovog sustava citiranja.

*Milas, Goran (2009). Istraživačke metode u psihologiji, Zagreb, Naklada Slap.*

Njegova praktičnost proizlazi iz jednostavnog i kratkog navođenja izvora u zagradi odmah iza citiranja, parafraziranja ili interpretiranja nekog djela, a nepraktičnost je što se informacija o izvoru ne nalazi na istoj stranici (fusnota) već na kraju djela. U društvenim se znanostima u pravilu upotrebljava ovaj sustav citiranja jer daje informacije o autoru i godini izdanja, što može biti važno prilikom procjene vjerodostojnosti i važnosti djela koje se navodi.

**Citiranje u fusnotama (još se naziva i oxfordski ili europski sustav)** razlikuje se od američkog po tome što citat, parafrazu ili interpretaciju označava arapskim brojem prema redoslijedu broja citata, a u podnožju stranice (fusnota) pod tim je brojem potpuna informacija o djelu iz kojega je citat. Ako se iz istog djela navodi više puta citat ili parafraza, tada se to označava s više kratica kao što su: *nav. dj.* (navedeno djelo, lat. op. cit. kratica „Opus citatum"), ili *ibidem* (na istom mjestu), ili *isto*. Pogledajmo na primjeru:

> *„U najširem smislu, metodologija nam pomaže da shvatimo, ne produkte znanstvenog istraživanja već postupke dolaženja do njih."*[93]
> *„Konačni cilj znanosti nedvojbeno je prikupljanje znanja odnosno spoznavanje svijeta, kako bi se nad njime, osobito nad pojavama od važnosti za ljudsku egzistenciju, uspostavio nadzor."*[94]

U numeričkom se načinu u slučaju citiranja u tekstu navede samo redni broj citata, a u popisu literature na kraju teksta uz taj redni broj navedu se puni podatci o citiranom djelu. Redni brojevi određuju se prema redoslijedu pojavljivanja u tekstu, a tim su redoslijedom djela navedena i u opisu literature. Najpoznatija realizacija ovakvog (pod)sustava tzv. vancouverski citatni stil koji se često upotrebljava u biomedicini zbog toga što „štedi" prostor u slučaju navođenja velikog broja referenci/istraživanja. Pri abecedno-numeričkom citiranju na kraju se navode citirana djela prema abecedi, a u tekstu se, obično u zagradi, navede broj citiranog djela. Drukčije rečeno, za razliku od numeričkog (pod)sustava, pri navođenju prve reference u supskriptu ne mora biti broj jedan, nego redni broj pod kojim je ta bibliografska jedinica navedena u popisu literature.

Današnje digitalno doba donosi sve veći broj elektroničkih, osobito internetskih izvora. Načelno govoreći, vrsta izvora ne utječe na njegovu vjerodostojnost. Ako je u pitanju izvor koji se upotrebljava prilikom znanstvenog i stručnog rada, mno-

---

93 Milas, Goran*: Istraživačke metode u psihologiji,* Naklada Slap, Zagreb, 2009., str. 14.

94 Nav. dj., str. 17.

go je važnije da je u pitanju izvor koji je recenziran, odnosno koji je prošao filter procjene drugih znanstvenika. Oraić Tolić (2011: 463) elektroničke izvore dijeli na (a) mrežne izvore, (b) druge elektroničke medije (CD, DVD i sl.). U prvom je slučaju riječ o internetskim (*online*) izvorima koje Oraić Tolić opet dalje dijeli na mrežne izvore u širem i mrežne izvore u užem smislu. Mrežni izvori u širem smislu riječi obuhvaćaju elektroničke izvore publikacija koje imaju i svoju tiskanu verziju. U tom je slučaju potrebno navesti sve citatne elemente kao i da je u pitanju isključivo tiskani izvor, no dodatno se treba navesti i internetska (URL) adresa mjesta na kojem je pohranjen dokument koji se citira. Iako se ovakva praksa može činiti nepotrebnom, ipak je radi preciznosti potrebno naznačiti vrstu medija u kojem je izvor/dokument pronađen. U mrežne izvore u užem smislu ulaze one publikacije koje nemaju svoju tiskanu varijantu, nego se nalaze isključivo na internetu. Prilikom upotrebe ovakvih izvora također treba konzultirati citatni stil koji se upotrebljava te vidjeti na koji se način unutar njega normira ovakva situacija. Pri tome valja vidjeti o kakvoj je podvrsti izvora riječ, zato što se citatni elementi razlikuju u ovisnosti o tome je li riječ o medijskim izdanjima, organizacijskim ili privatnim internetskim stranicama, online znanstvenim časopisima itd. Imajući u vidu promjenjivost ovakvih sadržaja, prilikom njihova navođenja potrebno je dati što više podataka koji poslije omogućuju laku identifikaciju navođenog dokumenta. Iz toga je razloga pri citiranju internetskih izvora uvijek potrebno navesti URL adresu i datum pristupanja sadržaju, naslov dokumenta, kao i detalje o autoru i organizaciji na čijoj se internetskoj stranici nalazi sadržaj. Pri tome je ponekad teško utvrditi konkretnog autora jer on nije ekplicitno naveden, a ponekad nedostaje i točan naziv dokumenta, odnosno autor mu nije dao naslov. Neki citatni stilovi također ne zahtijevaju navođenje datuma pristupa sadržaju ako je riječ o izvorima koji nisu vremenski promjenjivi (npr. izdanje novina određenog datuma). U drugim izvorima taj podatak potrebno je obavezno navesti. Primjer jedne reference na novinski članak pronađen u internetskom izdanju dnevnih novina u harvardskom citatnom stilu izgledao bi ovako:

> Rudež, T. (2018). *Nije istina da učestalost nasilja pada od početka čovječanstva!* Ugledni sociolog demontirao jedan od najraširenijih modernih mitova. [online] https://www.jutarnji.hr. Dostupno na https://www.jutarnji.hr/life/znanost/nije-istina-da-ucestalost-nasilja-pada-od-pocetka-covjecanstva-ugledni-sociolog-demontirao-jedan-od-najrasirenijih-modernih-mitova/6952299/ [Pristupljeno 2. veljače 2018.].

Ova se referenca u tekstu navodi kao i bilo koja druga. Primjerice, u gornjem slučaju na ovaj bi se izvor mogli pozvati na sljedeći način:

Iako mnogi tvrde da količina nasilja opada od nastanka čovječanstva, postoje i drukčija mišljenja (npr. vidjeti Rudež, 2018).

U drugim elektroničkim medijima, dovoljno je navesti klasične citatne elemente jer su ovi mediji stabilniji od mrežnih izvora (Oraić Tolić, 2011: 464). No i tu valja konzultirati izabrani citatni stil i poštovati njegove zahtjeve. Primjerice, u harvardskom citanom stilu DVD film naveli bismo na ovaj način:

> Schlesinger, J., et al. (2005). *Ponoćni kauboj*. Los Angeles, CA, MGM Home Entertainment [distributer].

Dakle, može se vidjeti da su navedeni autori, odnosno glavni autor (režiser), godina izdanja djela, naslov, mjesto izdanja i izdavač (distributer).

S druge strane, ako želimo citirati film kao takav, naveli bismo ga na ovakav način:

> *Ponoćni kauboj* (1969) režiser John Schlesinger [Film]. Los Angeles: United Artists.

## 13.2. POZIVNA BILJEŠKA

U dokumentacijsku osnovu rukopisa spada i bilješka. Širi joj je naziv *pozivna bilješka*, a često se koristi i izraz *napomena*. Prema mjestu stavljanja, bilješka je dobila još dva naziva: bilješka na *kraju/dnu stranice* ili fusnota, bilješka na *kraju poglavlja/cjeline* ili endnota. Bilješka ispunjava više potreba autora. Navedimo ih nekoliko:

a) U bilješci autor može navesti izvor citiranog, parafraziranog ili interpretiranog djela. Primjer tome je europski sustav citiranja.

b) U bilješci autor može ukazivati na dodatne izvore o istoj problematici (navođenje drugih autora, knjiga, članaka, zbornika radova i sl.).

c) Bilješka služi autoru i za proširivanje iznesenih argumenata. Npr. ako tekst ne trpi previše nabrajanja detalja, pozivanja na drukčije slučajeve iste problematike i sl., tada je autor sklon u bilješci proširiti argumentaciju za svoju tezu.

d) Često bilješka autoru služi i za navođenje drukčijih mišljenja. Time se u bilješci ograđuje od „neznanja" i potvrđuje svoju upoznatost s njima, ali i svoje neslaganje i vlastito viđenje problema.

## 13.3. ILUSTRACIJE

Pogledamo li neki znanstveni ili stručni tekst, uočit ćemo postojanje tekstualnog i ilustrativnog dijela. Ilustrativni je dio vrlo važna sastavnica svakog znanstvenog i stručnog djela jer omogućava bolju kvantifikaciju i vizualizaciju problematike o kojoj je u tekstu riječ. U ilustrativni dio spadaju *tablice*, *grafikoni*, *slike*, *zemljovidi*, *sheme* i sve ono što na neki način dopunjava tekstualni dio djela. Ako su ilustracije preuzete iz drugih izvora, obveza je autora to naznačiti i navesti izvor. Navedimo kao primjer tablicu i grafikon:

Svaka *tablica* treba imati *broj i naziv*, *metričku jedinicu*, *opis pojave*, *kvantitativna obilježja pojave*, *izvor* i, ako je potrebno, *napomenu* (za naznaku nekih odstupanja, predviđanja i sl.).

Kvantitativna obilježja tablice moraju se tekstualno interpretirati kako bi se ukazalo na značenje podataka u tablici za određenu pojavu o kojoj je u tekstu riječ.

*Tablica. Seosko stanovništvo RH u % (1953. – 2001.)*

| **REGIJA** | **1953.** | **1961.** | **1971.** | **1981.** | **1991.** | **2001.** |
|---|---|---|---|---|---|---|
| Središnja Hrvatska | 73,8 | 67,9 | 58,6 | 50,0 | 45,0 | 43,5 |
| Istočna Hrvatska | 77,5 | 71,7 | 64,5 | 52,8 | 47,4 | 46,9 |
| Gorska Hrvatska | 91,6 | 86,4 | 78,3 | 73,3 | 69,8 | 65,1 |
| Sjeverno Hrv. primorje | 60,0 | 50,1 | 41,8 | 34,5 | 33,2 | 35,8 |
| Južno Hrv. primorje | 76,7 | 71,2 | 60,3 | 44,3 | 39,7 | 36,1 |
| UKUPNO | 74,6 | 68,4 | 59,2 | 48,5 | 43,8 | 42,3 |

Izvor: Pokos, 2002: 41.

*Grafički prikaz* neke pojave (koja se može kvantificirati) vrlo je čest u znanstvenim i stručnim djelima, posebice danas kada je računalnim programima moguće relativno brzo napraviti vrlo precizne grafičke prikaze.

***Grafikone i tablice prije svega treba birati na temelju načela jasnoće i razumljivosti podataka koji se prikazuju.***

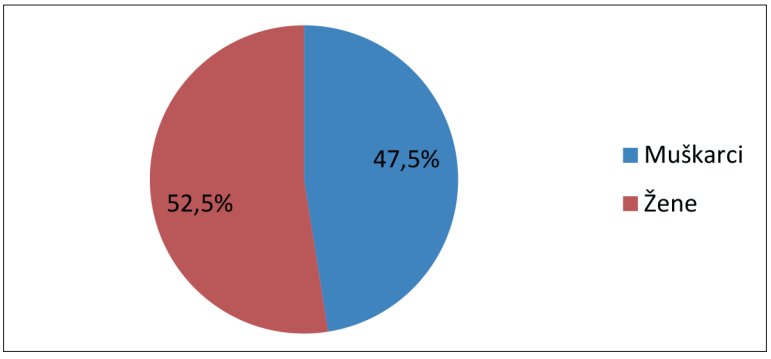
Kad je riječ o grafičkom prikazivanju podataka, potrebno je voditi računa da podatci budu prikazani jasno i razumljivo, tj. da estetski kriteriji budu podređeni kriteriju prenošenja informacija. U tom se smislu u praksi najčešće griješi prilikom upotrebe grafikona. Grafikoni se koriste u situacijama kada je najvažnije prikazati osnovna obilježja i sažeti dobivene podatke pa se stoga u pojedinim grafikonima ponekad i ne mogu pročitati precizni rezultati svih pojedinačnih

mjerenja. Prema kriteriju osnovnog sredstva pomoću kojeg su podatci prikazani, grafikone je moguće podijeliti na (1) površinske, (2) linijske, (3) prostorne (3D) i (4) kartograme. Površinski grafikoni prikazuju količine pomoću površine geometrijskih likova, dok linijski grafikoni koriste prikazivanje pomoću linije, a prostorni grafikoni geometrijska tijela. U kartogramima se koriste kombinacije geografskih karata i površinskih grafikona ili se pomoću malih slika ili točki prikazuje učestalost pojavljivanja nekog obilježja na nekom geografskom području (tzv. piktogram). S obzirom na učestalost korištenja, detaljnije ćemo prikazati prve dvije vrste – površinske i linijske grafikone.

Najvažnije su vrste površinskih grafikona koje ovdje prikazujemo kružni grafikoni (eng. *pie chart*), stupčasti grafikoni (eng. *bar chart*), grafikoni površine (eng. *area chart*) i histogrami.

Kružni grafikon koristi se u situacijama u kojima se želi vizualno prikazati odnos dijelova i cjeline, tj. kada ukupni podatci iznose 100%. Pri tome broj kategorija ne bi smio biti prevelik (najviše 5-6), a u slučaju velikog broja kategorije, udio nekih kategorija trebao bi biti istaknutiji. Primjerice, kružni grafikon sa sedam relativno podjednako zastupljenih kategorija ne bi bio osobito informativan. U niže navedenom primjeru kružnog grafikona prikazana je spolna struktura uzorka iz nekog istraživanja, a najjasniji ćemo prikaz ostvariti upravo ovim tipom grafikona jer je riječ o svega dvije kategorije, čija suma iznosi 100%, unatoč tome što je zastupljenost kategorija podjednaka.

*Grafikon 3. Primjer kružnog grafikona*

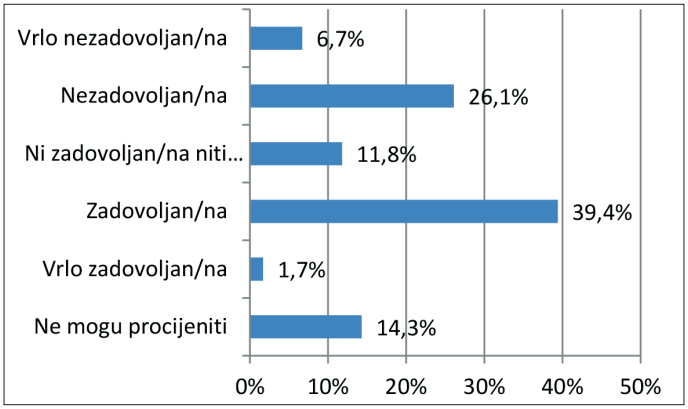



Stupčasti grafikon koristi se u dvije tipične situacije:

1. Prikazivanje rezultata na nekoj ordinalnoj ili intervalnoj varijabli,
2. Prikazivanje odnosa dijela i cjeline kada postoji veći broj kategorija pa je prikaz pomoću kružnog grafikona nedovoljno dobar.

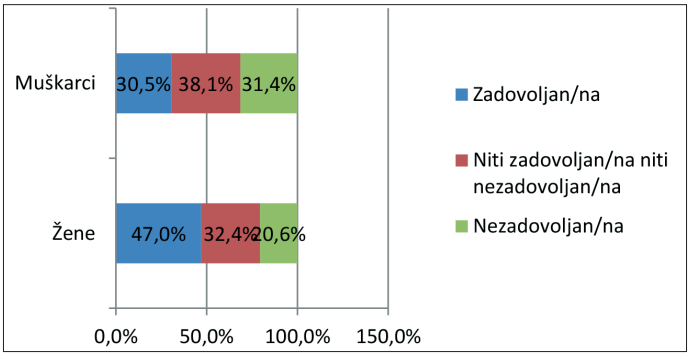
Stupčasti grafikon prikazan dolje pokazuje rezultate na ordinalnoj varijabli zadovoljstva kulturnim životom u jednom gradu, pri čemu je kao izdvojen rezultat naveden i udio sudionika istraživanja koji nisu mogli iznijeti svoju procjenu.

*Grafikon 4. Primjer stupčastog grafikona*




Ako se rezultati na nekoj nominalnoj ili ordinalnoj varijabli žele odvojeno prikazati prema kategorijama neke druge nominalne ili ordinalne varijable, tada se koriste *podijeljeni stupčasti grafikoni*. Primjerice, u donjem su grafikonu pojedine razine zadovoljstva kulturnim životom prikazane posebno za muškarce i posebno za žene.

*Grafikon 5. Primjer podijeljenog stupčastog grafikona*

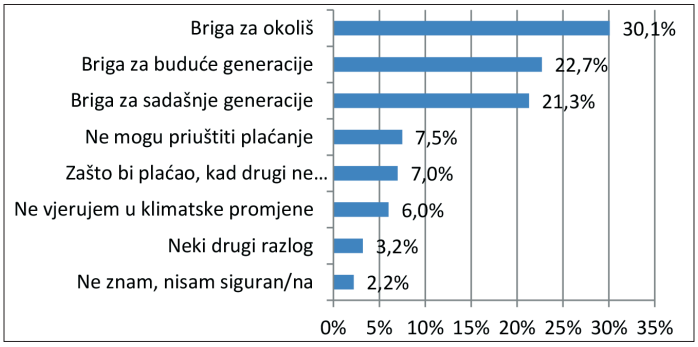



Ako se pomoću stupčastog grafikona prikazuje distribucija rezultata na nekoj intervalnoj ili omjernoj varijabli, tada se takav grafikon obično naziva *histogramom frekvencija*.

Sljedeći primjer stupčastog grafikona prikazuje odgovor na pitanje o najvažnijem razlogu (ne)plaćanja potencijalne ekološke rente. Iako je i ovdje riječ o odno-

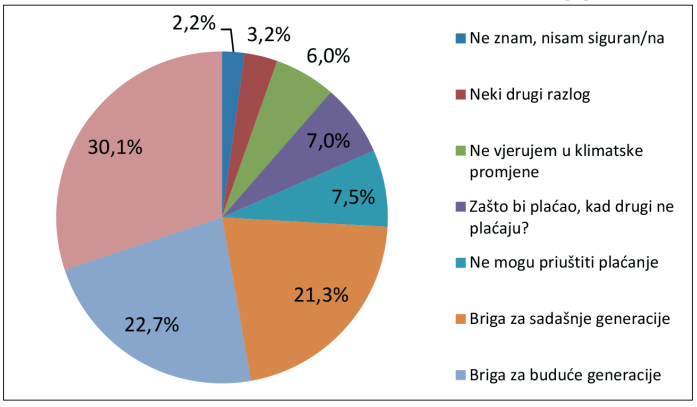
su dijelova i cjeline, tj. zbroj odgovora iznosi 100%, korištenje kružnog grafikona dalo bi slabije rezultate zbog većeg broja kategorija. Prikazivanje frekvencije odgovora u pojedinim kategorijama od najučestalije do najmanje učestale dodatno pridonosi jasnoći prikazanih podataka i njihovu brzom shvaćanju.

*Grafikon 6. Primjer stupčastog grafikona kod većeg broja kategorija*




Isti podatci dolje su prikazani u kružnom grafikonu, a taj prikaz ilustrira ranije navedenu postavku prema kojoj je taj grafikon manje pogodan za veći broj kategorija. Očito je da se u tom slučaju teško orijentirati i brzo razabrati udjele pojedinih odgovora, a u svakom je slučaju to znatno teže napraviti nego u slučaju primjene stupčastog grafikona.

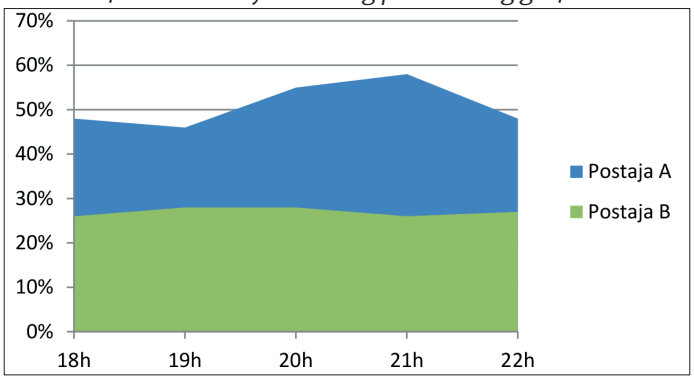
*Grafikon 7. Primjer neadekvatne upotrebe kružnog grafikona*




Grafikon površine (eng. *area chart*) najčešće se koristi za prikazivanje niza kategorija jedne varijable prema kategorijama neke druge varijable, najčešće vremena. Pri tome se odnos među varijablama može pročitati iz odnosa površina ispod linija koje pokazuju pojedine kategorije. U donjem grafikonu prikazani su udjeli u gledanosti dviju TV-postaja u terminu 18 do 22 h, a odnos između gledanosti

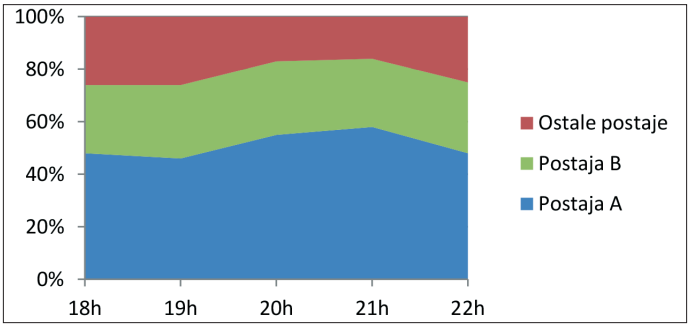
ovih postaja može se brzo razumjeti iz odnosa površina ispod linija. Tako npr. odmah možemo primijetiti da je razlika u gledanosti između postaje A i postaje B najmanja u 19 h, a najveća u 21 h.

*Grafikon 8. Primjer običnog površinskog grafikona*



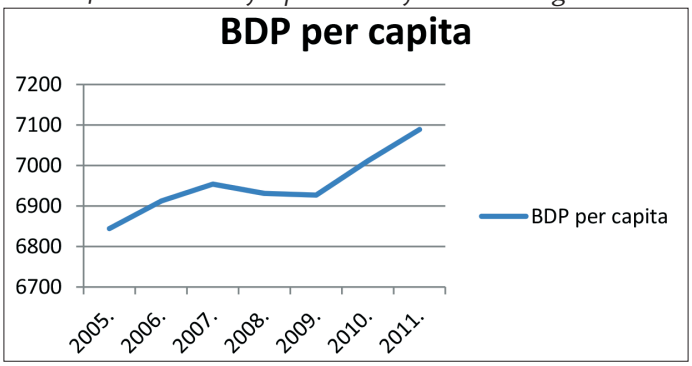

Ako je naglasak na prikazivanju udjela pojedinih kategorija u ukupnom iznosu varijable, tj. na prikazivanju postotaka čiji je ukupni zbroj 100%, tada obično koristimo tzv. *stožasti grafikon površine* (eng. *stacked area chart*). Na donjem grafikonu ove vrste prikazani su prethodno navedeni podatci kojima su dodane i ostale postaje. Iz tog grafikona odmah možemo uočiti da TV postaja B ima stabilan udjel u gledanosti, dok udjeli postaje A i ostalih postaja izrazitije variraju.

*Grafikon 9. Primjer stožastog površinskog grafikona*



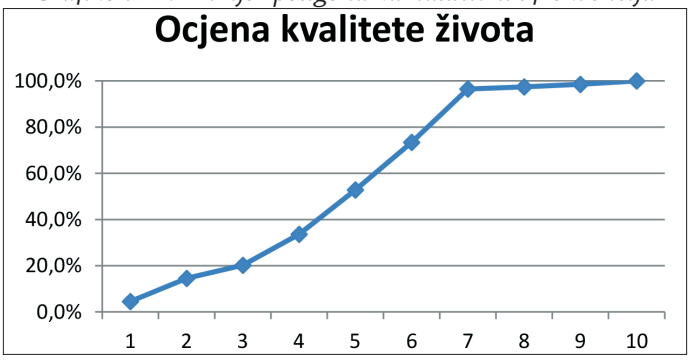

Linijski grafikon najčešće se koristi za prikazivanje vremenskih trendova neke varijable, tj. kretanje njezine vrijednosti tijekom vremena ili općenito u onim situacijama u kojima se pomoću linije želi ilustrirati dinamika raspodjele neke varijable. Prikaz vremenskih trendova varijabla najčešće se prikazuje na x-osi, a varijabla čije se kretanje prati tijekom vremena na y-osi. U donjem primjeru prikazan je linijski dijagram za prikazivanje vremenskog trenda kretanja *BDP-a per capita* neke države.

*Grafikon 10. Primjer prikazivanja vremenskog trenda*




Česta je primjena linijskog grafikona u obliku tzv. *poligona kumulativnih frekvencija*. U njemu se prikazuje broj ili udio podataka koji su jednaki nekom broju (rezultatu) ili manji od njega. Primjerice, uzmimo da smo od sudionika nekog istraživanja tražili da svoju kvalitetu života procijene na skali od 1 do 10, a rezultate smo prikazali na grafikonu kumulativnih frekvencija. Vidljivo je da iz njega odmah razabiremo da su gotovo svi sudionici svoju kvalitetu života ocijenili s ocjenom 8 ili nekom od nižih ocjena.

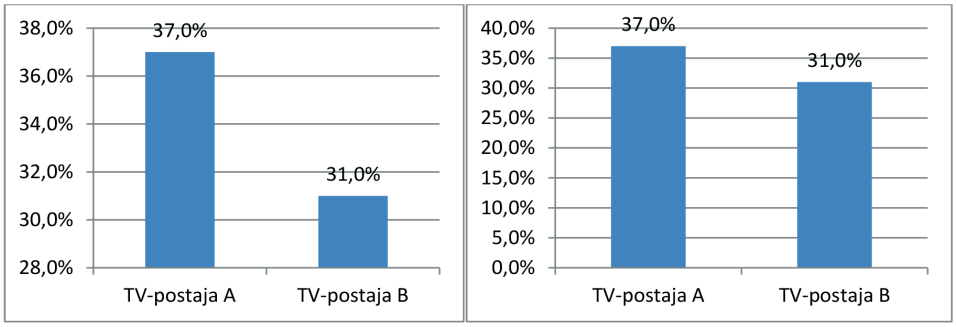
*Grafikon 11. Primjer poligona kumulativnih frekvencija*




Jedna je od stvari koju treba imati na umu prilikom crtanja grafikona izbor početne točke na osi(ma). Naime, različite početne točke mogu dovesti do posve različitog vizualnog dojma o podatcima. Ilustrirajmo to primjerom situacije u kojoj stupčastim grafikonom prikazujemo rejting dvije TV-postaje, od kojih prva ima rejting od 38%, a druga rejting od 31%. Iz donjih grafikona vidljivo je da će se razlika između ovih postaja na prvi pogled učiniti manje neizraženom ako smo kao početnu točku uzeli nulu, dok će razlika izgledati dramatično velika ako kao početnu točku uzmemo neki veći broj – u ovome slučaju 28%. Ovdje valja napo-

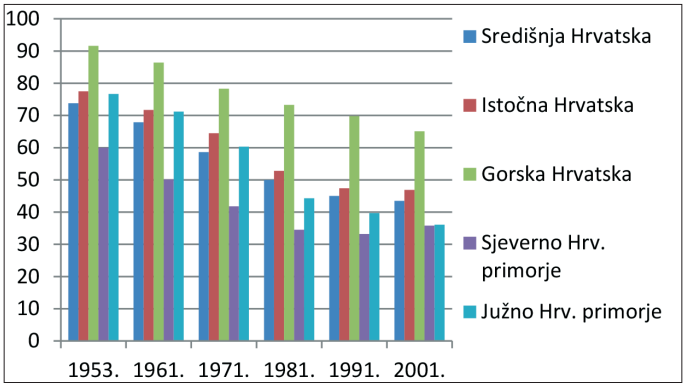
menuti da nijedan od tih prikaza nije pogrešan sâm po sebi, nego su u pitanju različiti prikazi. U slučaju izbora početne točke veće od nula, bit će moguće bolje razlučiti male razlike između vrijednosti na vertikalnoj osi, no razlika između postaja bit će naglašenija. U slučaju izbora nule kao početne točke, malene razlike između stupaca, pogotovo ako ih na grafikonu ima više, bit će teže zamjetljive, no razlika između vrijednosti na vertikalnoj osi bit će manje naglašena.

*Grafikon 12. Ilustracija važnosti izbora početne točke*




Kao i tablica i grafikon treba sadržavati broj i naziv, ishodište ili nultu točku, jedinično mjerilo, obilježenu os x i os y, prikaz frekvencija, legendu (tj. tumač prikazane pojave). Redni broj i ime najčešće se pišu iznad grafikona, a legenda i izvor u pravilu se pišu ispod ili unutar grafikona. Donji grafikon predstavlja primjer pravila označavanja.

*Grafikon 13. Seosko stanovništvo RH prema regijama u % (1953. – 2001.)*




Izvor: Pokos, 2002: 41.

## 13.4. LITERATURA

Već spomenuti sustavi navođenja izvornog djela prilikom citiranja, parafraziranja ili interpretiranja važni su i za izradu popisa korištenih izvora, tj. *literature ili bibliografije*, jednog od glavnih dijelova znanstvenog ili stručnog djela. Sâm autor odlučuje[95] na koji će način navoditi citate, parafraze i interpretacije pa prema tome ustrojava i popis literature.

**Europski sustav** pisanja literature ustrojava se tako da se bibliografske jedinice slažu prema abecednom poretku prezimena autora, urednika zbornika, prve riječi nekog dokumenta, pravilnika, strategije i slično. Navedimo nekoliko primjera:

Knjiga:
Milas, Goran*: Istraživačke metode u psihologiji,* Naklada Slap, Zagreb, 2009.

Zbornik radova:[96]
Granovetter, Mark – Swedberg, Richard (eds.): *The Sociology of Economic Life*, Westview Press, Cambridge, 2001.

Poglavlje u knjizi:
Lebert, D., Vercellone, C.: *Uloga znanja u dinamici dugog razdoblja kapitalizma: hipoteze o kognitivnom kapitalizmu*, u knjizi: Vercellone, Carlo: *Kognitivni kapitalizam*, Politička kultura, Zagreb, 2007., str. 15-28.

Članak u časopisu:
Šundalić, A., Pavić, Ž.: *Između vrijednosti obrazovanja i negativnog sociokulturnog nasljeđa*, „Društvena istraživanja", Vol. 20(2011), No 4(114), str. 943-965.

Znanstveni i stručni priručnik:
*Hrvatska književna enciklopedija*, Leksikografski zavod Miroslav Krleža, Zagreb, 2010.

**Američki ili harvardski** sustav pisanja literature sve je više u uporabi. Taj sustav prati tehniku označavanja citata, parafraze i interpretacije. U dijelu *Literatu-*

---

95 Osim autora, odluku o sustavu citiranja i načina pisanja literature može donijeti uredništvo nekog časopisa ili izdavač, ali i recenzenti.

96 Zbornici radova više autora imaju jednog ili više urednika pa se to u zagradi treba naznačiti, npr. (ur.) – ako je knjiga na hrvatskom jeziku, (ed.) – ako je knjiga na engleskom jeziku, kao u našem primjeru.

*ra* navode se izvori (bibliografske jedinice) abecednim redom prezimena autora, ili naslova dokumenata, pravilnika, strategija i slično. Tek tu čitatelj dobiva punu informaciju o korištenom izvoru. Navedimo nekoliko primjera:

Knjiga:
Milas, Goran (2009). *Istraživačke metode u psihologiji,* Zagreb, Naklada Slap.

Zbornik radova:
Granovetter, M., Swedberg, R. (2001). *The Sociology of Economic Life*, Cambridge, Westview Press.

Znanstveni i stručni priručnik:
*Hrvatska književna enciklopedija* (2010). Zagreb, Leksikografski zavod Miroslav Krleža.

Također treba napomenuti da se u literaturi mogu klasificirati izvori na više načina. Mogu se odvojeno prikazati *korišteni* izvori od *preporučenih* (koji mogu biti spomenuti u tekstu). Nadalje izvori se mogu klasificirati prema *vrsti publikacije*. Na primjer:

a) Knjige,
b) Zbornici radova,
c) Članci,
d) Priručnici,
e) Internetski izvori,
f) Ostalo (zakoni, dokumenti, pravilnici i sl.).

Popis literature u pravilu se stavlja na kraju djela, prije dodataka. No moguće je, prema odluci autora, izdavača ili urednika, popis korištene literature stavljati na kraju svake cjeline djela. Također je u nekim časopisima korištena literatura prikazana kao bilješka na kraju stranice (fusnota) ili na kraju poglavlja (endnota).

## DODATNA LITERATURA UZ TRINAESTO POGLAVLJE

Schimel, Joshua (2012). *Writing Science: How to Write Papers That Get Cited And Proposals That Get Funded*. Oxford: Oxford University Press.

Knjiga se bavi narativnom strukturom znanstvenog djela te pomoću niza primjera pokazuje kako rezultate vlastitih istraživanja učiniti zanimljivijim i prezentirati na što jednostavniji način.

## PITANJA UZ TRINAESTO POGLAVLJE

1. Koje norme autor treba poštivati pri pisanju znanstvenog ili stručnog djela?
2. Što čini „dokumentacijsku osnovu rukopisa“?
3. Kada autor navodi izvor iz kojega je neka misao preuzeta, koje načelo i zakonsko pravo time poštuje?
4. Što je citiranje, što parafraziranje, a što interpretiranje tuđe misli?
5. Koja su dva načina citiranja danas najprisutnija?
6. Kakav je europski sustav citiranja?
7. Kakav je američki ili harvardski sustav citiranja?
8. Za što autor znanstvenog ili stručnog djela koristi bilješku (ili pozivnu bilješku)?
9. Što sve čini ilustrativni dio teksta?
10. Koje su najvažnije vrste grafikona i kada se koriste pojedine vrste?
11. Zašto je izbor početne točke važan prilikom crtanja grafikona?
12. Koje dijelove treba imati tablica?
13. Kakav je europski sustav pisanja literature?
14. Kakav je američki ili harvardski sustav pisanja literature?
15. Kako se u literaturi mogu klasificirati izvori?
16. Kako se u literaturi klasificiraju izvori prema vrsti publikacije?

# 14. OBJAVLJIVANJE ZNANSTVENOG I STRUČNOG DJELA

Svrha je svakog pisanja konačno objavljivanje teksta. Bilo da je riječ o znanstvenom ili stručnom pisanju, o pisanju monografije, poglavlja za knjigu, članka za časopis, natuknice za enciklopediju i dr., pretpostavka je svakoga autora da će taj tekst netko čitati. Posebice kada je riječ o djelima namijenjenim stručnoj, kvalificiranoj čitateljskoj populaciji, autor mora voditi računa o pravilima pisanja, kao i o elementima strukture koje njegovo djelo treba sadržavati. Osim o formalnoj strukturi, autor bi trebao voditi i računa o nekim etičkim načelima vezanim uz objavu istraživanja. Tako je posve neprihvatljivo rad zasnovati na nepostojećim (izmišljenim) ili „uljepšanim" podatcima. Osim ovakvih težih prekršaja, postoji i niz dvojbenih postupaka koji se tiču integriteta objavljenih znanstvenih radova:[97]

1. Predaja rada na objavljivanje u više časopisa (u nadi da će biti prihvaćen u barem jednom),
2. Objavljivanje rada u više časopisa,
3. Objavljivanje radova koji su vrlo slični prethodnim vlastitim radovima,
4. Dijeljenje jednog rada u više radova bez opravdanog razloga,
5. Upitno autorstvo („dopisivanje" kolegâ kao suautora iako nisu sudjelovali u izradi rada),
6. Nemaran odnos prema podatcima (nečuvanje originalnih podataka, nepotpuno citiranje i sl.),
7. Konflikt interesa (npr. pozitivno pisanje o proizvodima tvrtke koja financira istraživanje).

***Prilikom objave znanstvenog i stručnog djela treba voditi računa o etičnosti objavljivanja, osobito kada su u pitanju konflikt interesa i autorstvo samoga djela.***

## 14.1. FORMA ILI OBLIK PISANJA

U 12. poglavlju prikazana je struktura znanstvenog i stručnog djela. Već prema tome kakvo je djelo, takvi su i zahtjevi prema njegovoj strukturi. Očekivati je da će glavni dijelovi biti zastupljeni u strukturi svakog djela,[98] dok će ovisno o pre-

[97] Prerađeno prema Kataviću (2010: 290).

[98] Ako ta zastupljenost i ne bude eksplicitno nabrojana, ona ipak može biti prisutna. Na primjer, u uvodni dio često se ugradi metodološki okvir djela.

tenzijama autora ili zahtjevima izdavača i recenzenata biti primjereno zastupljeni orijentacijski i pomoćni dijelovi.

Nadalje, kada je riječ o *formi* ili *obliku pisanja*, autor mora udovoljavati kriterijima jednog od odabranih oblika. To znači da ako se opredijeli za europski oblik pisanja i europski sustav citiranja, tada cijeli tekst mora biti pisan u istom stilu. Uvriježilo se razlikovati tri oblika pisanja:

**Europski oblik**: svaka nova misao počinje novim odjeljkom čiji se prvi redak uvlači. Na primjer:

> *Drugi esej, Globalizirajuće norme, polazi od konstatacije da se globalni sustav strukturno još stvara te pri tome nailazi na brojne zapreke. To je posebice uočljivo na primjeru stvaranja globalne kulture.*
>
> *U eseju Vrijednosti i sposobnosti autor propituje sastavnice funkcioniranja kapitalizma kao što su kapital, radnici i roba. No svemu tome smisao daje potrošnja, tj. društvo samo.*

**Američki oblik**: svaka nova misao počinje novim odjeljkom s povećanim razmakom od prethodnog odjeljka, ali bez uvlačenja prvog retka. Na primjer:

> *Drugi esej, Globalizirajuće norme, polazi od konstatacije da se globalni sustav strukturno još stvara te pri tome nailazi na brojne zapreke. To je posebice uočljivo na primjeru stvaranja globalne kulture.*
>
> *U eseju Vrijednosti i sposobnosti autor propituje sastavnice funkcioniranja kapitalizma kao što su kapital, radnici i roba. No svemu tome smisao daje potrošnja, tj. društvo samo.*

Postoji i **kombinirani oblik**: riječ je o kombinaciji europskog i američkog oblika, tj. nova misao počinje povećanjem razmaka od prethodnog odjeljka i uvlačenjem prvog retka. Na primjer:

> *Drugi esej, Globalizirajuće norme, polazi od konstatacije da se globalni sustav strukturno još stvara te pri tome nailazi na brojne zapreke. To je posebice uočljivo na primjeru stvaranja globalne kulture.*
>
> *U eseju Vrijednosti i sposobnosti autor propituje sastavnice funkcioniranja kapitalizma kao što su kapital, radnici i roba. No svemu tome smisao daje potrošnja, tj. društvo samo.*

## 14.2. STIL PISANJA

Poznato je da je stil znanstvene monografije drukčiji od stila beletrističkog djela, da je esej drukčije pisan od izvješća sudskog vještaka s mjesta nesreće i slično. No, korisno je postaviti pitanje zašto u pisanim djelima nalazimo različite stilove pisanja. Odgovor je u *svrsi djela* i *vjerodostojnosti autora* djela.

Na primjer, ako je svrha djela izvješće za naručitelja istraživanja o rezultatima istraživanja, utrošenim sredstvima, uključenim istraživačima, fazama istraživačkog procesa, neplaniranim teškoćama i dodatnim troškovima, tada se ne očekuje drugo do činjenično, argumentirano nabrajanje i obrazlaganje svega potrebnog za cjelinu koju izvješće predstavlja. Autor svoju vjerodostojnost potvrđuje argumentacijom ispunjenja ugovornih obveza i ostvarenim rezultatima, a ne ljepotom stila pisanja.[99]

Kada, pak, autor svojim osebujnim načinom prikazivanja neke povijesne ili religijske teme želi privući pozornost šire javnosti, neopterećen istinom i povijesnom argumentacijom već nošen žarom umjetničkog izražaja, tada je stil književni, beletristički, a čitatelji ne traže istinu već umjetnički doživljaj. Vjerodostojnost autora je u njegovoj sposobnosti književnog izražaja.[100]

R. Zelenika (1998: 529-531) navodi šest stilova pisanja:

**Razgovorni stil**, kao posebna forma književnog dijaloga među sugovornicima, vrlo jednostavan za razumijevanje.

**Znanstveni stil** je svojstven pisanju znanstvenika. Nije mu cilj naširoko opisivati pojave, uljepšavati formu izričaja kako bi se svidio čitateljima, već *jasno* i *precizno*, što je moguće *jednostavnije* prikazati činjenice znanstvenog istraživanja. Znanstveni stil obilježava i *uporaba znanstvenih pojmova* koji diferenciraju znanosti međusobno, ali i znanstveno od neznanstvenog pisanja.

**Administrativni stil** obilježava kratkoća i jasnoća, ustaljene forme izražavanja, a sve u cilju preciznog opisivanja konkretnog predmeta.

**Književnoumjetnički stil** nema pretenzije biti intelektualan, već je prije svega izraz mašte i umjetničke imaginacije. U njemu se posebno njeguje književni jezik, koriste dijalekti i sve potrebno da bi se što više osvojila čitateljska publika.

**Publicistički stil** je svojstven novinarskom izvještavanju. Jasnoća, kratkoća, aktualnost teme, ali i autorov polemički pristup temi, kojim utječe na čitatelje, prisutni su u publicističkom stilu pisanja.

---

99 Primjer ovoga je godišnje izvješće o tijeku i rezultatima znanstvenih projekata koje nositelji projekata moraju podnijeti naručitelju.

100 Kao dobar primjer može poslužiti roman *Da Vincijev kod* Dana Browna u kojemu se vjerska tema Isusova života ne prikazuje na evanđeoski način, već umjetnički slobodno i bez stvarnih povijesno utvrđenih činjenica.

**Znanstveno-popularni stil** predstavlja kombinaciju znanstvenog, književnog i publicističkog stila. Ne obraća se samo znanstvenoj javnosti, već široj čitateljskoj publici pa stoga mora biti pristupačan u prikazivanju nekih znanstvenih rezultata.

Ukratko ćemo prikazati **obilježja znanstvenog stila** pisanja koji je svojstven znanstvenim i stručnim djelima. Naime, znanstvena i stručna djela povezuje uporaba znanstvene metodologije u istraživanju, obraćaju se uglavnom istoj populaciji koja ne mora uvijek tražiti znanstveni doprinos djela, što je svojstveno znanstvenim djelima, već upoznavanje s postojećim spoznajama, njihovom primjenom u svakodnevici i slično.

Znanstvenik, pišući znanstveno ili stručno djelo, treba voditi računa o sljedećim *zahtjevima pisanja*: jasnoća i jednostavnost misli, precizna uporaba pojmova, skladnost i sustavnost u slijedu izlaganja, oblikovanje cjeline izloženog problema.

**Jasnoća i jednostavnost misli** zahtjev je koji se postavlja pred svakog autora znanstvenog i stručnog teksta. Udovoljiti mu može onaj koji je sposoban i najsloženije probleme izložiti na razumljiv i jednostavan način. Jasnoća izloženih misli znači da čitatelj razumije tekst na isti način kao i autor teksta. Ako tekstom prevladava nejasnoća i zbrkanost misli, kaže se da tada ni sâm autor nije dorastao problemu o kojemu piše.

**Precizna uporaba pojmova** također se traži u znanstvenom stilu pisanja. Kako je istaknuto u trećem poglavlju, preciznost je bitno obilježje znanosti pa je očekivati da se to potvrdi upravo u znanstvenom i stručnom tekstu. Preciznost se posebno traži pri uporabi znanstvenih pojmova, definicija i klasifikacija kako se ne bi višeznačno koristili.

**Skladnost i sustavnost u slijedu izlaganja** zahtjev je za smislenom povezanošću dijelova i logičkim slijedom izlaganja problema. To znači da manje cjeline trebaju prema smislu biti dijelom veće cjeline, da se problem prikazuje u fazama rješavanja (od početne, niže, jednostavnije prema višoj, završnoj fazi) bez preskakanja i vraćanja na već rečeno i slično.

**Oblikovanje cjeline izloženog problema** uvjet je koji u sebi sadrži više elemenata. Svako djelo treba udovoljiti *kriteriju cjelovitosti*, posebice kada je riječ o znanstvenom prikazivanju rezultata istraživanja. Pri tome valja voditi računa o *ekonomičnosti* prikazivanja rezultata (bez nepotrebnih opisivanja, bez nepotrebnog ponavljanja i sl.). Nadalje je važno u oblikovanju cjeline teksta voditi računa o *racionalnosti strukture* djela (osim uvažavanja neizbježnih glavnih dijelova, au-

tor mora racionalno pristupiti i korištenju poglavlja i potpoglavlja kako se zbog množine podjela ne bi izgubio smisao cjeline).

## 14.3. ZNANSTVENA I STRUČNA KRITIKA RADA

Svaki znanstveni i stručni rad, kada je predan na uvid javnosti, ne može izbjeći kritici. Bilo da je riječ o pohvalama i isticanju znanstvenih inovacija i doprinosa, bilo da je riječ o neprihvaćanju glavnih teza i isticanju slabosti djela, uvijek je na djelu kritika. Nju mogu izreći znanstvenici i stručnjaci, ali u posebnim okolnostima i šira društvena javnost.[101]

Kritika objavljenog znanstvenog ili stručnog djela je *javna ocjena djela*. Može biti (1) u *pisanoj formi* kao prikaz djela u nekom časopisu, novinama, ili na internetu; (2) u *govornoj formi* kao prikaz na radiju, ili na televiziji, ali i kao (3) *rasprava* na nekom okruglom stolu ili seminaru (kao dijalog ili polemika).

Kritiku treba shvaćati kao pozitivan doprinos vrijednosti nekog djela, a da bi to bila kritika, prema Lj. Babanu (2000: 197), treba biti:

*a) Objektivna*, dakle ni „za" ni „protiv" djela već o djelu.

*b) Pozitivno usmjerena*, tj. ne treba joj biti cilj „pokopati" djelo i autora, već poticajno djelovati ukazivanjem na ono dobro u djelu (formi, sadržaju, metodologiji i sl.).

*c) Cjelovita i svestrana* u analizi djela bez namjere „hvatanja u koštac" s jednim poglavljem ili jednom tezom. Posebice nije prihvatljivo u kritici vaditi iz konteksta pojedine teze, jer tada se najčešće događaju pogreške u interpretaciji i razumijevanju.

*d) Vremenski određena* kritika je ona koja uzima u obzir vrijeme u kojemu je djelo nastalo i prevladavajuće okolnosti toga vremena koje su mogle utjecati na djelo (njegovu formu, način izražavanja, eksplicitnost i sl.).

Posebno je važno istaknuti da kritika treba biti *stručna*. To znači da kritiku nekog znanstvenog ili stručnog djela trebaju pisati znanstvenici i stručnjaci za područja u kojima su stručni. Primjer stručne kritike je recenzija.

---

[101] Javnost može izraziti kritiku nekog djela primjenom njegovih rezultata u svakodnevnoj uporabi. Također, javnost daje sud o nekom djelu u vidu „povijesne kritike": neko djelo procjenjuje kao promašaj, zabludu ili mu pripisuje veliki povijesni doprinos.

**Recenziju** nekog znanstvenog i stručnog djela pišu stručnjaci za područje na koje se djelo odnosi. Svrha recenzije kao kritike provjera je vrijednosti djela s više aspekata:

1. s aspekta *znanstvenosti* (postoji li znanstveni doprinos),
2. s aspekta *forme i stila pisanja* (dosljednost u cijelom tekstu),
3. s aspekta *strukturiranosti teksta* (kako je tekst organiziran),
4. s aspekta *originalnosti pristupa* (u uporabi metoda, interpretaciji rezultata i sl.),
5. s aspekta *jasnoće i utemeljenosti zaključaka* (slijedi li zaključak iz prethodnog teksta),
6. s aspekta *aktualnosti teme* (zanimljiva ili već bezbroj puta obrađena problematika),
7. s aspekta *mogućih korisnika djela* (kome je djelo namijenjeno).

Recenziju djela obično piše nekoliko (najčešće dva) anonimna recenzenta, tj. znanstvenika čiji je identitet poznat samo uredništvu publikacije, ali ne i autoru djela koje se recenzira za objavljivanje u publikaciji. Anonimnost recenzenta omogućava kritiku oslobođenu od straha od negativnih posljedica, no za sobom povlači i niz etičkih pitanja (prema Bird i Housmanu, 1997). Naime, recenzent je obično osoba koja se u svom istraživačkom radu bavi područjem kojim se bavi i rad koji se recenzira. Stoga, u interesu recenzenta može biti onemogućavanje objave publikacije, tj. davanje negativne recenzije ili odugovlačenje s recenzijom kako bi vlastiti rezultati bili objavljeni prije recenziranog djela.

Osim recenzije i prikaza, u znanosti je kao kritika prisutna i polemika. Dok je **prikaz** nekog znanstvenog, stručnog ili umjetničkog djela usmjeren na upoznavanje stručne i šire javnosti s njegovom pojavom, strukturom, stilom, znanstvenim, stručnim ili umjetničkim pretenzijama i sl., **polemika** predstavlja sučeljavanje protuteza onima izloženima u djelu s kojim netko polemizira. Cilj je polemike oštrom, ali etičkom raspravom doći do istine o problemu koji je predmet polemike.

## 14.4. UVJETI OBJAVLJIVANJA RUKOPISA

Da bi neki rukopis ugledao svjetlo dana i doživio znanstvenu i stručnu kritiku, prvo mora udovoljiti uvjetima objavljivanja ili tiskanja. Uvjete možemo podijeliti na one tehničke naravi i one znanstvene naravi.

**a) Uvjeti znanstvene naravi** uglavnom su prikazani u prethodnom poglavlju, posebice u odlomku o recenziji. Naime, tek kada su za neko djelo dobivene (1) najmanje dvije pozitivne recenzije, djelo može biti objavljeno. Nadalje, (2) struktura djela mora udovoljavati znanstvenoj metodologiji. (3) Odabir i korištenje istraživačkih metoda i tehnika mora biti primjeren predmetu istraživanja, kao i sve drugo što recenzijama treba biti analizirano.

**b) Uvjeti tehničke naravi** odnose se na sve radnje koje treba obaviti da bi znanstveno i stručno djelo došlo pred čitatelja. Prije objavljivanja svako se djelo mora:

a) *lektorirati* (autorski rukopis lektor kao stručna osoba treba urediti i uskladiti s pravopisnnom i jezičnom normom)

b) *redakcijski urediti* (utvrđivanje opsega rada, izbor tipa slova, proreda, načina isticanja u tekstu, načina pisanja bilježaka, literature, izbor uveza i dr.),

c) *korigirati tiskarske* pogreške (korekturu mogu napraviti autor ili lektor, ili oboje),

d) *uvezati* (vodi se računa o financijskoj strani, marketinškoj, estetskoj).

Posebno je važno *opremanje* svakog djela onim dijelovima bez kojih bi ono bilo nepotpuno. Ti takozvani formalni dijelovi su:

*Ime autora* (i suautora, urednika, ako ih je više),

*Naslov rada* (primjeren predmetu koji djelo donosi, niti prekratak niti predugačak, može biti popraćen podnaslovom),

*Naslovna stranica* (najčešće donosi naslov rada, ime izdavača, mjesto i godinu izdanja, a sve je to najčešće grafički dizajnirano u dogovoru autora i izdavača),

*Impresum* (sadrži za tiskano djelo skupinu važnih podataka kao što su: ime izdavača, mjesto izdanja, godina izdanja, imena recenzenata, ime lektora, ime izvršitelja sloga i tiska, CIP te brojeve UDK, ISBN),[102]

*Ime institucije koja daje potporu* tiskanju djela (npr. „Knjiga je tiskana uz potporu Ministarstva znanosti, obrazovanja i sporta RH.“).

---

[102] CIP je skraćenica od *Cataloguing in Publication* (katalogizacija u publikaciji), a omogućuje povezivanje izdavača, knjižnicu i korisnika knjige.
UDK znači „univerzalna decimalna klasifikacija“ prema kojoj se djela klasificiraju u jednu od 10 skupina. To su: 0. opća djela, 1. filozofija, 2. religija, 3. društvene znanosti, 4. filologija, 5. prirodne znanosti, 6. primijenjene znanosti, 7. umjetnost, 8. jezici, književnost, 9. geografija, povijest.
ISBN je kratica od *International Standard Book Number* (međunarodni standardni književni broj). Taj se broj dodjeljuje svakoj knjizi zasebno (za svaku je knjigu jedinstven). Deset znamenaka ISBN-a označavaju zemlju, izdavača, naslov i kontrolni broj (detaljnije vidi u Zelenika, 1998: 562-569).

Prije samog tiskanja knjige važno je također odrediti veličinu i tip slova, širinu margina, format papira, gramaturu papira, kvalitetu papira kao i vrstu uveza.

## 14.5. KAKO PISATI?

Studenti se tijekom godina studija susreću s brojnim obvezama među kojima je nezaobilazna pisanje. Pisanje *seminarskog rada* tijekom preddiplomskog, diplomskog i poslijediplomskog studija, *završnog rada* preddiplomskog studija, stručnog *magistarskog rada* na kraju diplomskog studija, kao i doktorske disertacije na kraju poslijediplomskog studija jesu obveze koje treba odraditi prema važećim pravilima pisanja. Navest ćemo naputke kako pisati a) seminarski rad, b) završni rad c) diplomski rad i d) doktorsku disertaciju.

### 14.5.1. Seminarski rad

*Seminarski rad* pišu studenti tijekom preddiplomskog, diplomskog i poslijediplomskog studija. Već prema razini studija razlikuju se očekivanja od seminarskog rada (zahtjevnost teme, opseg rada, trajanje izrade rada, uključenost pojedinca ili tima studenata i sl.). U pravilu seminarski rad je stručni rad koji bi trebao prezentirati *korištenje primjerenih znanstvenih metoda* i imati *osnovnu strukturu* (naslov, uvod, raspravu, zaključak i literaturu). Nastavnik je ovdje uključen kao mentor, no ne i onaj koji odabire seminarsku temu i određuje literaturu. U tome studenti trebaju biti samostalni. No, nastavnik im mora odrediti tematski okvir vezan uz predmet u kojemu trebaju birati seminarske teme. Seminarski rad može pisati jedan ili više studenata i on se u pravilu referira na seminaru te se o temi vodi seminarska rasprava.

### 14.5.2. Završni rad

*Završni rad* na kraju preddiplomskog dijela studija piše se iz područja nastavnog programa preddiplomskog studija. U njemu student treba pokazati ovladanost gradivom koje se obrađuje u odabranoj temi, kao i istraživačkim metodama koje koristi. Također, u radu student treba pokazati snalaženje u stručnoj literaturi, njezino korištenje (citati, parafraziranja, interpretacije), ali i sposobnost zaključivanja koje je u smislenoj vezi s cjelinom teksta. Temu završnog rada student bira uz pomoć mentora, prema mogućnosti što samostalnije, i ona treba biti za-

htjevnija u odnosu na seminarski rad. Piše je uvijek jedan student. U pravilu, završni rad bi trebao sadržavati naslov, sažetak s ključnim riječima, uvod, raspravu, zaključak, literaturu te priloge (popis tablica, slika, kratica i dr.). Opseg rada je u pravilu između 15 i 20 stranica.

### 14.5.3. Diplomski rad

*Diplomski rad* piše se na kraju diplomskog dijela studija. On treba biti prikaz ili izvještaj o određenom predmetu U istraživanju literature ili u empirijskom istraživanju uz pomoć spoznaja koje daje literatura. Pristup problemu, strukturiranje rada, odabir i korištenje metoda i tehnika istraživanja, korištenje literature, stručnost izražavanja o problematici rada, sve to treba biti na jednoj višoj razini zrelosti i stručnosti u odnosu na završni rad. Pri odabiru teme diplomskog rada student se konzultira s mentorom tako da piše kratki projekt rada, ili da oblikuje dispoziciju rada kako bi se unaprijed postavili okviri za pisanje rada. Student tada treba biti samostalan i donekle originalan u zaključcima (ne traži se originalnost u smislu znanstvene izvornosti i doprinosa). Diplomski rad treba sadržavati sljedeće dijelove: sažetak i ključne riječi na jeziku na kojem je rad napisan, uvod, metodološki dio, raspravu, zaključak i literaturu, te priloge (popis tablica, slika, kratica i dr.), i to navedenim redoslijedom. Opseg rada je u pravilu između 30 i 50 stranica.

### 14.5.4. Doktorska disertacija

*Doktorska disertacija* piše se na kraju poslijediplomskog doktorskog studija. Doktorski studij upisuju polaznici koji udovoljavaju uvjetima natječaja (najčešće je to završen odgovarajući fakultet s prosječnom ocjenom studija iznad 4,0). Očekivati je da su polaznici studija natprosječni studenti te da im je motivacija za znanstvenim istraživanjem visoka pa se i rezultati toga trebaju vidjeti posebice u doktorskoj disertaciji.

Doktorska disertacija znanstveno je djelo iz određenog znanstvenog područja, polja i grane. Njezin autor treba imati znanja i sposobnosti koja mu omogućavaju znanstvenoistraživački rad udovoljavajući svim pravilima znanstvenoga istraživanja. Doktorand mora pokazati originalnost pristupa problemu, poznavanje već postojećih spoznaja, kreativnost u zaključivanju i utemeljenost zaključaka. Pri tome je osobito važna etička dimenzija u korištenju tuđih ideja i znanja kako bi se izbjeglo plagiranje. Rezultat toga uvijek mora biti znanstveni doprinos. Pi-

šući doktorsku disertaciju doktorand mora voditi računa o strukturi djela kako bi već u njoj naglasio jasnoću, preciznost, sustavnost i preglednost iznošenja ideje. Iako je disertacija samostalno djelo doktoranda, ona nastaje pod stalnim praćenjem i savjetima mentora (sve ćešće i sumentora) kako bi se izbjegle moguće pogreške uzrokovane nedovoljnim iskustvom kandidata.

## DODATNA LITERATURA UZ ČETRNAESTO POGLAVLJE

Lester, James D. (2015). *Writing Research Papers: A Complete Guide*. Harlow: Pearson Education.

Knjiga se bavi načinom pisanja radova, od izbora teme, preko istraživanja sekundarne literature, do stilistike pisanja radova i načina citiranja.

## PITANJA UZ ČETRNAESTO POGLAVLJE

1. Kako izgleda europski oblik pisanja, kako američki, a kako kombinirani?
2. Zašto u pisanim djelima nalazimo različite stilove pisanja?
3. Kojih šest stilova pisanja navodi R. Zelenika?
4. Koji su zahtjevi stavljeni kao obilježja znanstvenog stila pisanja?
5. Što je kritika objavljenog znanstvenog ili stručnog djela i na koje načine može biti izražena?
6. Kakva treba biti znanstvena kritika prema Lj. Babanu?
7. Tko može pisati recenziju i koja je njezina svrha (tj. na što treba ukazati)?
8. Što je prikaz znanstvenog ili stručnog djela, a što polemika?
9. Koje su dvije vrste uvjeta za objavljivanje znanstvenog ili stručnog rukopisa?
10. Koji su to „uvjeti znanstvene naravi“?
11. Koji su to „uvjeti tehničke naravi“?
12. Koji su formalni dijelovi rukopisa?
13. Što je seminarski rad i kako ga treba pisati?
14. Što je završni rad i kako ga treba pisati?
15. Što je diplomski rad i kako ga treba pisati?
16. Što je doktorska disertacija i kako je treba pisati?

# LITERATURA


Ajzen, Icek (2002). *Constructing a TPB questionnaire: Conceptual and methodological considerations.* Preuzeto u srpnju 2003., s http://www-unix.oit.umass.edu/~aizen/

American Sociological Association (2008). *Code of Ethics and Policies and Procedures of the ASA Commitee on Professional Ethics*, Washington.

Aristotel (1988). *Metafizika,* Zagreb: Globus.

Asch, Solomon (1951). *Effects of group pressure upon the modification and distortion of judgment*. U: H. Guetzkow (ur.) Groups, leadership and men. Pittsburgh, PA: Carnegie Press.

Asch, Solomon (1956). *Studies of independence and conformity: I. A minority of one against a unanimous majority*. Psychological monographs: General and applied, 70(9), 1-70.

Austin, John (1962). *How to Do Things With Words.* Oxford: Claredon Press.

Baban, Ljubomir; Ivić, Kata, Jelinić, Srećko; Lamza-Maronić, Maja; Šundalić, Antun (2000). *Primjena metodologije stručnog i znanstvenog istraživanja,* Osijek: Sveučilište J. J. Strossmayera – Ekonomski fakultet.

Babbie, Earl R. (2010). *The Practice of Social Research,* Wadsworth: Cengage Learning.

Back, Kurt W. (1997). *Chaos and Complexity: Necessary Myths*. U: R. A. Eve – S. Horsfal – M. E. Lee (Ed.) Chaos, Complexity and Sociology, London, SAGE Publicatios Ltd., str. 39-51.

Bekar, Clifford i Lipsey, Richard, G. (2002). *Science, institutions and the industrial revolution*. Simon Fraser University, Department of Economics, Discussion Papers.

Benda, Julien (1997). *Izdaja intelektualaca*, Zagreb: Politička kultura.

Ben-David, Johan (1986). *Uloga znanstvenika u društvu,* Zagreb: Školska knjiga.

Berger, Peter L. (1995). *Kapitalistička revolucija,* Zagreb: Naklada Naprijed.

Berger, Peter L., Luckmann, Thomas (1992). *Socijalna konstrukcija zbilje*, Zagreb: Naprijed.

Bethlehem, Jelke (2009). *Applied Survey Method. A Statistical Perspective*. Hoboken: John Wiley & Sons.

Bethlehem, Jelke (2018). *Understanding Public Opinion Polls*. Boca Raton: CRC Press.

Bickel, Robert (2007). *Multilevel Analysis for Applied Research: It's Just Regression!* New York: Guilford Press.

Biemer, Paul; Lyberg, Lars (2003). *Introduction to survey quality,* New Jersey: John Wiley&Sons.

Bird, Stephanie J.; Housman, David E. (1997). *Reporting and Funding Research.* U: Elliot, Deni i Stern Judy E. (ur.): Research Ethics: A Reader, Hanover: University Press of New England, str. 120-139.

Blaikie, Norman (2010). *Designing Social Research*, Cambridge: Polity Press.

Bloor, Michael (1997). *Techniques of validation in qualitative research: a critical commentary,* u knjizi G. Miller and R. Dingwall (ur.) Context and Method in Qualitative Research. London: Sage Publications..

Bloor, Michael; Frankland, Jane; Thomas, Michelle; Robson, Kate (2001). *Focus Groups in Social Research.* London: Sage Publications.

Boruch, R. F. (1971). *Assuring confidentiality of responses in social research: A note on strategies.* The American Sociologist, 6, 308–311.

Bošnjak, B. (1993). *Povijest filozofije I, II, III,* Zagreb, Nakladni zavod Matice hrvatske.

Bošnjak, Branko (1977). *Filozofija – uvod u filozofsko mišljenje i rječnik,* Zagreb: Naprijed.

Bošnjak, Branko (1978). *Grčka filozofija*, Zagreb: NZMH.

Brüggen, Elisabeth (2009). *A critical comparison of offline focus groups, online focus groups and e-Delphi.* International Journal of Market Research, 51(3): 363-381.

Burrel, Gibson; Morgan, Gareth (1979). *Sociological Paradigms and Organizational Analysis,* London: Heinemann Educational Books.

Campanelli, Pamela (2008). *Testing Survey Questions*. U: International Handbook of Survey Methodology (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 176-200.

Capra, Fritjof (1986). *Vrijeme preokreta*, Zagreb: Globus.

Castells, Manuel (2000). *Uspon umreženog društva,* Zagreb: Golden marketing.

Charmaz, Kathy (2006). *Constructing Grounded Theory*. London: Sage Publications.

Christiansen, Larry (1997). *Experimental methodology* (7th edition), Boston: Alyn and Bacon.

Cifrić, Ivan (1990). *Ogledi iz sociologije obrazovanja*, Zagreb: Školske novine.

Cohen, Louis; Manion, Lawrence; Morrison, Keith (2007). *Metode istraživanja u obrazovanju,* Jastrebarsko: Naklada Slap.

Coldwell, David; Herbst, F. J. (2004). *Business Research*. Cape Town: Juta.

Coolican, Hugh (1994). *Research Methods and Statistics in Psychology*. London: Hodder & Stoughton.

Crowne, Douglas P.; Marlowe, David (1960). *A new scale of social desirability independent of psychopathology*, Journal of Consulting Psychology, 24: 963-968.

Currivan, Douglas B. (2008). *Conversational Interviewing*. U: Paul J. Lavrakas (ur.), Encyclopedia of Survey Research Methods, Thousand Oaks: Sage Publications, str. 151–152.

Dalton, D. R., Wimbush, J. C., & Daily, C. M. (1994). *Using the Unmatched Count Technique (UCT) to estimate base rates for sensitive behavior.* Personnel Psychology, 47, 817–828.

Darlington, Richard B.; Hayes, Andrew F. (2017). *Regression Analysis and Linear Models: Concepts, Applications, and Implementation*. New York: The Guilford Press.

Daymon, Christine; Holloway, Immy (2002). *Qualitative Research Methods in Public Relations and Marketing Communications.* London: Routledge.

Del Rio-Roberts, Maribel (2011). *How I learned to conduct focus groups,* The Qualitative Report, 16(1), 312-315. Preuzeto s http://www.nova.edu/ssss/QR/QR16-1/rioroberts.pdf, 20. 09. 2011.

Dillman, D. A., & Christian, L. M. (2005). *Survey mode as a source of instability across surveys.* Field Methods, 17, 30–52.

Dillman, Don A. (2008). *The Logic and Psychology of Constructing Questionnaires.* U: International Handbook of Survey Methodology (European Association of Methodology

Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 161-175.

Dittmar, H., Halliwell, E., & Ive, S. (2006). *Does Barbie make girls want to be thin? The effect of experimental exposure to images of dolls on the body image of 5- to 8-year-old girls*. Developmental Psychology, 42, 283–292.

Drucker, Peter (1992). *Nova zbilja,* Zagreb: Novi Liber.

Drucker, Peter (2007). *Upravljanje u budućem društvu,* Zagreb: M.E.P. Consult.

Dunlap, Riley E; Van Liere, Kent D.; Mertig, Angela G.; Jones, Robert Emmet (2000). *Measuring endorsement of the new ecological paradigm: A revised NEP scale,* Journal of Social Issues, 56(3): 425-442.

Du Plooy, G. M. (1995). *Measurement in Communication Research,* U knjizi: G. M. Du Plooy (ur.), Introduction to Communication: Communication Research, Vol. 2, str. 67-86.

Durkheim, Emile (1996). *Obrazovanje i sociologija,* Zagreb: Societas.

Engdahl, William F. (2005). *Sjeme uništenja,* Zagreb, Detecta.

Erlandson, D. A., Harris, E. L., Skipper, B. L. and Allen, S. D. (1993) *Doing Naturalistic Inquiry*. Newbury Park, CA: Sage.

Faber, Jan; Scheper, Willem J. (2003). *Social Scientific Explanations? On Quine's Legacy and Contextual Fallacies*. Quality&Quantity, 37: 135-150.

Fairclough, Norman (1995). *Media Discourse.* London: Arnold.

Fairclough, Norman (2003). *Analysing Discourse. Textual Analysis for Social Research*. London: Routledge.

Fairclough, Norman (2012). *Critical Discourse Analysis*, u knjizi: James Paul Gee; Michael Handford (ur.), The Routledge Handbook of Discourse Analysis, London: Routledge, str. 9-20.

Fairclough, Isabela; Fairclough, Norman (2012). *Political Discourse Analysis. A Method for Advanced Students.* London: Routledge.

Fife-Schaw, Chris (2012). *Questionnaire Design.* U: Smith, Jonathan; Wright, Daniel; Breakwell, Glynis (ur.) Research Methods in Psychology. London: Sage Publications, str. 113-140.

Filipović, Vladimir (1982). *Klasični njemački idealizam,* Zagreb: NZMH.

Fowler, Floyd J.; Cosenza, Carol (2008). *Writing Effective Questions.* U: International Handbook of Survey Methodology (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 136-160.

Fuller, Theodore D., Edwards, John N., Vorakitphokatorn, Sairudee, Sermsri, Santhat (1993). *Using Focus Groups to Adapt Survey Instruments to New Populations. Experience From a Developing Country.* U: David L. Morgan (ur.) Successful Focus Groups. Advancing the State of the Art. London: Sage Publications.. str. 89-104.

Glaser, Barney; Strauss, Anselm (1967). *The discovery of grounded theory: strategies for qualitative research,* Chicago: Aldine.

Gomm, Roger (2009). *Key Concepts in Social Research Methods,* Houndmills: Palgrave MacMillan.

Goode, William J.; Hatt, Paul K. (1962). *Methods in Social Research.* New York: McGraw-Hill.

Gore, Al (1994). *Zemlja u ravnoteži – Ekologija i ljudski duh,* Zagreb: Mladost.

Grice, Herbert Paul (1989). *Studies in the Way of Words.* Cambridge: Harvard University Press.

Grmek, Mirko Dražen (1996). *Pogled u prošlost medicine.* U: Grmek, Mirko Dražen i Budak, Antun: *Uvod u medicinu*. Zagreb: Nakladni zavod Globus, str. 84-104.

Groves, Robert M.; Presser, Stanley; Dipko, Sarah (2004). *The Role of Topic Interest in Survey Participation Decisions,* Public Opinion Quarterly, 68(1): 2-31.

Guion, Robert M. (1965). *Personnel testing,* New York: McGraw-Hill.

Guilford, Joy Paul (1965). *Fundamental statistics in psychology and education (fourth edition),* New York: McGraw-Hill.

Gunter, Barrie (2000). *Media Research Methods: Measuring Audiences, Reactions and Impact*. London: SAGE publications.

Hayes, Andrew. F., & Krippendorff, Klaus (2007). *Answering the call for a standard reliability measure for coding data*. Communication Methods and Measures, 1, 77-89.

Hayes, Andrew F. (2013). *Introduction to Mediation, Moderation, and Conditional Process Analysis. A Regression-Based Approach*. New York, London: The Guilford Press.

Heerwegh, Dirk; Loosveldt, Geerth (2009). *Explaining the intention to participate in a web survey: a test of the theory of planned behaviour,* International Journal of Social Research Methodology, 12(3):181-195.

Henry, John (2008). *The Fragmentation of Renaissance Occultism and the Decline of Magic*. History of Science, 46:1-48.

Hijmans, Ellen (1996). *The logic of qualitative media content analysis: a typology*. Communications: The European Journal of Communication research, 21(1): 93-108.

Horgan, John (2001). *Kraj znanosti,* Zagreb: Naklada Jesenski i Turk.

Huff, Toby E. (1996). *The Fourth Scientific Revolution.* Society (Symposium Issue), 33(4): 8-12.

Ivan Pavao II. (1999). *Fides et ratio,* Zagreb: Kršćanska sadašnjost.

Ivanović, Zoran (1996). *Metodologija izrade znanstvenog i stručnog djela*, Opatija, Sveučilište u Rijeci.

Jefferson, Gail (2002). *Is „no" an acknowledgement token? Comparing American and British uses of (+)/(-) tokens*. Journal of Pragmatics 34: 1345-1383.

Kamberelis, George; Dimitriadis, Greg (2014). *Focus Groups Research: Retrospect and Prospect*. U knjizi: Patricia Levy (ur.), The Oxford Handbook of Qualitative Research. Oxford: Oxford University Press, str. 315-340.

Kangrga, Milan (1979). *Racionalistička filozofija*, Zagreb: NZMH.

Katavić, Vedran (2010). *Do we need training in fraud-science?*, Biochemia Medica, 20(3): 288-294.

Kerlinger, F. N. (1986). *Foundations of behavioral research*. New York: Holt, Rinehart & Winston.

Kitzinger, Jenny (1994). *Focus groups: method or madness?* U: M. Boulton (ur.) Challenge and Innovation: *Methodological Advances in Social Research on HIV/AIDS*. London: Taylor and Francis.

Kleck, G; Roberts, K. (2012). *What survey methods are most effective in eliciting self-reports of criminal or delinquent behavior?* U: L. Gideon (ur.), *Handbook of survey methodology in social sciences* (pp. 417-439). New York: Springer.

Kothari, C. R. (2004). *Research Methodology: Methods&Techniques*, New Delhi: New Age International Publishers.

Krippendorff, Klaus (1980). *Validity in Content Analysis*. U: Ekkehard Mochmann (ur.). Computerstrategien für die Kommunikationsanalyse, Frankfurt/New York: Campus.

Krippendorff, Klaus (2004). Content Analysis. An Introduction to Its Methodology. Thousand Oaks: Sage Publications.

Krueger, Richard A. (1994). *Focus Groups. A Practical Guide for Applied Research.* Thousand Oaks: Sage Publications.

Kuhn, Thomas S. (2002). *Struktura znanstvenih revolucija*, Zagreb: Naklada Jesenski i Turk.

Kukić, Slavo, Markić, Brano (2006). *Metodologija društvenih znanosti*, Mostar: Ekonomski fakultet Sveučilišta u Mostaru.

Lacy, Stephen, Riffe, Daniel; Randle, Quint (1998). *Sample Size in Multi-Year Content Analyses of Monthly Consumer Magazines*, Journalism and Mass Communication Quarterly, 75(2), 408-417.

Lacy, Stephen; Daniel Riffe, Stodard, S.; Martin, H.; Chang, K. (2001). *Sample Size for Newspaper Content Analysis in Multi-Year Studies*, Journalism and Mass Communication Quarterly, 78: 836-845.

Laertije, Diogen (1979). *O životu i mišljenju istaknutih filozofa*, Beograd: BIGZ.

Lalić, Dražen (1993). *Torcida: pogled iznutra*, Zagreb: AGM.

Lambert, Dominique (2003). *Znanost i teologija*, Zagreb: Kršćanska sadašnjost.

Lamza-Posavec, Vesna (1997). *Odbijanje ankete u istraživanjima javnog mnijenja*, Društvena istraživanja, 6(6): 747-772.

Landes, David S. (2003). *Bogatstvo i siromaštvo naroda*, Zagreb: Masmedia.

Lavrakas, Paul J. (2008). *Step-Ladder Question*, U: Paul J. Lavrakas (ur.), *Encyclopedia of Survey Research Methods*, Thousand Oaks: Sage Publications str. 847–848.

Leary, Mark R. (1995). *Behavioral Research Methods*. Pacific Grove: Brooks/Cole Publishing Company.

Lebert, Didier, Vercellone, Carlo (2007). *Uloga znanja u dinamici dugog razdoblja kapitalizma: hipoteze o kognitivnom kapitalizmu*, u knjizi: Vercellone, Carlo: *Kognitivni kapitalizam*, Zagreb, Politička kultura, str. 15-28.

Lensvelt-Mulders, Gerty (2008). *Surveying sensitive topics.* U: *International Handbook of Survey Methodology* (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 461-478.

Lesourne, Jacques (1993). *Obrazovanje & društvo*, Zagreb: Educa.

Lester, James D. (2015). *Writing Research Papers: A Complete Guide*. Harlow: Pearson Education.

Liessmann, Konrad Paul (2008). *Teorija neobrazovanosti, Zablude društva znanja*, Zagreb: Naklada Jesenski i Turk.

Lietz, Petra (2010). *Research into questionnaire design: A summary of the literature***,** International Journal of Market Research, 52(2): 249-272.

Lincoln, Y. S. and Guba, E. G. (1985). *Naturalistic Inquiry*. Beverly Hills, CA: Sage Publications.

Lobe, Bojana (2008). *Integration of online research methods. Information technology/social/informatics collection*. Ljubljana: University of Ljubljana, Faculty of Social Sciences.

Lobe, Bojana (2017). *Best Practises for Synchronous Online Focus Groups.* U: *A New Era in Focus Group Research: Challenges, Innovation and Practice* (ur. Rosaline S. Barbour; David L. Morgan), London: Palgrave Macmillan, str. 227-250.

Lohr, Sharon, L. (2008). *Coverage and Sampling*. U: *International Handbook of Survey Methodology* (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 97-115.

Lubienski, Christopher; Brewer, Jamison T. (2017). *The Weak Case fo Vouchers*. U: *The Wiley Handbook of School Choice* (ur. Robert A. Fox i Nina K. Buchanan), Chichester: John Wiley & Sons, str. 304-321.

Lucas, R. E. (2005). *Time does not heal all wounds: A longitudinal study of reaction and adaptation to divorce***.** Psychological Science, 16, 945–950.

Lucia, Sonia; Herrmann, Leslie; Killias, Martin (2007). *How important are interview methods and questionnaire designs in research on self-reported juvenile delinquency? An experimental comparison on Internet vs paper-and-pencil questionnaires and different definitions of the reference period*, Journal of Experimental Criminology, 3: 39-64.

Maclagan, Patrick (1998). *Management and Morality,* London: SAGE Publications Ltd.

Malhotra, Naresh K.; Birks, David F. (2006). *Marketing Research: An Applied Approach*. Harlow: Pearson Education.

Maltiel, Rachael; Raftery, Adrian E.; McCormick, Tyler H.; Baraff, Aaaron J. (2015). *Estimating Population Size Using the Network Scale Up Method*. The Annals of Applied Statistics, 9(3): 1247-1277.

Marshall, Gordon (1998). *Oxford Dictionary of Sociology*, Oxford: Oxford University Press.

Martin, Rod A.; Lefcourt, Herbert M. (1984). *Situational Humor Response Questionnaire: Quantitative Measure of Sense of Humor*. Journal of Personality and Social Psychology, 47(1): 145-155.

Mason, R., Carlson, J., & Tourangeau, R. (1994). *Contrast effects and subtraction in part-whole questions*. Public Opinion Quarterly, 58, 569-578.

McKenna, Eugene (2000). *Business Psychology and Organisational Behaviour: A Student's Handbook*, Philadelphia: Taylor & Francis.

Mejovšek, Milko (2008). *Metode znanstvenog istraživanja u društvenim i humanističkim znanostima*, Jastrebarsko: Naklada Slap.

Merton, Robert (1957). *Social Theory And Social Structure*. Glencoe: Free Press.

Milas, Goran (2005). *Istraživačke metode u psihologiji i drugim društvenim znanostima*, Jastrebarsko: Slap.

Milas, Goran (2009). *Istraživačke metode u psihologiji i drugim društvenim znanostima*, Zagreb: Slap.

Milgram, Stanley (1963). *Behavioral study of obedience*. Journal of Abnormal and Social Psychology, 67, 371-378.

Miller, Delbert C.; Salkind, Neil J. (2002). *Handbook of Research Design & Social Measurement* (6th Edition). Thousand Oaks: Sage Publications.

Millward, Lynne (2012). *Focus Groups*. U: Smith, Jonathan; Wright, Daniel; Breakwell, Glynis (ur.) Research Methods in Psychology. London: Sage Publications. (str. 411-438).

Morin, Edgar (2008). *Etika*, Zagreb: Masmedia.

Mytton, Graham; Diem, Peter; van Dam, Piet Hein (2016). *Media Audience Research.* Los Angeles: Sage Publications.

Naccarato, John (1990). *Predictors of readership and recall: A content analysis of industrial ads*. Magistarska radnja. Cleveland, Cleveland State University. Preuzeto 5. 6. 2012. s http://academic.csuohio.edu/kneuendorf/content/hcoding/hcindex.htm.

Neuman, Lawrence W. (2004). *Basics of Social Research. Qualitative and Quantitative Approaches*. Boston: Pearson Education.

Noy, Chaim (2008). *Sampling Knowledge: The Hermeneutics of Snowball Sampling in Qualitative Research*, International Journal of Social Science Methodology, 11(4): 327-344.

Onkvisit, Sak (2004). *International Marketing: Analysis and Strategy***,** London: Routledge.

Oraić Tolić, Dubravka (2011). *Akademsko pismo. Strategije i tehnike klasične retorike za suvremene studente i studentice*. Zagreb: Naklada Ljevak.

Osgood, Charles. E.; Suci, George; Tannenbaum, Perc (1957). *The measurement of meaning,* Urbana: University of Illinois Press.

Paltridge, Brian (2006). *Discourse Analysis: an Introduction*. London: Continuum.

Pavić, Željko (2012). *Znanost i pseudoznanost u društvima postmoderne*. U: Plenković, Mario; Galičić, Vlado (ur.), *Društvo i tehnologija 2012 – Dr. Juraj Plenković*, Zagreb: Hrvatsko komunikološko društvo / Croatian Communication Association.

Pejović, Danilo (1978). *Francuska prosvjetiteljska filozofija*, Zagreb: NZMH.

Perrin, S., & Spencer, C. (1980). *The Asch effect: a child of its time?* Bulletin of the British Psychological Society, 32, 405-406.

Petrović, Gajo (1979). *Engleska empiristička filozofija*, Zagreb: NZMH.

Popper, Karl Raimund (2003). *Otvoreno društvo i njegovi neprijatelji*, Zagreb: KruZak.

Price, Bob (1997). *The Myth of Postmodern Science*, u zborniku R. A. Eve – S. Horsfal – M. E. Lee (ur.): Chaos, Complexity and Sociology, London: SAGE Publicatios Ltd., str. 3-14.

Proctor, Tony (2005). *Essentials of Marketing Research (Fourth Edition).* Harlow: Pearson Education.

Prpić, Katarina, Brajdić Vuković, Marija (2005). *Znanstvena proizvodnja i produktivnost*. U: Prpić, Katarina (ur.). *Elite znanja u društvu (ne)znanja*. Zagreb: Institut za društvena istraživanja u Zagrebu.

Psathas, George (1995). *Conversation Analysis. The Study of Talk-in-Interaction*. London: Sage Publications.

Radermacher, Franz Josef (2003). *Ravnoteža ili razaranje, Eko-socijalno tržišno gospodarstvo kao ključ svjetskog održivog razvoja*, Zagreb: Intercon – Nakladni zavod Globus.

Reid, Donna J.; Ried, Fraser J. M. (2005). *Online focus groups. An in-depth comparison of computer-mediated and conventional focus group discussion*, International Journal of Market Research , 47(2):131-162.

Reisigl, Martin; Wodak, Ruth (2001). *Discourse and discrimination. Rhetorics of racism and antisemitism*. London: Routledge.

Riffe, Daniel; Aust, C. F.; Lacy, Stephen (1993). *The effectiveness of random ,consecutive day and constructed week sampling in newspaper content analysis*, Journalism Quarterly, 70: 133-139.

Richardson, John E. (2007). *Analysing Newspapers: An Approach from Critical Discourse Analysis*. New York: Palgrave Macmillan.

Ritzer, Georg (1997). *Suvremena sociologijska teorija*, Zagreb, Globus.

Rook, Dennis (2006): *Let's pretend: projective methods reconsidered*. U: Russell W. Belk (ur.). *Handbook of Qualitative Research Methods in Marketing*. Cheltenham: Edward Elgar Publishing, str. 143-155.

Rosenthal, Robert; Jacobson, Lenore (1968). *Pygmalion in the classroom*, New York: Holt, Rinehart & Winston.

Rwegashora, Hossea M. M. (2014). *A Guide to Social Science Research*. Dar es Salaam: MNN Publishers.

Saldaña, Johnny (2011). *Fundamentals of Qualitative Research*. Oxford: Oxford University Press.

Sardar, Ziauddin, Van Loon, Borin (2005). *Znanost za početnike*. Zagreb: Jesenski i Turk.

Searle, John R. (1976). *The Classification of Illocutionary Acts*, Language in Society, 5 (1): 1-24.

Shannon, Lyle W. (1954). *The opinions of the little orphan Annie and her friends*, Public Opinion Quarterly, 18: 169-79.

Shaughnessy, John J.; Zechmeister, Eugene B. i Zechmeister, Jeanne S. (2003). *Research Methods in Psychology* (1st edition). New York: McGraw-Hill.

Shaughnessy, John J.; Zechmeister, Eugene B. i Zechmeister, Jeanne S. (2012). *Research Methods in Psychology* (2nd edition). New York: McGraw-Hill.

Schimel, Joshua (2012). *Writing Science: How to Write Papers That Get Cited And Proposals That Get Funded*. Oxford: Oxford University Press.

Schmeder, Genevieve (2007). *Prijelomi i diskontinuiteti u dinamici podjele rada*. U: Vercellone, Carlo (ur.): *Kognitivni kapitalizam*, Zagreb, Politička kultura, str. 57-65.

Schreier, Margrit (2014). *Qualitative Content Analysis*. U: Uwe Flick (ur.), The Sage Handbook of Qualitative Data Analysis, London: Sage Publications, str. 170-183.

Schuman, Howard; Presser, Stanley (1981). *Questions&answers in attitude surveys*, New York: Academic Press.

Schuman, Howard; Presser, Stanley (1996). *Questions and Answers in Attitude Surveys*, London: Sage Publications.

Schwarz, N., Strack, F., & Mai, H. P. (1991). *Assimilation and contrast effects in part-whole question sequences: A conversational logic analysis*. Public Opinion Quarterly, 55, 3-23.

Schwarz, Norbert; Knäuper, Bärbel; Oyserman, Daphna; Stich, Christine (2008). *The Psychology of Asking Questions*. U: International Handbook of Survey Methodology (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 18-34.

Shroder, Mark D.; Orr, Larry, L. (2012). *Moving to Opportunity: Why, How, and What Next?* Cityscape: A Journal of Policy Development and Research, 14(2): 31-56.

Singer, Eleanor (1978). *Informed consent: Consequences for response rate and response quality in social surveys*. American Sociological Review, 43, 144-162.

Singer, Eleanor (2008). *Ethical Issues in Surveys*. U: *International Handbook of Survey Methodology* (European Association of Methodology Series, ur. Edith D. de Leeuw, Joop J. Hox, Don A. Dillman), New York: Psychology Press, str. 78-96.

Skoko, Božo; Benković, Vanesa (2009). *Znanstvena metoda fokus grupa – mogućnosti i načini primjene*, Politička misao, 46(3): 217-236.

Standing, Lionel G.; Shearson, Charles G. (2010). *Does the Order of Questionnaire Items Change Subject's Response? An Example Involving a Cheating Survey*, North American Journal of Psychology, 12(3): 603-614.

Stone, Philip J.; Dexter C. Dunphry; Marshall S. Smith; and Daniel M. Ogilvie. 1966. *The General Inquirer: A Computer Approach to Content Analysis*. Cambridge, MA: MIT Press.

Stylianou, Stelios (2008). *Interview Control Questions*, International Journal of Social Research Methodology, 11(3): 239-256.

Straus, Samuel (1997). *Technology, group process, and group outcomes: testing the connections in computer-mediated and face-to-face groups*, Human-Computer Interaction, 12: 227–266.

Supek, Rudi (1981). *Ispitivanje javnog mnijenja* (drugo izdanje), Zagreb: Sveučilišna naklada Liber.

Surowiecki, James (2004). *The Wisdom of Crowds: Why the Many Are Smarter Than the Few and How Collective Wisdom Shapes Business, Economies, Societies and Nations*, New York: Doubleday Anchor.

Sutherland, Edwin; Cressey, Donald; Luckenbill, David (1992). *Principles of Criminology* (Eleventh Edition). Lanham: Rowman & Littlefield.

Šešić, Bogdan (1974). *Osnovi metodologije društvenih nauka*, Beograd: Nolit.

Šram, Zlatko (2008). *Etnocentrizam, autoritarne tendencije i religioznost: relacije na uzorku zagrebačkih studenata*, Migracijske i etničke teme, 24(1-2): 49-66.

Šundalić, Antun (2011). *Sociologija, udžbenik sociologije za ekonomiste*, Osijek, Sveučilište J. J. Strossmayera – Ekonomski fakultet.

Švarc, Jadranka (2011). *Hrvatska u gospodarstvu znanja*, „Društvena istraživanja", Vol. 20(2011), No 4(114), str. 919-942.

Švarc, Jadranka (1998). *Uloga znanstvenih istraživanja i visokog obrazovanja u inovacijskom društvu: potreba stvaranja nove paradigme*. U: D. Polšek (ur.): *Vidljiva i nevidljiva akademija*, Zagreb, Institut društvenih znanosti I. Pilar, str. 175-202.

Thornberg, Robert; Charmaz, Cathy (2014). *Grounded Theory and Theoretical Coding*. U: Uwe Flick (ur.), The Sage Handbook of Qualitative Data Analysis, London: Sage Publications, str. 153-169.

Tkalac Verčič, Ana, Sinčić Ćorić, Dubravka, Pološki Vokić, Nina (2010). *Priručnik za metodologiju istraživačkog rada*, Zagreb, M.E.P. d.o.o.

Triola, Mario F. (1989). *Elementary Statistics*, Redwood City: The Benjamin Cummings Publishing Company.

Trochim, William, M. K. (2012). *Research Methods Knowledge Base*. Preuzeto s http://www.socialresearchmethods.net 15. siječnja 2012.

Uribe, Rodrigo; Manzur, Enrique (2008). *Sample Size in Content Analysis of Advertising: The Case of Weekly News Magazines*, Society for Marketing Advances Proceedings.

Van Leeuwen, Theo (1996). *The representation of social actors*. U: C. Caldas-Coulthard i M. Coulthard (ur.), *Texts and Practices: Readings in Critical Discourse Analysis*. London: Routledge, str. 32–70.

Verschuren, Piet J. M. (2003). *Case study as a research strategy: some ambiguities and oppurtunities*, International Journal of Social Science Research Methodology, 6(2): 121-139.

Vujević, Miroslav (2006). *Uvođenje u znanstveni rad u području društvenih znanosti*, Zagreb: Školska knjiga.

Vujević-Hećimović, Gordana i Vujević, Miroslav (2003). *Vjerodostojnost televizijskog referenduma*. Politička misao, 40(2): 104-113.

Warner, S. L. (1965). *Randomized response: A technique for eliminating evasive response bias*. Journal of the American Statistical Association, 60, 63–69.

Werhane, Patricia; Doering, Jeffrey (1997). *Conflicts of Interest and Conflicts of Commitment*. U: Elliot, Deni i Stern Judy E. (ur.): Research Ethics: A Reader, Hanover: University Press of New England, str. 165-190.

Wilkinson, Sue (2004). *Focus Group Research*. U: David Silverman (ur.), *Qualitative Research. Theory, Method and Practice*. London: Sage Publications, str. 177-199.

Wimmer, Roger D.; Dominick, Joseph R. (1994). *Mass Media Research: An Introduction*. Belmont: Wadsworth Publishing Company.

Windelband, Wilhelm (1988). *Povijest filozofije*, Zagreb: Naprijed.

Wolf, James. (2008). *Double Negative*. U: Paul J. Lavrakas (ur.), Encyclopedia of Survey Research Methods, Thousand Oaks: Sage Publications, str. 210–211.

Yin, Robert K. (1984). *Case Study Research: Design and Methods*, Beverly Hills: Sage Publications.

Zelenika, Ratko (1998). *Metodologija i tehnologija izrade znanstvenog i stručnog djela*, Rijeka, Ekonomski fakultet.

Živković, Branka (2014). *Analiza konverzacije: od sociologije do lingvistike*. U: Analiza diskursa: teorije i metode (ur. Slavica Perović), Podgorica: Institut za strane jezike, str. 77-96.

Žugaj, Miroslav (1997). *Metodologija znanstvenoistraživačkog rada*, Varaždin, Fakultet organizacije i informatike.

# KAZALO IMENA

Ajzen, Icak 228, 371
Aristarh 23, 24, 30
Aristotel 13, 14, 21, 22, 23, 24, 29, 30, 48, 302, 371

Baban, Ljubomir 71, 72, 73, 85, 335, 365, 370, 371
Babbie, Earl R. 102, 103, 108, 371
Back, Kurt W. 39, 371
Beck, Ulrich 335
Bekar, Clifford 28, 29, 371
Benda, Julien 45, 371
Ben-David, Joseph 27, 28, 66, 371
Benković, Vanesa 258, 379
Berger, Peter 15, 35, 371
Bird, Stephanie J. 366, 371
Blaikie, Norman 109, 371
Bogardus, Emory S. 120, 121, 136
Bošnjak, Branko 13, 14, 21, 24, 372
Brajdić Vuković, Marija 34, 377
Brüggen, Elisabeth 238, 270, 274, 372
Burrel, Gibson 75, 372

Capra, Fritjof 25, 372
Castells, Manuel 39, 40, 372
Christiansen, Larry 170, 372
Cifrić, Ivan 27, 34, 339, 372
Cohen, Louis 75, 141, 242, 283, 284, 285, 287, 288, 290, 372, 384
Crowne, Douglas P. 128, 201, 372

Del Rio-Roberts, Maribel 265, 372
Descartes, Rene 16, 17, 25, 48, 341
Doering, Jeffrey 95, 380
Drucker, Peter 45, 46, 373
Dunlap, Riley E. 130, 373
Du Plooy, G.M. 120, 373
Durkheim, Emile 35, 53, 54, 58, 373

Engdahl, William 42, 373
Eratosten 23
Eudoks 22

Faber, Jan 61, 373
Fife-Schaw, Chris 229, 230, 373
Filipović, Vladimir 26, 373
Foucault, Michael 51
Freeman, C. 37, 39

Galileo, Galilej 29, 30, 31
Gallup, George 194
Glaser, Barney 249, 373
Gomm, Roger 131, 256, 373
Groves, Robert M. 100, 228, 374
Guilford, Joy Paul 136, 371, 372, 374
Guion, Robert M. 123, 374
Guttman, Louis 6, 109, 120, 121, 122, 136, 388

Heerwegh, Dirk 228, 374
Henry, John 16, 374
Herodot 23
Herrmann, Leslie 376
Hipokrat 48
Horgan, John 15, 19, 47, 48, 374
Housman, David E. 366, 371
Huff, Toby E. 42, 374

Ivan Pavao II. 14, 374
Ivanović, Zoran 66, 335, 374
Ivić, Kata 371

Jacobson, Lenore 176, 378
Jelinić, Srećko 371

Kangrga, Milan 25, 374
Katavić, Vedran 361, 374
Kepler, Johannes 30
Killias, Martin 376
Kopernik, Nikola 23, 24, 29, 30
Kothari, C.R. 240, 241, 375
Krippendorff, Klaus 275, 281, 283, 285, 286, 287, 289, 290, 292, 374, 375
Kuhn, Thomas S. 31, 32, 33, 47, 48, 49, 61, 375

Kukić, Slavo 71, 80, 218, 335, 338, 343, 346, 375

Lacy, Stephen 148, 278, 375, 378
Lalić, Dražen 243, 375
Lambert, Dominique 14, 375
Lamza-Maronić, Maja 371
Lamza-Posavec, Vesna 228, 375
Landes, David S. 62, 375
Lebert, Didier 47, 357, 375
Lesourne, Jacques 36, 39, 375
Liessmann, Konrad Paul 45, 376
Lietz, Petra 201, 209, 210, 211, 214, 376
Likert, Renzis 6, 109, 114, 115, 116, 117, 119, 123, 136, 196, 388
Lipsey, Richard G. 28, 29, 371
Loosveldt, Geerth 228, 374
Lucia, Sonia 206, 376
Luckmann, Thomas 35, 51, 371

Maclagan, Patrick 46, 376
Manion, Lawrence 372
Manzur, Enrique 380
Markić, Brano 71, 80, 218, 335, 338, 343, 346, 375
Marlowe, David 128, 201, 372
Marshall, Gordon 39, 376, 379
McKenna, Eugene 118, 376
Mejovšek, Milko 79, 83, 105, 122, 123, 124, 135, 157, 170, 181, 183, 215, 376
Merton, Robert 53, 54, 80, 81, 257, 376
Milas, Goran 15, 52, 53, 54, 57, 73, 93, 94, 125, 134, 170, 172, 175, 178, 179, 190, 208, 216, 226, 227, 228, 261, 266, 277, 283, 346, 347, 357, 358, 377
Mill, John Stuart 83, 104, 179
Millward, Lynne 377
Morgan, Gareth 75, 372, 373, 376
Morin, Edgar 67, 70, 339, 377
Morrison, Keith 372

Naccarato, John 279, 280, 377
Noy, Chaim 155, 377

Onkvisit, Sak 230, 377
Osgood, Charles 113, 377

Pavić, Željko 69, 357, 377, 394
Pearson, Karl 59, 132, 159, 160, 289, 323, 370, 376, 377
Pejović, Danilo 26, 377
Petrović, Gajo 25, 377
Piet, J.M. 323, 377, 380
Pitagora 16
Platon 16, 21, 22, 34, 48
Pokos, Nenad 350, 356
Pološki Vokić, Nina 335, 344, 380
Presser, Stanley 213, 216, 374, 378
Price, Bob 51, 377
Prpić, Katarina 34, 377
Ptolomej 23, 24, 30

Radermacher, Franz Joseph 20, 378
Reid, Donna J. 270, 271, 378
Riffe, Daniel 278, 375, 378
Ritzer, Georg 33, 49, 378
Rosenthal, Robert 176, 378

Sardar, Ziauddin 33, 42, 378
Scheper, Willem J. 373
Schmeder, Genevieve 47, 378
Schuman, Howard 213, 216, 378
Shearson, Charles G. 216, 379
Sinčić Ćorić, Dubravka 335, 344, 380
Skoko, Božo 258, 379
Sokrat 21, 48
Spinoza, Baruch de 16, 25
Standing, Lionel G. 216, 379
Strauss, Anselm 246, 249, 373
Stylianou, Stelios 247, 248, 379
Suci, George 377
Supek, Rudi 215, 379
Surowiecki, James 273, 379

Šešić, Bogdan 80, 379
Šram, Zlatko 115, 379
Šundalić, Antun 74, 357, 371, 379, 394
Švarc, Jadranka 38, 47, 379

Tannenbaum, Perc 377
Thurstone, Robert 6, 108, 116, 117, 118, 119, 136, 196, 388
Tkalac Verčič, Ana 88, 253, 276, 335, 344, 345, 380
Triola, Mario 108, 380
Trochim, William M.K. 188, 246, 380
Tukidid 23

Van Loon, Borin 33, 42, 378

Werhane, Patricia 95, 380

Yin, Robert K. 253, 380

Zelenika, Ratko 52, 66, 73, 87, 332, 335, 343, 346, 363, 367, 370, 380
Zeleniki 63, 337

Žugaj, Miroslav 65, 330, 335, 340, 380

# KAZALO TEMELJNIH POJMOVA

Analitička matrica (analiza sadržaja) 268, 275, 276, 278, 279, 281, 282, 285, 307
Analiza sadržaja
konceptualna 275
pouzdanost 274, 283, 289, 307
relacijska 275
Anketna pitanja
demografska 7, 216, 218
dihotomna 196, 197, 233, 263, 264
dvostruka 209, 231
lijevak i obrnuti lijevak 218, 233
neuravnotežena 208, 233
otvorena i zatvorena 123, 194, 200, 205, 216, 221, 244, 245, 263, 264
rangiranje 6, 109, 110, 197, 198, 233, 263
socijalno osjetljiva 199, 214
sugestivna 207, 223, 233, 246
višestrukog izbora 196, 197, 233
Anketni upitnik
konstrukcija 231, 232, 258
način prikupljanja podataka 222
odaziv 222, 225, 226
redoslijed pitanja 200, 214, 215, 216, 218
Anonimnost sudionika istraživanja 97, 102, 103, 104, 237, 245, 256, 261, 269, 270
Anotacija 330
Apologija 330

Baždarenje mjernog instrumenta 135, 136
Bibliografija 329, 330, 337, 343
Biografija autora 341

Cilj istraživanja 85, 97, 236, 243, 244
Citiranje
abecedno-numerički sustav 346
harvardski sustav 346, 348, 349, 359
numerički sustav 346, 347
Cohenov kappa koeficijent 283, 284, 287, 290

Delfi metoda 7, 239, 273, 274, 307
Deskripcija 79, 80, 274
Diplomski rad 8, 368, 369, 370
Doktorska disertacija 8, 369, 370
Društvo znanja 45, 46, 49

Eksperimentalna kontrola 174
Eksperiment
međugrupni 171, 172, 173, 178, 182, 183
nedostatci 189, 190, 192
retest i posttest 172
„unutar“ ispitanika 184
unutrašnja i vanjska valjanost 183, 185, 186, 187, 188, 192, 254
Elaborat 330
Enciklopedija 26, 328, 329
Esej 330
Etička načela
sukob interesa 96
vezana uz objavu istraživanja 361

Fokus grupe
homogenost 258
moderator 258, 260, 261, 265, 266, 267, 271
obrada podataka 272
online 268
veličina 259
Forma ili oblik pisanja 8, 361

Glavni dijelovi znanstvenog rada 335
Grafikon
kružni 351, 353
linijski 351, 354, 355
početna točka 355, 356, 359
površinski 351, 353, 354
stupčasti 351, 352, 353, 355
temeljni elementi 350, 351

Hipoteza
obilježja 88
pogreška tipa I 90
pogreška tipa II 90
statistička hipoteza (nul i alternativna) 89, 90, 91, 92
vrste 87, 89

Ilustracije 8, 250, 343, 350
Indeks 30, 108, 109, 136, 314, 315, 320, 332
Informirani pristanak 97, 99, 100, 101
Interpretacija 13, 38, 94, 102, 327, 330, 333, 345, 346
Interpretiranje 8, 343, 345, 359
Intervju
definicija 244
kontrolna pitanja 247, 340
vrste pitanja 246
Istraživačke tehnike 274
Istraživački nacrt
eksperimentalni 157, 158, 169, 171
kohortna istraživanja 167
korelacijski 157, 158
longitudinalni 157, 162
panel istraživanja 167
ponovljen korelacijski 167
Izlaganje sa znanstvenog skupa 327
Izvor analize sadržaja 276
Izvorni znanstveni rad 327

Jedinica analize sadržaja 276, 277, 278

Kategorije analize sadržaja 267, 276, 277, 278, 285
Kauzalnost 61, 74, 81, 82, 103, 104, 157, 158, 169
Kazalo imena 339
Kazalo pojmova 339
Klasifikacija znanosti 5, 62, 63
Klasifikacija znanstvenih radova 8, 325, 326, 333
Kodna knjiga (analiza sadržaja) 268, 279, 307
Kritika 8, 25, 26, 331, 333, 365, 366, 370
Kvalitativne metode 7, 193, 235, 253, 304, 307
Kvantitativne metode 76, 235, 239, 274
Kvazieksperimentalna istraživanja
*ex post facto* 187, 188, 189, 192
nacrt prekinutih mjerenja 187, 189, 192
neekvivalentna kontrolna grupa 187, 188, 192

Leksikon 329
Literatura 337, 346, 357

Meditacija 331
Metodologija 52, 73, 74, 75, 76, 331, 336, 341, 347, 374, 375, 380
Metodologija istraživanja i hipoteze kao dio rada 336
Metrijske karakteristike
konstruktna 124
kriterijska 124
objektivnost 124
osjetljivost (diskriminativost) 124
paralelne forme 129
pouzdanost 124
sadržajna 124
test-retest 129
unutarnja konzistencija 117, 129
valjanost 124
Millove induktivne metode 83, 104
Mjerenje
fundamentalno 105
prema odluci 105
razine mjerenja 105
utemeljeno na zakonima koji određuju obilježja 105
Mjerna skala
Bogardusova skala socijalne distance 120, 121, 136
Guttmanova 6, 109, 120, 121, 122, 136
Likertova 6, 109, 114, 115, 136, 223
semantički diferencijal 109, 113, 136, 196

Thurstoneova 6, 108, 117, 118, 119, 136
Monografija 325, 326, 331, 343
Moto 341

Orijentacijski dijelovi znanstvenog rada 335, 337, 341, 362

Paradigma 32, 33, 37, 40, 45, 47, 49
Parafraziranje 8, 343, 344, 359
Paralelni prijevod (*parallel-blind translation*) 230
Pisanje literature
američki (harvardski) sustav 357, 359
europski sustav 357, 359
Podatci
primarni 93
sekundarni 93
Pogovor 340
Polemika 331, 333, 365, 366, 370
Popis kratica i simbola 338
Popis tablica, slika i grafikona 338
Postotak slaganja u analizi sadržaja 283, 284
Pouzdanost analize sadržaja 289, 307
Povjerljivost podataka 102, 103
Povratni prijevod (*back-translation*) 230
Pozivna bilješka 8, 343, 349
Predgovor 339
Pregledni rad 327
Prethodno priopćenje 327
Prikaz 27, 331, 354
Prilozi 341
Pristranost slaganja 116
Problem istraživanja 77
Projekt 331
Promatranje
bilježenje podataka 257
kontroliranost 242
strukturiranost 241
sudjelovanje istraživača 242
Pseudoznanost 69, 70, 377
Publikacije
primarne 332
sekundarne 332
tercijarne 332

Rasprava
kao dio znanstvenog rada 336
kao znanstveni rad 325, 330, 331
Razine mjerenja
načelo maksimalne razine 108, 136
Recenzija 328, 331, 365, 366, 370
aspekti 366
etičke dileme 366
Referat 331
Rječnik 329, 340

Sadržaj ili kazalo 337
Sažetak 340
Seminarski rad 8, 368
Skale procjene 123
Statistička značajnost 90, 91, 92, 104
Stilovi pisanja 344, 362, 363
Stručni rad 327, 330, 332, 333, 343, 365
Studija slučaja
definicija 252
prednosti i nedostatci 253
upotreba 253
Sveučilište 27, 28, 37, 38, 48, 228

Tablica 338, 350, 359
Tehnoznanost 5, 36, 39, 49
Teorija
hipoteze 15, 56, 57, 70, 86, 87, 88
konstrukti 54, 55, 70, 209
znanstveni zakoni 54, 56, 57, 70
Test 123, 129, 130, 131, 133, 135, 291, 322, 374
Teza 299, 300, 330, 331, 365
Treća varijabla 82

Udžbenik 10, 328
Upitnik
načini prikupljanja podataka 221
najčešće pogreške prilikom postavljanja pitanja 226
redoslijed pitanja u upitniku 7, 214, 215, 216

Utemeljena teorija (Grounded Theory) 249, 251
Uvjeti objavljivanja rukopisa
uvjeti tehničke naravi 367
uvjeti znanstvene naravi 367
Uvod kao dio znanstvenog rada 336
grude snijega 153
jednostavni slučajni 145
klaster 145
kvotni 153
prigodni 153
prosudbeni 153
reprezentativnost 138, 156
slučajni i neslučajni 142
standardna pogreška uzorka 134, 139, 142, 149, 150
stratificirani 145
sustavni 145
umjetni tjedan 278

Valjanost analize sadržaja
konstruktna 292, 293
pragmatička 292
semantička 292
valjanost uzorkovanja 292
Varijable
intervalne 105, 106
nominalne 105, 106
omjerne 105, 106
ordinalne 105, 106

Zahvale i posvete 341
Zaključak kao dio znanstvenog rada 337
Završni rad 8, 368, 369, 370
Znanost
antičko doba 22, 23
helenizam 23, 24, 48
obilježja znanosti 65, 67, 70
srednji vijek 26, 27
znanstvena revolucija 30, 62
znanstveni i neznanstveni pristup stvarnosti 15
Znanstvena knjiga 8, 325, 332, 335, 337
Znanstvena monografija 325, 326
Znanstveni članak 326, 327, 335, 337
Znanstveni zbornik 326
Znanstveno istraživanje
disciplinarno, interdisciplinarno, multidisciplinarno 78, 79
fundamentalno 34, 72, 73
nomotetsko i idiografsko 73, 104
povremeno i stalno 77
prema razini spoznaje 79
prethodno i konačno 77
primijenjeno 34, 72, 73, 309
razvojno 34, 72, 73

# BILJEŠKE O AUTORIMA

**Dr. sc. Željko Pavić** izvanredni je profesor i trenutačno voditelj Katedre za sociologiju Filozofskog fakulteta Sveučilišta Josipa Jurja Strossmayera u Osijeku, gdje predaje kolegije iz područja metodologije istraživanja i analize podataka. Diplomirao je na jednopredmetnom studiju sociologije na Filozofskom fakultetu u Zagrebu, na kojem je i doktorirao. Sudjeluje na znanstvenim skupovima u zemlji i inozemstvu, a bio je i u programsko-organizacijskim odborima petnaestak znanstvenih skupova. Obavljao je dužnost prodekana za znanost i međunarodnu suradnju, kao i zamjenika pročelnika sveučilišnog odjela u istom resornom području. Objavio je više od 40 znanstvenih radova, nekoliko stručnih radova, jednu autorsku knjigu, dva udžbenika te desetak uredničkih knjiga. Vodio je jedan sveučilišni znanstveni projekt, a trenutačno je voditelj istraživačkog projekta *Utjecaj interneta i internetskih društvenih mreža na stavove i odluke o cijepljenju*, koji financira Hrvatska zaklada za znanost. Član je Hrvatskog sociološkog društva (HSD) i Europskog sociološkog udruženja (ESA).

**Dr. sc. Antun Šundalić** redoviti je profesor u trajnom zvanju na Ekonomskom fakultetu Sveučilišta Josipa Jurja Strossmayera u Osijeku, gdje predaje *Sociologiju, Uvod u metodologiju znanstvenog rada* i *Poslovnu etiku*. Do sada je samostalno objavio pet knjiga – *Crkva, vjera i politika* (Zagreb, 1999.), *Od rezignacije do utočišta* (Osijek, 1999.), *Hrvatsko društvo i integracijski procesi* (Osijek, 2004.), *Selo – iz autentičnosti u neprepoznatljivost* (Osijek, 2010.) i *Obrazovanje i društveni razvoj* (Osijek, 2015.). Objavio je samostalno jedan sveučilišni udžbenik – *Sociologija, udžbenik sociologije za ekonomiste* (Osijek, 2011.), te jedan u suautorstvu – *Uvod u metodologiju društvenih znanosti* (Osijek, 2013.). Objavio je više od 100 znanstvenih i stručnih radova u časopisima i zbornicima s domaćih i međunarodnih znanstvenih skupova. Također je i suurednik sedam zbornika radova sa znanstvenih skupova. Bio je voditelj znanstvenog projekta *Posttranzicijski identitet ruralnog prostora Slavonije i Baranje*, financiranog od MZOS RH. Sudjelovao je kao suradnik u znanstveno-istraživačkim projektima Ekonomskog fakulteta u Osijeku i Instituta društvenih znanosti Ivo Pilar u Zagrebu. Član je Hrvatskog sociološkog društva.