

ZNANSTVENA MONOGRAFIJA

# UMIJEĆE ISTRAŽIVANJA

MARTINA MIKRUT NAĐSOMBAT / MARTINA HARC

*Metodologija istraživanja za vrijeme koje dolazi*

**RE-SEARCH — tražiti iznova. · IS-TRAŽIVANJE, tražiti do kraja.**

# UMIJEĆE ISTRAŽIVANJA

## KAD INFORMACIJA STVARA STVARNOST

Hrvatska akademija znanosti i umjetnosti
Zavod za znanstveni i umjetnički rad u Osijeku

Osijek, ožujak 2026.

**Nakladnik**
Hrvatska akademija znanosti i umjetnosti
Zavod za znanstveni i umjetnički rad u Osijeku
Trg Nikole Šubića Zrinskog 11
10000 Zagreb

**Za nakladnika**
Akademik Dario Vretenar

**Urednica**
Akademkinja Vlasta Piližota

**Autorice**
Izv. prof. dr. sc. Martina Mikrut Nađsombat
Doc. dr. sc. Martina Harc

**Naslov**
Umijeće istraživanja
*Kad informacija stvara stvarnost*

**Vrsta publikacije**
Znanstvena monografija

**Znanstveno područje**
Društvene znanosti — polje ekonomija

**Recenzenti**
Akademik Jurica Sorić
Prof. dr. sc. Marija Ham
Prof. dr. sc. Tomislav Volarić

**Lektura i korektura**
Sanda Dominiković

**Godina**
Ožujak 2026.

**ISBN**
ISBN 978-953-347-698-8 (Tisak)
ISBN 978-953-347-699-5 (Online)

*CIP zapis je dostupan u nacionalnom skupnom katalogu knjižničnog sustava Bukinet (katalog.bukinet.hr) pod brojem 991006044845809366.*

# Sažetak

Ova monografija razmatra metodologiju istraživanja u razdoblju ubrzane digitalne i tehnološke promjene, polazeći od teze da se mijenja sam odnos informacije i stvarnosti. Središnja je linija razlika između mjerenja i razumijevanja, odnosno između informacije i njezina značenja, provedena kroz hijerarhiju spoznaje od podatka do mudrosti. Težište je monografije na metodologiji poslovnih i tržišnih istraživanja: na mjerenju pažnje kao valute medijske industrije, kompozitnim mjerama i pokazateljima uspješnosti, segmentaciji tržišta te ponašanju medijske publike kao potrošača — čime se rad smješta u polje ekonomije, u poslovnu ekonomiju i marketing. Knjiga povezuje znanstvenu s medijskom i političkom metodologijom te posebnu pozornost posvećuje suvremenim izazovima, digitalnom terenu, računalnoj analizi podataka, zatvaranju pristupa podacima, statističkoj i suštinskoj značajnosti, uzročnosti te etici istraživanja u doba umjetne inteligencije. Kao izvoran empirijski doprinos poslovnoj ekonomiji i metodologiji tržišnih istraživanja, monografija donosi istraživanje medijske publike u kojem se jedinica segmentacije premješta s osobe na vrijeme: emocionalna potreba gledatelja opisuje se kao funkcija trenutka (doba dana i tjedna), a ne kao trajno svojstvo pojedinca. Zaključno se brani stav da tehnologija ubrzava informacije, ali da smisao, prosudba i odgovornost ostaju ljudski čin, pa budućnost istraživanja ne određuje alat, nego pitanje koje mu postavljamo i tumačenje kojim odgovaramo na njegov nalaz.

## Ključne riječi

istraživačka metodologija; poslovna i tržišna istraživanja; segmentacija tržišta; medijska ekonomija; digitalne metode; hijerarhija spoznaje; statistička značajnost; etika istraživanja; umjetna inteligencija; istraživačka pismenost; budućnost istraživanja

# ABSTRACT

This monograph examines research methodology in a period of accelerated digital and technological change, arguing that the very relationship between information and reality is shifting. Its central thread is the distinction between measurement and understanding, between information and its meaning, traced through the data-to-wisdom hierarchy of cognition. The monograph centres on the methodology of business and market research: the measurement of attention as the currency of the media industry, composite measures and key performance indicators, market segmentation, and the behaviour of media audiences as consumers — situating the work within business economics and marketing. The book connects scientific with media and political methodology and gives particular attention to contemporary challenges: the digital field, computational data analysis, the closing of data sources, statistical versus substantive significance, causality, and research ethics in the age of artificial intelligence. As an original empirical contribution to business economics and market research methodology, the monograph presents a study of media audiences in which the unit of segmentation shifts from the person to time: a viewer's emotional need is described as a function of the moment (time of day and week) rather than as a stable trait of the individual. It concludes that while technology accelerates information, meaning, judgement and responsibility remain human acts, so that the future of research is determined not by the tool but by the question posed to it and the interpretation of its findings.



## Keywords

research methodology; business and market research; market segmentation; media economics; digital methods; hierarchy of cognition; statistical significance; research ethics; artificial intelligence; research literacy; future of research

# Sadržaj

Sažetak ..... 3
Zašto ova knjiga ..... 9
O ustroju knjige ..... 11
Uvod: između znatiželje i znanosti ..... 12

**DIO I. Razumjeti istraživanja ..... 15**

1. Kada (ne) trebamo istraživanje ..... 16
    1.1. Istraživački način mišljenja ..... 16
    1.2. Istraživanje u kontekstu ..... 17
    1.3. Kada istraživanje nije potrebno ..... 18
    1.4. Znanstveni doprinos i pravo na pogrešku ..... 19

2. Pitanje kao početak znanja ..... 20
    2.1. Potvrda i sumnja — pokretači znanja ..... 20
    2.2. Snaga i granice pitanja ..... 20
    2.3. Reference kao razgovor kroz vrijeme ..... 21
    2.4. Od pitanja do postupka ..... 21

3. Od ideje do nacrta istraživanja ..... 23
    3.1. Kako ideja postaje istraživački problem ..... 23
    3.2. Granice mogućeg: vrijeme, resursi i realnost ..... 23
    3.3. Operacionalizacija: kako apstraktno postaje mjerljivo ..... 24
    3.4. Kako biramo pristup: mjerenje, razumijevanje ili oboje? ..... 24
    3.5. Primarni i sekundarni podaci u novom kontekstu ..... 24

**DIO II. Metodologija: pregled i primjena ..... 25**

4. Što je metodologija i zašto je važna ..... 26
    4.1. Metodologija kao način razmišljanja ..... 26
    4.2. Razlika između znanstvenog i stručnog istraživanja ..... 27
    4.3. Metodologija u praksi: mediji i politika ..... 28
    4.4. Metodologija i promjena ..... 28

5. Od podataka do mudrosti: hijerarhija spoznaje ..... 30
    5.1. Je li mudrost kraj? Gdje je intuicija ..... 32
    5.2. Hijerarhija spoznaje na djelu ..... 33

6. Mjerenje i razumijevanje ..... 34

7. Četiri istraživačke paradigme ..... 36

8. Kvalitativne, kvantitativne i mješovite metode ..... 38
    8.1. Paradoks kvalitativne prakse: kvantifikacija kvalitativnog ..... 38
    8.2. Kriteriji kvalitete u kvalitativnom istraživanju ..... 39

9. Odabir metode: što, kada i zašto ..... 41
    9.1. Komparativna i longitudinalna istraživanja ..... 42
    9.2. Analiza sadržaja: most između broja i značenja ..... 43

10. Digitalne metode i nova istraživačka praksa ..... 44
    10.1. Digitalni teren i njegove metode ..... 44
    10.2. Alati digitalnog istraživanja ..... 46
    10.3. Mediji kao laboratorij digitalne zbrke ..... 46

11. Poslovna istraživanja: kompozitne mjere i KPI ..... 48
    11.1. Od ocjene do indeksa ..... 48
    11.2. Bazni indeks i kako ne zavarati sami sebe ..... 49
    11.3. KPI: kada indeks postaje pokazatelj uspješnosti ..... 49

**DIO III. Suvremeni izazovi istraživanja..... 51**

12. Grafovi znanja i informacijski paneli .....52

13. Reprezentativnost — od popisa stanovništva do digitalnog traga .....53

13.1. Profil nije osoba .....53

14. Statistička značajnost i stvarno značenje .....55

15. Kada varijable varaju .....57

15.1. Kako pronaći skrivenu varijablu .....58

16. Etika, transparentnost i istraživanje u doba umjetne inteligencije .....59

**Dio IV. Upotreba rezultata ..... 62**

17. Istraživanje nije dokaz, nego argument u kontekstu.....63

18. Kad istraživanje intervenira u stvarnost .....64

18.1. Parcijalna istina i narativ .....64

18.2. Ono što umjetno ne može replicirati .....65

19. Kako koristiti rezultate za stvarne odluke .....67

20. Istraživačka pismenost: temelj odgovornog društva.....69

20.1. Odgovornost onih koji tumače istraživanja.....69

20.2. Znanstvena čestitost kao društvena vrijednost .....70

**Dio V. Empirijska provjera .....71**

21. Segmentacija vremena: emocionalne potrebe kao funkcija trenutka.....72

Teorijski okvir: od arhetipa osobe do arhetipa trenutka .....72

Metoda .....74

Rezultati .....75

Rasprava .....77

Doprinos i ograničenja .....77

Zaključna misao ..... 79
Prilozi ..... 80
Literatura ..... 82
Kazalo pojmova ..... 87

# Zašto ova knjiga

Od istraživanja se očekuju brzi, jednostavni i vrlo konkretni odgovori, često i gotovi prijedlozi aktivnosti. Ipak, istraživanja rijetko nude gotova rješenja. Ona pružaju smjernice, odgovore ograničene kontekstom i više novih pitanja nego jednoznačnih zaključaka. Ova monografija istraživanje promatra onako kako znatiželjni putnik koristi zemljovid — ne kao savršen plan puta, nego kao alat za bolje snalaženje u složenom svijetu.

U vremenu senzacionalističkih naslova često zaboravljamo što istraživanja zapravo donose: odgovore na jasno postavljena pitanja, podatke u kontekstu koje možemo pretočiti u informacije i smjernice za razumijevanje stvarnosti.

Knjiga razmatra svijet znanstvenih i stručnih istraživanja i pritom pojašnjava politička i medijska istraživanja — ona koja oblikuju javno mnijenje i utječu na donošenje odluka. Primjeri u knjizi pokazuju kako razlikovati podatke od poruke, rezultat od preporuke i činjenicu od interpretacije te kako se znanost i istraživanje susreću u praksi. Istraživanje je operativni mehanizam znanosti: svako dobro istraživanje nije nužno znanstveno, ali svaka znanost ovisi o kvalitetnom istraživanju.

U svojoj je jezgri ovo knjiga o poslovnim istraživanjima. Mediji su industrija u kojoj je izmjerena pažnja publike valuta kojom se trguje: gledanost određuje cijenu oglasnog prostora, vrijednost programa i sudbinu ulaganja, pa metodologija njezina mjerenja nije samo statističko, nego ekonomsko pitanje u najstrožem smislu. Kompozitni indeksi, pokazatelji uspješnosti, segmentacija tržišta i razumijevanje publike kao potrošača, okosnica ove knjige, temeljni su alati poslovne ekonomije i marketinga. Pisana je iz dvostruke pozicije, znanstvenika koji radi u biznisu, pa metodu ne brani kao akademsku formu, nego kao alat koji odgovara za posljedice.

U doba kada su podaci dostupni na svakom koraku, od izjava političara do vijesti na društvenim mrežama, sposobnost razlikovanja pouzdanih informacija od senzacionalističkih ili lažnih nikada nije bila važnija. Upravo je zato važno osnaživati pojedince da postanu aktivni sudionici društvenog dijaloga, sposobni analizirati, interpretirati i koristiti podatke za informirane odluke. Knjiga je zamišljena kao znanstveni doprinos promišljanju metodologije istraživanja u vremenu ubrzane digitalne i tehnološke promjene, namijenjen istraživačima, studentima i svima koji se metodološkim pitanjima bave kritički.

Glavni naslov imenuje tezu koju knjiga brani: živimo u dobu u kojem informacija sve češće prethodi stvarnosti i oblikuje je. Da ne bude nesporazuma: ta rečenica nije empirijska tvrdnja koju bismo mjerili, nego interpretativni okvir — leća kroz koju knjiga promatra metodologiju, srodna konstruktivističkoj tradiciji, i kao takva se kroz tekst brani argumentima, a ne podacima. Potpis nosi namjernu dvosmislenost. Istraživanje budućnosti govori o tome kako istražujemo svijet koji tek nastaje — digitalni, mjerljiv, ubrzan. Budućnost istraživanja pita se što će od naših metoda preživjeti to novo vrijeme, a što tek treba izmisliti. Između te dvije rečenice nalazi se cijela knjiga: problemi koje danas dobro poznajemo ne nestaju, ali nova vremena traže, i nude, nova rješenja.

# O ustroju knjige

Knjiga je ustrojena tako da prati prirodni tijek istraživačkog procesa, a ne kao slijed koji se nužno čita od korica do korica. Podijeljena je na pet dijelova. Prvi dio, Razumjeti istraživanje, bavi se time kada istraživanje uopće ima smisla i kako od ideje nastaje istraživačko pitanje. Drugi dio, Metodologija, objašnjava razliku između metodologije, metode i instrumenta, uvodi hijerarhiju spoznaje od podataka do mudrosti kao okosnicu cijele knjige te vodi kroz izbor pristupa i metode. Treći dio, Suvremeni izazovi, otvara probleme koje donosi digitalno doba: grafove znanja, reprezentativnost, značenje statistike, skrivene varijable i etiku istraživanja u vremenu umjetne inteligencije. Četvrti dio, Upotreba rezultata, govori o tome kako se nalazi odgovorno tumače i pretvaraju u odluke. Peti dio, Empirijska provjera, donosi izvorno istraživanje medijske publike u kojem se predložena načela iskušavaju na stvarnom problemu.

Primjeri u knjizi ciljano dolaze pretežno iz dvaju svjetova, medija i politike, i to nije slučajnost, nego metodološki izbor. Mediji su okruženje u kojem je mjerenje ljudske pažnje jedina valuta: gledanost, čitanost i doseg mjere se kontinuirano, a prema tim se brojkama određuju cijena oglasnog prostora, vrijednost programa i svaka poslovna odluka, pa se snaga i granice mjerenja ondje vide ogoljeno kao rijetko gdje. Politika, pak, nudi ono što gotovo nijedno drugo područje ne nudi: izborni dan kao trenutak istine, u kojem su izlazne ankete i konačni rezultati jedina prava, javna provjera točnosti mjerenja, jer se prognoza sudara sa stvarnošću istoga dana. Isti slučaj medijske publike zato prati čitatelja kroz cijelu knjigu kao provodni primjer: od sirove ocjene u hijerarhiji spoznaje (pogl. 5), preko mjerenja i razumijevanja (pogl. 6) i kompozitnih indeksa (pogl. 11), do izvornoga empirijskog istraživanja u završnom dijelu (pogl. 21), pa se načela izložena na početku na kraju provjeravaju na istim podacima.

Kroz cijelu knjigu provlači se nekoliko strukturnih elemenata. Zaključci na kraju poglavlja sažimaju glavne teze. Istaknuti okviri donose primjere iz prakse ili važne napomene. Tablice i dijagrami sažimaju usporedbe i klasifikacije te sistematiziraju ključne pojmove. Na kraju se nalaze prilozi s temeljnim pojmovima, popis literature u kojem su navedeni svi korišteni izvori te kazalo pojmova. Poglavlja čine cjelinu u kojoj svako sljedeće nadograđuje prethodno, premda se mogu čitati i zasebno.

**NAPOMENA O PRIMJERIMA I IZVORIMA**

Primjeri iz prakse u ovoj knjizi anonimizirani su i služe isključivo kao ilustracija metodoloških načela; ne odnose se na podatke bilo koje konkretne organizacije. Svi izvori na koje se tekst poziva navedeni su u popisu literature na kraju knjige.

# Uvod: između znatiželje i znanosti

> *„U svijetu koji proizvodi podatke brže nego što ih možemo razumjeti, istraživačka pismenost postaje nužna vještina.“*

Engleska riječ za istraživanje, research, u sebi krije uputu: re-search — tražiti iznova, i iznova, i iznova. Hrvatsko istraživanje nosi isti trag: glagol tražiti, pojačan tako da znači tražiti temeljito, do kraja, ne odustajući. Obje riječi, na dva jezika, govore istu stvar: istraživanje nije jednokratni čin kojim dolazimo do konačnog odgovora, nego traženje koje se stalno vraća. Jedino što je uistinu stalno jest sama potreba za traženjem, i upravo zato znanost nikada ne zastarijeva i nema kraj. Svaka spoznaja je početak novog propitivanja; svaki nalaz vrijedi dok ga novi kontekst ne pozove na provjeru. Zato istraživanje i budućnost pripadaju jedno drugome: oboje su otvoreni, oboje se moraju iznova promišljati.

No ako je traženje stalno, glavni izazov postaje znati što tražimo. To vrijedi jednako u znanosti i u struci, u poslovnim istraživanjima. Ovdje leži granica koju istraživanje mora poštovati: inovaciju samu ne možemo istraživanjem niti otkriti niti testirati unaprijed. Da je netko svojedobno bio ispitivao ljude o modelu umjetne inteligencije, takvo istraživanje ne bi „zaživjelo” — ljudi ne mogu vrednovati niti zamisliti ono što još ne postoji. Ali potreba koja stoji iza inovacije, potreba za bržim, jednostavnijim načinom rada, savršeno je mjerljiva. Istraživanje, dakle, ne pronalazi rješenje; ono osvjetljava pravi problem i prostor za napredak. Prosjek nam govori što jest, ali ne i što može biti; istraživanje nas dovodi do praga inovacije, a korak preko tog praga uvijek je čin mašte i prosudbe. Razumjeti tu razliku, između onoga što možemo izmjeriti i onoga što tek treba stvoriti, možda je najvažnija pouka cijele ove knjige.

Istraživanja su sastavni dio suvremenog života. Ne provode se samo u laboratorijima i znanstvenim institutima, nego i u institucijama, tvrtkama, medijima i digitalnim okruženjima u kojima svakodnevno boravimo. Svaka anketa, analiza tržišta, evaluacija projekta, izvještaj o javnom mnijenju ili podatak o ponašanju korisnika na internetu rezultat je nekog oblika istraživanja. Ono se događa stalno i svuda: u pozadini poslovnih odluka, političkih kampanja, medijskih naslova i društvenih rasprava. Mjerimo sve — od toga koliko trošimo, što mislimo i kako glasamo, do toga što čitamo i čemu vjerujemo.

Takva sveprisutnost istraživanja čini nas njihovim stalnim sudionicima, svjesno ili nesvjesno. Sudjelujemo u anketama, klikovima oblikujemo algoritme, komentiramo rezultate — i pritom često zaboravljamo da je istraživanje proces: niz odluka o tome što i kako mjeriti,

koga pitati, koje podatke uzeti, a koje zanemariti. Svaki rezultat istraživanja odraz je tih izbora, a ne neutralna slika stvarnosti.

Upravo zato, umjesto da od istraživanja očekujemo gotove odgovore, trebamo ga promatrati kao alat za bolje razumijevanje svijeta. Pitanje nije samo „što istraživanje kaže“, nego „kako je do tog zaključka došlo“ i „što to znači u konkretnom kontekstu“.

Razlika između informiranog i površnog čitanja istraživanja postaje presudna. Biti istraživački pismen znači znati prepoznati granice, pretpostavke i moguće pristranosti svakog istraživanja, a istodobno cijeniti njegovu vrijednost kao putokaza, a ne kao konačne istine. To ne znači da moramo biti stručnjaci za metodologiju ili statistiku, nego da znamo postaviti nekoliko jednostavnih pitanja: Tko je ovo istraživao? Kako? U kojem kontekstu? Što se zapravo mjeri, a što se ne mjeri? Takva pitanja razlikuju informiranog čitatelja od onoga koji samo preuzima zaključke.

U Hrvatskoj se istraživanja provode stalno, u različitim oblicima i s različitim ciljevima. Neka su znanstvena, neka stručna i vrlo učestala u praksi: u medijima, institucijama, obrazovanju, gospodarstvu i javnim politikama. Iako su metode i kvaliteta često neujednačeni, zajedničko im je nastojanje da razumiju ponašanje, stavove, odnose i obrasce koji oblikuju društvo u kojem živimo. Mediji redovito objavljuju ankete o političkim preferencijama, povjerenju u institucije i stavovima prema društvenim temama. Organizacije civilnog društva istražuju razinu medijske pismenosti, odnos građana prema dezinformacijama, sudjelovanje mladih u demokratskim procesima. Fakulteti i istraživački centri analiziraju kako ljudi koriste digitalne medije, kako oblikuju mišljenje o klimatskim promjenama, koliko vjeruju izvorima vijesti i kako tehnologija utječe na međuljudske odnose i obrazovanje. U svakom od tih procesa prisutna su ista temeljna pitanja: što želimo saznati, kako ćemo to mjeriti i što znači ono što smo otkrili.

Istodobno postoji i druga strana istraživačke stvarnosti: ograničeni resursi, povremeni pritisci na rezultate i sklonost brzom tumačenju nalaza bez dublje provjere. „Istraživanja pokazuju“ postala su česta medijska fraza, ali rijetko se pita — koje istraživanje, kako provedeno i s kojom namjerom. Tu nastaje prostor za kritičko čitanje i za ono što ova knjiga želi potaknuti: razumijevanje istraživanja kao procesa, a ne kao gotovog odgovora.

## POLAZIŠTE

Istraživanja su sveprisutna: u javnom i privatnom sektoru, u obrazovanju i u medijima, u poslovnim odlukama i društvenim raspravama. Ona nisu privilegij znanstvenika, nego svakodnevni alat kojim pokušavamo objasniti svijet oko sebe — ponekad precizno, ponekad nespretno, ali uvijek iz potrebe da nešto razumijemo ili izmjerimo. Ova knjiga potiče da istraživanje ne gledamo kao zatvoreni sustav stručnjaka, nego kao otvoreni proces u kojem svatko od nas ima ulogu: ponekad kao kreator, ponekad kao sudionik ili korisnik, kritičar ili promatrač. Pitanje je koliko smo svjesni načina na koji se ta istraživanja oblikuju i koliko odgovorno koristimo njihove rezultate.

# DIO I. Razumjeti istraživanja

*Prije nego što progovorimo o metodama, treba razumjeti samu prirodu istraživanja: kada ga uopće trebamo, a kada ne; kako od nejasne ideje nastaje istraživački problem, a iz njega pitanje; i zašto je način na koji pitamo jednako važan kao ono što pitamo. Ovaj dio postavlja temelje na kojima počiva sve ostalo.*

> *„Previše propitivanja vodi neodlučnosti,*
> *a premalo — površnosti. Između te dvije krajnosti nalazi se*
> *prostor istraživanja, prostor u kojem se oblikuje znanje.“*

# 1. Kada (ne) trebamo istraživanje

*„Razlika između običnog promatranja i istraživanja nije u sposobnosti, nego u namjeri i sustavnosti.“*

Istraživanje nije rezervirano za znanstvenike. Prisutno je u svakodnevici, u svakoj situaciji kada pokušavamo razumjeti svijet oko sebe — način na koji se donose odluke, osjećaje ili tuđe postupke. Razlika između običnog promatranja i istraživanja nije u sposobnosti, nego u namjeri i sustavnosti. Znatiželjni pojedinac promatra; istraživač promatra s ciljem da razumije i objasni. Istraživanje je promatranje koje se ponavlja, provjerava i uspoređuje. Ono zahtijeva disciplinu, dosljednost i spremnost na preispitivanje vlastitih opažanja.

## 1.1. Istraživački način mišljenja

U trenutku kada postavimo pitanje „zašto“, „kako“ ili „koliko“, već smo zakoračili u istraživački način mišljenja. To više nije prolazna znatiželja, nego svjesno nastojanje da se pronađe obrazac, smisao, uzrok ili posljedica.

Istraživački način mišljenja ne počiva na gomilanju podataka, nego na potrebi za razumijevanjem. Ne traži samo potvrdu onoga što već znamo, nego otvara prostor za provjeru i mogućnost drugačijeg tumačenja. Takav pogled nije izraz sumnje, nego kritičke svijesti — sposobnosti da razlikujemo opažanje od činjenice, pretpostavku od dokaza. Temelji se na tri misaone navike: promatranju, propitivanju i uspoređivanju.

Istraživački um prepoznaje koliko je percepcija nesigurna, kontekst promjenjiv, a zaključak vrijedan samo koliko vrijedi postupak koji ga je proizveo. U znanosti istraživački način mišljenja traži ravnotežu između otvorenosti i argumenta. Činjenice imaju smisao tek unutar konteksta, a podaci bez razumijevanja ostaju nijemi. Istraživački način mišljenja nije samo metoda, nego i svijest da je potraga često vrednija od zaključka.

Od istraživanja se danas očekuju brzi i jednostavni odgovori. No stvarnost nije linearna, i istraživanje to poštuje. Njegova snaga nije u brzini rezultata, nego u pažnji kojom se promatra i u spremnosti da se ono što znamo preispita. Istražujemo kad više ne možemo vjerovati dojmu; kad intuicija postane nepouzdana, a iskustvo nedostatno; kad ono što vidimo ne odgovara onome što mislimo da znamo; kad osjećaj da nešto nije u redu postane snažniji od objašnjenja koje već imamo. Neka pitanja traže razloge, druga odnose, treća broj. Jedna nas vode prema značenju, druga prema strukturi. Sva zajedno čine istraživački pejzaž — prostor u kojem razumijevanje i mjerenje ne stoje jedno nasuprot drugome, nego u kojem jedno bez drugoga ne čini cjelinu.

## 1.2. Istraživanje u kontekstu

Ovisno o kontekstu, istraživanje može biti alat odluke, način provjere, korektiv percepcije ili oblik razumijevanja. U poslu pomaže mjeriti rizik i učinak. U društvu — razlikovati činjenicu od dojma. U javnom prostoru štiti istinu od interpretacije. U znanosti povezuje opažanje i teoriju. U svakom od tih okvira istraživanje dobiva drukčiju ulogu, ali zadržava istu svrhu: razumjeti svijet točnije nego prije.

U poslu istraživanje postaje nužno kada odluke više ne možemo donositi samo po osjećaju, kada se intuicija mora susresti s podacima. Koristimo ga kada želimo smanjiti rizik odlučivanja, procijeniti ishod, predvidjeti rezultate ili razumjeti koje su varijable presudne. Ono ne jamči sigurnost, ali omogućuje svjesno preuzimanje rizika. U društvu istraživanje trebamo kada želimo razdvojiti činjenice od interpretacija, stvarnost od dojma, mišljenje od namjernog oblikovanja informacija. U javnom prostoru djeluje kao korektiv — vraća mjeru u razgovor, kriterij u odluku i činjenicu u priču.

U znanosti istraživanje nije samo alat za otkrivanje novog, nego i mehanizam provjere postojećeg. Kako ističe Popper (1959), znanstveno mišljenje počiva na mogućnosti pogreške: hipoteza vrijedi samo dok je ne opovrgnu bolji dokazi. Istraživanje je stoga temelj znanstvene etike — traži dokaze, ali i spremnost na njihovo preispitivanje. Kuhn (1962) pokazao je da se znanost ne razvija linearno, nego u paradigmama, misaonim okvirima koji određuju što uopće smatramo relevantnim pitanjem. Paradigma određuje ne samo što mjerimo, nego i što uopće prepoznajemo kao mjerljivo. Creswell (2018) ističe da istraživanje ima trostruku funkciju: opisati, objasniti i razumjeti. Opis govori što se događa, objašnjenje zašto, a razumijevanje kako to iskustvo dobiva značenje u kontekstu. Zato se u suvremenoj znanosti sve više govori o komplementarnosti pristupa, ne o izboru između metoda, nego o njihovoj integraciji.

Merton (1973) utemeljio je načelo „organiziranog skepticizma“ — ideju da znanost napreduje samo ako se svaki nalaz može preispitati. Taj skepticizam nije nepovjerenje, nego jamstvo vjerodostojnosti. Svako istraživanje mora biti dovoljno jasno da ga netko drugi može razumjeti, ponoviti ili osporiti. U novijim pristupima, osobito unutar pokreta otvorene znanosti (Nosek i sur., 2015; Munafò i sur., 2017), istraživanje se promatra i kao društvena praksa dijeljenja: podaci, alati i zaključci postaju zajedničko dobro. Istraživanje više nije zatvoreni laboratorij, nego otvoreni proces suradnje u kojem se točnost ne mjeri autoritetom, nego transparentnošću.

U konačnici, znanstveni smisao istraživanja leži u njegovoj trajnosti i provjerljivosti. Metode, alati i statistike samo su sredstva. Istraživanje vrijedi onoliko koliko omogućuje dru-

gima da razmišljaju dalje. To je njegova prava snaga: ne u konačnom odgovoru, nego u trajnoj sposobnosti da postavlja nova pitanja. Znanost istražuje ne zato što ne zna, nego zato što ne prestaje provjeravati.

## 1.3. Kada istraživanje nije potrebno

Prije postavljanja pitanja važno je znati da sustavno istraživanje nije uvijek potrebno. Ne traži svako pitanje empirijski odgovor, niti svaka dilema zaslužuje znanstvenu proceduru. U nekim situacijama nova analiza donijela bi samo privid novosti, a ponavljanje poznatoga bilo bi trošenje vremena, ljudi i povjerenja. Ne treba istraživati ono što je već razumljivo niti ono što zapravo ne želimo razumjeti. Istraživanje nije opravdanje za neodlučnost niti produžetak nesigurnosti.

Ponekad se istraživanje koristi kao alibi za odgodu odluke: još jedan upitnik, još jedan val podataka, još jedan pokušaj da brojke preuzmu odgovornost koju nismo spremni sami nositi. U praksi se to vidi u organizacijama koje naručuju istraživanje za potvrdu već donesene odluke, a ne za spoznaju — često sugestivno definirano i korišteno kao retoričko oružje.

Slično se događa i u znanosti. Kada istraživanje postane forma koju treba „ispuniti“, a ne proces koji treba voditi prema spoznaji, gubi svoj smisao. To je vidljivo u fenomenu publish or perish — objavi ili nestani. Pod pritiskom kvantitativnih pokazatelja, broja radova i citata, znanstveni rad ponekad se pretvara u proizvodnju tekstova bez stvarne novine: nova studija ponavlja poznate nalaze, novi uzorak potvrđuje staru teoriju bez konceptualnog pomaka.

U društvenim znanostima susrećemo fenomen inflacije istraživanja: ponavljaju se upitnici i metode koji su već iscrpili svoje mogućnosti. Desetljećima se ponavljaju istraživanja „povjerenja u medije“, „motivacije birača“ ili „percepcije političara“ — često bez teorijskog pomaka, novih mjera ili konteksta. Rezultat je privid dinamike: brojke se mijenjaju, ali se razumijevanje ne produbljuje. U prirodnim znanostima sličan se problem javlja kao pretjerana fragmentacija: jedna se tema dijeli na desetke manjih radova, od kojih svaki donosi minimalan uvid. Kako upozorava Ioannidis (2005), takva praksa vodi gomilanju slabih nalaza koje nitko ne može povezati u cjelinu.

Najgore je kad se istražuje jer se mora — kad istraživanje postane birokratska forma ili akademska obveza. Takvo istraživanje ne hrani znanje, nego ga iscrpljuje. Kad metoda postane rutina bez sumnje, a provjera tek korak na listi, forma ostaje, ali se sustavnost isprazni, a bez nje nema istinskog razumijevanja. Kao što znanstvena zajednica sve češće ističe (Nosek i sur., 2015), manje istraživanja, ali bolje postavljenih, vodi većem ukupnom znanju. Spoznaja se ne mjeri količinom radova, nego dubinom pitanja.

## 1.4. Znanstveni doprinos i pravo na pogrešku

U suvremenoj znanosti pojam „znanstvenog doprinosa“ postao je gotovo mjerna jedinica vrijednosti. Od istraživača se očekuje da svako istraživanje završi nekom vrstom doprinosa: novom spoznajom, metodološkim pomakom, potvrdom teorije ili nalazom koji se može mjeriti i citirati. No u toj stalnoj potrebi da se doprinos dokaže, često se gubi njegov smisao. Znanstveni doprinos nije „zadatak“, nego proces razumijevanja — nije rezultat koji se mora proizvesti, nego posljedica pitanja postavljenog s namjerom da otvori novi pogled.

Znanstvena praksa danas traži da već na početku znamo što ćemo dokazati. Ali pravo istraživanje rijetko ide po planu. Znanost je prostor pokušaja, pogrešaka i neizvjesnosti. Istraživanje koje ne potvrdi početnu pretpostavku nije neuspješno, nego nužan korak u razumijevanju. Kako piše Popper (1959), znanstveni napredak ne proizlazi iz točnosti, nego iz spremnosti da se pogreška prepozna i ispravi.

U kontekstu doprinosa nije važno samo otkriti novo, nego i provjeriti postojeće. Potvrditi teoriju, preispitati mjerni instrument ili razjasniti pojam može biti jednako vrijedno kao otkriti nešto što nitko prije nije vidio. U metodološkoj literaturi (Creswell, 2018) znanstveni se doprinos definira kao dodavanje nečeg novog postojećem znanju — teorijski, empirijski, metodološki ili praktično. Može značiti popunjavanje praznine, ali i rušenje pogrešne pretpostavke; inovaciju, ali i potvrdu da nešto djeluje baš onako kako mislimo.

Današnji znanstvenici nose dvostruki teret: odgovornost prema istini i obvezu prema sustavu koji traži mjerljive učinke. Taj pritisak stvara paradoks: što se više zahtijeva doprinos, to se teže usuditi riskirati pogrešku — a upravo je ona srce znanstvenog procesa. Pravo na pogrešku u tom je smislu pravo na istraživanje. „Promašeno“ istraživanje ponekad je važnije od uspješnog: pokazuje put kojim ne treba ići i štedi drugima vrijeme, resurse i iluzije. Znanstveni doprinos ne mjeri se veličinom nalaza, nego dubinom razumijevanja koje iza njega ostaje. Jer znanost ne postoji da bi potvrdila sigurnost, nego da bi nas učila kako misliti.

## ZAKLJUČAK

Istraživanje se razlikuje od svakodnevnog promatranja ne po sposobnosti, nego po namjeri i sustavnosti. Ono je disciplinirani oblik znatiželje koji svoje zaključke izlaže provjeri i spremno ih revidira pred novim dokazima. U tom obratu, od uvjerenja prema provjerljivoj tvrdnji, leži temeljna razlika između mnijenja i znanja.

# 2. Pitanje kao početak znanja

*„Dobar istraživač ne pita što može saznati, nego što zaista treba saznati da bi razumio problem.“*

Svako istraživanje počinje problemom ili pitanjem, ali nema svako pitanje istraživački potencijal. Dobar istraživač ne pita što može saznati, nego što zaista treba saznati da bi razumio problem. Problem je širi okvir, a pitanje njegov fokus. Jedan problem može otvoriti više različitih pitanja, ovisno o tome što nas zanima, koje odnose želimo razumjeti i s koje točke promatramo stvarnost. Primjerice, problem može biti: zašto mladi gube povjerenje u medije? Iz njega mogu proizaći različita pitanja — koji faktori najviše utječu na percepciju vjerodostojnosti medija kod mladih; kako mladi prepoznaju istinitost informacija na internetu; u kojoj mjeri povjerenje ovisi o izvoru, a u kojoj o temi. Problem postavlja pozornicu, a pitanje određuje kadar. Kvaliteta pitanja određuje i kvalitetu istraživanja, jer ono što ne pitamo ne možemo ni saznati.

## 2.1. Potvrda i sumnja — pokretači znanja

Istraživanja se ne rade samo da bi otkrila novo, nego i da bi provjerila ono što već znamo. Znanost ne napreduje samo revolucijama, nego i dosljednim potvrđivanjem činjenica. Bez provjere, znanje bi se pretvorilo u niz dojmova. Potvrda nije suprotnost istraživanju — ona je njegov temelj. No postoji razlika između dokazivanja i opravdavanja. Dokazivanje hipoteze znači provjeru njezine točnosti pod definiranim uvjetima, proces koji omogućuje da hipoteza bude potvrđena, odbačena ili preoblikovana. U praksi se, međutim, istraživanje često koristi ne za ispitivanje, nego za potvrđivanje već donesene odluke. Tada dokaz postaje forma, a ne spoznaja. Ono što istraživanje čini živim nije rezultat, nego sumnja koja ga pokreće. Prava sumnja ne znači nepovjerenje, nego metodičku svijest o tome da i dokazi imaju granice.

## 2.2. Snaga i granice pitanja

Loše postavljeno pitanje može proizvesti mnoštvo odgovora, ali nijedan smislen. Pitanje djeluje kao leća kroz koju promatramo svijet: preuska isključuje bitno, preširoka zamagljuje sliku. Loše pitanje nije ono na koje je teško odgovoriti, nego ono koje ne vodi razumijevanju — previše općenito, bez mogućnosti operacionalizacije, ili previše usko, tako da mjeri, ali ne objašnjava.

Ponekad je problem u jeziku. Ako u pitanje ugrađujemo pretpostavke, istraživanje postaje zatvoren krug. Pitanje „Zašto mladi više ne vjeruju medijima?“ već sugerira da je nepovjerenje činjenica i da je uzrok u mladima. Ispravnije bi bilo pitati: „Kako mladi oblikuju svoje povjerenje u medije?“ Prvo pitanje traži krivca, drugo razumijevanje procesa. Dobro pitanje ima tri osobine: jasnoću (znamo što doista pitamo), otvorenost (ne znamo unaprijed odgovor) i smisao (proizlazi iz stvarnog problema, ne iz slučajne znatiželje). Najbolja pitanja nisu ona koja traže „da“ ili „ne“, nego ona koja pozivaju na razumijevanje odnosa, značenja i uzroka.

Svako pitanje implicira određeni pogled na svijet. Pitanja koja isključuju vrijednosti, emocije ili iskustvo mogu biti točna, ali ne i cjelovita; ona koja ignoriraju mjerenje ostaju u domeni dojma. Zato istraživač mora balansirati između preciznosti i dubine. Nijedno pitanje ne može obuhvatiti svu složenost stvarnosti, ali dobro pitanje zna što svjesno ostavlja po strani. To je granica ne kao manjak, nego kao izbor.

## 2.3. Reference kao razgovor kroz vrijeme

Reference nisu formalnost, nego razgovor sa svima koji su tim putem već prošli. Pokazuju što se već znalo, gdje se zastalo, što se previđalo. Bez njih pitanje ostaje usamljeno — ponavlja već rečeno ili luta bez orijentira. Reference nisu ograničenje izvornosti, nego njezin preduvjet. Izvornost nije u tome da nitko prije nas nije o nekom problemu promišljao, nego u tome da mi mislimo svjesno nakon drugih. One su i etički čin: uključiti druge znači priznati da znanje ima kontinuitet, da postoji mreža misli, pokušaja i pogrešaka koju zovemo znanstvena zajednica. Zanemariti tu mrežu znači ponavljati pogreške i stvarati privid novosti.

## 2.4. Od pitanja do postupka

Istraživačko pitanje uvijek je dvosmjerno: usmjereno prema nepoznatom, ali ukorijenjeno u poznatom. Između ta dva pola, sumnje i kontinuiteta, rađa se spoznaja. No između pitanja i odgovora stoji ono što često zaboravljamo: postupak. Istraživački nacrt mora biti plan, a ne formalnost. U znanstvenom svijetu zove se nacrt ili dizajn istraživanja; u poslovnom, komunikacijskom i medijskom svijetu to je brief. Riječ je o istome — dokumentu koji definira što istražujemo, zašto, kako i s kojim očekivanim ishodom.

Pitanje je ideja; postupak je njezina disciplina. Kako piše Creswell (2018), dobar dizajn ne započinje instrumentima, nego razumijevanjem problema. Tek tada odabir metode ima smisla — kad proizlazi iz pitanja, a ne iz navike. Svako istraživanje u jednom trenutku mora

sići s razine apstrakcije na razinu odluke: što ćemo promatrati, kako mjeriti, koga uključiti, kada i zašto. To je trenutak kada intuicija postaje struktura. Nijedan dizajn nije savršen, ali svaki svjestan dizajn bolji je od improvizacije.

## ZAKLJUČAK

Istraživački potencijal nema svako pitanje, nego ono koje precizno mjeri ono što se doista želi saznati. Problem određuje okvir, a pitanje njegov fokus; jedan problem pritom otvara više legitimnih pitanja, ovisno o odabranoj razini analize. Kvaliteta cijeloga istraživanja unaprijed je ograničena kvalitetom pitanja od kojega polazi.

# 3. Od ideje do nacrta istraživanja

*„Ideja je iskra, ne struktura. Nacrt je trenutak kada se misaona intuicija pretvara u plan djelovanja.“*

Nijedno istraživanje ne počinje metodom ni instrumentom, nego idejom. Ali ideja sama po sebi nije dovoljna: ona je iskra, ne struktura. Da bi postala istraživanje, mora se pretvoriti u problem, zatim u pitanje, a potom u postupak. Nacrt istraživanja je trenutak kada se misaona intuicija pretvara u plan djelovanja.

**Tijek istraživanja - od nemira do značenja**

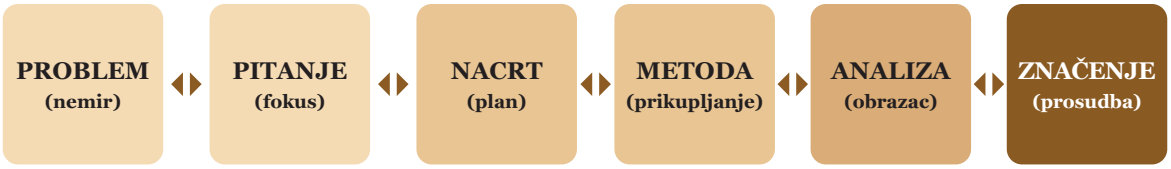


**Slika 1.** Tijek istraživanja — od početnog nemira, preko pitanja, nacrta, metode i analize, do značenja. Iz svake se faze može vratiti na prethodnu.

## 3.1. Kako ideja postaje istraživački problem

Svako istraživanje započinje nekom vrstom nemira: osjećajem da nešto nije dovoljno jasno, da objašnjenje koje imamo ne odgovara potpuno stvarnosti, da postoji praznina koju vrijedi ispitati. Istraživački problem nastaje tek kada mislima damo oblik — kada odredimo što je točno predmet interesa: pojava, odnos, obrazac, kontradikcija, anomalija ili nedostatak objašnjenja. Iz dobro formuliranog problema proizlazi pitanje, ne obratno. Dobro pitanje ima tri svojstva: jasnoću, smisao i mogućnost provjere. Loše pitanje ne vodi lošem istraživanju, vodi istraživanju koje ničemu ne služi.

## 3.2. Granice mogućeg: vrijeme, resursi i realnost

Istraživanje se ne odvija u idealnim uvjetima. Vrijeme, novac, dostupni podaci, kompetencije i uvjeti terena uvijek određuju što se može, a što ne može istražiti. Ograničenja nisu prepreke, nego okvir — parametri koji pomažu da istraživanje ostane realno. Bolje je postaviti manji, ali izvediv cilj, nego pokušati istražiti previše i završiti s površnim rezultatima. U poslovnom svijetu ta se odluka donosi u fazi briefa, u znanosti se isto pitanje zove operacionalizacija. Zreo istraživač ne ignorira ograničenja, nego ih uključuje u dizajn. Granice ne smanjuju kvalitetu istraživanja, one je štite.

### 3.3. Operacionalizacija: kako apstraktno postaje mjerljivo

Operacionalizacija je trenutak kad apstraktni pojmovi postaju nešto što možemo opisati, mjeriti ili promatrati. To je most između teorije i empirije. Ako istražujemo „povjerenje“, moramo odlučiti mjerimo li ga skalom, ponašanjem, izborima ili jezičnim obrascima. Ako istražujemo „kvalitetu“, moramo definirati kriterije. Preuska operacionalizacija osiromašuje pojavu; preširoka je čini neupotrebljivom. Dobro operacionaliziran pojam omogućava valjano mjerenje, ali još važnije — omogućava razumijevanje.

### 3.4. Kako biramo pristup: mjerenje, razumijevanje ili oboje?

Istraživanje nije samo pitanje metode, nego prije svega pitanje pristupa. Želimo li nešto izmjeriti, razumjeti, usporediti, predvidjeti, objasniti? Tek kada znamo kakvu vrstu odgovora trebamo, možemo birati kako ćemo do njega doći. Kvantitativni pristupi mjere i uspoređuju, traže uzorke i odnose; kvalitativni otkrivaju smisao, motiv i kontekst; mješoviti kombiniraju snage jednoga i drugoga. Izbor pristupa je strateška odluka, a ne tehnička. Loš izbor metode može uništiti i dobro pitanje; dobar izbor može otvoriti sasvim novu perspektivu.

### 3.5. Primarni i sekundarni podaci u novom kontekstu

Tradicionalno se razlikuju primarni podaci (oni koje sami prikupljamo) i sekundarni (oni koji već postoje). No u digitalnom okruženju ta se granica mijenja. Ako analiziramo društvene mreže, jesu li to primarni podaci jer ih mi prikupljamo, ili sekundarni jer već postoje kao digitalni tragovi? Primarni postaju oni podaci koje kontekstualiziramo; sekundarni su oni koji postoje bez pitanja. Podatak postaje informacija tek u trenutku interpretacije. Najveći izazov danas više nije nedostatak podataka, nego njihova obilnost. Zato dizajn istraživanja mora jasno odrediti koji su podaci relevantni, a koji su tek buka u sustavu.

## ZAKLJUČAK

Nacrt istraživanja označava prijelaz od zamisli prema provjerljivu postupku, u kojem se početna slutnja pretvara u plan djelovanja. Vrijednost nacrta mjeri se time koliko jasno povezuje problem, pitanje, mjerenje i očekivano značenje nalaza. Ondje gdje ta veza ostaje neizrečena, nalazi se metodološka slabost koju kasnije analize teško nadoknađuju.

# DIO II. Metodologija: pregled i primjena

*Metodologija je jezik kojim istraživanje govori. Ovaj dio razdvaja metodologiju, metodu i instrument, uvodi hijerarhiju spoznaje od podataka do mudrosti kao okosnicu cijele knjige te vodi kroz izbor pristupa, kvantitativnog, kvalitativnog ili mješovitog, i kroz odluke koje čine istraživački dizajn. Ovdje se apstraktno pretvara u mjerljivo.*

Metodologija je temelj svakog istraživanja. Ona određuje ne samo kako istražujemo, nego što uopće možemo saznati. Bez jasne metodološke strukture istraživanje se pretvara u zbirku podataka bez značenja. Dobra metodologija ne ograničava kreativnost — ona je poput kuhanja: moraš znati temeljne postavke, s čime i na koji način smiješ kombinirati sastojke, ali unutar toga imaš gotovo beskrajnu slobodu stvaranja. Svaki istraživač, kao i svaki dobar kuhar, prilagođava recept onome što ima i onome kome kuha.

# 4. Što je metodologija i zašto je važna

> *„Metodologija nije skup pravila koja sputavaju istraživača, nego jezik razumijevanja.“*

Metodologija osigurava da naši postupci imaju smisla, da rezultati budu usporedivi i da zaključci budu opravdani.

## 4.1. Metodologija kao način razmišljanja

Metodologija definira logiku postupka: kako postavljamo pitanja, kako biramo metode i kako tumačimo rezultate. Određuje kako od pitanja dolazimo do spoznaje — kako misli pretvaramo u postupke, postupke u podatke, a podatke u razumijevanje. Bez metodologije istraživanje se svodi na intuiciju i improvizaciju; s njom i najjednostavnije pitanje može proizvesti smislen, dosljedan i provjerljiv odgovor. Metodologija ne govori što misliti, nego kako misliti dosljedno.

Važno je razlikovati tri razine istog sustava — plan, postupak i alat. Metodologija je plan: logika, okvir i filozofija istraživanja; odgovara na pitanje kako uopće pristupiti istraživanju i zašto baš tako. Metoda je postupak: konkretan način prikupljanja i obrade podataka (anketa, intervju, eksperiment, analiza sadržaja, promatranje, studija slučaja); odgovara na pitanje kako dolazimo do podataka. Instrument je alat: tehnički medij kojim se podaci stvarno prikupljaju (upitnik, protokol intervjua, vodič za fokus-grupu, lista opažanja); odgovara na pitanje čime mjerimo ili bilježimo. Ukratko: metoda je kako, instrument je čime.

**Tablica 1.** Metodologija, metoda, instrument

| Razina | Opis | Pitanje na koje odgovara | Primjer |
|---|---|---|---|
| **Metodologija** | Logika i filozofija istraživanja; okvir koji povezuje teoriju i metodu. | Kako pristupamo istraživanju i zašto na taj način? | Kvalitativna, kvantitativna, mješoviti pristup. |
| **Metoda** | Postupak prikupljanja i analize podataka. | Kako dolazimo do podataka? | Anketa, intervju, analiza sadržaja, eksperiment. |
| **Instrument** | Alat kojim se prikupljaju konkretni podaci. | Čime mjerimo ili bilježimo? | Upitnik, vodič za intervju, test, lista opažanja. |

U svakodnevnoj praksi često se pogrešno koriste pojmovi upitnik, anketa i anketni upitnik. Razlika je zapravo precizna. Upitnik je instrument — skup unaprijed formuliranih pitanja; on sam po sebi nije istraživačka metoda, nego alat koji možemo upotrijebiti u više metoda.

Anketa je metoda, organizirani postupak prikupljanja podataka od većeg broja ispitanika pomoću standardiziranog instrumenta. Anketni upitnik znači da je upitnik dizajniran za anketno ispitivanje: standardiziran, strukturiran, namijenjen kvantitativnoj obradi. Upitnik postaje anketni instrument tek kada su pitanja standardizirana, kada je cilj kvantitativna obrada, kada je uzorak veći i strukturiran, i kada se podaci prikupljaju u istim uvjetima. Razumjeti tu razliku nije tehnički detalj, nego osnovni uvjet istraživačke pismenosti.

**Tablica 2.** Kako različiti autori razlikuju upitnik i anketu

| Autor | Upitnik | Anketa | Razlika po autoru |
|---|---|---|---|
| **Babbie (2021)** | Instrument za prikupljanje odgovora od ispitanika. | Metoda u kojoj se instrumenti sustavno koriste na velikim uzorcima. | Upitnik = alat; anketa = proces. |
| **Creswell (2018)** | Pisani instrument koji omogućuje samostalno davanje odgovora. | Kvantitativna strategija prikupljanja podataka radi generalizacije. | Anketa uključuje dizajn uzorka; upitnik je samo alat. |
| **Bryman (2016)** | Skup pitanja, često strukturiran, za standardizirane podatke. | Metoda koja koristi upitnik ili intervju s mnogo sudionika. | Upitnik = tehnički; anketa = metodološki okvir. |
| **Tkalac Verčić i sur. (2018)** | Instrument koji služi i kvantitativnom i kvalitativnom istraživanju. | Sustavno ispitivanje uzoraka populacije strukturiranim upitnicima. | Upitnik se može koristiti i izvan ankete. |

## 4.2. Razlika između znanstvenog i stručnog istraživanja

U praksi se istraživanja često dijele na znanstvena i stručna, kao da pripadaju različitim svjetovima. No i jedna i druga počivaju na istim temeljima: jasnoći cilja, transparentnosti postupka i odgovornosti prema podacima. Znanstvena istraživanja nastoje proširiti znanje, a stručna ga primijeniti. Razlika je u svrsi, ne u etičkoj ili metodološkoj razini. U suvremenoj praksi sve je češće da istraživanje osmisli znanstvenik, a prikupljanje podataka provede agencija. Očekivati da podatke mora osobno prikupiti istraživač jednako je kao očekivati da arhitekt mora osobno zidati kako bi mogao potpisati projekt. Agencije donose logistiku, brzinu i pristup širokim uzorcima; znanstvenici teorijsku jasnoću, metodološku kontrolu i istraživačku etiku. Nije presudno tko prikuplja podatke, nego tko jamči njihovu vjerodostojnost. Dobra metodologija nadilazi instituciju — nije važna adresa istraživanja, nego integritet postupka. Pregled definicija metodologije u različitih autora donosi Prilog 3.

## 4.3. Metodologija u praksi: mediji i politika

Mediji i politika pokazuju koliko je metodologija važna i koliko lako njezin nedostatak vodi pogrešnim zaključcima. Istraživanja u tom području često izgledaju kao „ankete javnog mnijenja“, ali ispod površine krije se mnogo više: način na koji su postavljena pitanja, redoslijed odgovora, sastav uzorka, interpretacija rezultata. Sve to čini razliku između istraživanja i manipulacije istraživanjem. U medijima se često čuje „istraživanja pokazuju da…“, ali rijetko se pita kako ta istraživanja pokazuju to što pokazuju. Je li riječ o reprezentativnom uzorku? O kvantitativnom ispitivanju ili o fokus-grupi? Je li pitanje bilo neutralno ili sugestivno? Je li istraživanje provedeno da informira javnost — ili da oblikuje njezin dojam?

U političkoj se komunikaciji istraživanja često koriste kao retorički alat: rezultati se ističu izvan konteksta, tumače selektivno, a metodološke se slabosti prikrivaju. Tada istraživanje, umjesto da bude alat razumijevanja stvarnosti, postaje sredstvo upravljanja njome. To nije problem metode, nego metodologije — jer kad izostane logika i etika postupka, svaka brojka može postati argument za bilo što. No upravo tu metodologija pokazuje svoju snagu. Dobar istraživač zna razliku između podatka i dojma; zna objasniti zašto pažljivo odabranih 500 ispitanika vrijedi više od 5.000 nasumično prikupljenih odgovora; zna da fokus-grupa ne pokazuje „što misli narod“, nego kako ljudi govore o nekoj temi. Metodologija tako nije samo tehnički okvir, nego i svojevrsni moralni kompas, način da razlikujemo informaciju od interpretacije, rezultat od dojma, činjenicu od narativa.

## 4.4. Metodologija i promjena

Metodologija počiva na pravilima, ali njezin smisao nije da nas sputava, nego da nas usmjerava. Bez pravila istraživanje bi bilo proizvoljno; bez prilagodbe bilo bi zastarjelo. Nekad je problem bio kako doći do podataka; danas je problem kako ih filtrirati. Nekad su istraživači radili u izoliranim disciplinama; danas se problemi rješavaju multidisciplinarno — kombinirajući znanje psihologa, informatičara, komunikologa, dizajnera, analitičara podataka i filozofa. Zato suvremena metodologija više nije samo skup pravila, nego ekosustav prilagodbe. Pristupi prilagođeni konkretnom kontekstu, publici i cilju ne ruše metodologiju; naprotiv, pokazuju da je razumijemo dovoljno duboko da je znamo primijeniti elastično, a ne mehanički. Prava metodološka pismenost nije sposobnost pamćenja pravila, nego razumijevanja zašto pravila postoje i kada ih ima smisla prilagoditi.

## ZAKLJUČAK

Metodologija nije skup ograničenja, nego jezik kojim se opravdavaju istraživački izbori i osigurava usporedivost i utemeljenost zaključaka. Ona ne propisuje što će se otkriti, nego omogućuje da otkriveno ima težinu. Razlikovanje metode, metodologije i epistemologije stoga nije terminološka finesa, nego uvjet intelektualne dosljednosti istraživanja.

# 5. Od podataka do mudrosti: hijerarhija spoznaje

*„Podatak dobiva smisao tek kroz kontekst, informacija kroz obrazac, znanje kroz prosudbu.“*

Ako postoji jedna slika koja objašnjava čemu istraživanje uopće služi, to je put od podatka prema razumijevanju. Taj se put najčešće prikazuje kao hijerarhija: podatak, informacija, znanje — mudrost, poznata po engleskoj kratici DIKW (data, information, knowledge, wisdom). Model je u današnjem obliku artikulirao Russell Ackoff (1989) u predsjedničkom obraćanju Međunarodnom društvu za opću teoriju sustava, premda su srodne ideje ranije razvijali i drugi (Zeleny, 1987). U ovoj ga knjizi ne crtamo kao piramidu, nego kao koordinatni sustav, slijedeći tumačenje kojim su model vratili u prostor razumijevanja Bellinger, Castro i Mills (2004): vodoravna os toga prostora jest kontekst, okomita razumijevanje, a podatak, informacija, znanje i mudrost nisu katovi građevine, nego točke koje unutar toga prostora rastu dijagonalno — svaka sljedeća nosi više konteksta i više razumijevanja od prethodne. Ono što nas od točke do točke pomiče jest mišljenje: proces pretvaranja podatka u znanje zajednički je svakom istraživanju, kvantitativnom i kvalitativnom podjednako. Za ovu knjigu model nije samo ilustracija, on je okosnica: svako poglavlje na neki način govori o jednom od prijelaza između tih razina (slika 2).

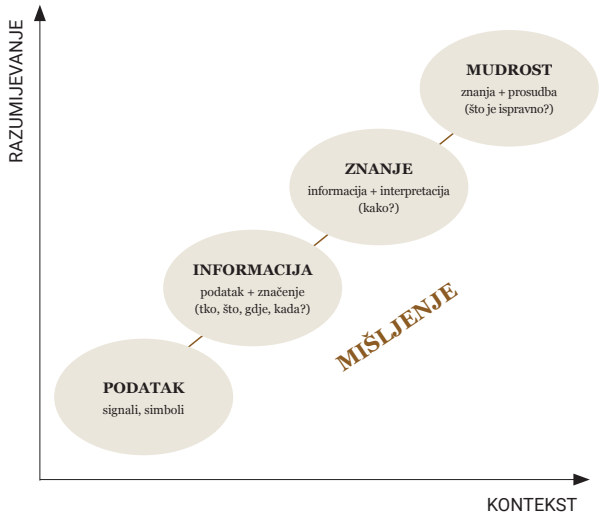


**Slika 2.** Hijerarhija spoznaje kao koordinatni sustav: vodoravna os je kontekst, okomita razumijevanje, a podatak, informacija, znanje i mudrost rastu dijagonalno unutar toga prostora — svaka razina nastaje dodavanjem: informacija je podatak sa značenjem, znanje je informacija s interpretacijom, mudrost je znanje s prosudbom. Strelica mišljenja pokazuje proces koji nas kroz prostor pomiče, zajednički kvantitativnom i kvalitativnom istraživanju (prema Ackoff, 1989; Bellinger, Castro i Mills, 2004).

Podatak je sirov i bez konteksta: broj, znak, zabilježena vrijednost. Sam po sebi ne znači ništa — „3,6“ nije ni dobro ni loše dok ne znamo što mjeri. Informacija nastaje kada podatak dobije kontekst i odgovori na pitanja tko, što, gdje, koliko: „prosječna ocjena zabavnosti programa iznosi 3,6 na skali od 1 do 5“. Znanje je organizirana informacija, obrasci, odnosi i pravila koja povezuju više informacija u razumijevanje kako nešto funkcionira: „kanali koje publika doživljava zabavnijima ujedno postižu i veći udio prvog izbora“. Mudrost je najviša razina: sposobnost da znanje primijenimo prosudbeno, s obzirom na vrijednosti, posljedice i kontekst, da znamo ne samo što je istina, nego što je ispravno učiniti.

Ackoff je izvornu hijerarhiju zapravo prikazao s pet razina, umećući razumijevanje (understanding) između znanja i mudrosti. Kasnije su ga verzije uglavnom izostavile, sažimajući model na četiri stupnja — a upravo koordinatni prikaz razrješava taj spor elegantnije od obiju strana. Razumijevanje nije zasebna stuba koju bismo morali negdje umetnuti: ono je okomica cijeloga prostora, dimenzija po kojoj se svaki prijelaz mjeri. Od podatka do informacije razumijemo odnose, od informacije do znanja razumijemo obrasce, od znanja do mudrosti razumijemo načela (Bellinger, Castro i Mills, 2004). Razumijevanje, drugim riječima, nije mjesto na koje se stiže, nego smjer u kojem se raste — sposobnost da iz onoga kako nešto jest predvidimo kako bi moglo biti. Kad se u ovoj knjizi opetovano ističe da mjerenje daje broj, a istraživanje značenje, zapravo govorimo o usponu po toj okomici: s razine informacije prema znanju i dalje.

**Tablica 3.** Razine hijerarhije spoznaje. Četiri su razine točke unutar prostora sa slike 2; razumijevanje nije peta točka, nego okomica po kojoj se svaki prijelaz mjeri, pa je u tablici navedeno zasebno.

| Razina | Pitanje na koje odgovara | Primjer iz istraživanja |
|---|---|---|
| **Podatak** | — | „3,6“ — zabilježena vrijednost bez konteksta. |
| **Informacija** | Tko, što, gdje, koliko? | Prosječna ocjena zabavnosti programa jest 3,6 na skali 1–5. |
| **Znanje** | Kako? Zašto? | Zabavniji programi imaju veći udio prvog izbora publike. |
| **Razumijevanje (okomica prostora)** | Što bi bilo kad bi…? | Ako se percepcija zabavnosti poveća, može se očekivati rast lojalnosti. |
| **Mudrost** | Što je ispravno učiniti? | Prosudba treba li i kako djelovati — s obzirom na vrijednosti i posljedice. |

## 5.1. Je li mudrost kraj? Gdje je intuicija

Model DIKW privlačan je jer je uredan, ali upravo je zbog te urednosti i kritiziran. Frické (2009) upozorava da hijerarhija sugerira čisto induktivni tok — kao da se znanje mehanički „proizvodi“ gomilanjem podataka odozdo prema gore. Stvarnost je složenija: često znanje i teorija oblikuju to koje podatke uopće prikupljamo i kako ih tumačimo (Rowley, 2007). Prijelaz između razina nije automatski dizalo, nego niz interpretativnih odluka, a svaka od njih može biti pogrešna. Zato hijerarhiju treba čitati kao heuristiku, korisnu kartu, a ne kao zakon prirode.

Ostaje i teže pitanje koje si postavljaju i sami autori: je li mudrost stvarno vrh? Ackoff je razliku između znanja i mudrosti vidio u prosudbi — mudrost, za razliku od nižih razina, uvijek uključuje ljudsku vrijednosnu procjenu i ne može se u potpunosti formalizirati niti automatizirati. To znači da vrh hijerarhije po definiciji izmiče stroju: sustav umjetne inteligencije može briljantno prelaziti s podataka na informacije i znanje, ali procjena što je vrijedno i ispravno ostaje ljudska odgovornost. U tom smislu mudrost nije „sljedeći podatak“, nego kvalitativno drugačija sposobnost.

A intuicija? Ona ne stoji niti iznad mudrosti niti ispod podatka — ona teče usporedno cijelom hijerarhijom. Intuicija je prečac koji iskusan istraživač koristi kad prepozna obrazac prije nego što ga može do kraja obrazložiti; ona nas upozori da „nešto nije u redu“ i pokrene istraživanje, ali ne može ga zamijeniti. Kroz cijelu ovu knjigu ponavlja se ista pouka: intuicija je dragocjen pokretač, ali sama po sebi nije dokaz. Istražujemo upravo onda kad intuicija postane nepouzdana. Zrelo istraživanje ne odbacuje intuiciju, ono je disciplinirano metodom pretvara u provjerljivo znanje. Ako model želimo dopuniti, poštenije je ne dodati peti kat iznad mudrosti, nego priznati intuiciju kao prečac koji dijagonalno presijeca cijeli prostor, i razumijevanje kao okomicu uz koju se svaki korak mora provjeriti.

### STVARALAČKA INTUICIJA, VRIJEME I ODMAK

Uz analitičku intuiciju, koja prepoznaje obrazac u podacima, djeluje i stvaralačka — ona koja povezuje naizgled nespojivo, uz kreativnu percepciju i maštu koja prodire u nepoznato, u budućnost i u još nepostojeće. Inovacija počinje ondje gdje mjerenje poznatog prestaje, a mašta nastavlja; metoda potom provjerava zaslužuje li odgovor povjerenje. Razumijevanje pritom gleda iz triju perspektiva odjednom: prošlosti (ne možemo znati kamo idemo ako ne znamo gdje smo bili), sadašnjosti (da ne propustimo promjene koje se već događaju) i budućnosti (koju vrijedi čuvati kao imovinu, a ne plaćati kao propuštenu priliku). I često traži odmak: kao pred impresionističkom slikom ili u teoriji kaosa, veći se obrazac razabire tek iz daljine.

## 5.2. Hijerarhija spoznaje na djelu

Pratimo jedan primjer kroz sve razine. Anketa zabilježi da je 36 % gledatelja iskazalo slaganje s tvrdnjom da bi zbog društveno odgovornog djelovanja radije odabrali neki kanal. Sam taj postotak je podatak — bez konteksta, ne znači ništa. Kada mu pridružimo skalu, formulaciju pitanja i veličinu uzorka, postaje informacija: znamo tko je odgovorio, na što i u kojem obliku. Kada taj nalaz povežemo s drugima, primjerice da je utjecaj društvene odgovornosti izraženiji kod starije i najlojalnije publike, dobivamo znanje: obrazac koji povezuje više informacija. Ako iz tog obrasca zaključimo kako bi jačanje društveno odgovornih aktivnosti moglo djelovati na lojalnost određenih segmenata, popeli smo se visoko uz okomicu razumijevanja — od pitanja kako jest prema pitanju kako bi moglo biti. A tek odluka o tome treba li i kako uopće djelovati, s obzirom na vrijednosti, troškove i moguće posljedice, pripada mudrosti. Nijedan algoritam ne može donijeti tu posljednju prosudbu umjesto nas; on nas može dovesti do njega, ali korak preko praga ostaje ljudski. (Riječ „praga” inače se ponavlja dvaput u istoj rečenici.)

## ZAKLJUČAK

Put od podatka do mudrosti nije mehaničko dizalo, nego niz interpretativnih odluka: podatak dobiva smisao kroz kontekst, informacija kroz obrazac, znanje kroz prosudbu. Mudrost ostaje granica koju metoda priprema, ali ne može proizvesti sama, jer uključuje vrijednosnu procjenu koja se ne da formalizirati. Intuicija prati cijeli taj put kao pokretač spoznaje, ali je ne zamjenjuje kao dokaz.

# 6. Mjerenje i razumijevanje

*„Mjerenje je tehnički čin; istraživanje je spoznajni proces.“*

U suvremenoj se metodologiji često poistovjećuju mjerenje i istraživanje, premda označavaju dvije različite, ali komplementarne razine spoznaje. Mjerenje podrazumijeva sustavno prikupljanje podataka prema unaprijed definiranim pravilima i skalama — ono pretvara svojstva stvarnosti (ponašanja, stavove, pojave) u brojčane ili kategorizirane vrijednosti. Cilj mjerenja je kvantifikacija: precizno utvrditi koliko nečega ima, koliko se često pojavljuje ili u kojoj je mjeri prisutno. Prema Stevensu (1946), svako mjerenje uključuje preslikavanje empirijskih svojstava u numerički sustav na temelju definiranih pravila; ono osigurava ponovljivost i usporedivost, ali samo po sebi ne daje značenje.

Istraživanje, naprotiv, obuhvaća logiku i svrhu mjerenja. Uključuje sve faze — od postavljanja pitanja i izbora metoda do interpretacije i teorijskog uokvirenja rezultata. Ono ne pretvara samo pojave u podatke, nego podatke u značenje. Dok mjerenje odgovara na pitanje koliko, istraživanje odgovara i na to što to znači i zašto je važno. Kako ističe Neuman (2014), mjerenje opisuje svijet, a istraživanje pokušava razumjeti njegove uzroke i posljedice. Razlika, dakle, nije u alatu, nego u namjeri: mjerenje traži preciznost, istraživanje traži smisao. Broj bez razumijevanja ostaje podatak bez značenja, a razumijevanje bez dokaza ostaje dojam bez osnove.

**PRIMJER IZ PRAKSE: GLEDANOST TELEVIZIJE**

Sustavi mjerenja publike (poput panela za mjerenje gledanosti) bilježe što se gleda, koliko je ljudi bilo pred ekranom, u koje vrijeme i na kojem programu. To je mjerenje: precizan, standardiziran postupak koji pretvara ponašanje publike u brojke i omogućuje usporedbe i trendove, ali ne objašnjava zašto ljudi nešto gledaju. Istraživanje traži značenje iza brojke — zašto su gledali baš taj sadržaj, što im znači, kako ga doživljavaju. Takva pitanja zahtijevaju kvalitativne metode: intervjue, fokus-grupe, analizu narativa. Mjerenje kaže što se dogodilo, istraživanje zašto se dogodilo. Tek zajedno daju cjelovitu sliku.

### PRIČA O ZEMLJOPISNOJ DUŽINI

Godine 1675. engleski je kralj podigao opservatorij u Greenwichu s jednim zadatkom: pronaći način točnog određivanja zemljopisne dužine, kako bi mornari mogli sigurno ploviti dalekim morima. Zemljopisna širina bila je poznata i omogućavala je tek regionalnu plovidbu; tek je dužina, koju je stoljeće kasnije riješio precizni mornarski sat, otvorila daleke oceane. U istraživanju je zemljopisna širina kvantitativno mjerenje — pokazuje gdje smo, jasno i usporedivo. Zemljopisna dužina je kvalitativni pristup — ono što nam tek omogućuje da nacrtamo kartu nepoznatih voda budućnosti. Jedno bez drugoga vodi tek do obale; tek zajedno vode na otvoreno more. U toj se slici krije i podnaslov ove knjige. Metafora je prilagođena prema knjizi Corporate Longitude Leifa Edvinssona (2002), u kojoj zemljopisna dužina služi kao slika za ono što se u organizaciji ne da izravno izmjeriti — intelektualni kapital u ekonomiji znanja.

## ZAKLJUČAK

Mjerenje i istraživanje pripadaju različitim razinama spoznaje: prvo je tehnički čin pretvaranja svojstava u vrijednosti, drugo spoznajni proces njihova tumačenja. Sposobnost mjerenja daleko nadmašuje sposobnost razumijevanja izmjerenoga, pa težište istraživačke odgovornosti leži upravo na tumačenju. Broj bez značenja ostaje nijem, a značenje bez mjere neprovjerljivo.

# 7. Četiri istraživačke paradigme

*„Sva metodologija pretpostavlja nekakvu sliku svijeta; kad je istraživač ne artikulira, drugi to čine umjesto njega.“*

Prije nego što odaberemo metodu, vrijedi biti svjestan pretpostavki o samoj stvarnosti koje svaki izbor sa sobom nosi. Kako upozoravaju Lincoln i Guba, sva metodologija pretpostavlja nekakvu sliku svijeta; kad je istraživač ne artikulira, drugi to čine umjesto njega. Zato je korisno razlikovati tri razine: metodu (kako), metodologiju (zašto baš tako) i epistemologiju (što uopće znači znati). Svako istraživanje implicitno odgovara na tri velika pitanja — ontološko (što postoji, kakva je priroda stvarnosti), epistemološko (što znači znati, kakav je odnos istraživača i predmeta) i metodološko (kako istražiti). Iz različitih odgovora izrastaju četiri velike paradigme.




**Slika 3.** Četiri istraživačke paradigme prema odnosu istraživača i stvarnosti — od objektivističke do refleksivne.

**Tablica 4.** Četiri istraživačke paradigme

| Paradigma | Ontologija | Epistemologija | Tipične metode |
|---|---|---|---|
| **Pozitivizam** | Realizam | Objektivizam | Ankete, eksperimenti, kvantitativne metode. |
| **Konstruktivizam** | Relativizam | Subjektivizam | Intervjui, utemeljena teorija, fenomenologija. |
| **Kritička teorija** | Povijesni realizam | Participativnost | Akcijsko istraživanje, kritička analiza diskursa. |
| **Poststrukturalizam** | Nestabilna zbilja | Refleksivnost | Diskurzivna analiza, dekonstrukcija. |

Iste se pojave iz različitih paradigmi vide posve drukčije. Uzmimo pitanje kako mladi koriste određenu društvenu platformu za političko izražavanje. Pozitivist bi kvantificirao broj političkih objava i njihovu povezanost s demografijom. Konstruktivist bi dubinskim intervjuima istražio što za same mlade znači „političko“. Kritički teoretičar pitao bi tko u tom prostoru ima glas, a tko ne, i kako algoritam pojačava ili gasi određene pozicije. Poststrukturalist bi analizirao koje subjekt-pozicije sam diskurs platforme nudi. Nijedan pristup nije „točan“ sam po sebi — svaki osvjetljava drugu stranu iste stvarnosti. Refleksivnost je zato metodološki imperativ: istraživač nije nevidljivi instrument koji „snima“ stvarnost, nego dio istraživanja čiji identitet, položaj i alati oblikuju ono što uopće može vidjeti.

U praksi refleksivnost znači kontinuirano odgovaranje na četiri pitanja. Tko sam ja, odnosno kako identitet, iskustvo i disciplinarna formacija oblikuju moj pogled? Gdje stojim: jesam li insider ili outsider u zajednici koju istražujem? S čim radim, to jest kako alati i platforme, koji nisu neutralni, određuju što uopće mogu vidjeti? I kako pišem, jer pisanje nije tek predstavljanje rezultata, nego dio analize. Provjerena tehnika discipliniranja te samosvijesti jest refleksivni dnevnik: nakon svake sesije rada na terenu istraživač bilježi vlastite pretpostavke, reakcije i iznenađenja, čime osobni dojam pretvara u provjerljiv trag.

## ZAKLJUČAK

Svaki metodološki izbor počiva na neizrečenim pretpostavkama o naravi stvarnosti i naravi znanja. Četiri paradigme — pozitivistička, konstruktivistička, kritička i poststrukturalistička — čine te pretpostavke eksplicitnima i pokazuju kako ista pojava poprima različit oblik ovisno o polazištu. Artikulacija paradigmatske pozicije uvjet je za refleksivno i intelektualno pošteno istraživanje.

# 8. Kvalitativne, kvantitativne i mješovite metode

*„U svijetu istraživanja postoje mnogi pristupi, ali samo tri temeljne logike: broj, smisao i njihov spoj.“*

Paradigme iz prethodnoga poglavlja u istraživačkoj se praksi najčešće prelamaju kroz tradicionalnu podjelu na kvantitativni i kvalitativni pristup, no ta granica postaje sve propusnija.

Kvantitativna istraživanja mjere i uspoređuju, koristeći broj kao dokaz i argument. Traže obrasce i odnose između varijabli, pretvarajući svijet u niz postotaka, prosjeka i korelacija. Njihova je snaga u strukturi i ponovljivosti: brojke ne ovise o raspoloženju ispitanika ni o interpretaciji istraživača. Kvantitativno je istraživanje učinkovito kad želimo znati koliko ljudi misli nešto, kako su raspoređeni po skupinama ili što utječe na koju odluku. No brojke nisu neutralne — one su rezultat izbora: kako smo formulirali pitanje, što smo odlučili mjeriti, koga smo pitali, što smo izostavili.

Kvalitativno istraživanje traži značenje iza broja. Nastoji razumjeti iskustvo, motiv i kontekst koji se ne mogu svesti na mjeru. Umjesto mjerenja, ono sluša; umjesto generaliziranja, razumije. Kroz razgovore, promatranja i analize sadržaja pokušava uhvatiti kako ljudi doživljavaju svijet, što ih pokreće i zašto vjeruju u ono u što vjeruju. Njegova je snaga u dubini i kontekstu, ali slabost u ograničenoj primjenjivosti. Kvalitativno istraživanje nije stvoreno da donosi odluke, nego da ih informira — treba ga čitati kao kompas, ne kao kartu.

U praksi se često pogrešno koristi samo jedan pristup. Kvantitativno bez kvalitativnog razumijevanja daje plitke odgovore; kvalitativno bez kvantitativne potvrde daje neprovjerene dojmove. Menadžeri i komunikatori vole kvalitativna istraživanja jer su „živa“ — sadrže priče, izjave i dojmove. Kada netko u fokus-grupi kaže nešto što „zvuči točno“, to se lako pretvori u zaključak, iako iza njega stoji šest sudionika i jedno popodne razgovora. Tako kvalitativno istraživanje, umjesto da proširi razumijevanje, postaje alibi za već donesenu odluku. To nije krivnja metode, nego načina na koji je koristimo.

## 8.1. Paradoks kvalitativne prakse: kvantifikacija kvalitativnog

Danas se kvalitativne metode koriste češće nego ikad — u poslovanju, marketingu, politici, obrazovanju i znanosti. To je dobar znak: tražimo složenije odgovore. Ali u toj popularnosti krije se paradoks: sve češće pokušavamo kvantificirati kvalitativno. U intervjuima brojimo koliko je puta netko spomenuo određenu riječ; u fokus-grupama prebrojavamo pozitivne

i negativne reakcije; u analizi narativa tražimo učestalost pojmova umjesto značenja rečenice. Tako kvalitativno istraživanje gubi ono što ga čini vrijednim, slojevitost, dubinu, kontekst. Istodobno kvantitativna istraživanja preuzimaju elemente kvalitativnih: ankete uključuju slike, asocijacije i otvorena pitanja. Nastaje nova praksa, istraživanja koja kombiniraju brojke i priče. To nije pogreška, nego znak vremena u kojem više ne biramo između mjerenja i razumijevanja, jer moramo oboje.

Mješoviti pristupi polaze od ideje da stvarnost nije ni samo brojiva ni samo tumačiva i da je jedino cjelina istinita. Kvantitativni dio pokazuje što se događa, kvalitativni objašnjava zašto. Anketa može pokazati da je povjerenje u institucije nisko, a dubinski intervjui otkriti što to nepovjerenje zapravo znači. Zajedno daju uvid koji je istodobno mjerljiv i smislen — broj koji ima priču i priču koja ima broj.

**Tablica 5.** Pregled pristupa i njihove primjene

| Pristup | Svrha | Tipični oblici | Ograničenja u praksi |
|---|---|---|---|
| **Kvantitativni** | Utvrditi što, koliko i kako su pojave povezane. | Ankete, testovi, eksperimenti, analiza baza. | Površnost; ne objašnjava motive ni kontekst. |
| **Kvalitativni** | Istražiti kako i zašto; otkriti obrasce interpretacije. | Intervju, fokus-grupa, etnografija, analiza narativa. | Ograničena generalizacija; rizik pretjeranog tumačenja. |
| **Mješoviti** | Povezati dokaz i značenje; provjeriti jedno drugim. | Sekvencijalni i paralelni dizajni, triangulacija. | Zahtjevnost; potreba za više vještina i resursa. |

## 8.2. Kriteriji kvalitete u kvalitativnom istraživanju

Kvantitativno istraživanje svoju vjerodostojnost gradi na valjanosti i pouzdanosti. Kvalitativno istraživanje, koje ne teži generalizaciji u statističkom smislu, treba drukčije kriterije. Lincoln i Guba (1985) predložili su četiri koja su i danas mjerilo dobre prakse: kredibilnost (točnost interpretacije), prenosivost (mogućnost primjene na druge kontekste), pouzdanost (konzistentnost procesa) i potvrdivost (neutralnost rezultata). Svaki se osigurava konkretnim postupcima — od produljenog boravka na terenu i provjere nalaza sa sudionicima, preko bogatog opisa konteksta, do vođenja tragova o svim odlukama i refleksivnog dnevnika istraživača.

**Tablica 6.** Kriteriji vjerodostojnosti kvalitativnog istraživanja

| Kriterij | Što štiti | Kako se osigurava |
|---|---|---|
| **Kredibilnost** | Točnost interpretacije | Produljeni angažman, provjera sa sudionicima, triangulacija izvora. |
| **Prenosivost** | Mogućnost prijenosa na druge kontekste | Bogat opis konteksta, svrhovito uzorkovanje. |
| **Pouzdanost** | Konzistentnost procesa | Trag odluka (audit trail), refleksivni memo, dokumentacija. |
| **Potvrdivost** | Neutralnost rezultata | Triangulacija, kolegijalna provjera, refleksivnost autora. |

## ZAKLJUČAK

Kvantitativni i kvalitativni pristup ne predstavljaju suprotstavljene tabore, nego dvije komplementarne logike, logiku broja i logiku smisla, čija je granica u praksi sve propusnija. Mješoviti nacrti priznaju da cjelovita spoznaja često zahtijeva obje. Odabir logike stoga ne proizlazi iz metodološke sklonosti, nego iz naravi istraživačkog pitanja.

# 9. Odabir metode: što, kada i zašto

*„Odabrati metodu nije tehnički, nego strateški čin. Prava metoda nije najpoznatija, nego najprimjerenija cilju.“*

Svaka metoda ne samo da prikuplja podatke, nego i oblikuje način na koji ih vidimo. Istraživanje koje počne pitanjem „koju metodu da koristim?“ često je već krenulo pogrešnim smjerom. U praksi razgovor prečesto kreće rečenicom „idemo napraviti fokus-grupe“ ili „trebamo anketu“. Dobar odabir počinje pitanjem: što točno želim saznati, u kojem kontekstu i zašto baš sada? Tek nakon toga dolazi tehnički izbor — kako ću to mjeriti, koliko puta, na kome i kojim instrumentom.

Tradicionalni popisi metoda često su metodološki nedosljedni: neke se metode dijele po načinu provedbe, druge po vrsti interakcije, treće po cilju. U digitalnom dobu ta konfuzija postaje očitija — postoje online fokus-grupe, video-intervjui, chat-ankete i virtualni paneli koji istodobno kombiniraju više razina klasifikacije. Umjesto da metodu „biramo“ s popisa, korisnije ju je dizajnirati kroz nekoliko temeljnih dimenzija. Nijedna dimenzija nije po zadanome kvalitativna ili kvantitativna; metoda je kombinacija tih odluka.

**Tablica 7.** Osam dimenzija istraživačkog dizajna

| Dimenzija | Tipovi | Značenje |
|---|---|---|
| **Svrha** | istraživačko, opisno, objašnjavajuće, evaluativno | Zašto istražujemo — otkrivanje, opis, objašnjenje ili procjena učinka. |
| **Vremenski horizont** | presječno, longitudinalno (panel, kohorta, trend) | Snimka stanja ili praćenje promjena. |
| **Kontrola i uzročnost** | eksperimentalno, kvazieksperimentalno, neeksperimentalno | Koliko upravljamo uvjetima i možemo li tvrditi uzročnost. |
| **Usporedba** | komparativno (unutar/između slučajeva, cross-national) | Što i kako uspoređujemo. |
| **Vrsta podataka** | kvantitativni, kvalitativni, tekstualni, vizualni, digitalni | Priroda podataka i kako „govore“. |
| **Jedinica analize** | pojedinac, grupa, organizacija, dokument, država | Kome pripisujemo opažanja. |
| **Kontekst prikupljanja** | terensko, laboratorijsko, online, sekundarno | Gdje i kako prikupljamo. |
| **Logika zaključivanja** | deduktivno, induktivno, abduktivno | Kako povezujemo podatke i teoriju. |

**Tablica 8.** Kriteriji odabira metode u praksi

| Kriterij | Ključno pitanje | Implikacija |
|---|---|---|
| **Cilj** | Što želimo saznati? | Uzroci › (kvazi)eksperiment; značenja › kvalitativno; mjere › kvantitativno. |
| **Vrijeme** | Stanje ili promjena? | Presječno naspram longitudinalnog (panel, trend, kohorta). |
| **Publika** | Tko koristi rezultate? | Znanost › valjanost i replikabilnost; praksa › brzina i primjenjivost. |
| **Resursi** | Koliko vremena, ljudi, sredstava? | Manje resursa › hibridi, sekundarni podaci, uži fokus. |
| **Etika** | Možemo li odgovorno prikupljati podatke? | U digitalnom okruženju etika je sastavni dio dizajna. |

## 9.1. Komparativna i longitudinalna istraživanja

Ova se dva pojma u praksi često koriste kao etikete, a ne kao dizajni. Usporediti rezultate iz dva razdoblja ili dva područja nije nužno komparativno istraživanje. Komparativno zahtijeva jasno definirane jedinice usporedbe, isti instrument i uvjete mjerenja te cilj da se objasni smisao razlike, a ne samo razlika. Slično, ponavljanje mjerenja nije automatski longitudinalno. Longitudinalno znači isti nacrt u više valova uz praćenje istih jedinica (panel) ili iste pojave kroz vrijeme (trend, kohorta). Ako su uzorci različiti i samo uspoređujemo prosjeke, to je trend, ne panel. Nategnute etikete stvaraju metodološku iluziju ozbiljnosti i zamućuju zaključke.

Kombinacije tih dimenzija u praksi izgledaju vrlo konkretno. Komparativno kvalitativno istraživanje moglo bi obuhvatiti dvije organizacije s po dvadesetak intervjua u svakoj, kako bi se razumjelo kako kultura upravljanja oblikuje povjerenje. Komparativno kvantitativno moglo bi u osam gradova, na uzorku od oko tisuću dvjesto ispitanika, mjeriti varijacije u povjerenju u lokalne institucije. Longitudinalno kvantitativno pratilo bi isti panel kroz tri vala u dvije godine da uhvati dinamiku promjene stavova, dok bi longitudinalno kvalitativno intervjuiralo istu skupinu mladih svaka tri mjeseca kako bi pratilo kako se mijenja njihov narativ o budućnosti. Analiza sadržaja kao hibrid mogla bi algoritamski obraditi tisuće objava, a zatim ih dopuniti stotinjak dubinskih kvalitativnih čitanja. Nijedan od tih dizajna nije „bolji“ — svaki odgovara na drukčije pitanje.

## 9.2. Analiza sadržaja: most između broja i značenja

Analiza sadržaja često se pogrešno svrstava isključivo u kvalitativne metode jer kreće od riječi, ali zapravo prirodno spaja kvalitativno i kvantitativno. U kvantitativnoj varijanti broji učestalosti i svrstava u kategorije prema kodnoj knjizi definiranoj unaprijed; cilj su objektivnost, ponovljivost i generalizacija. U kvalitativnoj varijanti otkriva značenja, narative i kontekst kroz induktivno kodiranje; cilj je razumjeti latentni smisao. U digitalnom dobu sve češće uključuje algoritme koji prepoznaju uzorke, ton ili sentiment — no broj pojavljivanja riječi ne znači da znamo što te riječi znače. Analiza sadržaja mjeri vidljivo i objašnjava neizrečeno, ali i dalje traži ljudsko razumijevanje.

## ZAKLJUČAK

Odabir metode strateški je, a ne tehnički čin, jer metoda ne samo da prikuplja podatke, nego oblikuje ono što je uopće moguće opaziti. Primjerenost cilju i kontekstu, a ne poznatost ili navika, mjerodavno je mjerilo izbora. Istraživanje koje polazi od metode umjesto od pitanja izlaže se opasnosti da prilagodi problem raspoloživom alatu.

# 10. Digitalne metode i nova istraživačka praksa

*„Internet više nije medij ni alat; on je okoliš.“*

Nekoć je „digitalno“ bilo posebno područje — nova sfera koja je živjela uz „stvarni“ svijet. Danas je digitalno stvarni, gotovo jedini svijet. Ne postoji „digitalno istraživanje“ nasuprot „klasičnom“, postoji samo istraživanje u digitalnom kontekstu. Internet više nije medij ni alat; on je okoliš. Sve se u njemu bilježi, povezuje i pretvara u podatke, često bez svjesne namjere ljudi da sudjeluju u istraživanju. Zato se i sama praksa mora mijenjati, ne zato što su metode postale loše, nego zato što više ne odgovaraju stvarnosti u kojoj živimo.

Nije, međutim, dovoljno samo bilježiti. Broj klikova može biti pokazatelj interesa, ali i slučajnosti. Lajk može značiti odobravanje, ali i ironiju. Komentar može biti reakcija, ali i algoritamski šum. Kada analiziramo digitalne tragove, više ne provodimo klasično primarno istraživanje — ne prikupljamo nove odgovore, nego tumačimo već postojeće obrasce ponašanja: podatke koji su „zatečeni“, a ne „stvoreni“ za istraživanje, sa svim prednostima i zamkama koje ta razlika nosi (boyd, d. i Crawford, 2012; Salganik, 2019). To nas vraća ključnoj razlici našeg doba: primarni i sekundarni podaci više nisu jasno razdvojeni. Kad analiziramo klikove, lajkove ili komentare, koristimo podatke koji su i primarni i sekundarni, mi ih stvaramo, ali ih ne posjedujemo. Digitalni trag postaje i izvor i kontekst istraživanja.

## 10.1. Digitalni teren i njegove metode

Digitalni teren nije „isto kao klasični, samo online“; on traži novi konceptualni okvir. Klasični teren je fizičko mjesto s vidljivim granicama i sinkronom prisutnošću istraživača; digitalni je distribuirani prostor čije su granice algoritamski filtrirane, u kojem je prisutnost asinkrona, a tragovi trajni. Razgovor više nije samo licem u lice, nego tekst, slika, video i emotikon; dokumenti su efemerni i promjenjivi; sam ulazak u teren često je tiho promatranje, a izlazak nejasan. Među ključnim metodama izdvajaju se digitalna etnografija (netnografija), online intervjui i kritička analiza diskursa.

Digitalni izvori pritom su raznovrsniji nego što se obično pretpostavlja — od teksta foruma, komentara i blogova, preko slika, videa i memova te metapodataka i tragova poput oznaka sviđanja, do algoritamskih artefakata kakvi su preporučeni sadržaji i poluzatvorenih prostora grupnih aplikacija za dopisivanje. Svaki tip izvora nosi vlastiti izazov, a svaki izazov traži svoj metodološki odgovor: efemernost traži arhiviranje i dokumentiranje podrijetla podatka, anonimnost identiteta triangulaciju izvora, algoritamsko filtriranje refleksiju o

vlastitu pristupu, masovnost građe svrhovitu selekciju, a klizna granica javnoga i privatnoga jasan etički protokol. Uz to, svaka je platforma vlastiti teren: zajednica, pravila i algoritamska logika jedne mreže ne mogu se preslikati na drugu. Većina ozbiljnih projekata zato kombinira dva do tri tipa izvora, triangulacija u digitalnom okruženju nije luksuz, nego metodološka nužnost.

Netnografija (Kozinets, 2020) prilagođava etnografsko promatranje online zajednicama i tipično prolazi kroz šest faza. Počinje introspekcijom, tko sam ja u odnosu na zajednicu i što tražim, i istragom, kartiranjem zajednica i čitanjem bez sudjelovanja. Slijedi informiranje, etička priprema s pristankom, anonimizacijom i odlukom o ulasku, pa interakcija: sudjelovanje u zajednici, po izboru, uz terenske bilješke. Interpretacija kodira građu i gradi teme uz triangulaciju, a integracija zatvara krug: pisanjem, vraćanjem rezultata zajednici i završnom refleksijom. Online intervjui pokazuju da format oblikuje sadržaj: video je najbliži razgovoru uživo, ali tehnički zahtjevan; audio uklanja vizualnu distrakciju i smanjuje pritisak; pisani i asinkroni formati daju vrijeme za promišljanje, ali gube spontanost.

Za online intervjue vrijedi praktično pravilo da tehnologija nije samo kanal, nego medij koji oblikuje iskaz. Prije razgovora to znači unaprijed poslan informirani pristanak, tehničku provjeru i pričuvni plan za slučaj prekida; na početku eksplicitnu, snimljenu dozvolu za snimanje; tijekom razgovora strpljenje s tišinom, koja se u online okruženju „osjeća“ dulje nego uživo, i glasno bilježenje vizualnih signala; a na kraju pitanje „što sam zaboravio pitati?“ i ponovnu provjeru pristanka na korištenje materijala. Kritička analiza diskursa, naposljetku, puni smisao pokazuje tek kad se tri razine primijene zajedno: na razini teksta analiziraju se jezična sredstva (zamjenice „mi“ i „oni“, imperativi, prešutne pretpostavke), na razini diskurzivne prakse okolnosti nastanka i potrošnje iskaza (brzina, anonimnost, algoritamska distribucija), a na razini društvene prakse strukture koje iskaz reproducira — od ekonomske anksioznosti do isključujućih narativa.

Posebno su važan dio digitalne infrastrukture online paneli — nekoć longitudinalni dizajni s istim ispitanicima kroz više valova, danas stalne baze sudionika dostupne putem interneta. Njihove su prednosti brzina, fleksibilnost, segmentacija i povezivanje s analitikom; ograničenja su samoselekcija, „umor panela“, profesionalni ispitanici koji mijenjaju ponašanje radi nagrada te etički izazovi praćenja metapodataka. Prema smjernicama strukovnih tijela i preporukama međunarodnih organizacija, online paneli moraju počivati na načelima transparentnosti i pristanka: istraživač više ne upravlja kontaktom, nego odnosom s podatkom.

## 10.2. Alati digitalnog istraživanja

Digitalni teren donio je i novu generaciju alata koji istraživaču pomažu da se u njemu snađe. Prvu skupinu čine alati za praćenje spomena i društveno osluškivanje (social listening): oni kontinuirano prate spominjanje pojmova, osoba ili tema na webu, u medijima i na društvenim mrežama, nude analizu sentimenta i upozorenja u stvarnom vremenu. Za kvalitativnog istraživača takvi alati nisu analiza sami po sebi, nego faza pripreme — pomažu identificirati dominantne narative, kartirati najaktivnije sudionike i pratiti kako se diskurs mijenja kroz vrijeme, čime kasniju dubinsku analizu čine fokusiranom. No imaju i ograničenja: automatski klasifikatori sentimenta često griješe na ironiji i slengu, ne pristupaju zatvorenim grupama i ne zamjenjuju interpretaciju.

Drugu skupinu čine sindicirana istraživanja potrošača i publike — kontinuirana, reprezentativna mjerenja stavova, navika i potrošnje koja daju populacijski okvir. Ona odgovaraju na pitanja „što“ i „koliko“, ali ne i „zašto“; to ostaje posao kvalitativnog istraživača. Treću skupinu čine programi za kvalitativnu analizu podataka (tzv. QDA-softver), koji pomažu u kodiranju i organizaciji velikih količina teksta, zvuka i videa. Nijedan od njih ne „analizira umjesto istraživača“, oni ubrzavaju rukovanje građom, ali značenje i dalje pridaje čovjek. Optimalan digitalni dizajn najčešće kombinira sve tri skupine: alat za osluškivanje kartira aktivni diskurs, sindicirano istraživanje daje populacijski kontekst, a kvalitativni intervjui donose dubinu, pri čemu se sva tri izvora na kraju povezuju triangulacijom.

**ETIČKA NAPOMENA O DIGITALNIM ALATIMA**

Podaci prikupljeni komercijalnim alatima često sadrže imena, fotografije i lokacije. Pri akademskom ili javnom korištenju nužna je anonimizacija koja ide dalje od zamjene imena, jasno razlikovanje javne osobe u javnoj funkciji od običnog korisnika te dokumentiranje parametara pretrage (datum, ključne riječi, broj spomena) — jer o tome ovisi mogućnost ponavljanja istraživanja. Tehnička dostupnost podatka nije isto što i etička prihvatljivost njegove upotrebe.

## 10.3. Mediji kao laboratorij digitalne zbrke

U društvenim istraživanjima još uvijek nailazimo na pitanja poput: „Kojem mediju najviše vjerujete — televiziji, radiju, novinama ili internetu?“ Ta pitanja danas nemaju smisla, jer su sve te opcije digitalne. Televizija je i IPTV, radio je i streaming, novine su i portali, a internet je sve to zajedno. Internet nije kanal koji uspoređujemo, to je infrastruktura kroz koju se sve medijatizira. Mjerenje publike još uvijek počiva na starim kategorijama (gledanost, slušanost, čitanost, posjećenost), no svi ti pojmovi danas označavaju istu aktivnost: konzumaciju sadržaja koji prolazi digitalnim putem. Kada korisnik pročita članak s porta-

la jer ga je vidio na društvenoj mreži, je li to „čitanje portala“ ili „aktivnost na mreži“? U medijskom svijetu, gdje je istraživanje jedina zajednička valuta, bit će presudno razvijati metodologiju koja u središte stavlja osobu, a ne medij.

Ali osoba u središtu ne rješava drugo pitanje koje digitalni teren nameće: kako uopće doći do podataka i što s njima raditi kad ih je previše da bi ih itko pročitao. Ondje gdje je klasično istraživanje mjerilo desetke ili stotine odgovora, digitalni izvor nudi milijune tragova — objava, komentara, poveznica, oznaka. Zbog toga se u posljednjem desetljeću oblikovalo posebno područje, računalne društvene znanosti (Lazer i sur., 2009; 2020), koje računalu prepušta ono što ljudsko čitanje ne stigne: prepoznavanje tema u golemim količinama teksta, kartiranje mreža spominjanja, praćenje kako se riječ ili stav šire kroz vrijeme. Metoda se pritom ne mijenja u svojoj srži. I dalje vrijedi da algoritam može prebrojati i grupirati, ali ne može reći što nalaz znači, to ostaje na istraživaču. Ono što se mijenja jest razmjer, a s razmjerom i iskušenje da se veličina uzorka zamijeni za razumijevanje.

Postoji i tiši, praktičniji obrat koji mijenja svakodnevicu istraživanja: podaci se zatvaraju. Dugo se činilo da je javni internet otvorena knjiga iz koje se slobodno crpi. To više nije točno. Sučelja preko kojih se nekad slobodno prikupljalo (takozvani API-ji) sve se češće naplaćuju ili gase — u literaturi se već govori o „post-API dobu“ istraživanja (Freelon, 2018; Bruns, 2019); pristup podacima jedne velike mreže postao je plaćen, a druga je od 2024. dopustila prikupljanje samo unaprijed prijavljenim istraživačima s odobrenim projektom. Za istraživača to nije tehnička sitnica. Reprezentativnost i ponovljivost odjednom ovise o tome što platforma toga dana dopušta, a arhiva koja je jučer postojala danas može nestati. Tko istražuje na tuđem terenu, istražuje pod tuđim pravilima — i mora to jasno reći u opisu metode, jer bez toga nitko ne može provjeriti niti ponoviti ono što je učinjeno.

## ZAKLJUČAK

Digitalno više nije zasebno područje istraživanja, nego okoliš u kojem se ono odvija; teren se proširio na goleme količine tragova, a analitički alati na računalne postupke koji nadilaze ljudsko čitanje. Istodobno se pristup podacima sužava, pa transparentan opis uvjeta pod kojima su prikupljeni prestaje biti formalnost i postaje dio samoga nalaza. Razmjer podataka pritom ne smije zamijeniti razumijevanje, nego ga tek nadopunjuje.

# 11. Poslovna istraživanja: kompozitne mjere i KPI

*„U poslovnom kontekstu rezultat mora biti operativan — mora se moći pretočiti u odluku, cilj i pokazatelj.“*

Dosad smo govorili o istraživanju kao putu prema razumijevanju. U poslovnom kontekstu tom se putu pridružuje dodatni zahtjev: rezultat mora biti operativan — mora se moći pretočiti u odluku, cilj i mjerljiv pokazatelj uspješnosti. Upravo zato poslovna istraživanja često grade kompozitne mjere: pojedinačne ocjene i postotke sažimaju u indekse koji cjelovito opisuju neku apstraktnu pojavu, primjerice snagu brenda. Kompozitna mjera je oblik operacionalizacije o kojem smo već govorili, samo što ovdje više varijabli spajamo u jednu, ponderiranu prema njihovoj važnosti.

## 11.1. Od ocjene do indeksa

Kompozitni indeks nastaje u nekoliko koraka. Prvo se prikupe sirovi podaci — primjerice prosječne ocjene na skali od 1 do 5 za niz tvrdnji (čestica) i postotak ispitanika koji se s tvrdnjom snažno slažu (tzv. Top-2-Box, T2B). Zatim se srodne čestice grupiraju u dimenzije koje mjere jedan pojam: percepciju sadržaja, povjerenje i kvalitetu, emocionalnu povezanost, poznavanje i sklonost izboru. Svaka se dimenzija skalira na razumljiv raspon (najčešće 0–100) i ponderira prema procijenjenoj važnosti, često regresijski, gdje se kao zavisna varijabla uzima ukupna sklonost ili sviđanje, pa ponderi odražavaju koliko svaka dimenzija doista pridonosi tom ishodu. Naposljetku se dimenzije spajaju u krovni indeks.

**ILUSTRATIVNI PRIMJER (POSLOVNO ISTRAŽIVANJE SNAGE BRENDA)**

Zamislimo studiju snage televizijskih brendova na fiktivnom tržištu, provedenu telefonskom anketom na uzorku od 800 ispitanika. Konstruira se pet dimenzija: poznavanje kanala (CSI), očekivanje sadržaja (CEI), povjerenje i kvaliteta (TQI), emocionalna povezanost (ECI) i izbor gledatelja (VCI). Svaka se računa kao ponderirani prosjek pripadajućih čestica, skaliran na 0–100. Krovni indeks kombinira dimenzije prema njihovim ponderima (primjerice: CSI 15 %, CEI 25 %, TQI 30 %, ECI 20 %, VCI 10 %). Time se desetci pojedinačnih ocjena sažimaju u jedan broj koji opisuje ukupnu snagu brenda — pod uvjetom da razumijemo kako je nastao.

**Tablica 9.** Primjer strukture kompozitnog indeksa snage brenda

| Dimenzija | Izvor podataka | Ponder |
|---|---|---|
| **Poznavanje kanala (CSI)** | Postotak ispitanika koji su čuli za brend. | 15 % |
| **Očekivanje sadržaja (CEI)** | Čestice percepcije sadržaja (ocjene 1–5). | 25 % |
| **Povjerenje i kvaliteta (TQI)** | Čestice povjerenja i kvalitete (ocjene 1–5). | 30 % |
| **Emocionalna povezanost (ECI)** | Čestice emocionalne povezanosti (ocjene 1–5). | 20 % |
| **Izbor gledatelja (VCI)** | Udio prvog izbora kanala. | 10 % |
| **Krovni indeks** | Ponderirani zbroj svih dimenzija. | 100 % |

## 11.2. Bazni indeks i kako ne zavarati sami sebe

Sirovi indeksi na skali 0–100 intuitivni su, ali teško usporedivi među dimenzijama jer im se prosjeci razlikuju. Zato se često prikazuju kao bazni indeks, gdje se tržišni prosjek postavi na 100, a vrijednost svakog brenda izrazi u odnosu na njega: bazni indeks = (vrijednost brenda / tržišni prosjek) × 100. Brend s indeksom 111 nalazi se 11 % iznad tržišnog prosjeka; onaj s 90 nalazi se 10 % ispod. Postoji i varijanta s rasponom od −200 do +200, gdje je nula prosjek, a razlike među brendovima djeluju naglašenije — no upravo ta naglašenost može zavarati. Isti podaci prikazani na širem rasponu izgledaju dramatičnije, pa naizgled velike vrijednosti (primjerice +186) lako se pogrešno protumače kao golem jaz ondje gdje razlika, u stvarnim postocima, i nije tako velika.

Ovdje se vraća temeljna pouka knjige: brojka nije istina sama po sebi. Kompozitni indeks je koristan jer sažima, ali svako sažimanje nešto skriva. Odabir pondera je interpretativna odluka; skaliranje mijenja dojam; prosjek na kojem počiva bazni indeks ovisi o tome koje smo brendove uključili u „tržište“. Odgovoran istraživač uz indeks uvijek izvještava i kako je nastao, jer bez toga kompozitna mjera postaje retorički alat, a ne spoznajni.

## 11.3. KPI: kada indeks postaje pokazatelj uspješnosti

Kada se indeks počne pratiti kroz vrijeme kao cilj, postaje ključni pokazatelj uspješnosti (engl. key performance indicator, KPI). Za KPI je bazni indeks (prosjek = 100) obično najprikladniji jer je usporediv i intuitivan: „+15 % iznad tržišta“ razumije se odmah. Dobra praksa razlikuje primarni KPI (npr. krovni indeks, s ciljem da se zadrži iznad neke razine) od sekundarnih KPI-jeva po pojedinim dimenzijama, koji pokazuju gdje su prostori za po-

boljšanje. No KPI nosi i opasnost: kad pokazatelj postane cilj, prestaje biti dobra mjera. Ako se organizacija fokusira isključivo na podizanje broja, može ga „optimizirati“ na način koji ne odražava stvarnu vrijednost. Zato KPI treba čitati kao instrument razumijevanja napretka, ne kao njegovu zamjenu — jednako kao što smo pokazali da mjerenje treba istraživanje da bi dobilo smisao.

**NAPOMENA O PRIMJERIMA**

Brojčani primjeri i struktura indeksa u ovom poglavlju služe isključivo kao ilustracija metodološkog postupka. Riječ je o prikazu logike kompozitnih mjera, a ne o podacima bilo koje konkretne organizacije ili brenda.

## ZAKLJUČAK

U poslovnom kontekstu istraživanje mora biti operativno, pretočivo u odluku i mjerljiv pokazatelj, pa se oslanja na kompozitne mjere koje sažimaju složene pojave u indekse. Svako takvo sažimanje istodobno nešto skriva, zbog čega razumijevanje konstrukcije indeksa postaje uvjet njegove ispravne uporabe. Pokazatelj bez uvida u vlastitu strukturu lako postaje sredstvo samozavaravanja.

# DIO III. Suvremeni izazovi istraživanja

*Digitalno je doba promijenilo tlo pod nogama istraživača. Ovaj dio otvara pitanja koja su nekad imala jasne odgovore, a danas ih više nemaju: kako nastaje „gotovo znanje“ koje tražilice i strojevi sami sklapaju; što znači reprezentativnost kad jedan čovjek postaje pet algoritamskih profila; što uistinu govori statistička značajnost; kako varijable varaju; i kako izgleda etika kada dio istraživanja preuzimaju strojevi.*

Društvo se mijenja brže nego što metodologija uspijeva pratiti. Nekada su istraživači morali tražiti podatke; danas podaci traže istraživače. Sve se bilježi i sve je mjerljivo — ali nije sve smisleno. Najveći izazov nije prikupljanje podataka, nego njihovo razumijevanje i kontekstualizacija.

U nastavku razmatramo četiri ključna izazova suvremenog doba: strojno strukturiranje znanja, reprezentativnost uzorka, značenje statističke značajnosti i skrivene varijable, te etiku istraživanja kada dio posla preuzimaju algoritmi.

# 12. Grafovi znanja i informacijski paneli

*„Grafovi znanja sve više oblikuju kako ljudi dolaze do ‚činjenica' i kako se znanje strukturira na webu."*

Sve dosad rečeno o putu od podatka prema znanju danas se odvija i izvan istraživačevih ruku — u pozadini tražilica i sustava umjetne inteligencije, kroz tehnologije poznate kao grafovi znanja (knowledge graphs) i informacijski paneli (knowledge panels). Za istraživača su relevantni jer sve više oblikuju kako ljudi dolaze do „činjenica" i kako se znanje strukturira na webu.

Graf znanja je semantička mreža koja povezuje entitete, osobe, organizacije, mjesta, proizvode, pojmove, i odnose među njima. Umjesto da samo traži podudaranje ključnih riječi, sustav prepoznaje o kojem je entitetu riječ i s čime je taj entitet povezan. U takvom grafu svaki entitet je čvor s vlastitim identifikatorom i atributima (naziv, datum, lokacija), a bridovi predstavljaju odnose („osnovao je", „nalazi se u", „autor je"). Podaci se crpe iz javnih i licenciranih izvora te izravno od vlasnika sadržaja. Informacijski panel je vidljivo sučelje tog grafa — sažeti okvir s činjenicama koji se pojavljuje uz rezultate pretrage kad je sustav dovoljno „siguran" u podatke o entitetu.

Metodološki gledano, graf znanja je pokušaj da se cijela DIKW-hijerarhija automatizira: sirovi podaci s weba pretvaraju se u strukturirane informacije o entitetima, a njihove veze u nešto nalik na znanje. No time se vraćaju sva pitanja o kojima govori ova knjiga. Tko odlučuje koji su izvori pouzdani? Kako se rješava dvoznačnost (isti naziv za tvrtku i za pojam)? Što se događa kad je entitet pogrešno povezan? Isti grafovi danas napajaju i odgovore generativnih sustava umjetne inteligencije, pa pogreška u strukturi znanja tiho putuje dalje. Za istraživačku pismenost to znači novu vještinu: razumjeti da ni „gotova činjenica" iz panela nije neutralna, nego rezultat niza odluka o tome što se broji kao pouzdano znanje — jednako kao i svaki drugi istraživački nalaz.

## ZAKLJUČAK

Put od podatka do znanja sve se češće odvija izvan istraživačeva nadzora, u pozadini tražilica i sustava koji oblikuju ono što se pojavljuje kao činjenica. Grafovi znanja i informacijski paneli time postaju predmet istraživanja jednako koliko i njegov alat. Razumijevanje strukturiranja znanja na webu postaje dio razumijevanja kako nastaje javna slika svijeta.

# 13. Reprezentativnost — od popisa stanovništva do digitalnog traga

*„Danas više ne znamo gdje društvo počinje, a tehnologija završava.“*

Reprezentativnost je temelj vjerodostojnosti svakog istraživanja, no kriteriji koji su nekad bili jasni danas postaju upitni. Nekoć se činilo jednostavno: popis stanovništva bio je okvir, kućanstvo jedinica analize, a istraživanje je tražilo uzorak koji odražava „stvarno društvo“. Kad je došao telefon, logika se promijenila — jedan broj, jedno kućanstvo. Danas više ne znamo gdje društvo počinje, a tehnologija završava. Svaka osoba ima više digitalnih identiteta: nekoliko adresa e-pošte, profila, uređaja, i svaki od njih generira podatke. Kako uopće definirati jedinicu analize u svijetu u kojem jedan čovjek može biti pet algoritamskih profila?

Klasična reprezentativnost značila je vjeran presjek populacije po demografskim kategorijama — spolu, dobi, obrazovanju, mjestu stanovanja. Taj model još dominira, ali podrazumijeva društvo u jasno omeđenom prostoru sa stabilnim popisima. U digitalnom dobu ti su temelji uzdrmani: popisi zastarijevaju čim su objavljeni, mobilnost briše granice, a komunikacija se odvija po algoritamskoj sličnosti, a ne po adresama. Online ankete isključuju one koji nisu digitalno aktivni, starije, siromašnije, ruralne, digitalno nepismene građane. Reprezentativnost tako postaje i pitanje digitalne pristupačnosti. Uz to stopa neodgovaranja stalno raste, a oni koji odgovore često se razlikuju od većine: imaju izraženiji stav ili veću medijsku prisutnost. Time nerijetko mjerimo angažirane, a ne prosječne građane.

## 13.1. Profil nije osoba

Sve češće mjerimo profil, ne čovjeka. Digitalni tragovi otvaraju istraživanju obzore kakve klasični uzorak nikada nije imao, ali uz sustavne pristranosti koje se ne smiju prešutjeti (Golder i Macy, 2014). Podaci o klikovima, lajkovima i pretragama pripadaju korisničkim računima, ne nužno pojedincima. Jedna osoba može dijeliti uređaj, imati više računa ili biti pogrešno profilirana. Zato reprezentativnost više ne možemo temeljiti samo na demografiji: dvoje ljudi istih godina i obrazovanja može imati posve različit svjetonazor jer pripadaju različitim vrijednosnim zajednicama. U novijim se istraživanjima sve više koristi vrijednosna tipologija — segmentacija prema stavovima, prioritetima i obrascima digitalne participacije. Suvremena reprezentativnost tako počiva na tri dimenzije: demografskoj (osnovni okvir populacije), digitalnoj (razina i način korištenja tehnologije) i vrijednosnoj (stavovi, povjerenje, orijentacije). Takva trodimenzionalna reprezentativnost bolje odražava društvenu stvarnost, a ne samo statističku strukturu.

## ZAKLJUČAK

Reprezentativnost ostaje temelj vjerodostojnosti, ali su kriteriji koji su nekoć bili jasni postali upitni u okruženju u kojem se granica društva i tehnologije zamagljuje. Sve češće profil, skup obilježja, zamjenjuje stvarnu osobu, čime se mijenja i sam pojam uzorka. Vrijednost nalaza određena je time koga uzorak sustavno izostavlja jednako koliko i time koga obuhvaća.

# 14. Statistička značajnost i stvarno značenje

*„Statistička značajnost kaže je li razlika slučajna; tek suština kaže je li važna.“*

Jedan od najčešćih problema interpretacije jest miješanje statističke i suštinske značajnosti. Pojam značajnosti označava vjerojatnost da opaženi rezultat nije posljedica slučajnosti; ako je $p < 0,05$, kažemo da je razlika „statistički značajna“. Ali taj broj ne govori ništa o veličini učinka ni o važnosti nalaza u praksi. Razlika od 0,5 % u preferenciji stranaka može biti društveno beznačajna, ali „značajna“ u medijskom naslovu; promjena povjerenja u institucije od 4 % može biti društveno presudna, a ipak ne „statistički značajna“ ako je uzorak premalen. Kako upozorava Gigerenzer (2004), p-vrijednost ne govori o istinitosti hipoteze, nego samo o konzistentnosti podataka s njom.

U medijskim izvještajima o rejtingu često se čuje: „Stranka je pala za 0,8 %, a pogreška uzorka iznosi ±3,5 %.“ To se izgovara mehanički, ali se ne razumije. Margina pogreške ne znači da „rezultat može biti ±3,5 %“, nego da 95 % uzoraka iste veličine u istoj populaciji daje rezultat unutar tog raspona — to nije granica pogreške u mjerenju, nego granica povjerenja u procjenu. U praksi političari i novinari te granice koriste kao retoričke alate: ako rezultat raste, „trend je jasan“; ako pada, „pad je beznačajan jer je unutar greške“. Kad se toj mehanici doda sloboda istraživača da analizu prilagođava dok rezultat ne postane „značajan“, dobiva se recept za lažno pozitivne nalaze (Simmons, Nelson i Simonsohn, 2011) — upravo ono što je veliki projekt ponavljanja stotinu psiholoških studija ogolio pokazavši da se manje od polovice nalaza uspjelo replicirati (Open Science Collaboration, 2015). Postoji i cijeli znanstveni pokret koji preispituje značenje statističke značajnosti (Wasserstein i Lazar, 2016), jer je postala zamjena za razmišljanje, umjesto da razumijemo veličinu učinka, trajnost promjene i kontekst, istraživanje često staje na $p < 0,05$, kao da je to dokaz, a ne tek oznaka.

**Tablica 10.** Statistička i suštinska značajnost

| Kriterij | Statistička značajnost | Suštinska značajnost |
|---|---|---|
| **Definicija** | Vjerojatnost da rezultat nije slučajan. | Koliko je rezultat važan u stvarnosti. |
| **Temelj** | Uzorak i distribucija. | Kontekst i interpretacija. |
| **Oslonac** | P-vrijednost, testovi, intervali. | Veličina učinka, posljedice, društveni smisao. |
| **Opasnost** | Formalizam bez smisla. | Pretjerano tumačenje bez dokaza. |
| **Potrebno** | Statistička pismenost. | Konceptualna pismenost. |

## ZAKLJUČAK

Statistička značajnost govori o vjerojatnosti da je razlika slučajna, ali ne i o njezinoj važnosti; tek suštinska značajnost, veličina učinka i kontekst, odgovaraju na to je li razlika bitna. Brkanje tih dviju razina jedan je od najraširenijih izvora pogrešnog tumačenja, i u znanstvenoj i u javnoj komunikaciji. Odgovorna interpretacija zahtijeva da se oba mjerila iznesu zajedno.

# 15. Kada varijable varaju

*„U svijetu u kojem su pojave višeslojne, vidimo liniju, ali ne i mrežu.“*

Jedno od najvećih iskušenja svake analize jest riječ „utjecaj“. Koristimo je svakodnevno: mediji utječu na javnost, obrazovanje utječe na stavove, povjerenje utječe na odluke. Ali najčešće nemamo dokaz za utjecaj, nego samo za povezanost — i to parcijalnu, izoliranu. U svijetu u kojem su pojave višeslojne, to znači da vidimo liniju, ali ne i mrežu.

Tu leži razlika koju je lako izgovoriti, a teško poštovati: povezanost nije uzročnost. Dvije pojave mogu rasti zajedno, a da jedna ne uzrokuje drugu — često ih obje pokreće nešto treće, skrivena varijabla koju nismo mjerili. Da bismo smjeli govoriti o uzroku, nije dovoljno da se pojave kreću zajedno; treba pokazati da promjena jedne prethodi promjeni druge, da veza opstaje kad isključimo druge objasnidbe, i da postoji razuman mehanizam koji ih spaja. Eksperiment to postiže nadzorom nad uvjetima; promatračko istraživanje gotovo nikad ne može tvrditi uzrok sa sigurnošću. Zato je „utječe“ riječ koju treba zaslužiti, a ne posuditi.

Zamislimo istu populaciju, isto istraživanje i iste varijable, provedeno jednom telefonski, a jednom putem online panela — s bitno različitim rezultatima o preferenciji medijskih kanala. Tehnički su oba uzorka reprezentativna i statistički valjana, ali kontekst u kojem sudjeluju nije isti. Telefonski ispitanik odgovara uz prisutnost druge osobe, društvenu normu i zadani redoslijed pitanja; online ispitanik ima vrijeme, anonimnost i slobodu izbora. Razlika nije u uzorku, nego u načinu na koji se pitanje doživljava. U tom smislu i sama metoda postaje varijabla, ona najčešće prešućena. Kad dvije metode daju različite rezultate, to ne znači da je jedna pogrešna, nego da mjere različite aspekte iste pojave. Skrivena varijabla ovdje može biti percipirana društvena poželjnost ili intenzitet digitalne prisutnosti, nešto što nije mjereno, ali je utjecalo na odgovor. Razlika između rezultata nije greška, nego signal.

**Tablica 11.** Razine interpretacije

| Razina | Što se mjeri | Što se može zaključiti |
|---|---|---|
| **Deskriptivna** | Pojedinačna varijabla (prosjek, distribucija). | Što jest, ali ne i zašto jest. |
| **Korelacijska** | Dvije ili više varijabli u istom trenutku. | Postoji povezanost, ali smjer i uzrok nisu poznati. |
| **Uzročna** | Odnos uzroka i posljedice uz kontrolu varijabli. | Može se govoriti o utjecaju, uz jasne uvjete i model. |
| **Konceptualna** | Sustav odnosa koji povezuje više uzroka. | Razumijevanje mehanizma i značenja odnosa. |

Pogreška nastaje kada nižu razinu (npr. korelaciju) tumačimo kao višu (uzročnost). Još je opasnija suprotnost — kada rezultate koji govore o stvarnom iskustvu ljudi pokušamo svesti na „broj koji to dokazuje“. Ne vjerovati podacima znači odustati od znanosti; vjerovati im bez konteksta znači odustati od razumijevanja. Pravo pitanje nije kojim podacima vjerovati, nego što svaki od njih može reći.

## 15.1. Kako pronaći skrivenu varijablu

Kada dvije metode ili dva uzorka daju različite rezultate, do skrivene varijable možemo doći u tri koraka. Prvi je analiza razlika među uzorcima — demografija, digitalna pismenost, navike konzumacije: ako postoji dosljedna razlika (primjerice, stariji ispitanici prevladavaju u telefonskom uzorku), to je prvi trag. Drugi je kvalitativno dopunjavanje, intervjui ili fokus-grupe sa sudionicima iz oba uzorka mogu otkriti razliku u načinu na koji doživljavaju pitanje. Treći je multivarijabilno testiranje, uvrštavanje novih varijabli poput učestalosti korištenja interneta, povjerenja u medije ili vrijednosne orijentacije, kako bismo vidjeli što stabilizira razliku. Ako se nakon kontrole svih poznatih faktora razlika i dalje zadržava, skrivena varijabla vjerojatno pripada emocionalnom ili kulturnom sloju, nečemu što statistika može registrirati, ali ne razumjeti bez interpretacije.

Stvarni svijet rijetko funkcionira binarno. Tradicionalna korelacijska analiza gleda odnose dva po dva, varijabla A i varijabla B, no u stvarnosti A utječe na B, ali i B na A; obje su posredovane varijablom C, ovisne o kontekstu D i modificirane kroz vrijeme. Tu ulazi potreba za multivarijabilnim razumijevanjem, ne samo tehnički (regresijski modeli, faktorska analiza, modeliranje strukturnih jednadžbi), nego i konceptualno: da se uzrok ne traži u jednoj točki, nego obrazac u sustavu. Svaka izolirana korelacija ostaje sumnjiva dok ne vidimo njezin kontekst.

> *„Kad se podaci ne slažu, to ne znači da lažu — nego da svijet govori više jezika. Zadatak istraživača nije da utiša razlike, nego da ih prevede.“*

## ZAKLJUČAK

Jezik uzročnosti redovito nadilazi ono što podaci dopuštaju, jer istraživanje najčešće utvrđuje povezanost, a ne uzrok. Skrivena varijabla može objasniti vezu koja se pripisuje izravnom utjecaju, pa tvrdnja o uzroku zahtijeva vremenski slijed, isključivanje alternativa i razuman mehanizam. U umreženom svijetu pojava izolirana korelacija stoga je nepouzdan temelj za zaključak o djelovanju.

# 16. Etika, transparentnost i istraživanje u doba umjetne inteligencije

*„Etika istraživanja više nije samo pitanje pristanka i anonimnosti, nego tko posjeduje podatke i tko odlučuje što se s njima radi.“*

U digitalnom dobu pitanje etike više nije samo pristanak i anonimnost, nego glasi: tko posjeduje podatke i tko odlučuje što se s njima radi? U tradicionalnim istraživanjima etika se temeljila na informiranom pristanku. Danas većina ljudi sudjeluje nesvjesno — svaki klik, pretraga i reakcija postaje podatak. Tko je dao pristanak i tko uopće zna da sudjeluje? Regulatorni okviri poput Opće uredbe o zaštiti podataka (GDPR) postavljaju granice, ali ne mogu pratiti brzinu tehnoloških promjena. Pravo pitanje nije samo imamo li dopuštenje, nego imamo li povjerenje. Transparentnost pritom ne znači tek objaviti metodologiju, nego i priznati ograničenja, interese i rizike.

Digitalna je transformacija promijenila prirodu istraživanja: alati su brži, podaci masovniji, ali pitanje ostaje isto — tko istražuje koga? Algoritmi prate ponašanje milijuna korisnika u stvarnom vremenu, a tehnologije analize sentimenta i prediktivnog modeliranja stvaraju privid „istraživanja bez istraživača“. No automatizacija donosi širinu, a gubi dubinu: ispitanici postaju podaci, a podaci predviđanja, a predviđanje nije razumijevanje. Kad umjetna inteligencija analizira ljudsko ponašanje, granica između istraživača i istraživanog postaje porozna. Zato se suvremeno istraživanje mora temeljiti na etičkom okviru, ne samo na tehničkom. Ključni izazov nije kako prikupiti više podataka, nego kako ih povezati u smisao, a svaka je takva sinteza već interpretacija.

Za digitalni teren najrazrađenije su smjernice Udruge istraživača interneta (AoIR, 2019), s tri načela koja se čitaju kao gramatika novoga terena. Kontekstualna cjelovitost: granica javnoga i privatnoga nije svojstvo platforme, nego konteksta, jer objava tehnički dostupna svima može biti napisana s očekivanjem intimnosti male zajednice. Razmjernost ranjivosti: što je zajednica ranjivija, obveza istraživača je veća, a anonimizacija mora ići dalje od puke zamjene imena. I procesualnost: etika se ne događa jednom, u obrascu pristanka, nego traje koliko i istraživanje. Korisna je provjera pitanje bi li sudionik bio uznemiren da zna kako je njegov trag upotrijebljen.

### TRI DILEME DIGITALNOG TERENA

Istraživačica se pod osobnim identitetom učlanila u veliku privatnu roditeljsku grupu i mjesecima prikupljala dragocjen materijal. Smije li ga upotrijebiti u disertaciji i mora li naknadno otkriti svoju ulogu? Arhiva od pedeset tisuća objava iz izborne kampanje sadrži i javne dužnosnike i anonimne građane. Smiju li se svi tretirati jednako, kad javna funkcija nosi drukčija očekivanja privatnosti? Dvogodišnje praćenje zajednice za oporavak od ovisnosti otkrilo je uznemirujuće obrasce, a norme zajednice traže da joj se nalazi vrate. Kako predstaviti rezultate koji bi je mogli povrijediti i tko uopće „posjeduje“ nalaze? Nijedna od tih dilema nema jednoznačan odgovor; upravo zato etički protokol mora biti dio dizajna istraživanja, a ne naknadna provjera.

Uz Opću uredbu o zaštiti podataka, od 2024. godine, djeluje i prvi cjeloviti propis o umjetnoj inteligenciji, europski Akt o umjetnoj inteligenciji. On ne govori izravno o metodologiji, ali postavlja okvir unutar kojeg će se istraživanje sve više odvijati: sustave dijeli prema riziku, od zabranjenih do onih s obvezom transparentnosti, i traži da bude jasno kada s nekim razgovara stroj, a ne čovjek. Za istraživača koji se koristi takvim alatima to znači novu razinu odgovornosti — ne samo prema ispitaniku, nego i prema tome kako je nastao svaki podatak koji ulazi u analizu.

Tu se otvara pitanje koje prije nekoliko godina nije ni postojalo: smije li odgovor uopće doći od stroja. Suvremeni jezični modeli mogu uvjerljivo odglumiti ispitanika — popuniti anketu, odigrati intervju, proizvesti stotine „mišljenja“ u sekundi; prvi radovi pokazuju da simulirani uzorci mogu iznenađujuće vjerno oponašati odgovore stvarnih skupina (Argyle i sur., 2023), a rasprava o tome što generativna umjetna inteligencija istraživanju doista može, a što ne može dati, tek je otvorena (Bail, 2024). Napast je očita, osobito kad su pravi ljudi skupi, spori ili teško dostupni. No takav, sintetički podatak nosi zamku o kojoj istraživač mora znati. Model odgovara onako kako je najvjerojatnije, pa teži sredini i gasi rubove, upravo one manjinske, neočekivane glasove zbog kojih istraživanje ima smisla. Kada se modeli k tome počnu hraniti vlastitim izmišljenim odgovorima, kvaliteta im se urušava (Shumailov i sur., 2024). Sintetički ispitanik zato može biti koristan za vježbu i pripremu, ali nije zamjena za čovjeka; u trenutku kad ga proglasimo dokazom, prestali smo istraživati stvarnost i počeli istraživati pretpostavke ugrađene u model.

## ZAKLJUČAK

Etika istraživanja nije završni formalni korak, nego briga prisutna od oblikovanja pitanja. U digitalnom okruženju ona nadilazi pristanak i obuhvaća vlasništvo nad podacima, regulatorne okvire poput Opće uredbe o zaštiti podataka i Akta o umjetnoj inteligenciji, te pitanje smije li odgovor uopće potjecati od stroja. Sintetički podaci pritom mogu poslužiti pripremi, ali proglašeni dokazom prestaju opisivati stvarnost i počinju odražavati pretpostavke ugrađene u model.

# Dio IV. Upotreba rezultata

*Istraživanje ne završava kad su podaci prikupljeni, nego kad netko prema njima postupi. Ovaj dio govori o najodgovornijem trenutku cijelog procesa: kako se nalazi tumače bez pretjerivanja, kako se pretvaraju u odluke a da ne postanu izgovor za njih, i zašto je istraživačka pismenost postala temeljna vještina odgovornog društva.*

U svijetu u kojem se brojevi citiraju kao dokazi, odgovorna upotreba rezultata postaje temeljna vještina. Ona znači znati što podaci pokazuju, a što ne; razlikovati promjenu od šuma; prepoznati granice metoda; i komunicirati rezultate jasno, bez retoričkog „pojačavanja“. Najveća opasnost istraživanja nije u pogrešci mjerenja, nego u pretjeranom tumačenju. Kad rezultat postane argument, a brojka dokaz, istraživanje prelazi svoju granicu.

# 17. Istraživanje nije dokaz, nego argument u kontekstu

*„Istraživanje ne smije tvrditi ‚ovo je istina', nego ‚u ovom trenutku, prema ovim kriterijima, ljudi misle ovako'."*

Svako istraživanje djeluje unutar određenog konteksta — vremena, kulture, tržišta, tehnologije. Rezultati vrijede dok se kontekst ne promijeni; u trenutku kad ih izvučemo iz tog okvira, gube smisao. Zato istraživanje ne smije tvrditi „ovo je istina", nego može reći „u ovom trenutku, prema ovim kriterijima, ljudi misle, osjećaju ili rade ovako". Upravo u toj privremenosti leži njegova snaga: ono nije kraj rasprave, nego njezin početak. Brojevi imaju autoritet, ali ne i savjest, zato je na istraživaču odgovornost da pokaže granicu između onoga što znamo i onoga što pretpostavljamo.

Najčešća zloupotreba istraživanja nije u izmišljanju podataka, nego u manipulaciji značenjem — kad se rezultat koristi za potvrđivanje unaprijed zadanog stava. Zato istraživač mora znati reći „ne znamo". To nije slabost, nego znak profesionalne čestitosti. Postoje područja u kojima istraživanje treba šutjeti, emocije, uvjerenja, moralne vrijednosti, ne zato što ih ne razumije, nego zato što ih ne može izmjeriti a da ih ne promijeni. Zrelost znanstvenog mišljenja prepoznaje se po onome o čemu šuti jednako kao po onome o čemu govori.

## ZAKLJUČAK

Istraživanje ne izriče apsolutnu istinu, nego privremen i kontekstualno ograničen nalaz — tvrdnju o tome što, prema danim kriterijima, u danom trenutku vrijedi. U toj privremenosti nije slabost, nego snaga, jer nalaz postaje početak, a ne kraj rasprave. Tko uz nalaz navede i kriterije i kontekst u kojima on vrijedi, ne slabi svoj argument, čini ga provjerljivim.

# 18. Kad istraživanje intervenira u stvarnost

*„Istraživanje više nije samo mjerilo stvarnosti. Ono ju je počelo proizvoditi.“*

Danas mnogo govorimo o lažnim vijestima, o manipulaciji, o algoritmima i neprovjerenim izvorima. No pritom lako zaboravimo jedno teže pitanje. Problem više nije samo u tome što je nešto lažno. Problem je što stvarnost sve češće nastaje tek nakon informacije o njoj. Nekad je slijed bio jednostavan: nastupi događaj, mediji ga prenesu, javnost reagira. Danas je redoslijed često obrnut. Informacija se objavi, ljudi reagiraju, a reakcija proizvede novu stvarnost. Informiranje javnog mnijenja tako neprimjetno prelazi u njegovo oblikovanje.

To se najjasnije vidi u političkoj i medijskoj komunikaciji, a istraživanje je u samom središtu tog obrata. Zamislimo tijek izbora. Objavi se anketa: dvije velike stranke vode izjednačenu utrku, mali kandidati nemaju šanse, samo jedan kandidat može pobijediti drugoga. I što se tada zbiva? Dio birača odustane od kandidata kojega uistinu želi, jer ne želi „baciti glas“. Dio prelazi prema onome tko „može pobijediti“. Mediji počinju govoriti o zamahu, stranke mijenjaju strategiju, aktivisti dobivaju ili gube energiju. I odjednom postaje jasno nešto važno: istraživanje više nije samo mjerilo političke stvarnosti. Ono ju je počelo proizvoditi. Ponekad istraživanja ne predviđaju pobjednika — ponekad ga stvaraju.

Politika je ujedno i jedino područje u kojem mjerenje redovito polaže javni ispit. Izlazne ankete na dan izbora rijedak su trenutak u kojem se procjena i stvarnost sudare iste večeri, pred svima: svaka pogreška uzorka, ponderiranja ili prešućenog odgovora postaje vidljiva u satu kad stignu službeni rezultati. Upravo zato izborna istraživanja nisu tek primjer nego laboratorij metodologije: nigdje se povratna informacija o kvaliteti mjerenja ne dobiva tako brzo, tako javno i tako nemilosrdno.

To nije zabuna metode, nego njezino naličje. Klasična pretpostavka istraživanja glasi da mjerenje ne dira mjereno — da anketa opisuje raspoloženje kakvo bi ono bilo i bez ankete. U mnogim područjima to vrijedi. Ali ondje gdje je predmet mjerenja ljudsko očekivanje, sama objava rezultata postaje događaj koji to očekivanje mijenja. Istraživanje tada nije zrcalo, nego akter. A akter ima odgovornost kakvu zrcalo nema.

## 18.1. Parcijalna istina i narativ

Nakon percepcije dolaze brojevi — i tu se krije još suptilnija opasnost. Većina ljudi ne razumije marginu pogreške, ali svatko razumije naslov. Recimo da jedna stranka ima dvadeset šest posto, a druga dvadeset tri, uz pogrešku uzorka od plus-minus 3,6 posto. Statistički, to

može biti gotovo izjednačeno. Medijski, netko uvjerljivo vodi. Između statistike i percepcije često ne pobjeđuje točnost, nego narativ. O tome smo već govorili kada smo razdvajali statističku od suštinske značajnosti; ovdje ta ista razlika prelazi iz metodologije u politiku.

Tako dolazimo do možda najsofisticiranijeg oblika manipulacije današnjice — parcijalne istine. Kažemo: osamdeset posto građana podržava neku odluku. I to može biti potpuno točno. Ali ako je na izbore izašlo tek četrdeset dva posto ljudi, odjednom vidimo koliko parcijalna istina može izgledati kao apsolutna. Najsofisticiranije manipulacije danas više ne nastaju iz laži. Nastaju iz selektivno točnih informacija. Broj bez konteksta može manipulirati, informacija bez razumijevanja može polarizirati, a percepcija bez odgovornosti može mijenjati demokraciju.

Zato danas više nije dovoljno imati informaciju. Informacija sama po sebi više nije moć — moć je razumjeti njezino značenje. Znanje postaje prednost tek kada nije odvojeno od interpretacije. I budimo iskreni: problem nisu samo mediji. Problem smo i mi. Svaki put kada biramo emociju umjesto konteksta, brzinu umjesto provjere, reakciju umjesto odgovornosti, sudjelujemo u stvaranju te iste stvarnosti. Komunikacija zato više nije samo pitanje kreativnosti. Ona je pitanje etike, ali i inteligencije. Jer danas nije problem nedostatak informacija. Problem je nedostatak razumijevanja.

## 18.2. Ono što umjetno ne može replicirati

Zanimljivo je kako svaka nova tehnologija prolazi isti put. Na početku nas fascinira umjetno: jagode savršena oblika, savršeno filtrirana lica, savršeno generiran sadržaj. A onda, nakon nekog vremena, počnemo čeznuti za onim što djeluje stvarno. Danas je gotovo luksuz da nešto izgleda prirodno. Isto će se dogoditi i s inteligencijom. Sada nas fascinira umjetna inteligencija. A onda će najveća vrijednost postati upravo ono što umjetno ne može potpuno replicirati: ljudska procjena, kontekst, etika, odgovornost, intuicija, razumijevanje čovjeka.

O tome se u posljednjih nekoliko godina povela ozbiljna rasprava i u samoj znanosti. Jedan krug autora vidi u umjetnoj inteligenciji priliku da se istraživanje ubrza i proširi — da se hipoteze o ljudskom ponašanju iskušavaju brže i na većem broju slučajeva nego ikad (Grossmann i sur., 2023). Drugi upozoravaju na tišu opasnost. Messeri i Crockett (2024) pišu o „iluziji razumijevanja“: alat koji samouvjereno sažima i objašnjava lako stvori dojam da smo shvatili, a zapravo smo samo dobili uglađen sažetak koji prikriva složenost. Ako se svi počnu oslanjati na iste modele i iste postupke, upozoravaju, znanost postaje monokultura, proizvodi sve više, a razumije sve manje.

Ta se opomena gotovo doslovno poklapa s onim o čemu ova knjiga govori od prve stranice. Razlika između informacije i razumijevanja nije akademska sitnica; ona je linija na kojoj se odlučuje hoće li nam tehnologija pomoći da mislimo ili da prestanemo misliti. Umjetna inteligencija tu ništa ne ukida. Ona samo pojačava i dobro i loše: u rukama istraživača koji zna što traži, ubrzava put do uvida; u rukama onoga koji traži potvrdu, ubrzava put do zablude. Zato budućnost istraživanja neće odlučiti alat, nego pitanje koje mu postavljamo i prosudba kojom tumačimo njegov odgovor.

To je i razlog zašto istraživanja kakva poznajemo neće nestati slučajno ni zato što ih tehnologija ukida. Ona se mijenjaju jer se mijenja sam odnos informacije i stvarnosti. Stara logika, najprije izmjeri, potom izvijesti, više ne opisuje svijet u kojem mjerenje mijenja mjereno. Ono što ostaje, i postaje najvrjednije, jest ljudsko razumijevanje: sposobnost da procijenimo, smjestimo u kontekst i preuzmemo odgovornost za ono što brojka sama ne može reći.

Nema, dakle, razloga za paniku. Tehnologija može ubrzati informacije, ali smisao im daje ljudska inteligencija — sposobnost da se znanje pretvori u razumijevanje, informacija u odgovornost, a percepcija u povjerenje. Ako istraživanje već intervenira u stvarnost, neka to bude stvarnost u kojoj vrijedi živjeti.

„Istraživanje koje mijenja ono što mjeri ne prestaje biti istraživanje — ono samo postaje odgovornije.“

## ZAKLJUČAK

Odnos informacije i stvarnosti obrnuo se: objavljena brojka mijenja ponašanje koje je mjerila, pa istraživanje povremeno postaje sila koja stvarnost oblikuje. Najveća odgovornost zato više ne leži samo u točnosti podatka, nego u odluci što će se, kada i kako objaviti. Umjetna inteligencija tu polugu ne ukida, nego pojačava, i uvid i zabludu, pa se težište vraća onamo gdje je oduvijek bilo: na pitanje koje postavljamo i prosudbu kojom odgovaramo.

# 19. Kako koristiti rezultate za stvarne odluke

*„Rezultati istraživanja imaju smisla tek kad postanu temelj odluke. Ali odluke donose ljudi, ne tablice.“*

Između brojke i odluke nalazi se prostor interpretacije. U poslovnom, političkom i društvenom kontekstu istraživanje je alat, a ne autoritet: podaci ne odlučuju, oni informiraju. Odgovornost za odluku ne može se prebaciti na brojke. Istraživanje koje se ne može primijeniti nije korisno, ali istraživanje koje se zloupotrijebi može biti štetno.

**PRIMJER IZ PRAKSE:**
**GRANICE ISTRAŽIVANJA U ODLUČIVANJU**

U poslovnoj praksi često se javlja razočaranje: čeka se istraživanje koje bi trebalo olakšati odluku, a rezultati se dožive kao nedovoljno konkretni. Traži se, primjerice, „novo lice“ neke emisije, pa se istraži što publika misli o postojećim voditeljima — koliko ih poznaje, kakav dojam ostavljaju, potiču li na gledanje. No pravo rješenje ne mora biti ni najpoznatija ni najomiljenija osoba. Istraživanje ne daje gotove odgovore — ono daje kontekst i sastojke odluke. Kada bi istraživači donosili rješenja, bili bi direktori i urednici; kada bi svaki podatak bio jednoznačna informacija, ne bi nam trebali ni odvjetnici ni suci — brojke bi same presuđivale. Poseban je izazov s inovacijama: njih nikada ne stvaramo na temelju istraživanja prosjeka. Prosjek govori što jest, ali ne i što može biti: mjerenje osvjetljava poznato, a korak prema novome ostaje odluka koju brojka ne može donijeti umjesto nas.

Utemeljena odluka nije ona koja slijedi broj, nego ona koja razumije njegovo značenje. Za to su potrebne tri kompetencije: analitička (razumjeti što podaci doista govore), kontekstualna (znati kako nastaju i što mogu, a što ne mogu obuhvatiti) i etička (odlučivati svjesno o posljedicama koje brojke ne predviđaju). To je razlika između upravljanja podacima i korištenja podataka za upravljanje. Kada istraživanje postane dio procesa odlučivanja, a ne formalna provjera, ono mijenja kulturu organizacije ili društva: umjesto „odgovora na zahtjev“, postaje način razmišljanja. Istraživanje vrijedi samo onoliko koliko mijenja odluke — a odluke vrijede samo onoliko koliko poštuju ono što istraživanje ne zna.

Tu se vraćamo temeljnom izazovu: znati što tražimo. Istraživanje najbolje služi kad ne traži gotovo rješenje, nego kad precizno mjeri problem i prostor za napredak. Zato dobra organizacija istraživanjem ne traži odgovor koji će donijeti odluku umjesto nje, nego jasnu kartu problema na kojoj će njezina mašta i prosudba pronaći put. Istraživanje osvjetljava teren; korak u nepoznato ostaje ljudski.

## ZAKLJUČAK

Rezultat istraživanja dobiva smisao tek kad postane temelj odluke, ali odluku donosi čovjek, a ne podatak, pa se odgovornost ne može prenijeti na brojku. Utemeljeno odlučivanje zahtijeva analitičku, kontekstualnu i etičku kompetenciju istodobno. Istraživanje osvjetljava teren odluke, no korak u nepoznato ostaje ljudski čin.

# 20. Istraživačka pismenost: temelj odgovornog društva

*„Istraživačka pismenost nije vještina brojanja, nego navika zdrave, konstruktivne sumnje.“*

Istraživačka pismenost ne znači znati koristiti statistički softver, nego znati misliti u okvirima dokaza — tražiti objašnjenje, a ne potvrdu. U društvu koje se guši u informacijama postaje osnovni alat snalaženja: bez nje javni prostor preplavljuju „istraživanja koja kažu“ i „brojke koje govore“, a nitko više ne pita tko ih je pitao, kako i zašto.

Društvo koje ne razumije istraživanja ne može prepoznati manipulaciju. Ako ne znamo što znači margina pogreške, vjerovat ćemo da razlika od pola postotnog boda znači „pad“. Ako ne razlikujemo korelaciju od uzročnosti, vjerovat ćemo da su dvije pojave povezane samo zato što su zajedno spomenute. Istraživačka pismenost uči razlikovati činjenicu od dojma, metodu od mišljenja, podatak od interpretacije — ona je svojevrsni imunološki sustav društva: ne sprječava pogreške, ali prepoznaje ih prije nego što se prošire. Zato ne pripada samo istraživačima, nego je građanska kompetencija, dio kritičkog mišljenja.

Kad čitamo rezultate istraživanja, vrijedi se pitati: tko ga je proveo i zašto; koja je metoda korištena i što ona omogućuje, a što ne; u kojem je kontekstu provedeno; kako su formulirana pitanja i što je time isključeno; tko interpretira rezultate i u čijem interesu. To su jednostavna, ali presudna pitanja. Postoje dva ekstrema u odnosu prema istraživanju: jedni se skrivaju iza statistike, kojoj su brojke štit od odgovornosti; drugi statistiku zanemaruju, dovoljno im je da „dokažu“ ono što već misle. Prvi traže sigurnost, drugi potvrdu — a oba zaboravljaju da istraživanje nije niti opravdanje niti oružje, nego način razmišljanja.

## 20.1. Odgovornost onih koji tumače istraživanja

Svatko tko javno prenosi rezultate istraživanja, novinar, analitičar, političar, nastavnik, ima odgovornost tumačiti ih pošteno. Objasniti što istraživanje ne govori jednako je važno kao objasniti što govori. Kao što u medijskoj pismenosti učimo razlikovati činjenice od mišljenja, tako moramo naučiti razlikovati istraživanje od dojma o istraživanju. Odgovorna interpretacija znači ne pretjerivati s tvrdnjama, ne prilagođavati podatke očekivanjima, ne izvlačiti zaključke koje podaci ne podupiru i priznati sumnju kao sastavni dio znanja. Takva interpretacija gradi povjerenje — a povjerenje je valuta svakog društva koje želi biti otvoreno i demokratsko.

## 20.2. Znanstvena čestitost kao društvena vrijednost

Znanstvena čestitost nije samo pitanje akademskog morala — ona je temelj povjerenja u cijelo društvo. Kada istraživač prizna ograničenja svojega rada, pokazuje poštenje; kada ih sakrije, stvara sumnju u cijelu znanstvenu zajednicu. Povjerenje u znanost ne gradi se brojem objavljenih radova, nego transparentnošću i iskrenošću u tome što znamo, a što tek pokušavamo saznati. Istraživanje bez odgovornosti postaje mehaničko, a mišljenje bez istraživanja proizvoljno; tek njihova kombinacija stvara društvo koje razumije složenost i zna postavljati pitanja umjesto da traži jednostavne odgovore.

Čestitost se ne pokazuje samo u tome kako mjerimo, nego i u tome kako priznajemo tuđe. Citiranje nije formalnost ni ukras na kraju rada — ono je trag koji drugima omogućuje da provjere odakle nam znanje i da nastave od mjesta na kojem smo stali. Preuzeti tuđu misao bez navođenja, ili je prepričati tako da se izgubi izvor, nije sitni propust nego pukotina u povjerenju na kojem cijela znanost počiva. Isto vrijedi i za recenziju: tuđi rad prosuđujemo mjerilima kojima bismo pristali da se prosuđuje naš, iznosimo primjedbe koje pomažu, a ne one koje ponižavaju. Pismen istraživač zna da je znanost razgovor kroz vrijeme, i da u tom razgovoru vrijedimo onoliko koliko pošteno priznajemo od koga smo učili.

## ZAKLJUČAK

Istraživačka pismenost nije vještina računanja, nego navika utemeljene sumnje koja traži objašnjenje umjesto potvrde, i kao takva predstavlja građansku, a ne samo stručnu kompetenciju. U društvu zasićenom informacijama ona djeluje kao mehanizam koji pogreške prepoznaje prije nego što se prošire. Nju ne mogu preuzeti ni stručnjaci ni strojevi: prosudba o tome čemu vjerovati posljednja je vještina koju ne možemo nikome prepustiti.

# Dio V. Empirijska provjera

*Načela iznesena u prethodnim dijelovima ovdje se stavljaju na kušnju. Izvorno istraživanje medijske publike pokazuje kako metodološki zaokret, premještanje jedinice segmentacije s osobe na vrijeme, nastaje, provjerava se i pretvara u praktičnu odluku.*

# 21. Segmentacija vremena: emocionalne potrebe kao funkcija trenutka

Prethodna poglavlja razmatrala su metodologiju istraživanja na načelnoj razini. Ovo poglavlje iznosi izvorno empirijsko istraživanje koje tu metodologiju stavlja na kušnju na konkretnom problemu iz medijske prakse, i pritom predlaže jedan metodološki zaokret. Riječ je o prijedlogu da se u istraživanju medijske publike jedinica segmentacije premjesti s osobe na vrijeme.

Klasična segmentacija publike, uključujući utjecajne okvire poput NeedScopea, polazi od pretpostavke da se ljudi razlikuju po trajnim emocionalnim potrebama i da svakoga gledatelja možemo smjestiti u segment koji ga u dobroj mjeri opisuje. Ta je pretpostavka korisna, ali skriva jednu tešku činjenicu svakodnevnog iskustva: ista osoba ne traži isto u svako doba. Sama misao da situacija objašnjava ponašanje bolje od trajnih osobina nije nova — u literaturi o ponašanju potrošača postavljena je još prije pola stoljeća (Belk, 1975), a segmentacija po sprezi osobe i situacije prepoznata je kao „karika koja nedostaje“ klasičnoj segmentaciji (Dickson, 1982). Novost ovoga istraživanja jest u tome što tu misao dosljedno provodi na emocionalnim potrebama medijske publike i na vremenu kao jedinici. Čovjek koji ujutro želi sažetu, pouzdanu informaciju navečer traži opuštanje, a vikendom bijeg od svega. Ako je tomu tako, onda potrebu ne nosi samo osoba, nego i trenutak — i pitanje koje ovo istraživanje postavlja glasi: može li se emocionalna potreba gledatelja pouzdanije opisati kao funkcija vremena nego kao trajno svojstvo pojedinca?

## Teorijski okvir: od arhetipa osobe do arhetipa trenutka

NeedScope, metodološki okvir koji su razvili TNS i danas Kantar, počiva na jungovskoj teoriji arhetipova i na ideji da izborom brenda upravljaju emocionalne, često nesvjesne potrebe (Mark i Pearson, 2001). Okvir smješta potrebe u prostor određen dvjema osima — otvorenošću prema van nasuprot okrenutosti prema unutra, te usmjerenošću na zajedništvo nasuprot isticanju pojedinca, i tako dobiva nekoliko emocionalnih segmenata, od potrebe za snažnim uzbuđenjem do potrebe za pripadnošću i mirom. U medijskoj primjeni okvir se koristi da bi se utvrdilo koji programi, kanali i osobe zadovoljavaju koju emocionalnu potrebu, pa se publika dijeli na segmente prema tome što od gledanja traži.

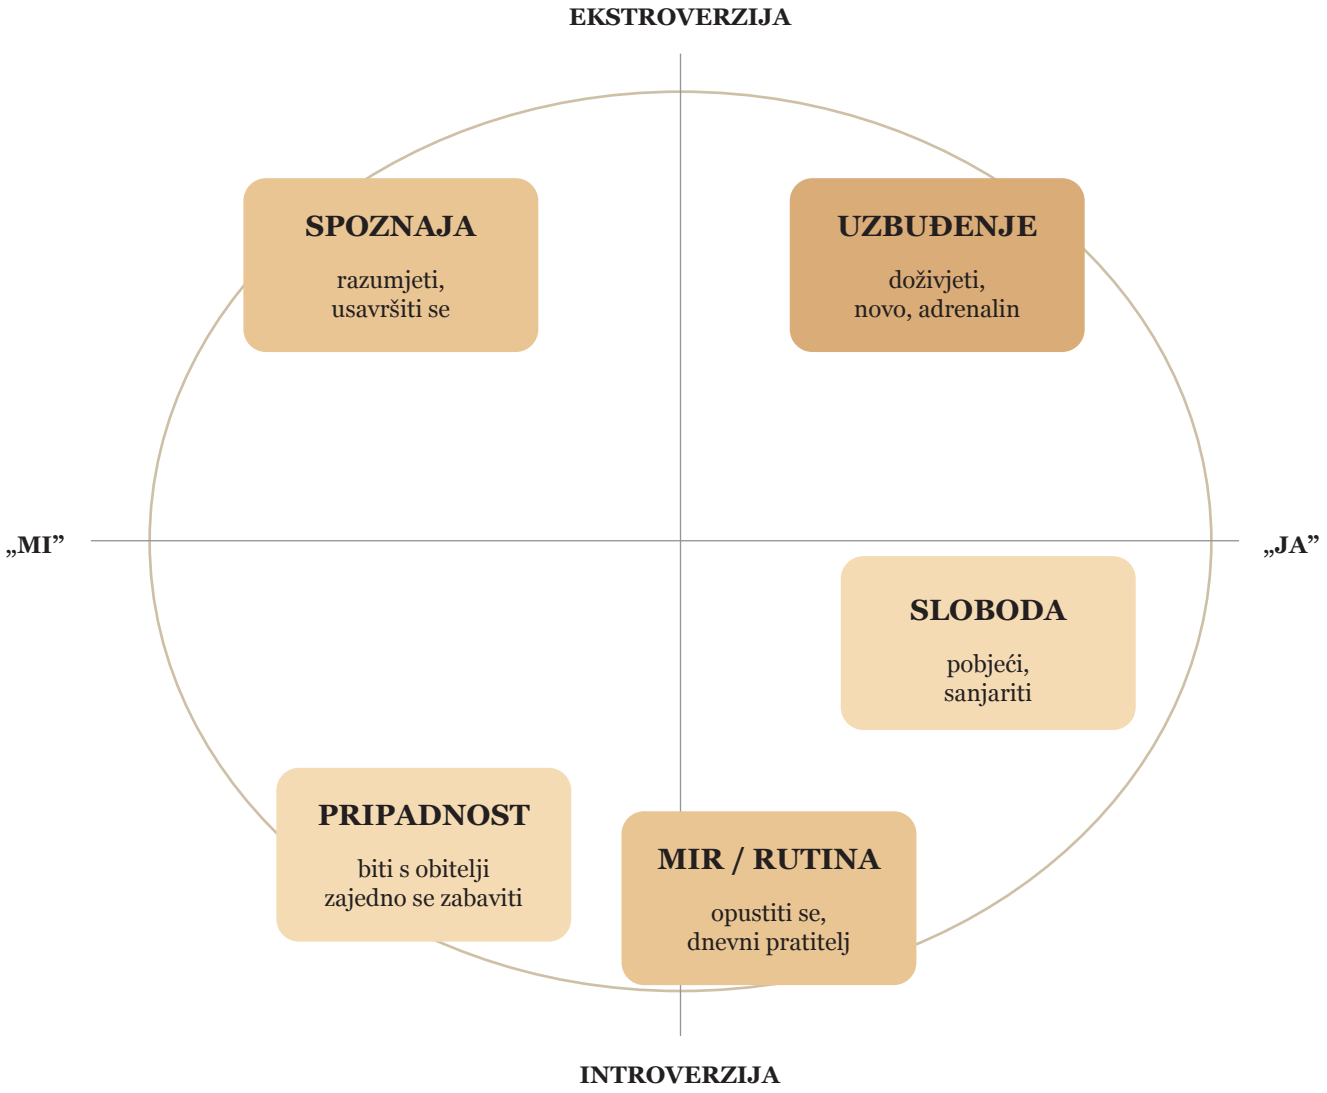


*Segmenti opisuju emocionalne potrebe, ne demografske skupine*

**Slika 4.** Prostor emocionalnih potreba prema okviru NeedScope. Segmenti su određeni dvjema osima (ekstroverzija–introverzija, „mi“–„ja“) i opisuju emocionalne potrebe, ne demografske skupine.

Zadržavajući teorijsku jezgru toga okvira — misao da je izbor vođen emocijom i da se emocionalne potrebe mogu smisleno rasporediti u prostor — ovo istraživanje mijenja ono na što se prostor primjenjuje. Umjesto da arhetip pripišemo osobi kao trajnu oznaku, pripisujemo ga situaciji gledanja. Isti prostor potreba ostaje, ali se popunjava vremenskim jedinicama: jutrom radnog dana, poslijepodnevom, udarnim terminom, kasnom večeri, vi-

kendom. Time se pretpostavka o stabilnosti seli s osobe na obrazac: ne tvrdi se da je osoba stalna, nego da je raspored potreba kroz tjedan dovoljno pravilan da ga se može mjeriti i predviđati.

## Metoda

Istraživanje je provedeno u okviru sustava NeedScope na jednome nacionalnom televizijskom tržištu, s dvostrukim ciljem tipičnim za taj okvir: poduprijeti poslovne ciljeve televizijskog brenda, zadržati i povećati udio u oglašivačkim ulaganjima, i provjeriti koliko ponuda odgovara potrebama gledatelja, što se u praksi mjeri gledanošću. Već u ciljevima, dakle, stoji ekonomska logika opisana u prethodnim poglavljima: mjerenje potreba u službi je valute pažnje. Studija NeedScope po svojoj naravi ima dva dijela prikupljanja podataka, koja odgovaraju dvama različitim pitanjima i ne smiju se brkati: kvalitativni dio otkriva sadržaj karte potreba (razumijevanje), a kvantitativni dio tu kartu iscrtava (mjerenje).

U kvalitativnome dijelu provedeno je dvadeset dubinskih intervjua u trajanju od oko devedeset minuta, s muškarcima i ženama u dobi od 18 do 49 godina koji televiziju gledaju barem jednom tjedno, u trima većim gradovima. Cilj te faze nije bio mjeriti, nego otkriti: projekcijskim tehnikama — fotosetovima i kolažima osoba koje utjelovljuju različite arhetipske dinamike — prikupljen je jezik kojim gledatelji opisuju kanale, situacije i osjećaje gledanja. Iz te je građe izveden popis atributa za drugu fazu: konkretni programi i tipovi programa, televizijske ličnosti, razlozi gledanja, stavovi prema gledanju, slika kanala, životni stil gledatelja, osjećaji tijekom gledanja te supstituti, što bi ispitanik radio umjesto gledanja.

U kvantitativnome dijelu provedeno je 716 osobnih intervjua uz računalnu podršku (CAPI), također u trajanju od oko devedeset minuta, s gledateljima u dobi od 15 do 54 godine, uz kvote po dobi, spolu, veličini naselja i regiji. Tijek intervjua slijedio je dvostruku logiku okvira. U dijelu koji odgovara pozicioniranju ispitanik svaki kanal povezuje s jednim od šest standardiziranih kolaža i opisuje ga atributima iz kvalitativne faze — čime se mjeri osobnost kanala, njegova simbolička razina, zaobilazeći samocenzuru racionalnih odgovora. U dijelu koji odgovara segmentaciji ispitanik od preferiranoga kolaža gradi „idealnu televiziju“, čime se mjeri potreba gledatelja neovisno o postojećoj ponudi. Uz to su prikupljeni podaci o navikama: količini gledanja, dobu dana i tjedna, svrsi, načinu i mjestu gledanja, upravo oni koji omogućuju kasniji vremenski korak analize.

Analitički postupak okvira ima nekoliko pravila o kojima ovisi interpretacija, pa ih navodimo izrijekom. Pozicija kanala ili atributa računa se iz broja izbora na svakome od šest kolaža, pri čemu je svaki kanal mogao biti izabran po kolažu onoliko puta koliko je ispitanika;

ukupan broj izbora ujedno je pokazatelj snage brenda, a kao donji prag pouzdane interpretacije uzima se pedesetak izbora. Profil kanala, atributi prikazani oko pozicije, računa se iz standardiziranih odstupanja od očekivanih vrijednosti i prikazuje samo statistički značajna odstupanja, dakle atribute doista specifične za kanal. Otisak kanala pokazuje prema kojim je potrebama kanal oblikovan: usko usmjeren otisak znači jasno ciljan brend, raspršen otisak brend bez jasne pozicije. Veličina segmenata potreba iskazuje se udjelom u ukupnom vremenu gledanja, a zasićenost segmenta korelacijom između potrebe i zbirne isporuke svih kanala: visoka korelacija znači da je potreba dobro podmirena i da novi sadržaj gledatelje može dobiti uglavnom preotimanjem, a niska da postoji nepodmiren prostor.

Na tako pripremljenoj građi slijedi korak koji je izvorni doprinos ovoga poglavlja i koji podatke obiju faza čita iznova, u tri poteza. Najprije se odgovori o svrsi i doživljaju gledanja rasporede u prostor emocionalnih potreba, čime se svakoj situaciji gledanja pridružuje dominantna potreba. Zatim se te situacije grupiraju prema vremenskim pojasevima, pa se za svaki pojas utvrđuje koja potreba prevladava i koliko je izražena. Naposljetku se dobiveni vremenski profil potreba uspoređuje s postojećom programskom shemom, kako bi se utvrdilo gdje ponuda odgovara potrebi trenutka, a gdje se od nje razilazi. Statistička značajnost razlika među pojasevima prati se kako bi se trend razlikovao od slučajne oscilacije u uzorku.

Valjanost i pouzdanost nalaza počivaju na četiri izričita oslonca. Prvo, na instrumentu: fotosetovi i kolaži nisu ad hoc podražaji, nego standardizirani materijali koji su prije primjene prošli kvalitativnu provjeru i kvantitativnu validaciju arhetipskog izraza, uz prilagodbu lokalnom tržištu u kvalitativnoj fazi. Drugo, na pragu interpretacije: pozicija se tumači tek od pedesetak izbora naviše, čime se sprječava čitanje šuma kao nalaza. Treće, na kriteriju značajnosti: u profilima se prikazuju samo statistički značajna odstupanja od očekivanih vrijednosti, pa svaki prikazani atribut nosi provjerenu, a ne dojmovnu specifičnost. Četvrto, na triangulaciji: kvalitativna faza daje sadržaj karte, kvantitativna njezinu mjeru, a vremenski se korak provjerava na objema — obrazac koji bi postojao samo u jednoj fazi ne bi bio sastavni dio zaključaka. Mješoviti nacrt time nije stilski izbor, nego ugrađeni mehanizam uzajamne provjere: ono što razumijevanje predloži, mjerenje mora izdržati.

## Rezultati

Prvi signal da je vrijeme prava jedinica dolazi već iz samoga okvira. Veličina segmenata potreba u NeedScopeu ne iskazuje se udjelom osoba, nego udjelom u ukupnom vremenu gledanja — segment lagane zabave, primjerice, zauzima otprilike trećinu gledateljskog vremena. Okvir, dakle, i sam prešutno priznaje da se potrebe broje u satima, a ne u glavama; ovo poglavlje tu prešutnu pretpostavku samo dovodi do kraja.

Analiza pokazuje da se emocionalna potreba sustavno mijenja s vremenom, i to pravilnije nego što bi se mijenjala kad bi bila vezana isključivo uz tip osobe. Jutarnji i rani poslijepodnevni termini obilježeni su potrebom za informacijom, pouzdanošću i kontrolom; udarni večernji termin potrebom za zajedništvom i sadržajem koji povezuje kućanstvo; kasna večer potrebom za uzbuđenjem i odmakom; vikend potrebom za bijegom i lakoćom. Isti ispitanik pritom prelazi iz jednoga profila u drugi ovisno o terminu, što potvrđuje da vremenski pojas nosi dio potrebe koji se osobi ne može trajno pripisati.

**Dominantna potreba po vremenskom pojasu**




*Isti gledatelj prolazi kroz različite potrebe ovisno o trenutku - potrebu nosi vrijeme, ne samo osoba.*

**Slika 5.** Dominantna emocionalna potreba po vremenskom pojasu. Isti gledatelj prolazi kroz različite potrebe ovisno o trenutku, pa vremenski pojas nosi dio potrebe koji se osobi ne može trajno pripisati.

Najizravniji dokaz te promjenjivosti daje usporedba izbora postaje ovisno o svrsi gledanja, provedena na kvantitativnom uzorku. Ista osoba za informativni sadržaj, za zabavu i za večernje opuštanje ne bira nužno istu postaju — a razlike su znatne. Javna postaja, koja je za informativu gotovo izjednačena s vodećom komercijalnom (31,8 % naspram 35,2 %), za zabavu i opuštanje ispada iz kruga vodećih; tematska komercijalna postaja, obrnuto, postaje relevantna tek kod zabave i opuštanja. Isti ljudi, dakle, mijenjaju izbor prema tome što u danom trenutku traže.

**Tablica 12.** Udio prvog izbora iste postaje ovisno o svrsi gledanja (kvantitativna faza, n = 716). Znak „—“ označava da postaja za tu svrhu nije među vodećima. Postaje su anonimizirane; vrijednosti su stvarne.

| Postaja | Informativa | Zabava | Opuštanje |
|---|---|---|---|
| **Vodeća komercijalna postaja** | 35,2 % | 30,0 % | 26,2 % |
| Javna postaja (1. program) | 31,8 % | — | — |
| Druga komercijalna postaja | 20,5 % | 23,0 % | 22,4 % |
| Tematska komercijalna postaja | — | 15,1 % | 14,0 % |

Usporedba s programskom shemom otkriva mjesta neusklađenosti — termine u kojima ponuda odgovara nekoj drugoj potrebi od one koja u tom trenutku prevladava. Upravo ta mjesta predstavljaju najizravniju praktičnu vrijednost pristupa: ondje gdje se profil potrebe i profil ponude razilaze nalazi se ili rizik gubitka gledatelja ili prilika za novi sadržaj. Time analiza vremenskih profila daje uredništvu operativnu kartu koju segmentacija po osobama, po svojoj naravi, ne može dati.

## Rasprava

Rezultati ne osporavaju segmentaciju po osobama, nego joj dodaju komplementarnu os. Podjela publike na trajne emocionalne tipove ostaje korisna za strateško pozicioniranje brenda; podjela vremena na emocionalne profile korisnija je za upravljanje programskom shemom, jer se shema ionako gradi oko termina, a ne oko pojedinaca. Dva pristupa opisuju istu stvarnost iz dva kuta: jedan pita tko gleda, drugi kada se što traži.

Zaokret prema vremenu ima i teorijsku posljedicu. Ako je potreba dijelom svojstvo trenutka, onda stabilnost segmenta, na kojoj počiva klasična segmentacija, nije svojstvo ljudi nego obrazaca ponašanja — a obrasci se mjere lakše i mijenjaju sporije nego što se to obično pretpostavlja. To pomiče težište istraživanja s pitanja kakvi ljudi jesu na pitanje kako se ponašaju kroz vrijeme, što je pitanje na koje suvremeni podaci o gledanju odgovaraju izravnije i pouzdanije.

## Doprinos i ograničenja

Doprinos ovoga istraživanja trostruk je. Na metodološkoj razini predlaže pomak jedinice segmentacije s osobe na vrijeme i pokazuje da se dobro utemeljen okvir emocionalnih potreba može primijeniti na vremenske jedinice bez gubitka teorijske dosljednosti. Na prak-

tičnoj razini nudi uredništvu kartu neusklađenosti između potrebe trenutka i programske ponude, koju klasična segmentacija ne daje. Na razini poslovne ekonomije, konačno, nalaz izravno ulazi u ekonomiku medija: gledanost je valuta u kojoj se trguje oglasnim prostorom, pa preciznije razumijevanje potrebe trenutka znači točnije vrednovanje programskog vremena, bolju alokaciju programskih ulaganja i manji rizik promašene ponude.

Ograničenja otvaraju vrata budućim istraživanjima. Pridruživanje potreba vremenskim pojasevima ovisi o tumačenju odgovora o svrsi i doživljaju gledanja, pa je osjetljivo na način na koji su pitanja postavljena. Uzorak i tržište su specifični, što ograničava izravnu poopćivost na druge medijske sustave. Naposljetku, vremenska pravilnost potreba utvrđena u jednom razdoblju zahtijeva ponovljeno mjerenje da bi se potvrdila njezina stabilnost kroz duže vrijeme. Dvofazni nacrt, k tome, dijeli slabosti obiju sastavnica: kvalitativna faza ovisi o dubini projekcije i vještini vođenja intervjua, a kvantitativna o tome koliko standardizirani kolaži vjerno prenose arhetipske dinamike u lokalni kulturni kontekst. Ta ograničenja ne obaraju tezu, nego određuju smjer njezine daljnje provjere.

## ZAKLJUČAK

Unatoč tim ogradama, nalazi upućuju na zaključak koji nadilazi pojedinačni slučaj: u istraživanju medijske publike vrijeme nije samo okvir unutar kojega mjerimo, nego i predmet koji vrijedi mjeriti. Tko razumije ritam potreba kroz dan i tjedan, razumije publiku na način koji joj je bliži nego bilo koja trajna oznaka — jer opisuje ne ono što ljudi jesu, nego ono što traže u trenutku u kojem uključe ekran.

# Zaključna misao

Istraživanje nije samo proces prikupljanja podataka, nego način razumijevanja svijeta. U vremenu u kojem svatko može „istraživati“ i „objavljivati rezultate“, ključna razlika više nije između onih koji imaju podatke i onih koji ih nemaju, nego između onih koji ih razumiju i onih koji ih koriste bez razumijevanja. Istraživačka pismenost znači sposobnost da uočimo gdje podaci prestaju, a počinje interpretacija; gdje broj postaje argument i gdje se činjenice zamjenjuju vjerovanjima.

Istraživač koji priznaje granice svoga znanja čini više za znanost od onoga koji tvrdi da ih nema. Zrelost se ne mjeri sigurnošću u rezultat, nego pažnjom prema onome što ostaje nepoznato. Jer svijet ne postaje razumljiviji zato što smo ga izmjerili, nego zato što smo spremni misliti o tome što mjerenje znači. Istraživanje nije potraga za gotovim odgovorima, nego stalni pokušaj da svijet razumijemo točno onoliko koliko možemo — i dovoljno da znamo što još trebamo pitati.

A to nas vraća promišljanju ove knjige. Istraživanje budućnosti i budućnost istraživanja nisu dvije teme, nego jedna: metode se mijenjaju, teren postaje digitalan, mjere postaju sve složenije, ali temeljna pitanja ostaju ista — što želimo saznati, kako ćemo to mjeriti i što znači ono što smo otkrili. Jer jedino što je uistinu stalno jest sama potreba za traženjem. Research je uvijek re-search, istraživanje je uvijek traženje iznova, i zato znanost nema kraj, nego samo sljedeće pitanje. Nova vremena ne ukidaju stara pitanja; ona samo traže hrabrost da na njih odgovaramo iznova.

# Prilozi

**Prilog 1.** Temeljni pojmovi istraživačke pismenosti

| Pojam | Kratka definicija | Napomena u praksi |
|---|---|---|
| **Istraživačko pitanje** | Jasno formulirano pitanje koje usmjerava cijeli proces. | Dobar dizajn počinje pitanjem, ne hipotezom. |
| **Hipoteza** | Privremena pretpostavka koju istraživanje provjerava. | Alat za testiranje ideje, a ne za dokazivanje stava. |
| **Populacija** | Cjelokupni skup jedinica o kojima donosimo zaključke. | Ne „svi građani“, nego svi koji zadovoljavaju kriterije. |
| **Uzorak** | Manji broj jedinica iz populacije na kojima se istražuje. | Ključna je njegova reprezentativnost. |
| **Reprezentativnost** | Svojstvo uzorka da odgovara populaciji po ključnim obilježjima. | Danas uključuje i digitalne navike i vrijednosti. |
| **Pouzdanost** | Stupanj u kojem bi ponovljeno mjerenje dalo slične rezultate. | Nestabilni odgovori znače nepouzdan instrument. |
| **Valjanost** | Mjeri li instrument ono što tvrdi da mjeri. | Mjeriti „poznatost“ umjesto „povjerenja“ nije valjano. |
| **Instrument** | Alat kojim se prikupljaju podaci (upitnik, test, vodič). | Instrument je dio metode, ne metoda sama. |
| **Anketa** | Standardizirano ispitivanje većeg broja ispitanika. | Nije svaka anketa istraživanje javnog mnijenja. |
| **Fokus-grupa** | Grupna rasprava vođena po pripremljenim temama. | Za stavove i percepcije, ne za mjerenje udjela. |
| **Panel** | Stalni uzorak ispitanika koji se periodično ispituje. | Za praćenje promjena kroz vrijeme. |
| **Primarni podaci** | Podaci prikupljeni izravno za svrhu istraživanja. | Intervju, anketa, eksperiment. |
| **Sekundarni podaci** | Već postojeći podaci prikupljeni u drugu svrhu. | U digitalnom dobu granica s primarnima blijedi. |
| **Pristranost (bias)** | Sustavno odstupanje rezultata od stvarnosti. | Nastaje u uzorkovanju, pitanjima, interpretaciji. |
| **Triangulacija** | Kombiniranje metoda, izvora ili istraživača radi provjere. | Ne „više podataka“, nego više perspektiva. |
| **Interpretacija** | Proces davanja značenja podacima. | Najodgovorniji dio; povezuje brojke s razumijevanjem. |

## **Prilog 2.** Kompozitne mjere i pokazatelji

| Pojam | Kratka definicija | Napomena |
|---|---|---|
| **Čestica** | Pojedinačna tvrdnja ili pitanje unutar instrumenta. | Više čestica čini jednu dimenziju. |
| **T2B (Top-2-Box)** | Udio ispitanika koji biraju dvije najviše ocjene skale. | Sažima sklonost, ali gubi nijanse srednjih ocjena. |
| **Dimenzija / indeks** | Skupina čestica koje mjere jedan pojam, sažeta u vrijednost. | Skalira se najčešće na 0–100. |
| **Ponder** | Težina kojom dimenzija ulazi u kompozitnu mjeru. | Često regresijski, prema doprinosu ishodu. |
| **Krovni indeks** | Kompozit svih dimenzija u jedan pokazatelj. | Sažima, ali svako sažimanje nešto skriva. |
| **Bazni indeks** | Vrijednost izražena spram tržišnog prosjeka (prosjek = 100). | „+15 %“ znači 15 % iznad prosjeka tržišta. |
| **KPI** | Pokazatelj uspješnosti koji se prati kroz vrijeme kao cilj. | Kad pokazatelj postane cilj, prestaje biti dobra mjera. |

## **Prilog 3.** Kako različiti autori definiraju metodologiju

| Autor | Definicija / stav | Naglasak |
|---|---|---|
| **Babbie** | Sustav pravila i logike istraživačkog postupka. | Razlikuje metodu (tehniku) i metodologiju (logiku izbora). |
| **Creswell** | Filozofija i proces koji povezuje pretpostavke i konkretne metode. | Način razmišljanja o istraživanju, ne samo tehnički koraci. |
| **Blaikie** | Most između teorije i metode. | Povezuje spoznajne pretpostavke i praktične korake. |
| **Bryman** | Odnos između teorije i istraživačke prakse. | Metodološki izbori odražavaju vrijednosti i ciljeve. |
| **Harding** | Refleksivna praksa: kako naša pozicija utječe na istraživanje. | Samosvijest i etička odgovornost istraživača. |
| **Tkalac Verčić i sur.** | Osmišljen, logičan i sustavan proces povezivanja spoznaja. | Metodologija kao proces odlučivanja i povezivanja. |

# Literatura

## Metodološki priručnici i temeljni izvori

Babbie, E. R. (2021). *The practice of social research* (15. izd.). Cengage.

Blaikie, N. W. H. (2009). *Designing social research: The logic of anticipation* (2. izd.). Polity Press.

Bryman, A. (2016). *Social research methods* (5. izd.). Oxford University Press.

Creswell, J. W. i Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5. izd.). SAGE Publications.

Creswell, J. W. i Plano Clark, V. L. (2018). *Designing and conducting mixed methods research* (3. izd.). SAGE Publications.

Flick, U. (2018). *An introduction to qualitative research* (6. izd.). SAGE Publications.

Guba, E. G. i Lincoln, Y. S. (1994). Competing paradigms in qualitative research. U: N. K. Denzin i Y. S. Lincoln (ur.), *Handbook of qualitative research* (105–117). SAGE Publications.

Kozinets, R. V. (2020). *Netnography: The essential guide to qualitative social media research* (3. izd.). SAGE Publications.

Lincoln, Y. S. i Guba, E. G. (1985). *Naturalistic inquiry*. SAGE Publications.

Neuman, W. L. (2014). *Social research methods: Qualitative and quantitative approaches* (7. izd.). Pearson Education Limited.

Patton, M. Q. (2015). *Qualitative research & evaluation methods: Integrating theory and practice* (4. izd.). SAGE Publications.

Silverman, D. (2020). *Interpreting qualitative data* (6. izd.). SAGE Publications.

Tkalac Verčić, A., Sinčić Ćorić, D. i Pološki Vokić, N. (2010). *Priručnik za metodologiju istraživačkog rada: Kako osmisliti, provesti i opisati znanstveno i stručno istraživanje*. M.E.P.

Wimmer, R. D. i Dominick, J. R. (2014). *Mass media research: An introduction* (10. izd.). Cengage.

## Filozofija znanosti, hijerarhija spoznaje i znanstvena čestitost

Ackoff, R. L. (1989). From data to wisdom. *Journal of Applied Systems Analysis, 16*(1), 3-9.

Bellinger, G., Castro, D. i Mills, A. (2004). *Data, information, knowledge, and wisdom*. Systems Thinking. https://resources.saylor.org/wwwresources/archived/site/wp-content/uploads/2012/11/BUS206-4.1.1-Data-Information-Knowledge-and-Wisdom.pdf.

Edvinsson, L. (2002). *Corporate longitude: What you need to know to navigate the knowledge economy*. Financial Times Prentice Hall.

Frické, M. (2009). The knowledge pyramid: A critique of the DIKW hierarchy. *Journal of Information Science, 35*(2), 131-142. https://doi.org/10.1177/0165551508094050.

Ioannidis, J. P. A. (2005). Why most published research findings are false. *PLOS Medicine, 2*(8), e124. https://doi.org/10.1371/journal.pmed.0020124.

Kuhn, T. S. (1962). *The structure of scientific revolutions*. University of Chicago Press.

Merton, R. K. (1973). *The sociology of science: Theoretical and empirical investigations*. University of Chicago Press.

Munafò, M. R., Nosek, B. A., Bishop, D. V. M., Button, K. S., Chambers, C. D., Percie du Sert, N., Simonsohn, U., Wagenmakers, E.-J., Ware, J. J. i Ioannidis, J. P. A. (2017). A manifesto for reproducible science. *Nature Human Behaviour, 1*(1), 0021. https://doi.org/10.1038/s41562-016-0021.

Nosek, B. A., Alter, G., Banks, G. C. i sur. (2015). Promoting an open research culture. *Science, 348*(6242), 1422-1425. https://doi.org/10.1126/science.aab2374.

Open Science Collaboration. (2015). Estimating the reproducibility of psychological science. *Science, 349*(6251), aac4716. https://doi.org/10.1126/science.aac4716.

Popper, K. R. (1959). *The logic of scientific discovery*. Hutchinson.

Rowley, J. (2007). The wisdom hierarchy: Representations of the DIKW hierarchy. *Journal of Information Science, 33*(2), 163-180. https://doi.org/10.1177/0165551506070706.

Zeleny, M. (1987). Management support systems: Towards integrated knowledge management. *Human Systems Management, 7*(1), 59-70. https://doi.org/10.3233/HSM-1987-7108.

## Mjerenje, statistika i interpretacija

Gigerenzer, G. (2004). Mindless statistics. *The Journal of Socio-Economics, 33*(5), 587-606. https://doi.org/10.1016/j.socec.2004.09.033.

Simmons, J. P., Nelson, L. D. i Simonsohn, U. (2011). False-positive psychology: Undisclosed flexibility in data collection and analysis allows presenting anything as significant. *Psychological Science, 22*(11), 1359-1366. https://doi.org/10.1177/0956797611417632.

Stevens, S. S. (1946). On the theory of scales of measurement. *Science, 103*(2684), 677-680. https://doi.org/10.1126/science.103.2684.677.

Wasserstein, R. L. i Lazar, N. A. (2016). The ASA statement on p-values: Context, process, and purpose. *The American Statistician, 70*(2), 129-133. https://doi.org/10.1080/00031305.2016.1154108.

## Digitalno okruženje, podaci i etika

Argyle, L. P., Busby, E. C., Fulda, N., Gubler, J. R., Rytting, C. i Wingate, D. (2023). Out of one, many: Using language models to simulate human samples. *Political Analysis, 31*(3), 337-351. https://doi.org/10.1017/pan.2023.2.

Bail, C. A. (2024). Can generative AI improve social science? *Proceedings of the National Academy of Sciences, 121* (21), e2314021121. https://doi.org/10.1073/pnas.2314021121.

Belk, R. W. (1975). Situational variables and consumer behavior. *Journal of Consumer Research, 2*(3), 157-164. https://doi.org/10.1086/208627.

boyd, d. i Crawford, K. (2012). Critical questions for big data: Provocations for a cultural, technological, and scholarly phenomenon. *Information, Communication & Society, 15*(5), 662-679. https://doi.org/10.1080/1369118X.2012.678878.

Bruns, A. (2019). After the 'APIcalypse': Social media platforms and their fight against critical scholarly research. *Information, Communication & Society, 22*(11), 1544-1566. https://doi.org/10.1080/1369118X.2019.1637447.

Couldry, N. i Mejias, U. A. (2019). *The costs of connection: How data is colonizing human life and appropriating it for capitalism*. Stanford University Press.

Dickson, P. R. (1982). Person–situation: Segmentation's missing link. *Journal of Marketing, 46*(4), 56-64. https://doi.org/10.1177/002224298204600407.

Freelon, D. (2018). Computational research in the post-API age. *Political Communication, 35*(4), 665-668. https://doi.org/10.1080/10584609.2018.1477506.

Golder, S. A. i Macy, M. W. (2014). Digital footprints: Opportunities and challenges for online social research. *Annual Review of Sociology, 40*, 129-152. https://doi.org/10.1146/annurev-soc-071913-043145.

Grossmann, I., Feinberg, M., Parker, D. C., Christakis, N. A., Tetlock, P. E. i Cunningham, W. A. (2023). AI and the transformation of social science research. *Science, 380*(6650), 1108-1109. https://doi.org/10.1126/science.adi1778.

Lazer, D., Pentland, A., Adamic, L., Aral, S., Barabási, A.-L., Brewer, D. i sur. (2009). Computational social science. *Science, 323*(5915), 721-723. https://doi.org/10.1126/science.1167742.

Lazer, D. M. J., Pentland, A., Watts, D. J., Aral, S., Athey, S., Contractor, N. i sur. (2020). Computational social science: Obstacles and opportunities. *Science, 369*(6507), 1060-1062. https://doi.org/10.1126/science.aaz8170.

Mark, M. i Pearson, C. S. (2001). *The hero and the outlaw: Building extraordinary brands through the power of archetypes*. McGraw-Hill.

Marwick, A. E. i boyd, d. (2014). Networked privacy: How teenagers negotiate context in social media. *New Media & Society, 16* (7), 1051-1067. https://doi.org/10.1177/1461444814543995.

Messeri, L. i Crockett, M. J. (2024). Artificial intelligence and illusions of understanding in scientific research. *Nature, 627*, 49–58. https://doi.org/10.1038/s41586-024-07146-0.

Nissenbaum, H. (2010). *Privacy in context: Technology, policy, and the integrity of social life*. Stanford University Press.

Salganik, M. J. (2019). *Bit by bit: Social research in the digital age*. Princeton University Press.

Shumailov, I., Shumaylov, Z., Zhao, Y., Papernot, N., Anderson, R. i Gal, Y. (2024). AI models collapse when trained on recursively generated data. *Nature, 631*, 755-759. https://doi.org/10.1038/s41586-024-07566-y.

Tufekci, Z. (2015). Algorithmic harms beyond Facebook and Google: Emergent challenges of computational agency. *Colorado Technology Law Journal, 13*, 203-218.

Van Dijck, J. (2021). Seeing the forest for the trees: Visualizing platformization and its governance. *New Media & Society, 23*(9), 2801-2819. https://doi.org/10.1177/1461444820940293.

Zuboff, S. (2019). *The age of surveillance capitalism: The fight for a human future at the new frontier of power*. PublicAffairs.

## Institucionalni i regulatorni izvori

Europski parlament i Vijeće Europske unije. (2016). *Uredba (EU) 2016/679 Europskog parlamenta i Vijeća od 27. travnja 2016. o zaštiti pojedinaca u vezi s obradom osobnih podataka i o slobodnom kretanju takvih podataka te o stavljanju izvan snage Direktive 95/46/EZ (Opća uredba o zaštiti podataka)*. Službeni list Europske unije, L 119, 1–88. https://eur-lex.europa.eu/eli/reg/2016/679/oj?locale=hr&utm

Europski parlament i Vijeće Europske unije. (2024). *Uredba (EU) 2024/1689 Europskog parlamenta i Vijeća od 13. lipnja 2024. o utvrđivanju usklađenih pravila o umjetnoj inteligenciji i izmjeni određenih zakonodavnih akata Unije (Akt o umjetnoj inteligenciji)*. Službeni list Europske unije, L 2024/1689. https://eur-lex.europa.eu/eli/reg/2024/1689/oj.

Franzke, A. S., Bechmann, A., Zimmer, M., Ess, C. i Association of Internet Researchers. (2020). *Internet research: Ethical guidelines 3.0*. https://aoir.org/reports/ethics3.pdf.

OECD. (2021). *Good practice principles for data ethics in the public sector*. OECD Publishing. https://doi.org/10.1787/caa35b76-en.

# Kazalo pojmova

Kazalo upućuje na poglavlja u kojima se pojam obrađuje, a ne na pojedine stranice — tako ostaje točno bez obzira na prijelom teksta. Definicije ključnih pojmova nalaze se u Prilogu 1.

**A**

algoritamska pristranost pogl. 16, 18

anketa pogl. 7, 9, 13

API, zatvaranje podataka pogl. 10

**B**

bazni indeks pogl. 11

big data / veliki podaci pogl. 10, 13

**C**

citiranje, etika pogl. 20

**D**

datafikacija pogl. 10, 16

digitalni teren pogl. 10

DIKW hijerarhija pogl. 5

**E**

eksperiment pogl. 7, 15

etika istraživanja pogl. 16

EU Akt o umjetnoj inteligenciji pogl. 16

**F**

fokus-grupa pogl. 7, 9

**G**

GDPR pogl. 16

graf znanja pogl. 12

**H**

hipoteza pogl. 2, 3

**I**

indeks, kompozitni pogl. 11

informacija (razina) pogl. 5

instrument pogl. 4

intervju pogl. 7, 9

intuicija pogl. 5

istraživačka pismenost pogl. 20

iluzija razumijevanja pogl. 18

**K**

kompetencije za odlučivanje pogl. 19

KPI pogl. 11

kvalitativni pristup pogl. 8

kvantitativni pristup pogl. 8

**M**

margina pogreške pogl. 14

medijska ekonomija pogl. 11, 18, 21

metodologija pogl. 4

mješovite metode pogl. 8

mudrost (razina) pogl. 5

mjerenje pogl. 6

**N**

nacrt istraživanja pogl. 3

narativ i parcijalna istina pogl. 18

NeedScope pogl. 21

netnografija pogl. 10

**P**

paradigme pogl. 7

podatak (razina) pogl. 5

populacija pogl. 13

pouzdanost pogl. 8

povezanost vs. uzročnost pogl. 15

**R**

računalna analiza podataka pogl. 10

razumijevanje (razina) pogl. 5

refleksivnost pogl. 7, 10

reprezentativnost pogl. 13

**S**

segmentacija vremena pogl. 21

sintetički podaci pogl. 16

skrivena varijabla pogl. 15

statistička značajnost pogl. 14

suštinska značajnost pogl. 14

**T**

triangulacija pogl. 8, 10, 21

tržišna istraživanja pogl. 11, 21

**U**

umjetna inteligencija u istraživanju pogl. 16, 18

uzorak pogl. 13

uzročnost pogl. 15

**V**

valjanost pogl. 8

varijabla pogl. 15

## Z

znanje (razina) pogl. 5

znanstvena čestitost pogl. 20

ISBN 978-953-347-699-5