

METODE ISTRAŽIVANJA U AGROBIOTEHNIČKIM ZNANOSTIMA

Mladen Jurišić • Ivan Plaščak • Dorijan Radočaj • Željko Barač



Sveučilište Josipa Jurja
Strossmayera u Osijeku

Fakultet
agrobiotehničkih
znanosti Osijek



prof. dr. sc. Mladen Jurišić
prof. dr. sc. Ivan Plaščak
doc. dr. sc. Dorijan Radočaj
doc. dr. sc. Željko Barač

METODE ISTRAŽIVANJA U AGROBIOTEHNIČKIM ZNANOSTIMA

Fakultet agrobiotehničkih znanosti Osijek ♦ Osijek, 2026.



Sveučilište Josipa Jurja
Strossmayera u Osijeku

Fakultet
agrobiotehničkih
znanosti Osijek

Izdavač
SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
Fakultet agrobiotehničkih znanosti Osijek

Za izdavača
prof. dr. sc. Tomislav Vinković (dekan)

Autori

prof. dr. sc. Mladen Jurišić
prof. dr. sc. Ivan Plaščak
doc. dr. sc. Dorijan Radočaj
doc. dr. sc. Željko Barač

Tehnički urednici

prof. dr. sc. Ivan Plaščak
doc. dr. sc. Dorijan Radočaj

Recenzenti

prof. dr. sc. Luka Šumanovac, Fakultet agrobiotehničkih znanosti Osijek, Sveučilište J.
J. Strossmayera u Osijeku, Hrvatska
izv. prof. dr. sc. Vjekoslav Tadić, Fakultet agrobiotehničkih znanosti Osijek, Sveučilište
J. J. Strossmayera u Osijeku, Hrvatska
prof. dr. sc. Silvija Šiljeg, Odjel za geografiju, Sveučilište u Zadru, Hrvatska

Lektorica

Ivana Heffer-Rakonić, mag. educ. philol. croat.

Osijek, 2026. godina

Sva prava pridržana. Nijedan dio ovog djela ne smije se reproducirati ni prenositi ni u kojem obliku bez prethodne suglasnosti autora i izdavača. Izvori slika djelo su autora udžbenika. One koje nisu djelo autora udžbenika posebno su označene. CIP zapis je dostupan u nacionalnom skupnom katalogu knjižničnog sustava Bukinet (katalog.bukinet.hr) pod brojem 991006039144409366.

Sveučilište Josipa Juraja Strossmayera u Osijeku



Suglasnost za izdavanje ovog sveučilišnog udžbenika donio je Senat Sveučilišta Josipa Jurja Strossmayera u Osijeku na X. sjednici održanoj XX.XX.2026. godine pod brojem XX/XX.

ISBN 978-953-8421-20-4

RIJEČI ZAHVALE

Zahvalnost dugujem kolegama i stručnjacima iz područja primjene novih metoda i trendova u znanosti, posebno agrobiotehničkim znanostima te geoinformacijskih tehnologija i GIS-a, koji su mi bili koristan poticaj za stručno i znanstveno određenje.

Zahvalnost i poštovanje izražavam recenzentima ovog udžbenika na nesebičnoj pomoći i podršci te vrijednim sugestijama, i to prije svega dugogodišnjem kolegi prof. dr. sc. Luki Šumanovcu i prof.dr.sc. Tomislavu Juriću. Zahvalnost izražavam kolegi izv. prof. dr. sc. Vjekoslavu Tadiću te kolegama sa Fakulteta agrobiotehničkih znanosti u Osijeku.

Posebnu zahvalnost na izuzetno uspješnoj i plodnoj suradnji na području geoinformacijskih tehnologija i GIS-a recenzentici izv. prof. dr. sc. Silviji Šiljeg s Odjela za geografiju Sveučilišta u Zadru.

U pisanju i konceptualiziranju ovog udžbenika, osim koautora, veliku pomoć i podršku imao sam u kolegama, koautorima udžbenika, na području primjene geoinformacijskih tehnologija i GIS-a u agrobiotehničkim znanostima.

prof. dr. sc. Mladen Jurišić

predsjednik katedre za
geoinformacijske tehnologije i GIS

PREDGOVOR

Poštovane kolegice i kolege, dragi prijatelji,

pred Vama je udžbenik objavljen na temu primjene znanstvenih metoda, postupaka i diseminacije rezultata istraživanja općenito, ali s naglaskom na agrobiotehničke i srodne znanosti.

Udžbenik će poslužiti studentima specijalističkih i doktorskih studija, znanstvenicima te istraživačima različitih skupina i usmjerenja, posebno onih agrobiotehničkih na višoj razini. Osobito se to odnosi na poslijediplomsku, specijalističku te doktorsku razinu obrazovanja i znanstvenog diskursa.

Poslužiti će i drugim područjima i poljima gdje se izučava napredna i propulzivna znanost i njeni sofisticirani alati i oprema. Posebni benefit ovim publiciranim djelom vrijede za fakultete, institute i druge institucije kao što su geografija, poljoprivreda, šumarstvo, geodezija, geologija, građevinarstvo i razna interdisciplinarna područja.

Udžbenik ovakvog sadržaja (cjeloviti prikaz povijesti znanosti, znanstvene metode, teorija o znanosti, novi trendovi i pristupi te organizacija istraživanja i prezentacije rezultata i sažeti prikazi materijala i obrazaca potrebnih za stjecanje zvanja nije do sada objavljena na ovakav način i u ovakvom objedinjenom konceptu.

Zajedno s kolegama i bliskim suradnicima prihvatio sam se samostalnog priređivanja udžbenika za navedena područja. Intencija i postavljeni cilj bio je popuniti prazninu s cjelovitim prikazom (na jednom mjestu) na polju visokoškolske izobrazbe i primjene istraživanja uporabom suvremenih metoda, alata i koncepata.

Udžbenik daje opći pregled povijesti znanosti i temeljnih znanstvenih koncepata i premisa. Poseban naglasak postavljen je na opis mnoštva znanstvenih metoda i koncepata te njihovu primjenu u istraživanju i publiciranju rezultata dobivenih istraživanjem.

Vrijedno poglavlje i značajan autorski doprinos nalazi se u poglavlju Razvoj znanosti o tehničkim sustavima u poljoprivredi (agrobiotehničke znanosti) te u poglavlju Suvremene znanstvene metode.

U daljnjem tekstu detaljno je opisana povijest i teorija znanosti (koncepti). Obrađen je i Zakon o autorstvu te Organizacija znanstvenih istraživanja.

U poglavlju Sastavnice znanstvenih i stručnih radova, na priručnički je i jednostavan način dan svojevrsni hodogram kao pomoć i obrazac za korisnike kao vodič na putu do stjecanja željenog zvanja.

Zainteresiranim čitateljima prenosimo veći dio onoga što sam dugi niz godina predavao studentima poljoprivrede, geografije, ekoloških i ekonomskih disciplina te poslijediplomcima na Sveučilištu J. J. Strossmayera u Osijeku i Sveučilištu u Zadru. Ovo se odnosi i na praksu, gdje sam vodio i vodim nekoliko projekata te istraživački tim koji se bavi istraživanjem i promicanjem navedenih i suvremenih metoda u znanosti te novih znanstvenih određenja i trendova.

Cijenimo iznimno važnom činjenicu da će ovaj udžbenik potaknuti mlađe kolege istraživače i znanstvenike na još intenzivnije korištenje ovih naprednih metoda, alata, tehnologija i vrijedne sofisticirane opreme u budućem razdoblju.

prof. dr. sc. Mladen Jurišić

SADRŽAJ

1. UVOD	1
2. POVJESNI RAZVOJ I TEORIJA ZNANOSTI	6
2.1. Znanost o znanosti	7
2.2. Opća teorija sustava	10
2.3. Holistički nazor	14
2.4. Novi pravci u znanosti, metodologiji i pristupu	16
2.5. Prirodni zakoni	21
2.6. Društveni zakoni	25
2.7. Predviđanje budućnosti	26
2.8. Slučaj	27
2.9. Kaos	30
3. ZAKONI O AUTORSTVU	32
4. ZNANSTVENA METODA	37
4.1. Definiranje znanstvenog problema	38
4.2. Postavljanje hipoteze	39
4.2.1. Prirodni fenomen	42
4.2.2. Simulirani fenomen	44
4.2.3. Zamišljeni fenomen (znanstvene priče)	44
4.3. Metodologija znanstvenog rada	47
4.4. Metode znanstvenog istraživanja	50
5. ORGANIZACIJA ZNANSTVENOG ISTRAŽIVANJA	61
5.1. Prikupljanje literature	61
5.2. Definiranje ciljeva i istraživačkih pitanja	67
5.2.1. Operacionalizacija	69
5.3. Oblikovanje i vrste hipoteza	70
5.3.1. Vrste hipoteza	73

5.4. Obrada i analiza podataka.....	75
5.4.1. Osnovni statistički pojmovi i postupci.....	75
5.5. Postupak obrade kvantitativnih podataka	78
5.5.1. Odabir računalnog alata za obradu podataka	79
5.5.2. Unos podataka.....	79
5.5.3. Odabir prikladnih metoda za obradu podataka	80
5.5.4. Interpretacija kvantitativnih nalaza	82
5.5.5. Obrada i analiza kvalitativnih podataka.....	83
5.6. Prikaz rezultata istraživanja.....	84
5.6.1. Tablično prikazivanje podataka	85
5.6.2. Grafičko prikazivanje podataka	86
5.7. Rasprava	86
5.8. Zaključak	87
5.9. Jezik i stil pisanja.....	88
5.10. Navođenje literature i sustav navođenja	90
5.10.1. Izravno navođenje (citiranje)	95
5.10.2. Neizravno navođenje (parafraziranje).....	98
5.10.3. Pisanje bibliografskih jedinica (sastavljanje popisa literature).....	100
6. RAZVOJ ZNANOSTI O TEHNIČKIM SUSTAVIMA U POLJOPRIVREDI	109
6.1. Povijest razvoja znanosti o tehničkim sustavima	109
6.2. Uvod u znanost o tehničkim sustavima u poljoprivredi	111
6.2.1. Znanstveni problem	114
6.2.2. Metode znanstvenog istraživanja	115
6.3. Tehničke upute za pisanje rada.....	121
6.4. Mentorstvo i suradnja	123
6.5. Usmena obrana rada	125
7. SASTAVNICE ZNANSTVENIH I STRUČNIH RADOVA.....	128

7.1. Seminarski rad	137
7.2. Kritički prikaz.....	138
7.3. Završni i diplomski (magistarski) rad.....	139
7.4. Specijalistički poslijediplomski rad.....	140
7.5. Doktorska disertacija	142
7.6. Stručni članak	144
7.7. Znanstveni članak	145
8. SUVREMENE ZNANSTVENE METODE I TRENDVI	148
8.1. Ekspertni računalni sustavi.....	153
8.2. Strojno i duboko učenje.....	157
8.2.1. Nadzirano učenje.....	158
8.2.2. Nenadzirano učenje.....	161
8.2.3. Pojačano učenje	163
8.2.4. Duboko učenje	164
8.2.5. Hibridni pristupi u strojnom učenju	166
8.2.6. Primjena strojnog učenja u agrobiotehničkim znanostima	168
8.3. Računalna vizualizacija i kartografija	172
8.3.1. QGIS	174
8.3.2. Geoprostorna analiza	176
8.3.3. Geostatistika.....	178
8.3.4. Vremenska analiza	181
8.3.5. Interaktivnost	182
9. POPIS LITERATURE.....	185

1. UVOD

Znanost je sistematičan proces istraživanja, proučavanja i razumijevanja prirodnih fenomena, zakonitosti, pojava i procesa u svijetu oko nas. Ona se temelji na kritičkom promišljanju, empirijskom testiranju i logičkom zaključivanju kako bi se steklo znanje o svijetu i razvile teorije koje objašnjavaju prirodu, funkciju i ponašanje objekata ili pojava. Znanost se obično dijeli na različite discipline, a njezin cilj je unaprijediti razumijevanje svijeta i primijeniti to znanje u rješavanju problema, poboljšanju tehnologije i donošenju informiranih odluka.

Znanost se temelji na objektivnom promatranju, eksperimentiranju, analizi podataka i logičkom zaključivanju. Njen je cilj stjecanje novih spoznaja i razumijevanje svijeta oko nas. Kroz sistematičan pristup, znanstvenici razvijaju teorije i modele koji objašnjavaju prirodne i društvene fenomene te omogućuju predviđanje njihovih budućih ponašanja. Znanost je temeljni stup modernog društva jer omogućuje inovacije, tehnološki napredak i donošenje informiranih odluka.

Riječ „znanost“ potječe od latinskog glagola „*scire*“, što znači „znati“ ili „biti svjestan“. Iz ovog korijena, „*scientia*“ označava „znanje“ ili „razumijevanje“. Ovaj izraz postao je središnji pojam za označavanje sustavnog proučavanja prirodnih fenomena, zakonitosti i procesa. Suštinska diferencijacija između pojmova „znanost“ i „nauka“ može predstavljati izazov, a postavlja se pitanje je li takva razlika nužna (Milat, 2005).

U hrvatskom jeziku, cjelokupna ljudska djelatnost vezana uz stjecanje istinitog znanstvenog znanja, sistematizaciju znanja i njegovu provjeru naziva se **znanost** (Baban i sur., 2000). U definiranju pojma znanosti, ključne su komponente znanje, traganje za novim spoznajama te stalna provjera istinitosti znanja. Na razini jezika, korijen termina „nauka“ naglašava učenje, za razliku od „znanost“ koja proizlazi iz pojma znanja.

Važnost odnosa između znanosti, znanstvenih disciplina i znanstvenih doktrina ističe se u znanstvenom metodološkom pristupu kao ključnom putu za stjecanje istinitog znanja. Utemeljenje znanosti leži u znanstvenoj metodi i znanstvenom razmišljanju obuhvaćajući dinamički proces definiranja, sistematizacije i provjere znanja. U kontekstu znanstvenih disciplina, utemeljenje se očituje u predmetu istraživanja, prihvatanju definiranog znanja te trajnom provjerom istinitosti u određenom vremenskom trenutku. „Znanstvena disciplina“ određena je predmetom istraživanja i metodološkom osnovom istraživanja. Određenje nekog posebnog predmeta znanstvenog istraživanja i metodologije istraživanja, na koje presudno utječe sam predmet istraživanja, svakako znači da je određenje predmeta i metoda vrijedno u

nekom vremenskom periodu. Predmet znanstvene discipline i metode traje već duže vrijeme (Mejovšek, 2008. i Simonić, 2001.). Isti autori, a i brojni drugi, navode da se analizom područja znanstvene discipline predmet može mijenjati zbog novih spoznaja, a to može rezultirati primjenom novih metoda istraživanja. Ovakav proces čini znanstvenu disciplinu manje dinamičnom u promjeni metodološke i teorijske osnove u usporedbi s cjelokupnom znanosti. Intenzitet promjena unutar znanstvene discipline znatno je manji od onog u cjelokupnoj znanosti, stoga se znanstvena disciplina često opisuje kao statičniji dio znanosti.

U skladu s prethodnom analizom, **znanstvena disciplina** je specifično područje znanstvenog istraživanja koje se fokusira na proučavanje određenog skupa fenomena, pojava ili zakonitosti unutar određenog područja interesa. Svaka znanstvena disciplina obično ima svoj vlastiti skup teorija, metodologija, terminologije i pristupa istraživanju koji su karakteristični za tu disciplinu. Ona je bitan dio sveukupne znanosti i čini jedan zaokruženi dio znanstvenog područja. Svaka znanstvena disciplina obično se sastoji od poddisciplina ili specijalizacija koje se fokusiraju na specifičnije aspekte tog šireg područja. Na primjer, u području poljoprivrede postoje poddiscipline poput agroekologije, poljoprivredne tehnike, agrokemije, zootehnike, itd. Ključna obilježja znanstvenih disciplina uključuju sustavno pristupanje istraživanju, uporabu empirijskih metoda prikupljanja podataka, provjeru hipoteza i teorija putem testiranja i ponovljivosti eksperimenata, te razvoj teorija koje objašnjavaju i predviđaju opažene fenomene unutar područja interesa.

Znanstvena teorija je sistematično objašnjenje nekog aspekta prirode, fenomena ili procesa, koje se temelji na temeljitom istraživanju, empirijskim podacima, logičkom zaključivanju i testiranju. Teorije u znanosti su najviši stupanj organizacije znanja i obično su potkrijepljene brojnim eksperimentalnim podacima. Znanstvena paradigma, s druge strane, predstavlja dominantni okvir ili model za promatranje i tumačenje fenomena u nekom području znanosti. Ona uključuje osnovna uvjerenja, metode i pristupe istraživanju koji su prihvaćeni u toj znanstvenoj zajednici u određenom razdoblju. Paradigme se mogu mijenjati s vremenom kako znanstveno znanje i razumijevanje napreduju.

Segmentacija znanosti odnosi se na podjelu znanstvenog istraživanja na specifična područja interesa ili discipline, kako bi se omogućilo dublje razumijevanje i proučavanje različitih aspekata prirode ili društva. U kontekstu poljoprivrede, segmentacija znanosti očituje se kroz različite discipline koje istražuju specifične aspekte poljoprivredne proizvodnje i sustava. Primjerice, agronomija se bavi proučavanjem osnovnih principa uzgoja biljaka, uključujući tlo, klimu, uzgoj biljnih kultura i kontrolu štetnika. Fitopatologija se fokusira na proučavanje bolesti

biljaka i metoda zaštite usjeva. Na drugoj strani, zootehnika istražuje uzgoj domaćih životinja, njihovo ponašanje, prehranu i genetiku radi poboljšanja proizvodnje mesa, mlijeka i drugih životinjskih proizvoda. Biotehnologija je važna disciplina koja primjenjuje principe biologije i genetike kako bi se unaprijedili uzgojni procesi i razvili otporniji i produktivniji usjevi i životinje. Agroekonomika istražuje ekonomske aspekte poljoprivredne proizvodnje, uključujući troškove, profitabilnost, tržišta i politike. Ekologija poljoprivrede proučava utjecaj poljoprivrednih praksi na okoliš te razvija strategije održive proizvodnje. Ovi primjeri ilustriraju segmentaciju znanosti u poljoprivredi, gdje svaka disciplina pruža specijalizirano znanje i metode istraživanja kako bi se razumjeli i unaprijedili različiti aspekti poljoprivredne proizvodnje. Integracija ovih disciplina omogućava holistički pristup rješavanju izazova u poljoprivredi, doprinoseći dugoročnoj održivosti i produktivnosti agroekosustava.

Problem pojave rezultata znanstvenog istraživanja, istraživačkog rada i interdisciplinarnog pristupa može biti složen, ali istovremeno i ključan za razvoj znanosti i rješavanje složenih problema. Problem pojave rezultata znanstvenog istraživanja odnosi se na činjenicu da znanstveni rezultati ponekad nisu dostupni široj javnosti ili drugim znanstvenicima. To može biti posljedica ograničenja pristupa zbog plaćenih članaka u znanstvenim časopisima, složenih jezičnih prepreka, nedostatka transparentnosti u istraživačkom procesu ili čak zadržavanja podataka od strane istraživača ili institucija. Ovaj problem može ograničiti mogućnost reprodukcije istraživanja, provjere rezultata i korištenja novih spoznaja za daljnji napredak u znanosti. Istraživački rad može biti izazovan zbog specijalizacije i fragmentacije znanstvenih disciplina. Istraživači koji su duboko ukopani u jednoj disciplini mogu imati poteškoća u razumijevanju širih konteksta i prepoznavanju veza s drugim područjima znanosti. Ovo može dovesti do uskogrudog pristupa problemima i propuštanja potencijalno inovativnih rješenja koja proizlaze iz interakcije različitih disciplina. Interdisciplinarni pristup može biti otežan zbog administrativnih, institucionalnih i kulturnih prepreka. Tradicionalno, znanstveno istraživanje organizirano je po disciplinama, a interdisciplinarni rad zahtijeva suradnju među istraživačima različitih struka i disciplina. To može biti izazovno zbog različitih kultura rada, metodoloških pristupa, terminologije i administrativnih ograničenja. Osim toga, financiranje interdisciplinarnih projekata može biti složenije jer se često financira po disciplinama.

Rješavanje ovih problema zahtijeva promjene u praksi znanstvenog istraživanja. To uključuje otvaranje pristupa znanstvenim podacima, promicanje suradnje među istraživačima iz različitih disciplina, poticanje interdisciplinarnih programa obuke te promicanje kulture otvorenosti,

transparentnosti i dijeljenja znanja. Takvi napori mogu olakšati suradnju i inovacije te pridonijeti rješavanju kompleksnih problema koji zahtijevaju interdisciplinarni pristup.

Proučavanje znanosti kao znanstvene discipline, može se nazvati **Teorija znanosti** ili **Znanstvena metoda**. U skladu s gledištem Simonića (2001.), koji pristupa temi filozofski, znanost se opisuje kao „jedna od najosobnijih od svih humanih stvaranja“ (J. C Eccles).

Zastupanje stavova s uvjerenjem i objektivnošću istovremeno često je težnja mnogih, no organizirano to često čine filozofi i znanstvenici. Ipak, važno je priznati da čak i njihovi učinci nisu uvijek nedvojbeni zbog inherentne krhkosti filozofskih i znanstvenih spoznaja.

Ljudska sklonost subjektivizmu i pridavanje nepoznatom preveliki ili premali značaj čini te spoznaje nesigurnima.

Već odavno raspravlja se o subjektivnosti ljudskog duha, a G. Vico cit. prema Simonić, 2001. je primijetio: „Zbog ograničene prirode ljudskog duha svaki put kada taj duh upadne u neznanje, čovjek postavlja sebe za pravilo svemira.“ Često se pojavljuje i samozadovoljstvo i hvalisanje, kako pojedinaca, znanstvenika, tako i cijelih naroda ili čovječanstva.

Veza između znanosti i ostatka svijeta, temeljena na mehanizmima povratne sprege i interakcije, čini situaciju nešto drugačijom. Ovaj kompleksan odnos trebala bi istražiti sama znanost zbog velikog broja mogućih interakcija. Primjerice, učinci fizikalnih teorija poput relativnosti, kvantne mehanike, fizike elementarnih čestica, atomske fizike, astrofizike i fizike plazme rezultirali su pronalaskom mikroprocesora i elektronskih računala te izazvali značajne promjene u raznim područjima ljudske djelatnosti.

Razvoj znanosti, osim što mijenja svijet oko sebe, bitno mijenja i samu sebe. Ovaj dinamičan proces donosi uske i kompleksne međudnose između znanosti i svih ostalih civilizacijskih događanja, kao i promjena u prirodi. Ernest Renan je još davne 1848. godine (cit. prema Lauc, 2000.) iznio stav u svojoj knjizi „L'Avenir de la Science“, koji potvrđuje aktualnost i danas.

Etimološki, izraz „znanost“ izvire iz riječi „znati“. Znanost obuhvaća opsežno skupljanje znanja. Prema Oxfordskom rječniku, znanost je definirana kao „znanje (*scientia*) ili stanje znanja“. B. Težak pristupa temi tvrdeći da je znanost „zajedničko, koherentno, organizirano i sustavno znanje ljudskog roda“. Kutleša (2013.) dopunjuje tvrdnju da je znanost „izgradnja principa koji omogućuju determinaciju uočljivih činjenica“. U užem smislu, znanost predstavlja organizirani sustav ljudskog znanja stečenog opažanjem procesa i pojava u prirodi i društvu obradom racionalnih, znanstveno prihvatljivih metoda. U ovoj definiciji znanosti ne obuhvaćaju se, primjerice, senzorna saznanja, religijska istina, sirova isključivo osjetilna

spoznaja, filozofsko znanje, umjetnička spoznaja itd. Slijedom toga, empiričari zaključuju: „Znanost je objektivno, sistematsko i argumentirano znanje o zakonitostima, činjenicama, pojavama i njihovim vjerojatnim uzrocima. To znanje je stečeno i provjereno egzaktnim promatranjem, organiziranim eksperimentima i pravilnim razmišljanjem.”

Znanost se strukturira kroz definirane znanstvene discipline, kao što su fizika, kemija, medicina, zemljopis, sociologija, povijest itd. Ove discipline, uključujući njihove poddiscipline poput mehanike, optike, dinamike, statike, fiziologije, mikrobiologije, farmakologije i drugih, čine sistematizirane skupove specifičnih znanja stečenih putem priznatih i relevantnih znanstvenih metoda istraživanja.

2. POVJESNI RAZVOJ I TEORIJA ZNANOSTI

Pojam početka znanosti obično je povezan s različitim kulturama i civilizacijama koje su doprinijele razvoju ranog znanja. Primjerice, drevne civilizacije poput one u Mesopotamiji, Egiptu, Kini, Indiji i Grčkoj imale su svoje sustave znanja koji su obuhvaćali matematiku, astronomiju, medicinu, filozofiju i druge discipline. Ovi rani znanstveni napori obično su bili povezani s potrebama poput poljoprivrede, trgovine, gradnje i religioznih obreda. Međutim, moderna znanost obično se smatra razvojem koji je započeo tijekom europskog renesansnog razdoblja (14.–17. stoljeće) i intenzivirao se tijekom znanstvene revolucije (16.–17. stoljeće). Ovo razdoblje karakterizira nagli napredak u razumijevanju prirodnih zakonitosti, razvoj novih metoda istraživanja poput eksperimenta i promatranja te jačanje kritičkog razmišljanja. Ključne figure poput Galileja, Newtona, Copernicusa i mnogih drugih pridonijele su temeljnim promjenama u načinu na koji ljudi promatraju svijet oko sebe. Tijekom modernog doba, znanost je postala sve više institucionalizirana, s osnivanjem sveučilišta, istraživačkih institucija i znanstvenih časopisa. Ovo je omogućilo sustavnu razmjenu znanja i daljnji napredak u različitim disciplinama znanosti. Razvoj znanosti može se pratiti povijesnim pristupom, pri čemu se analizom ključnih događaja, otkrića i promjena u pristupima razumijevanju svijeta može shvatiti kako je znanost evoluirala kroz različite epohe i kulture.

Proučavanje povijesti znanosti odnosi se na analizu njezina razvoja tijekom vremena identificirajući ključne trenutke, otkrića i promjene koje su oblikovale njezin napredak. Ova disciplina pruža uvid u evoluciju znanja, tehnologije i metodologije koja je dovela do suvremenih znanstvenih disciplina.

Povijesni razvoj znanosti može se podijeliti na nekoliko ključnih faza koje su oblikovale suvremeno shvaćanje znanosti i njezinu primjenu u različitim područjima, uključujući i agrobiotehničke znanosti. Prva faza obuhvaća drevna razdoblja civilizacija poput Sumerana, Egipćana, Kineza i Grka, gdje su počeli procesi sistematičnog promatranja i zapisivanja prirodnih fenomena. Ovo je razdoblje obilježeno ranih oblicima matematike, astronomije, medicine i filozofije koji su postavili temelje za budući razvoj znanosti. U poljoprivredi, ovi drevni narodi razvili su tehnike navodnjavanja, uzgoj biljaka i stočarstvo kako bi zadovoljili svoje potrebe za hranom i resursima. Druga faza obuhvaća srednji vijek i renesansno razdoblje, gdje su ključni događaji poput osnivanja prvih sveučilišta, kao što su ona u Bologni i Oxfordu, omogućili sustavnu organizaciju znanja i razvoj novih disciplina poput anatomije, astronomije i kemije. U ovom razdoblju, poljoprivreda je i dalje bila temeljna aktivnost, a brojna otkrića i

inovacije u poljoprivrednim praksama poboljšale su produktivnost i učinkovitost uzgoja. Treća faza, koja obuhvaća 17. i 18. stoljeće, označena je znanstvenom revolucijom, koja je dovela do fundamentalnih promjena u načinu na koji ljudi razmišljaju o prirodi. Otkrića poput Newtonovih zakona kretanja, Galilejevih opservacija i Keplerovih astronoma temeljito su promijenila naše razumijevanje svemira i postavila temelje moderne znanosti. U poljoprivredi, ovaj period obilježen je razvojem novih tehnika obrade tla, upotrebe gnojiva i selekcije biljnih vrsta radi povećanja prinosa i kvalitete usjeva. Četvrta faza obuhvaća razdoblje industrijske revolucije i 19. stoljeće, gdje su tehnološki napredak i ubrzani znanstveni razvoj omogućili ekspanziju znanosti u različite nove domene. U ovom razdoblju, poljoprivreda je doživjela znatan napredak s uvođenjem strojeva, sintetičkih gnojiva i pesticida, što je dramatično povećalo produktivnost i omogućilo intenziviranje poljoprivredne proizvodnje. Posljednja faza obuhvaća 20. i 21. stoljeće, gdje su znanstveni napredak i tehnološka inovacija doveli do daljnjeg produbljivanja i proširenja znanstvenih disciplina. Interdisciplinarni pristupi postali su sve važniji za rješavanje složenih problema, uključujući one u poljoprivredi, poput održivog upravljanja resursima, zaštite okoliša i prilagodbe klimatskim promjenama.

Metode u znanosti evoluirale su od jednostavnog opažanja i razmišljanja do sofisticiranih eksperimenata, statističke analize i računalnog modeliranja. Znanstvena zajednica danas djeluje prema jasnim etičkim smjernicama i međunarodnim standardima kako bi osigurala kvalitetu i integritet znanstvenog istraživanja.

2.1. Znanost o znanosti

Empirijski i racionalni pristup su dva ključna stupa znanstvene metodologije koji se koriste za stjecanje znanja i razumijevanje prirodnih fenomena. Empirijski pristup znanosti temelji se na prikupljanju podataka iz opažanja i eksperimenata. Ovaj pristup podrazumijeva da se znanje stječe putem iskustva i osjetilnih opažanja svijeta oko nas. Osnovna ideja je da se fenomeni mogu promatrati, opisati i kvantificirati kako bi se izvukli zaključci o njihovim uzrocima i svojstvima. Empirijski pristup podrazumijeva korištenje različitih metoda istraživanja kako bi se prikupili relevantni podaci, koji se potom analiziraju i interpretiraju kako bi se donijele zaključci. Primjeri empirijskih metoda uključuju eksperimente, opservacijske studije, ankete i opažanja u stvarnom svijetu. S druge strane, racionalni pristup znanosti koristi logičko razmišljanje, analitičke vještine i argumentaciju kako bi se izgradile teorije i objašnjenja. Ovaj pristup podrazumijeva korištenje razuma, logike i matematike kako bi se razvili modeli i teorije koji opisuju prirodne fenomene. Ključni element racionalnog pristupa je sposobnost izvođenja

zaključaka iz prethodno prikupljenih podataka i pretpostavki. Znanstvenici koriste deduktivno i induktivno razmišljanje kako bi formirali hipoteze, predviđali rezultate eksperimenata i provjeravali njihovu valjanost.

Empirijski i racionalni pristup često se međusobno nadopunjuju u znanstvenom istraživanju. Empirijski podaci pružaju osnovu za provjeru teorija i razvoj novih koncepta, dok racionalno razmišljanje omogućuje interpretaciju rezultata eksperimenata i izvođenje općenitih zaključaka. Kombinacija ova dva pristupa omogućuje razvoj pouzdanog i temeljitog znanja o prirodi i svijetu koji nas okružuje.

Znanstvena metoda koja omogućuje stjecanje i sintezu pouzdanih, provjerljivih i relevantnih spoznaja, temelji se na tri ključna metodološka pristupa proizašla iz filozofskih pravaca poznatih kao empirizam, racionalizam i skepticizam. Empirijski temelj znanstvene metode uvodi ograničenja na znanje i pripadajuće dokaze koji su prihvatljivi. Zahtjev da sva znanja i dokazi u znanosti moraju biti ponovljivi, osigurava provjerljivost, čime se sve svodi na iskustvena, empirička znanja i dokaze. Empirički dokazi obuhvaćaju sve što se može osjetiti osjetilima, poput viđenja, slušanja, dodira, okusa ili mirisa ili posredno izmjeriti te time potvrditi i kvantificirati. Ostali podaci koji se koriste u drugim društvenim aktivnostima, ali ne i u znanosti, uključuju svjedočenja, glasine, dojmove paranormalnih ili duhovnih događanja, emocionalne događaje i njihove refleksije, izraze nadahnuća te božanskih ili nadnaravnih događanja. Pojam empiričkih dokaza ponekad se smanjuje na pojam prirodnih dokaza, definiranih u naturalizmu kao filozofiji prirode.

Poseban tip dokaza u znanosti, često korišten u obrazovanju i društvenom životu, su autoritarni dokazi. Primjena autoritarnih dokaza u znanosti predstavlja ključni razlog postojanja znanstvenog skepticizma, pri čemu su autoritarni dokazi obrazovanja najčešće korišteni.

Povijesno gledano, logika je imala ključnu ulogu u razvoju znanosti. U antičkoj Grčkoj, filozofi poput Aristotela razvijali su logičke sisteme koji su oblikovali temelje zapadne misli i znanosti. Aristotelova logika, posebno njegova deduktivna metoda zaključivanja, imala je dubok utjecaj na kasniji razvoj znanstvene metodologije. Logika u perspektivi znanosti predstavlja temeljnu metodologiju koja se koristi u procesu razumijevanja, analiziranja i zaključivanja o prirodnim fenomenima. Logika omogućava znanstvenicima da primjenjuju sustavno i kritičko razmišljanje kako bi izvodili zaključke na temelju dostupnih podataka, teorija i pretpostavki. U znanosti, logika se koristi kako bi se izgradile argumentacije, formirale hipoteze, testirale teorije i izvodili zaključci iz rezultata istraživanja. Ključni elementi logike u znanosti uključuju deduktivno i induktivno razmišljanje.

Deduktivno razmišljanje podrazumijeva izvođenje specifičnih zaključaka iz općih pretpostavki. To znači da, ako su pretpostavke istinite, onda su i zaključci nužno istiniti. Na primjer, u znanstvenom istraživanju, znanstvenik može izvesti hipotezu iz teorijskog okvira i pretpostavki te provjeriti njezinu valjanost eksperimentalnim testiranjem. Induktivno razmišljanje, s druge strane, podrazumijeva izvođenje općih zaključaka iz specifičnih opažanja. To znači da znanstvenik izvlači zaključke ili formuliра općenite zakone na temelju ponovljenih i konzistentnih opažanja u empirijskim istraživanjima. Na primjer, ako su svi dosadašnji opaženi primjeri nekog fenomena bili u skladu s određenim zakonom, znanstvenik može induktivno zaključiti da će se taj zakon primjenjivati i na buduće situacije.

Filozofski doprinos racionalizma znanstvenoj metodi manifestira se kroz ključni alat za formiranje znanstvenog razmišljanja - logiku. Filozofija skepticizma, temelj znanstvene metode, implicira opću sumnju u svako stečeno znanje, ali i u sposobnost stjecanja apsolutno istinitog i apsolutno neistinitog, znanja. Znanstveni skepticizam predstavlja pristup koji se temelji na kritičkom promišljanju i sumnji prema tvrdnjama i idejama dok se ne dobiju empirijski dokazi koji ih potvrđuju. U suštini, znanstveni skepticizam potiče na zdravu sumnju i otvorenost prema novim informacijama, te potiče znanstvenike da izazivaju pretpostavke, teorije i zaključke kako bi osigurali njihovu valjanost i pouzdanost. Znanstveni skepticizam igra važnu ulogu u znanstvenom istraživanju jer potiče na provjeru i ponovljivost eksperimenata te na postavljanje preciznih pitanja o prirodi stvarnosti. On potiče na propitkivanje autoriteta, tradicije i predrasuda, potičući znanstvenike da budu otvoreni prema različitim interpretacijama podataka i mogućim alternativnim objašnjenjima. Kroz povijest znanosti, znanstveni skepticizam često je bio pokretač napretka i inovacija. Kritičko propitivanje i sumnja prema uvriježenim idejama potiču na daljnje istraživanje, reviziju teorija i razvoj novih paradigmi. Stoga, znanstveni skepticizam nije suprotstavljen znanstvenom napretku, već je njegov sastavni dio koji osigurava rigoroznost, pouzdanost i istinitost znanstvenog znanja.

Potreba za sustavnim proučavanjem znanosti dovela je do stvaranja discipline koja se bavi samom znanstvenom praksom nazvane „**Znanost o znanosti**“. Ova disciplina još uvijek nije u potpunosti definirala svoju teoriju i metode ostajući stoga znanstvenom disciplinom u razvoju. Disciplinama koje analiziraju znanost, poput povijesti znanosti, filozofije znanosti, sociologije znanosti, psihologije znanosti, ekonomike znanosti i metodologije znanosti bilo je potrebno vrijeme da se usklađuju u koherentan sustav. Povijest znanosti bilježi evoluciju ljudskog razmišljanja kroz prizmu praktičnih i znanstvenih djelatnosti, dok teorija znanosti adresira

različite probleme uključujući one teorijske filozofije, prirodnih znanosti te društvenih i životnih aspekata. Ova podjela unutar 'Znanosti o znanosti' ukazuje na sintezu znanosti kao osnove teorije znanosti kroz povijest znanosti.

2.2. Opća teorija sustava

„Govor o konačnoj teoriji izgleda da ljuti neke filozofe i znanstvenike. Mogu vas optužiti za nešto ružno, poput redukcionizma ili čak fizikalnog imperijalizma. To je djelomično reakcija na razne glupe stvari koje bi mogle biti promišljane konačnom teorijom. Primjerice, da bi otkriće konačne teorije u fizici moglo označiti kraj znanosti. Naravno da finalna teorija neće dokinuti znanstveno istraživanje, niti čistu znanost, niti čak čistu znanost u fizici. Prekrasni fenomeni, od turbulentnosti do misaonost, i dalje će tražiti tumačenje je li konačna teorija pronađena. Otkriće konačne teorije u fizici čak neće značajno pomoći u razumijevanju tih fenomena (premda bi moglo djelomično). Konačna teorija će biti finalna u samo jednom smislu: dokinut će samo jednu vrstu znanosti, drevno traženje onih principa koji se ne mogu rastumačiti dubljim principima“ (Weinberg, St. 1994., kojeg citira Simonić, 2001.)

Povijest znanosti proizlazi kao organski rast iz odnosa između čovjeka i prirode. Tijekom svog razvoja znanost rijetko direktno odbacuje prethodne hipoteze i zakone; umjesto toga, širi se i razvija mijenjajući se i obogaćujući (Vujević, 2000). Nije moguće općenito tvrditi da je stara znanstvena teorija nužno bila pogrešna, a nova nužno istinita niti je znanstveni napredak isključivo slijed uzastopnih otkrića gdje svaka nova zakonitost i teorija mehanički zamjenjuje prethodnu. Svaka kulturološka cjelina ima vlastitu misaonu strukturu tijekom povijesti, što rezultira hipotezama i stavovima koji su odgovarali tom vremenu i okolišu, stoga su mnogi čimbenici, koji su bili značajni za znanstvenike u prošlim kulturama, možda nevažni u suvremenom kontekstu i obrnuto. Razvoj znanosti pokazuje unutarnju nužnost i pravilnost koja se očituje u formiranju glavnih znanstvenih sustava prilagođenih određenom kulturološkom okruženju, iz kojih ponekad iskaču pojedinci znanstvenici.

Opća teorija sustava igra ključnu ulogu u agrobiotehničkim znanostima kao sveobuhvatan okvir za razumijevanje složenih interakcija unutar poljoprivrednih ekosustava. Ova teorija pruža znanstvenicima alate i koncepte za analizu poljoprivrednih sustava kao cjelina, uzimajući u obzir različite komponente i njihove međudnose. Agrobiotehnički sustavi uključuju biljke, tlo, vodu, klimatske čimbenike, kao i različite biološke organizme poput korova, štetnika i korisnih insekata. Opća teorija sustava omogućuje znanstvenicima da prouče kako ovi elementi međusobno djeluju i kako se promjene u jednom dijelu sustava mogu odraziti na ostatak

ekosustava. Primjenom opće teorije sustava, znanstvenici mogu identificirati složene uzročno-posljedične veze unutar poljoprivrednih sustava te razviti strategije za optimizaciju proizvodnje uz istovremeno očuvanje okoliša i resursa. Na primjer, korištenje integrirane poljoprivrede ili održivih poljoprivrednih praksi može biti rezultat primjene opće teorije sustava, koja promiče holistički pristup rješavanju problema u poljoprivredi. Opća teorija sustava također omogućuje znanstvenicima da identificiraju obrasce i trendove unutar poljoprivrednih sustava, kao i da predviđaju njihov budući razvoj. Kroz interdisciplinarni pristup koji promovira opća teorija sustava, znanstvenici mogu bolje razumjeti kompleksne dinamike poljoprivrednih ekosustava te razviti inovativne pristupe za poboljšanje produktivnosti, održivosti i otpornosti na promjene u okolišu.

Napredak znanosti može se promatrati kao kontinuirano stvaranje novih pojedinačnih spoznaja koje, kada se združe, doprinose cjelovitom razumijevanju svijeta, stoga mnogi zagovaraju sintetičko korištenje znanstvenih i metafizičkih spoznaja, što bi omogućilo novo filozofsko razmatranje svijeta povezano s dimenzijama svemira, a neraskidivo povezano s razumijevanjem svjesnosti.

Sastavni dijelovi tumače se obzirom na njihove interakcije u okviru cjeline, a ne obratno. Sustavom se naziva:

- skup čimbenika sjedinjenih principima uzajamne interakcije (svemir, biće, atom, stanica);
- skup elemenata koji sačinjavaju cjelinu unutar koje se obnašaju određene aktivnosti;
- formalnu shemu koja sređuje elemente (npr. decimalni sustav, periodični sustav elemenata);

Veze među dijelovima sustava mogu biti materijalne (npr. hormonske ili neurotransitorske veze među neuronima), energetske (između električne centrale i stroja za pranje rublja) i informacijske.

Sustav je sastavljen od većeg ili manjeg broja sastavnica, više ili manje je otvoren prema okolini (ako je proučavanje dovoljno iscrpno niti jedan sustav nije zatvoren) te je o njoj u različitoj mjeri ovisan. Sustav može biti više ili manje statičan ili dinamičan.

Statični sustavi često su autonomni i u stanju ekvilibrija – poput kristala ili deoksiribonukleinske kiseline (DNK) (koja služi kao pohrana nasljednog znanja). Statičnost im je često ovisna o principima kvantne matematike.

Dinamički sustavi stalno se mijenjaju pa im je stabilnost dinamična. Zahtijevaju interakciju s okolinom, toplinu u slučaju konvekcije te toplinu ili neki drugi oblik energije i negentropiju u organskom slučaju. Oba su slučajeve disipativnih struktura udaljenih od stacionarnog stanja te rasipaju energiju.

Stacionarno stanje postižu u situaciji najmanje potencijalne energije i najmanje konzumacije energije. Nelinearni disipativni sustavi često su kaotični, živi sustavi koji zahtijevaju veliku količinu energije kako bi održali životne funkcije i udaljili se od stacionarnog stanja i visoke entropije.

Klasična znanost postigla je značajan uspjeh afirmirajući princip da se cjelina može razumjeti analizom njezinih sastavnica, s obzirom na to da sastavnice u potpunosti određuju kvalitetu cjeline. Ova filozofija bila je ključna u postignućima kao što su atomska teorija, kvantna mehanika i molekularna biologija.

Budućnost znanosti ukazuje na kinematičke osobine elementarnih čestica i njihovo kretanje. Sile postaju pomoćna sredstva koja omogućuju pokretanje djelića unutar cjeline. Smatra se da se cijeli svijet temelji na kretanju elementarnih čestica, a odgovori na postojeće probleme traže se u kinematici. Primjerice, kretanje plinovitih ili tekućih čestica objašnjava fenomene kao što su tlak, strujanje, provođenje, konvekcija, toplina itd.


S obzirom na to da kompleksni sustavi uključuju dijelove s raznolikim položajima i kretanjem, razvijaju se nove izvedenice koje imaju svoju strukturu i osobitosti. To omogućava fizičarima razlikovanje između jednostavnih i složenih distribucija sastavnica unutar izvedenica. Jednostavne su distribucije pravilne i prisutne su u plinovima, tekućinama i krutim fizikalnim sustavima.

Složene distribucije često su nepravilne, iako se u mnogim biološkim sustavima pridržavaju poznatih zakonitosti, stoga su nazvane *organiziranim*. Fizikalno-kemijski procesi, poput onih u DNK, omogućuju umnožavanje na način koji se bitno razlikuje od umnožavanja kristala u hiperkoncentriranoj otopini ili kod umnožavanja konstrukcija računala.

Rezultati uključuju različite vrste čelika s ključnim značajem za tehnologiju, materijale s efektom pamćenja oblika koji se vraćaju u prvotni položaj nakon zagrijavanja pa sve do polutekućih kristala koji osjetljivo reagiraju na promjene temperature i električnog polja te snježnih pahuljica koje zadržavaju heksagonalnu strukturu unatoč promjenama u izgledu ovisno o vlažnosti i temperaturi, itd.

Kristali s minimalnom energijom smatraju se stabilnima. No, otvara se pitanje dinamike kompleksnog sustava koji se stalno mora boriti protiv kaosa, kako to opisuje Waldrop, 1995. „Kompleksnost leži na granici reda i kaosa”.

Trenutno ne postoji teorija koja može potpuno tumačiti cjelokupni svijet. Neki sanjaju o takvoj sveobuhvatnoj teoriji, poznatoj kao „teorija svega” ili „konačna teorija”. Jedan od prvih znanstvenika koji je sanjao o tome bio je hrvatski znanstvenik Ruđer Bošković (Slika 1), koji je još 1757. predložio ujedinjenje tadašnjeg znanja fizike (uključujući Newtonove zakone gravitacije sa silama koje drže hipotetske subatomske čestice zajedno) u jedinstvenu i temeljnu teoriju sile. Kako je rekao J. D. Barrow, „To je bila prva znanstvena teorija sveobuhvatnosti.”. Prema istom izvoru, mnogi vizionari takvog kalibra ostvarili su značajne proboje u nepoznatom pridonoseći napretku znanosti, filozofije te umjetnosti. Neki od tih vizionara uključuju Pierre-Simona de Laplacea, strastvenog znanstvenog progresista iz 19. stoljeća, Michaela Faradaya, lorda Kelvina, Ludwiga Boltzmann, Jamesa Clarka Maxwella, Arthura Stanleya Eddingtona, Alberta Einsteina, Erwina Schrödingera, Stephena Williama Hawkinga i mnoge druge.



Slika 1. Ruđer Bošković (<https://metkovic-news.com/news/zracna-luka-dubrovnik-od-danas-nosi-ime-znanstvenika-i-filozofa-rudera-boskovica/>)

Pokušaji stvaranja opće teorije koja bi objedinila kvantnu teoriju, teoriju relativiteta i četiri temeljne sile (gravitacija, elektromagnetizam, jake i slabe sile) predstavljaju izazov koji je do sada izmakao većini poznatih suvremenih teoretskih fizičara. Ovaj napor, koji seže od pokušaja Alberta Einsteina da poveže gravitaciju i elektromagnetizam do doprinosa Hermanna Weyla, dobio je oblik „teorije standardne mjere“ formulirane od strane Chen Ning Yanga i Roberta L.

Millsa. Kroz daljnji razvoj i primjenu ova teorija postala je važno matematičko oruđe u proučavanju elementarnih čestica, čime se uspješno objedinjuju i jake sile.

Unatoč tvrdnjama redukcionista, prihvaćanje fizikalno-kemijskih temelja biološkog svijeta ne znači automatski mogućnost stvaranja života putem fizike i kemije. Ovi redukcionistički pristupi, iako nasljednici redukcionizma, nisu nužno zagovornici konstruktivizma.


Stephen Hawking ističe „da bi potpuna predvidljivost budućnosti dovela do situacije u kojoj su sve naše odluke unaprijed poznate, što bi bitno promijenilo naše razmišljanje i ponašanje“. Ova ideja postavlja izazov pred „sveopću teoriju“ i postavlja pitanje tko će procijeniti njezinu ispravnost i istinitost. Mnogi znanstvenici, poput Jacquesa Luciena Monoda i J. Duprea, izražavaju sumnju u mogućnost postojanja sveobuhvatne jedinstvene znanstvene teorije. Oni se suprotstavljaju vjerovanju znanstvenika da je znanost homogena cjelina, proglašavajući to vjerovanje metafizičkom spekulacijom koja izmiče znanstvenoj provjeri. Dupre tvrdi da znanost nije i neće biti ujedinjeni homogeni sustav, a redukcionističke stavove o hijerarhijskom klasificiranju svijeta smatra neispravnima. On naglašava da je znanost labav i heterogen skup različitih istraživanja s različitim stupnjem uspjeha. Dupre podržava ideju sjedinjavanja znanosti kroz povezivanje do tada odvojenih dijelova, ali istovremeno upozorava na opasnost od pokušaja svodjenja sveukupne znanosti na jednu sveobuhvatnu teoriju, što uspoređuje sa scijentizmom, utopijom ili totalitarizmom. On naglašava da možda nije moguće u potpunosti definirati ili spoznati najnižu, bazičnu razinu svijeta. Ova ambivalentnost odražava se i među današnjim znanstvenicima koji, iako odbacuju praktičnu primjenjivost redukcionističkih postavki, koriste njihove dijelove kako bi smirili vlastite nedoumice o ograničenjima znanstvenog promišljanja (Dupre, 2023).

2.3. Holistički nazor

Holistički pristup predstavlja filozofiju koja naglašava važnost promatranja sustava kao cjeline, umjesto pojedinačnih dijelova. Ovaj pristup proizlazi iz potrebe da se shvati složenost interakcija unutar prirodnih i društvenih sustava te da se istakne povezanost između različitih elemenata koji čine cjelinu. Principi holističkog pristupa uključuju povezanost, složenost, interdisciplinarnost i emergentna svojstva. Nastanak holističkog nazora može se pratiti kroz različita područja znanosti i filozofije. Različiti filozofi i znanstvenici tijekom povijesti istraživali su ideje koje podržavaju holistički pristup, od drevnih kultura do modernih teorija sustava. Međutim, razvoj holističkog pristupa doživio je poseban zamah u suvremeno doba kroz različite znanstvene discipline, uključujući sustavnu biologiju, ekologiju, sociologiju i sustavno

upravljanje. Ovi napori doprinose boljem razumijevanju složenih sustava u prirodi, društvu i tehnologiji te potiču primjenu holističkog pristupa u rješavanju izazova suvremenog svijeta.

Holistička teorija pomaže razumjeti svemir, a bez nje bi bilo teško objasniti „učinak leptira“ Edwarda Lorenza koji opisuje vezu između leptirovog lepršanja krilima na jednom kontinentu i pojave tornada na drugom (Slika 2). Ovaj pristup suprotan je redukcionističkom gledištu svijeta koje se temelji na materijalističkim i kartezijanskim principima. Redukcionistički pristup svijet vidi kao skup malenih objekata, poput pojedinačnih stanica, atoma itd., a njihovim zbrajanjem nastaje doživljaj sveukupnog svijeta. Iako je kartezijanska tradicija, koja se oslanja na analitička i matematička tumačenja stvarnosti, postigla fascinantne uspjehe u znanosti, mnogi smatraju da ima svoja ograničenja.



Slika 2. Učinak leptira (<https://www.nbcnews.com/id/wbna45727263>)

Holistički nazor u agrobiotehničkim znanostima predstavlja pristup koji promatra poljoprivredne sustave kao kompleksne i integrirane cjeline, a ne samo kao zbirku pojedinačnih dijelova ili komponenata. Ovaj pristup prepoznaje da su biljke, tlo, mikroorganizmi, klima, voda, životinje i ljudi međusobno povezani i da njihovi međusobni odnosi oblikuju dinamiku cijelog agroekosustava. U ovom holističkom pristupu, agrobiotehnički znanstvenici promatraju poljoprivredne sustave kao kompleksne mreže interakcija koje uključuju biološke, kemijske, fizičke, ekonomske i društvene čimbenike. Umjesto da se fokusiraju samo na pojedinačne aspekte proizvodnje, poput povećanja prinosa ili suzbijanja štetnika, holistički pristup uključuje

promatranje i razumijevanje svih faktora koji utječu na održivost i produktivnost poljoprivrednih sustava.

Primjenom holističkog pristupa, agrobiotehnički znanstvenici razvijaju strategije koje uzimaju u obzir kompleksnost poljoprivrednih sustava. To može uključivati integrirani pristup upravljanju štetnicima, održivim metodama gnojidbe i upravljanju vodom, kao i promicanje biodiverziteta i zaštite okoliša. Osim toga, holistički pristup potiče suradnju između različitih struka i dionika kako bi se razvile sveobuhvatne strategije koje uzimaju u obzir različite interese i potrebe poljoprivrednika, lokalne zajednice i okoliša. Kroz primjenu holističkog pristupa, agrobiotehnički znanstvenici teže ostvariti održivu proizvodnju hrane koja osigurava visoku razinu produktivnosti, ekonomsku profitabilnost i očuvanje prirodnih resursa. Ovaj nazor naglašava važnost sagledavanja poljoprivrednih sustava u njihovoj cjelini kako bi se razumjele kompleksne interakcije i postigla ravnoteža između produktivnosti, ekonomskih ciljeva i očuvanja okoliša.

2.4. Novi pravci u znanosti, metodologiji i pristupu

Razvoj znanstvenih metoda i pravaca u znanosti kontinuirano se odvija kako bi se odgovorilo na nove izazove i pitanja tehnoloških, društvenih, i prirodnih znanosti.

Dano je nekoliko suvremenih pravaca i razvoja znanstvenih metoda:

- Interdisciplinarnost - sve više znanstvenika radi na projektima koji spajaju različite discipline. Interdisciplinarni pristup omogućuje bolje razumijevanje složenih sustava i problema.
- Biotehnologija i genomika - napredak u biotehnologiji omogućuje manipulaciju genima i stvaranje genetski modificiranih organizama. Genomika proučava kompletni genetski materijal organizama otvarajući put razumijevanju genetske osnove bolesti i razvoju novih terapija.
- Umjetna inteligencija (AI) i strojno učenje - transformiraju način na koji znanstvenici analiziraju podatke, modeliraju složene sustave te obavljaju predviđanja. Ovo se posebno ističe u područjima poput medicine, fizike i ekologije.
- Kvantno računarstvo - razvoj kvantnog računarstva obećava revoluciju u računalnom modeliranju i rješavanju složenih problema koji su izazovni za klasične računalne sustave.
- Nanotehnologija - manipulacija materijalima na nano razini omogućuje razvoj novih materijala i uređaja s jedinstvenim svojstvima. To se koristi u područjima poput medicine, elektronike i energetike.

- *Big Data* i analitika – znanstvenici sve više koriste tehnike analitike podataka kako bi izvukli korisne informacije i identificirali obrasce.
- Održivost i ekološka znanost - fokus na održivosti potiče istraživanje obnovljivih izvora energije, upravljanje otpadom i prilagodbu na klimatske promjene.
- Znanost o mozgu - intenzivna istraživanja znanosti o mozgu doprinose boljem razumijevanju neuroloških poremećaja, kognitivnih funkcija i razvoja terapija za mentalne bolesti.
- Znanost o svemiru - svemirska istraživanja otkrivaju nove informacije o nastanku svemira, planeta i potencijalnom životu izvan Zemlje.
- Reproducibilnost i transparentnost - povećan naglasak na osiguranju reproducibilnosti znanstvenih istraživanja kako bi se osigurala valjanost rezultata.).

Svi ovi pravci ukazuju na dinamičnost i rastuću kompleksnost suvremene znanosti, pri čemu inovacije u metodama i tehnologijama igraju ključnu ulogu u postizanju novih otkrića.

Znanstveno-metodološki trendovi evoluiraju kako bi odgovorili na suvremene izazove i integrirali nove tehnologije. Dano je nekoliko ključnih trendova i metoda u znanstvenoj metodologiji:

- Otvorena znanost - postoji snažan naglasak na otvorenosti u znanstvenom istraživanju, što uključuje dijeljenje podataka, rezultata istraživanja i istraživačkih alata. Cilj je poboljšati transparentnost, reproducibilnost i suradnju među znanstvenicima.
- Prediktivna analitika i umjetna inteligencija (AI) - korištenje naprednih analitičkih metoda i algoritama strojnog učenja za analizu velikih skupova podataka kako bi se identificirali uzorci, predviđali budući događaji i donosili informirani zaključci.
- Citiranje podataka - unapređenje prakse citiranja podataka kako bi se priznala važnost podataka kao ključnog resursa u znanstvenim istraživanjima.
- Metode istraživanja s otvorenim kodom - korištenje otvorenog koda u znanstvenim istraživanjima omogućava drugima da pregledaju, reproduciraju i prilagode postojeće kodove. To potiče suradnju i transparentnost.
- Sistematski pregledi i meta-analize - kombiniranje rezultata više istraživanja kako bi se dobila cjelovitija slika o nekom pitanju. Sistematski pregledi literature i meta-analize pomažu u sumiranju postojećih saznanja.
- Inovacije u istraživačkim instrumentima - razvoj naprednih alata, senzora i mjernih uređaja koji omogućuju preciznija i sveobuhvatnija znanstvena mjerenja.
- *Crowdsourcing* u znanstvenom istraživanju - uključivanje šire javnosti u prikupljanje

podataka ili rješavanje znanstvenih problema putem internetskog *crowdsourcinga*.

- Eksperimentalni dizajn i statistička analiza - postavljanje preciznih eksperimenata s kontroliranim varijablama i korištenje naprednih statističkih metoda za interpretaciju rezultata.
- Multidisciplinarni pristupi - povezivanje različitih disciplina kako bi se dobile sveobuhvatnije slike i bolje razumjelo složene sustave.
- Inovacije u komunikaciji znanstvenih rezultata - korištenje vizualizacija podataka, interaktivnih medija i novih načina komunikacije kako bi se znanstveni rezultati učinili pristupačnijima i razumljivijima široj publici.

Ovi trendovi ukazuju na dinamičnost i promjene u načinu na koji se znanstvena istraživanja provode, analiziraju i komuniciraju u suvremenom okruženju.

Suvremeni pravci razvoja znanstvenih metoda odražavaju dinamičan karakter znanstvenog istraživanja i tehnoloških inovacija. Evo nekoliko ključnih suvremenih pravaca:

Primjena novih inovativnih metoda i postupaka u znanosti ima širok spektar učinaka i doprinosi napretku u različitim područjima. Dano je nekoliko primjera:

- **Znanstvena istraživanja**
 - Napredna analitika podataka - korištenje naprednih tehnika analize podataka, poput strojnog učenja, omogućuje znanstvenicima otkrivanje uzoraka i veza u velikim skupovima podataka koje bi bilo teško identificirati konvencionalno.
 - Genomska istraživanja - razvoj novih tehnologija za sekvenciranje genoma omogućuje brže i jeftinije analize genetskog materijala, što pomaže u razumijevanju genetskih temelja bolesti i razvoju personalizirane medicine.
- **Medicinska istraživanja**
 - Napredne terapije - razvoj inovativnih metoda liječenja, poput terapije genskom terapijom, imunoterapije i regenerativne medicine, otvara nove mogućnosti za tretiranje bolesti na molekularnoj i staničnoj razini.
 - Telemedicina - korištenje informacijske tehnologije za pružanje medicinskih usluga na daljinu omogućuje pacijentima pristup bržoj i učinkovitijoj skrbi, posebice u udaljenim ili teško dostupnim područjima.
- **Inženjering i tehnologija**
 - Napredna proizvodnja - primjena 3D ispisa, umjetne inteligencije i drugih inovacija u proizvodnji omogućuje brže prototipiranje i prilagodbu proizvoda prema specifičnim potrebama.

- Kvantno računarstvo - razvoj kvantnih računala može značajno ubrzati rješavanje kompleksnih problema u područjima poput kemije, materijala i financija.
- Energetska učinkovitost
 - Obnovljivi izvori energije - razvoj inovativnih metoda za povećanje učinkovitosti i smanjenje troškova obnovljivih izvora energije pridonosi održivoj energetskej budućnosti.
 - Pametne mreže - integracija informacijske tehnologije u energetske mreže omogućuje bolje upravljanje potrošnjom energije, smanjenje gubitaka i optimizaciju distribucije.
- Okolišna istraživanja
 - Senzorske tehnologije - korištenje naprednih senzorskih tehnologija omogućuje precizno praćenje okoliša, proučavanje klimatskih promjena i identifikaciju izvora onečišćenja.

Strojno učenje (engl. *machine learning*, ML) grana je umjetne inteligencije koja se bavi razvojem algoritama i modela koji omogućuju računalima da uče iz podataka. Osnovna ideja iza strojnog učenja je da sustav može automatski poboljšavati svoje performanse bez izravne ljudske intervencije.

Postoje četiri glavne vrste učenja u okviru strojnog učenja:

- ***Nadzirano učenje (Supervised Learning)***: algoritam se trenira na označenim podacima, gdje su ulazi (značajke) povezani s odgovarajućim izlazima (oznake ili ciljevi). Cilj je naučiti računalo mapiranje između ulaza i izlaza, kako bi se moglo predviđati izlaz za nove, neviđene ulaze.
- ***Nenadzirano učenje (Unsupervised Learning)***: algoritam radi s neoznačenim podacima, gdje nema unaprijed definiranih izlaza. Cilj je pronaći obrasce ili strukturu u podacima, kao što su grupe sličnih podataka (klastiranje) ili smanjenje dimenzionalnosti.
- ***Polunadzirano učenje (Semi-Supervised Learning)***: kombinacija nadziranog i nenadziranog učenja. Algoritmu se pruža skup podataka koji uključuje i označene i neoznačene primjere.
- ***Ojačano učenje (Reinforcement Learning)***: algoritam uči putem interakcije s okolinom. Agent donosi određene akcije u određenom kontekstu, a sustav nagrađuje ili kažnjava agenta na temelju rezultata njegovih akcija. Cilj je maksimizirati

kumulativnu nagradu tijekom vremena.

Strojno učenje koristi različite vrste modela, kao što su neuronske mreže, odlučivački sustavi, klasifikatori, regresijski modeli, i druge tehnike, ovisno o zadatku i vrsti podataka s kojima se radi. Važan dio procesa strojnog učenja je evaluacija performansi modela na neviđenim podacima kako bi se osigurala njegova generalizacija na različite situacije.

Primjena *dubokog učenja i neuronskih mreža* u znanosti postala je sveprisutna i donosi značajne inovacije u različitim područjima. Evo nekoliko primjera kako se ova tehnologija koristi u znanstvenim istraživanjima:

- Genomika: duboko učenje koristi se za analizu genoma, identifikaciju gena povezanih s određenim bolestima te predviđanje genetskih varijacija.
- Proteinska struktura: neuronske mreže mogu pomoći u predviđanju trodimenzionalne strukture proteina, što je ključno za razumijevanje biokemijskih procesa i razvoj novih lijekova.
- Analiza podataka sudara čestica: veliki hadronski sudarač (LHC) proizvodi enormne količine podataka, a duboko učenje pomaže u brzjoj analizi i prepoznavanju značajnih događaja.
- Simulacije: neuronske mreže koriste se za simulaciju kompleksnih fizikalnih sustava, olakšavajući istraživačima razumijevanje ponašanja materijala ili dinamike plazme.
- Dizajn molekula: duboko učenje može ubrzati proces dizajniranja novih molekula, posebno u području razvoja novih lijekova i materijala.
- Kvantna kemija: neuronske mreže mogu poboljšati točnost kvantno-kemijskih proračuna i smanjiti potrebno vrijeme za analizu.
- Dijagnoza i predviđanje bolesti: duboko učenje koristi se za analizu medicinskih slika (npr. rendgenskih snimki, CT-a) radi rane dijagnoze bolesti i predviđanja ishoda.
- Personalizirano liječenje: neuronske mreže mogu analizirati genetske podatke pacijenata kako bi se prilagodilo liječenje prema njihovim individualnim karakteristikama.
- Prognostički modeli: duboko učenje primjenjuje se u razvoju točnijih prognostičkih modela za vremenske uvjete, seizmičke aktivnosti i slično.
- Analiza senzorskih podataka: neuronske mreže mogu interpretirati podatke dobivene

iz različitih senzora, što pomaže u praćenju promjena u okolišu.

- Računalni modeli učenja: duboko učenje koristi se za razvoj naprednih modela učenja koji mogu poboljšati sposobnost računala da prepoznaju obrasce i rješavaju kompleksne probleme.


Primjena dubokog učenja i neuronskih mreža u znanosti ima ogroman potencijal za ubrzanje istraživanja, pronalazak novih rješenja i poboljšanje načina na koji razumijemo svijet oko nas.

2.5. Prirodni zakoni

Bronowski (1974) se bavio paradoksima prirodnih znanosti tvrdeći da „raznolike manifestacije života ukazuju na snažnu komponentu slučajnosti“. S druge strane, ističe da je život svojom prirodom jedinstven, vjerojatno određen brojnim nužnostima. U latinskoj izreci stoji: „*Naturae non imperatur nisi parendo*.“ („Prirodi nećeš zapovijedati ako joj se ne pokoravaš.“).

Galileo (vidi Sliku 3) je koristio pojmove poput „proporcije“, „odnosi“, „principi“, umjesto izraza „prirodni zakoni“. S druge strane, F. Bacon razmatra „prirodni zakon“ kao najviši stupanj znanja, ali izražava mišljenje da ga ljudski um ne može doseći. U XVII. stoljeću Newton i Boyle govore o „prirodnim zakonima“, sugerirajući da se planeti i kemijske tvari pokoravaju tim zakonima. Prvi put se znanstveni smisao „prirodnih zakona“, koji odbacuje uobičajenu teološku frazu, pojavljuje u dokumentima „*Philosophical Transactions*“ glasila „*Royal Society*“ 1665. godine.

Prema istom izvoru, spomenuti pojedinci poput Keplera, Newtona (vidi Sliku 4) i drugih, zagovarali su ideju da istraživači svojim radom otkrivaju zakone prirode, odnosno naredbe koje je izdalo nadnaravno biće. To je odražavalo stanje civilizacijske svijesti u kojem se prihvaćala ideja da je nadnaravno biće razumno te da je priroda organizirana prema principima razuma. Vjerovanje je bilo da se korištenjem ljudskog uma ti principi mogu spoznati. Prema toj logici, primjerice, potreba za navodnjavanjem zemlje oko Nila poticala je napore ljudi da shvate geometrijske zakonitosti.




Slika 3. Galileo Galilei (<https://www.history.com/topics/inventions/galileo-galilei>)

Sustav zakona, koji je rastao i postajao sve sofisticiraniji kako je znanost napredovala, čini osnovu iz koje proizlaze nove spoznaje. Primjerice, naši su preci već davno istraživali geometriju pretpostavljajući vremenski okvir u kojem su prostorne relacije konstantne, a tek je Newton predstavio znanstvene principe vremenskog slijeda. Ova spoznaja proizlazi iz mogućnosti da se svemirska tijela, unatoč velikim udaljenostima, smatraju točkama velikih masa i sila, sposobnih za kretanje. Veliki korak za u znanost ostvaren je mjerenjem brzine i položaja planeta omogućujući proračun njihovih prošlih i budućih položaja.

Odbacujući antičko i renesansno shvaćanje priroda je proglašena kompletnom serijom pojava koje se pojavljuju u precizno definiranom uzročno-posljedičnom slijedu egzistirajući u vremensko-prostornom kontekstu i, po uzoru na Newtonove principe, ovise o položaju i sili.

Friedrich Nietzsche tvrdi da su znanstvene zakonitosti i pravilnosti samo slikoviti izrazi koji opisuju stanje uzročne povezanosti. Zakonima se opisuje formula o posljedicama koje se ponavljaju kad su zadovoljeni određeni odnosi. Međutim, ovo ne otkriva pokretača ili uzročnika zbivanja, niti dopušta zaključak da je jedno stanje uzrok, a drugo posljedica.



Slika 4. Isaac Newton (<https://www.history.com/topics/inventions/isaac-newton>)

U početku XIX. stoljeća znanstveni uspjesi potaknuli su Laplacea da postavi hipotezu: „Cijeli svemir i sve što se u njemu zbiva potpuno je određeno znanstvenim zakonima“. Prema njegovu uvjerenju, poznavanjem svih detalja stanja svemira u određenom trenutku mogli bismo izračunati sva prošla i buduća stanja. No, ovakva deterministička perspektiva naišla je na snažan otpor, posebice zbog suprotstavljanja slobodi Božjeg utjecaja na svijet.

Ovo uvjerenje izazvano je nizom znanstvenih izazova uključujući mjerenja svemirskih tijela od strane astronoma Jeansa i J. W. S. Rayleigha te razvojem teorija kvantne mehanike, neodređenosti i relativnosti tijekom XX. stoljeća. Unatoč neuspjehu Laplaceove teorije znanstvenog determinizma, vjerovanje u buduću pojavu sveobuhvatne, koherentne teorije koja bi obuhvatila sve postojeće teorije i dalje je prisutno (Belak, 2005).


Može se istaknuti da je Einstein (Slika 6) posljednje godine svoga rada posvetio baš tom problemu. U determinizam se sve uspješnije ugrađuju elementi nasumičnosti, a u nasumičnost elementi determinizma. Temeljem brojnih zakonitosti jasno je da „ničemu kraja nema“.

Tisućljeća ljudskih civilizacija iznjedrila su mnoge prirodne zakone i sustave zakona, među kojima se ističu: *euklidski sustav*, Newtonovi zakoni, geometrijska optika, termodinamika, sustav kemijskih elemenata i spojeva, sustav bioloških vrsta i Darwinova teorija evolucije, Maxwellove jednačbe, Einsteinove teorije relativnosti, Planckova kvantna mehanika, molekulama biologija, itd. Oko njih se okuplja, dopunjujući ih mnoštvom znanja, puno drugih znanstvenih zakona. Rasprave o rodoslovlju znanosti poticane su i nepoznanicama o npr.

razlozima postojanja istovrsnih, istodobnih, a nezavisnih otkrića” (Belak, 2005). To kazuje da se znanstvena područja razvijaju postupno te da bez prethodnog znanja nema znanstvene nadgradnje. Očito se znanstveno rodoslovlje ne može iskrenuti.



Slika 5. Pierre-Simon Laplace (<https://www.bbc.co.uk/programmes/m000twgj>)



Slika 6. Albert Einstein (<https://www.newscientist.com/people/albert-einstein/>)

Čim neki novi znanstveni zakoni budu postavljeni, uklapaju se u ljudsko iskustvo otvarajući nove mogućnosti otkrivanja nekim sljedećim zakonitostima. Počeci i granice znanstvenog rodoslovlja nisu u cijelosti znani, ali su neupitno određeni ljudskim bićem i sveobuhvatnim okolnostima našeg postojanja i djelovanja. „Prirodno pravo“, širokim zahvaćanjem problema prirode i „pozitivno pravo“ zbog preciznih formulacija kojima se služilo, pomogli su razvitku znanosti.

„Prirodni zakoni“ nisu vezani uz ideje o dužnosti poštovanja „prirodnih zakona“ i zapovijedanja putem „prirodnih zakona“. Većina znanstvenika podržava stav (makar i podsvjesno) da priroda ili Bog (lat. *deus sive natura*) imaju vlastite zakone, a „ljudski zakoni prirode“ samo su aproksimacije prethodno spomenutih. Pri tome su u znanosti i u filozofiji sve dominantniji oni koji dovode u pitanje opstojnost vanjskog svijeta neovisnog od promatrača. Naime, zakoni prirodoslovnog tipa ne tumače bit ponašanja društva i čovjeka, već serviraju samo nekolicinu mudrih načela.

U nastojanju da se razriješi taj problem, a pokušavajući uočiti bit društvenih zakonitosti, koriste se dvije metode. Prva ima cilj razgraničiti homogene ljudske skupine definiranih osobitosti što bi trebala biti pretpostavka određenju relacija među njima. Moguće je istražiti različite civilizacije i društva te njihove međuodnose. Druga metoda ima cilj definirati bit čovjeka i njegove mijene u različitim uvjetima. Posljedično tom pristupu traži se bit problema, a konačni rezultat zadržava se na apstraktnim razmatranjima.

Matematički i prirodoslovni zakoni primjenjivi su na događaje koji prate ljudski rad i proizvodnju, ali ne obuhvaćaju sveukupnu ljudsku populaciju, kao što su ljudske želje i povijest.

2.6. Društveni zakoni

Auguste Comte, 1798., (kojeg navode Abazović i suradnici, 2021) svoju je percepciju sociologije opisao kao „društvenu fiziku“ temeljenu na „nepromjenjivim zakonima ljudske prirode“. Prema Heisenbergovom stavu, prema kojem prirodni zakoni „izražavaju mogućnost izračunavanja budućih kretanja sustava“, postoji potencijalna primjena principa prirodnih zakonitosti na društvene aspekte. Ova ekstrapolacija otvara vrata za definiranje „zakona povijesne znanosti“, koji opisuju predviđena ponavljanja odnosa među pojavama i procesima u društvenom životu, proizašlim iz njihovih unutarnjih karakteristika te manifestiraju postupni razvoj povijesti.

Kod društvenih kretanja izoliranje pojedinačnih događaja od ostalih tijekova života principijelno je nemoguće, a istovrsna ponavljanja često izostaju. Kao rezultat toga, usporedba identičnih pojava nije izvediva, već samo analiza varijacija događanja koji se razlikuju u različitim mjerama. Ovo stvara odstupanja od pretpostavljenih pravilnosti i slijeda društvenih događanja. Povijesni zakoni predstavljaju zakone smjera koji utječu na razvoj masovnih pojava, ali ne određuju unaprijed specifične aktivnosti svakog pojedinog čovjeka. Rezultat društvenog procesa ovisi ne samo o općim principima, već i o konkretnim uvjetima u kojima se taj proces odvija.

Društvena znanost pretpostavlja opće smjerove budućih društvenih kretanja, no ti su smjerovi određeni brojnim hipotetskim mogućnostima i ograničenim uvjetima. Ipak, postoje razlike među društvenim znanostima povezanim s ovim pitanjima.

2.7. Predviđanje budućnosti

Korištenjem poznatih zakonitosti moguće je predvidjeti buduće događaje iako je razumijevanje nužnih zakonitosti često kompleksno. Primjerice, u predviđanju učinka mehaničkog sustava treba uzeti u obzir ne samo mehaničke već i elektromagnetske, termodinamičke i druge zakonitosti. Ove zakonitosti često predstavljaju djelove većih sustava pravilnosti. Kada bi se uspjelo objediniti sve postojeće procese pod jedinstvenim zakonima, uz poznavanje svih tih zakona i početnih uvjeta, tada bi se mogla predvidjeti budućnost bez pogreške. S obzirom na to da znanost teži tumačiti postojanost i zakonitost svijeta na temelju općih principa koji bi vrijedili za „sve“ slučajeve, jasno je da se time proteže i u budućnost ulazeći u područje koje nije trenutno prisutno i prelazi okvire ljudskog iskustva.

Znanstvene zakone treba oblikovati ne samo da generaliziraju već i da tumače sve posebne slučajeve kako bi bili primjenjivi i provjerljivi. Ti zakoni testiraju se kroz eksperimente i proračune, a kada se opaženo i proračunato poklapaju, zakonitost se potvrđuje iako još uvijek nije potpuno dokazana.

Znanstvenik mora biti sposoban predviđati buduće događaje. Činjenice same po sebi nisu dovoljne, stoga je potrebna znanost koja je organizirana i strukturirana. Svaka opažena činjenica omogućuje predviđanje velikog broja drugih činjenica, ali važno je zapamtiti da je samo prva činjenica apsolutno sigurna, dok su sve ostale tek vjerojatne. Bez obzira na čvrst temelj predviđanja ne postoji apsolutna sigurnost da će pokusi uvijek potvrditi predviđanja. Ipak, vjerojatnost je često dovoljno visoka da se praktički može zadovoljiti, stoga je bolje predviđati

s određenim stupnjem neizvjesnosti nego uopće ne predviđati jer ponovljena koincidencija nije nužno rezultat slučajnosti.

Znanstvena metoda prvenstveno omogućuje uvid u prošla zbivanja i istraživanje istinitosti ideja i činjenica. U puno manjoj mjeri kompetentno ukazuje na put kojim treba ići u budućnosti pa čak i kako nastaviti u sadašnjosti. Očito sagledavanje još nepostojećeg, slavljenje intuicije i imaginacije, maštovitost i kreativnost u hrabrom razmišljanju o budućnosti nisu snažne strane znanstvene metode.

Znanost često ne pruža zadovoljavajuće odgovore na ta traženja jer su ti problemi izvan njezinog dosega. Činjenice na kojima bi znanost temeljila svoje odgovore u takvim situacijama često su izvan dosega znanstvene metode ili, u nekim slučajevima, znanstvena zajednica ne smatra dostupne činjenice dovoljno kvalitetnima pa ne želi ugroziti svoj renome njihovim korištenjem.

Predviđanja o budućnosti postaju istinita kada se nedvosmisleno može utvrditi da će pri definiranim uvjetima, zbog poznatih zakonitosti, nastati u cijelosti predvidivi učinci. Današnje znanje omogućuje da se u mnogim slučajevima miješaju pojmovi proricanja i objašnjavanja usprkos poteškoćama koje postavlja Heisenbergov „zakon neodređenosti“ u fizici odbacujući determinizam kao svjetonazor. Povjesničari tumače razloge zbog kojih se nešto dogodilo, a neki, poput metodologa C. G. Hempela, primjenjuju opće zakonitosti kako bi objasnili ta događanja gotovo kao da proučavaju prirodne pojave. No, problemi nastaju kada se ne mogu jasno obrazložiti „individualni čimbenici“, što često ograničava sposobnost povjesničara da interpretiraju sve relevantne aspekte prošlih događaja.

2.8. Slučaj

„Slučaj je jedini izvod svake novine sveukupnog stvaranja u biosferi. Čist slučaj, potpuno slobodan ali slijep, nalazi se u samim temeljima ogromne zgrade evolucije: taj središnji pojam moderne biologije više nije jedna između ostalih mogućih hipoteza. To je danas jedina moguća hipoteza, jedina koja pristaje uz zapažene i provjerene činjenice.“ (Monod Jacques).

O ulozi slučajnosti u povijesnim, vojnim, diplomatskim, religioznim, umjetničkim, znanstvenim, sportskim i tehnološkim događanjima, kao i u pojedinačnim i kolektivnim sudbinama, postoje brojni opisi i navodi. Slučajnost ima značajan utjecaj ne samo u teoriji genskih mutacija, estetskih otkrića, lutrijskih dobitaka, nastanka prirodnih katastrofa poput potresa i tornada već i u visoko racionalnim aktivnostima.

U mnogim ljudskim djelatnostima nastoji se smanjiti utjecaj slučaja. Primjerice, u konstrukciji zrakoplova nastoji se izbjeći slučaj kako bi se povećala sigurnost letenja. Vojske razvijaju strategije i planove kako bi minimizirale utjecaj slučaja. Znanstvenici i tehnolozi planiraju svoj rad, a države, poduzeća i druge društvene institucije imaju dugoročne i kratkoročne programe i planove rada kako bi smanjile nepredvidljive događaje i kaos.

Uvjeti evolucije svemira i zemlje mijenjali su se, ali mogućnosti za nastanak života u svemiru vrlo su male. Postojanje raznolikog života na zemlji svjedoči o čudu slučajnosti. Postojanje svijesti i brojnih postignuća civilizacije, kao što su mostovi, kuće, knjige, umjetnička djela, predstavlja pravo čudo. Mogućnost za nastanak takvih čuda nevjerojatno je mala u svemirskim razmjerima, ali ipak postoji. Ne može se unaprijed odrediti tko će ostvariti neko znanstveno otkriće ili što će biti pronađeno.

Ovo stoji u suprotnosti s uvjerenjem nekih filozofa, laika, političara i sljedbenika *scijentizma* koji smatraju da postoji znanstvena metoda kao neka vrsta posebne formule koja omogućuje znanstvena otkrića. Prema njima, znanstvenik samo treba dovoljno dugo i ispravno „proizvoditi“ znanost, a otkriće će se oblikovati samo po sebi. Međutim, u znanstvenom istraživanju sudjeluje mnoštvo čimbenika, od metodoloških elemenata do imaginacije, pri čemu se naglašava važnost inspiracije i sposobnosti postavljanja hipoteza.

Mnogi autoriteti u znanosti ističu važnost sreće u znanstvenim aktivnostima. Nobelovac Hodgkin (1963) govoreći o svojim znanstvenim postignućima, spomenuo je osjećaj krivnje zbog umanjivanja uloge slučaja i sreće u onome što se često smatra logičkim napretkom. Kako slučaj poticati ili pronaći, kako ga uz sebe vezati te kako procijeniti njegov intenzitet i količinu pa samim time i značenje za znanstveni učinak? Kako to istražiti kada je problem procijeniti značenje slučaja, čak i u situacijama kada je slučaj neupitno postojao.

- Arhimed je po naredbi kralja Hijerona tražio način da dokaže prevaru jednog zlatara koji je vladaru podvalio ukras umanjene vrijednosti zamjenjujući dio zlata srebrom. Znajući da je zlato značajno teže od srebra, kao i da je 20 puta teže od jednakog obujma vode. Zadubljen u rješavanje spomenutog problema ulazeći u kadu primijetio je izlivanje vode preko njezina ruba ovisno o vlastitom uranjanju. Nevjerojatnog li niza događanja koji rezultiraju Arhimedovim razrješavanjem problema te se pitam: kakve posljedice bi imao drugačiji tijek događanja? O značenju opisanog slijeda događaja kazuje i anegdota sačuvana do današnjeg dana, u kojoj se opisuje radosno iskakanje Arhimeda iz kade koji je trčeći gradom vikao: „*Heureka, heureka*“ („Našao

sam, našao sam“).

- Kepler - najbolji astronomski teoretičar svojega doba, naslijedio je sve zapise najboljeg promatrača neba toga vremena Brachea. Jer da nije baš on došao u posjed tih dokumenata, možda bi bili uništeni.
- Lippershey je učinio prvi dalekozor 1606. god. Vjerojatno temeljem slučajnog pronalaska njegove djece tijekom igre da se sretnom i spretnom kombinacijom leća mogu dobro vidjeti udaljeni objekti.
- Newton nije išao na prisilni odmor na selo tijekom 1666. god. zbog zaraze koja je prekinula nastavu na Cambridgeu pa je tada u dokolici ostvario najveća otkrića.
- Galvanske struje otkrila je supruga profesora anatomije kuhajući ručak. Na metalnom pladnju nožem je rezala oguljene žablje krakove i oni su se trgli kao da su živi. Bio je to veliki poticaj spoznavanju elektriciteta, a temeljio se na kuharskim iskustvima gospođe Galvani te činjenici da ih je mogla podijeliti sa suprugom koji je bio profesor.
- Na ideju da kotače cestovnih vozila obloži gumom prvi je došao škotski veterinar J. B. Dunlop. Srdit na djecu koja su pred prozorom njegove ordinacije stvarala silnu buku jureći romobilima, potrčao je na cestu. U tom trenutku mu je pogled zapeo za nekoliko gumenih želučanih sondi za goveda, koje su visile na zidu njegova hodnika. Rješenje je pronađeno pa su se djeca mogla voziti ispod prozora.
- Anegdota kazuje da je P. Erlich zabunom stavio obojene preparate ispljuvka i organa inficiranih tuberkulozom na peć, u kojoj je naknadno njegova čistačica pripalila vatru. Ta je zgoda navodno omogućila Erlichu da otkrije izuzetno značajnu dijagnostičku metodu te ga je potaknula da dođe na genijalnu ideju o traženju lijekova.
- Flemingov laborant ukazao je svom šefu na neobično ponašanje bakterijske kulture, što je ustanovio nakon dugotrajnog izbjivanja iz laboratorija poslije povratka s godišnjeg odmora. Tada su na davno prije pripremljenoj kulturi kokošje kolere, učinjenoj da istraže mogućnost atenuiranja uzročnika spomenute bolesti, pronašli da je nešto spriječilo razvoj uzročnika kolere. Ustanovili su da je kultura bila slučajno zagađena gljivicom *Penicillium notatum*, što kazuje da je najznamenitiji antibiotik pronađen slučajno.
- Mladi je arheolog H. Bingham 1911. godine, slučajno, u zabitima peruanske džungle otkrio zaboravljeni grad Machu Picchu.

- C. Powell dobio je Nobelovu nagradu za otkriće pi-mezona. U taj eksperiment uložio je samo sedam funti, što je bilo dostatno za slanje specijalnih fotoploča meteorološkim balonima u stratosferu. U usporedbi s ogromnim ulaganjima u druge znanstvene projekte desio se zaista neuobičajen slučaj.
- Ogromnu sreću imao je i dobitnik Nobelove nagrade za fiziku Ch. V. Raman. Njegovo znanje fizike bilo je oskudno, ali se slučajno našao u pravom laboratoriju imajući uza sebe baš neophodni spektograf pomoću kojeg je potvrdio Heisenbergove hipoteze.
- J. D. Watson i F. H. C. Crick spretno povezujući informacije dobivene iz raznih laboratorija, a bez vlastitih eksperimentalnih rezultata i uz dozu sreće, odabrali su ispravne hipotetske kombinacije te rastumačili strukturu DNK. Za spomenuto dobili su Nobelovu nagradu 1962. godine, a ispravnost njihova modela molekule DNK dokazana je tek u naknadnim istraživanjima.

Baveći se znanstvenim radom stvaraju se nove prilike i slučajnosti u različitim vremenima i prostorima. Unatoč izazovima koje postavlja Heisenbergov „zakon neodređenosti“ u fizici, odbacujući determinizam kao svjetonazor, ova promišljanja ne moraju biti uzaludna, već mogu donijeti korisna saznanja.

2.9. Kaos

Matematički fenomen kaosa utemeljio je francuski matematičar Jules Henri Poincaré (1854.-1912.). Kaotični sustavi često se opisuju kao deterministički i kompjutabilni, ali u praksi se manifestiraju kao nepredvidivi. Nepredvidivost proizlazi iz mnogih čimbenika početnog stanja koji izmiču preciznoj izmjeri, kao što je vidljivo u prognozi vremena ili u procjenama vanjskih znakova ljudske inteligencije.

Problem nepredvidivosti kaotičnih sustava leži u izazovima mjerenja čimbenika početnog stanja. Primjerice, nije moguće precizno izmjeriti početno stanje svih molekula zraka u turbulentnim kretanjima tekućina ili predvidjeti dugoročnu vremensku prognozu. Meteorolozi mogu simulirati tipične situacije, ali nisu u mogućnosti jamčiti da će simulacija biti jednaka stvarnoj situaciji.

Teorija kaosa ima veliki značaj u proučavanju dinamičkih sustava čija su ponašanja izrazito osjetljiva na početne uvjete. Primjenjuje se u mnogim disciplinama, uključujući fiziku,

biologiju, ekonomiju i meteorologiju. Klasični primjer kaotičnog sustava je „toplinski leptir” efekt, koji ilustrira osjetljivost na početne uvjete i tešku predvidivost na dugi rok.

Jedan od pionira u razvoju teorije kaosa bio je meteorolog Edward Lorenz čija su istraživanja dinamike atmosfere dovela do razvoja Lorenzovog sustava i Lorenzovog atraktora, klasičnih primjera kaotičnih sistema. Teorija kaosa često se koristi u analizi složenih dinamičkih sustava koristeći alate poput fraktala, bifurkacijskih dijagrama i Lorenzovog atraktora (Žugaj, 1996).

Teorija kaosa i fraktala dva su interdisciplinarna koncepta koja se često povezuju i koriste u različitim disciplinama, uključujući matematiku, fiziku, biologiju, ekonomiju, računarstvo i umjetnost. Dani su osnovni pojmovi vezani za teoriju kaosa i fraktale:

1. *Teorija kaosa*

- Teorija kaosa bavi se proučavanjem nelinearnih dinamičkih sistema čiji su rezultati vrlo osjetljivi na početne uvjete. Ovi sistemi mogu izgledati nasumično, ali su zapravo deterministički.
- Male promjene u početnim uvjetima tih sistema mogu rezultirati dramatično različitim ishodima, što se često opisuje kao „efekt leptira”.
- Teorija kaosa često uključuje proučavanje sistema koji pokazuju ataktično ponašanje, tj. neregularnosti i nepredvidljivost.

2. *Fraktali*

- Fraktali su kompleksni oblici koji se ponavljaju na različitim skalama. To znači da se isti oblik može vidjeti kad se poveća ili smanji skaliranje. Fraktali se često koriste za opisivanje prirodnih fenomena koji imaju kompleksnu strukturu, poput planinskih lanaca, obalnih linija ili oblaka.
- Iteracija - fraktali se često generiraju iteracijom jednostavnih matematičkih formula. Pojam iteracije znači ponavljanje procesa na temelju prethodnih rezultata

3. ZAKONI O AUTORSTVU

Doprinosi znanosti vlasništvo su cijelog čovječanstva i da ih temeljem toga mogu koristiti svi ljudi. To se uostalom ističe i u jednoj od uobičajenih definicija znanosti: *znanost je zajedničko, koherentno, organizirano i sistematizirano znanje ljudskog roda* (Kumar, 2018).

Tijekom evolucije društva postaje sve izraženiji stav o potrebi priznavanja prava na autorstvo i prvenstvo za pronalazače u području znanosti. Iako to pravo nije uvijek tako očito kao vlasništvo nad nekretninama, važno je prepoznati da znanstveno autorsko pravo često donosi značajne financijske dobitke, slavu ili druge nagrade. Ova dinamika dovodi do toga da se znanstvenici sve više udaljavaju od isključivog traganja za istinom i činjenja dobročinstava za čovječanstvo, dok se u znanost uvode elementi vlasničkih odnosa. To potiče razmišljanje o idealističkim ciljevima znanosti koji postaju utopistički neostvarivi.

Unatoč rastućem utjecaju komercijalizirane kulture na znanstveno, tehničko i umjetničko stvaralaštvo, većina znanstvenika još uvijek pokreće iskrena radoznalost (*libido sciendi*) kao temeljni radni motiv. Ipak, kako se cijene znanja koja donose materijalnu dobit, postaje nužno stjecanje barem osnovnih komercijalnih znanja pa čak i putem kolegija iz marketinga i menadžmenta često uključenih u razne poslijediplomske studije.

Razlika između znanstvene spoznaje i patenta ističe se kao značajna. Iako se ponekad ti pojmovi djelomično preklapaju, aktivnosti koje se poduzimaju radi zaštite ili prodaje znanstvenih djela ne smatraju se čistom znanstvenom djelatnošću. OECD definira patent kao pravo koje država dodjeljuje pronalazaču u zamjenu za objavljivanje pronalaska čime se štiti pronalazač od neovlaštenog korištenja njegova izuma.

Važnost patentnih ureda kao nezaobilaznih izvora svježih znanstveno-tehničkih podataka sve više raste, a potreba za međunarodnim ujednačavanjem sustava patentiranja i zajedničkim kriterijima vrednovanja znanstvenih dostignuća postaje sve izraženija. Nacionalni zavodi za patente odgovorni su za dodjelu intelektualnih patentnih prava, pružajući informacije o zaštiti, publiciranju i korištenju podataka vezanih uz intelektualno vlasništvo. Ovi zavodi postaju ključni izvori informacija o stanju tehnike i tehnologije nužnih za istraživače i izumitelje.

Intelektualno vlasništvo dijeli se na industrijsko i autorsko s povezanim pravima, a većina suvremenih zemalja poštuje međunarodne dogovore o zaštiti intelektualnog vlasništva. Međunarodne i nacionalne institucije, poput „*Patent Cooperation Treaty*“ (PCT) i „*European Patent Organization*“ (EPO), brinu se o provedbi i sankcioniranju takvih dogovora.

Zakoni o autorstvu predstavljaju pravne norme koje reguliraju prava i obveze autora u vezi s njihovim originalnim djelima. Ovi zakoni štite intelektualna vlasništva autora potičući ih da stvaraju i omogućuju im kontrolu nad korištenjem njihovih radova od strane drugih. Dane su općenite karakteristike zakona o autorstvu:

1. Prava autora - zakoni o autorstvu obično dodjeljuju autorima određena ekskluzivna prava nad njihovim djelima. To uključuje pravo na reprodukciju, distribuciju, izvedbu, prijevod, prilagodbu i javnu komunikaciju njihovih radova.
2. Trajanje autorskih prava - autorska prava nisu vječna. U većini zakona o autorstvu, prava traju određeno vrijeme nakon smrti autora (npr. života autora plus određeni broj godina). Nakon isteka tog razdoblja, djelo postaje dio javne domene i može se slobodno koristiti.
3. Javna domena - djela koja su u javnom vlasništvu nisu zaštićena autorskim pravima. To uključuje djela čija su autorska prava istekla ili djela koja su izričito stavljena u javnu domenu od strane autora.
4. Prava moralnosti - osim ekonomskih prava neki zakoni o autorstvu uključuju i prava moralnosti koja štite nematerijalne interese autora, poput prava na priznanje autorstva i prava na integritet djela.
5. Izuzeci i ograničenja - zakoni o autorstvu obično sadrže izuzetke i ograničenja koja dopuštaju određenu upotrebu autorskih djela bez prethodnog odobrenja autora. To može uključivati upotrebu u obrazovanju, citiranje u skladu s pravilima citiranja, parodije i druge oblike „*fair use*” (pravednog korištenja).
6. Međunarodna pravila - s obzirom na globalnu prirodu intelektualnog vlasništva, postoji i niz međunarodnih sporazuma koji reguliraju autorska prava, poput Berneovog ugovora.
7. Digitalna autorska prava - s razvojem digitalnih tehnologija, zakoni o autorstvu prilagodili su se kako bi adresirali pitanja kao što su digitalna distribucija, kopiranje, digitalna prava upravljanja i zaštita od kršenja autorskih prava na internetu.



Slika 7. Logo institucije *European Patent Organization* (<https://unionsyndicale.eu/en/epc-50-years-celebrations-a-balanced-view/>)

Vrijedno je napomenuti da specifičnosti zakona o autorstvu mogu varirati od zemlje do zemlje. Ako postoje pitanja o konkretnim zakonima o autorstvu u određenoj zemlji, potrebno je preporučiti konzultacije pravnog stručnjaka ili istražiti vrijedeći zakon u toj zemlji.

- Pitanje autorskih intelektualnih prava nije novotarija. Povijest bilježi situacije u kojima su nezavisni istraživači istovremeno otkrivali nove spoznaje uzrokujući brojne sporove oko prvenstva u korištenju znanja i proizvoda. Primjerice, krajem XVI. stoljeća Švicarac J. Börgi (1552.-1632.) i Škot J. Napier (1550.-1617.) otkrili su logaritme istodobno. Pascal i Torricelli iste su godine (1655.) stvorili barometar, dok su G. Dela Porta, H. Lippershey, Z. Jansen, J. Metius i Galileo gotovo istodobno otkrili dalekozor. Newton i G.W. Leibniz zajedno su razvili diferencijalni račun, dok je reputacija Cardanova bila uništena unatoč njegovim doprinosima razvoju automobilske industrije i stvaranju preduvjeta za kvantnu teoriju.
- Newton je bio škrt u dijeljenju informacija čuvajući fluksiju kao tajno oružje za svoja druga otkrića. P. Erlich bio je povrijeđen nekorektnošću svog učitelja E. Behringa u vezi suradnje s farmaceutskom industrijom i akademskog napredovanja, što ih je dovelo do nepomirljivog sukoba. N. Tesla sa svojih 700 patenata suočio se s

beskrupuloznim kršenjem njegovih izuma u području radiotehnike.

- Suvremeni sukobi poput spora oko uzročnika AIDS-a između francuskih znanstvenika oko L. Montagniera i američke grupe R. Galloa također su pokazatelji izazova u očuvanju prava na patente i autorska prava. Industrijski sukobi, poput dugogodišnjeg sukoba između Volkswagena i General Motorsa potaknuti su prijelazom menadžera J. I. Lopeza de Arriortua iz američke u njemačku tvrtku rezultirajući industrijskom špijunažom i naknadnom izvansudskom nagodbom.

Povijest također pamti etičke postupke intelektualnih velikana, poput K. F. Gaussa, koji je prvi otkrio neeuclidsku matematiku, ali nije odmah objavio podatke. Slično, A. R. Wallace prepoznao je principe biološke evolucije prije Ch. Darwina, ali je prepustio slavu Darwinu. Osim sebičnosti, strah od zlouporabe znanja bio je motiv, kao u slučaju fizičara L. Szilarda, koji je, kao pronalazač lančane nuklearne reakcije, svoj patent pohranio kako ga ne bi zloupotrijebili nacisti.

Poznate su i razne druge, a opet ilustrativne situacije s patentnim zavrzlamama:

Nizozemac H. Lippershey je 1606. god. zatražio privilegije i državnu potporu za pronalazak sprave kojom se udaljeni predmeti dobro vide. Sugerirajući značajnu mogućnost korištenja naprave u vojne svrhe. Obvezao se da tu tajnu neće drugima otkrivati te da će takve sprave proizvoditi samo za svoju zemlju. Državno povjerenstvo pohvalno je ocijenilo dalekozor, ali je zahtijevalo da se pripremi za binokularno gledanje. Završivši posao ipak nije dobio potporu države. Naime, dva dana iza njega J. Metius podnio je vladi slično traženje pa uočivši da pronalazak nije tajna povjerenstvo nije nijednome htjelo dodijeliti privilegije.

Luj XIV. dao je liječniku R. Talbotu 2 000 zlatnika, plemićku titulu i obilnu mirovinu da mu otkrije tajnu pripremanja i uporabe kore od kininovca, kako bi ju mogao obznaniti cijeloj medicinskoj javnosti. Time je bitno unaprijeđeno liječenje milijuna ljudi – široko je postao dostupan djelatni lijek protiv malarije.

L. Daguerreu francuska je vlast plaćala 6 000 franaka godišnje da svoju tajnu o fotografiji dade svijetu na uvid. Inicijator te aktivnosti F. Arago, fizičar, astronom i političar tada je izjavio: „Francuska je taj izum usvojila i pribavila pa je gorda da ga može sada kao poklon uručiti cijelom svijetu“.

Whitney je krajem XVIII. st. postao pravim narodnim herojem Amerike zbog pronalaska stroja koji odvaja pamučne niti od sjemenki te uvećava učinak radnika 50 puta. Prvi stroj mu je netko

ukrao, a zbog ogromne praktične vrijednosti i jednostavne izrade proizvodnja stroja brzo se proširila cijelim američkim Jugom.

Otkriće penicilina, jednog od najfundamentalnijih lijekova modernog doba - antibiotika koji se propisuje u golemim količinama – Britanci nisu zaštitili. To su vrlo spretno iskoristile brojne farmaceutske kompanije, dominantno u SAD- u, te zaradile ogroman novac.

U SAD-u veliki broj sveučilišta ima ugovore sa svojim djelatnicima o patentnim pravima. Na taj način ostvaruju se značajna sredstva za pronalazače i za sveučilišta. Primjerice, najveći prihod sveučilištima donio je patent za vakcinu protiv hepatitisa i patent za nikotinske „krpice“ koje služe za odvikavanje ljudi od pušenja.

Sveučilište Stanford bilo je godinama najuspješnije u ostvarivanju financijskih prava od privatne industrije temeljem patentnih zaštita. Npr. tijekom 1992. god. inkasirao je Stanford po opisanoj osnovi 25 milijuna dolara. Najprihodniji bio je patent Cohen/Boyerove tehnike rekombinantne genetike, koji je istekao 1997. god., do kada je Sveučilištu donio 87 milijuna dolara (Belak, 2005).

Značajan izazov potreba je za djelatnim sustavom, koji bi spriječio zlouporabe kojima se ometa afirmacija novog patenta, sputava njegova primjena u praksi i sl.

Postoje mogućnosti da se npr. od pronalazača otkupe patentna prava i zatim da se ne dozvoli praktična upotreba pronalaska, bez obzira koliko revolucionaran on bio, kako se ne bi ugrozili financijski interesi postojeće tehnologije.

Postoje i strateški značajna područja, npr. vojne tehnologije, aeronautike, nuklearne tehnologije, kemijske industrije, itd. unutar kojih se inovativni procesi ponekad tretiraju po principima koji odudaraju od proklamiranih etičkih normi.

4. ZNANSTVENA METODA

Znanstvena metoda je metoda za stjecanje pouzdanih znanja, odnosno metoda za pouzdano stjecanje znanja. Načelo pouzdanosti znanja temelji se na **ponovljivosti i provjerljivosti** iskustva kao izvora znanja nastalog opažanjem prirodnih procesa ili fenomena. Provjerljivost znanja implicira postojanje metode za provjeru znanja koja je dovoljno pouzdana da se rezultate provjere, a time i znanje, može smatrati istinitim s dovoljnom pouzdanošću (Tkalac i suradnici, 2010 i Kumar, 2018).

Znanstvena metoda kao sredstvo i način stjecanja istinitog i pouzdanog znanja sastoji se u svim znanstvenim istraživanjima neovisno o znanstvenom području, polju ili grani od sljedećih postupaka i grupa aktivnosti, koji čine strukturu znanstvenog istraživanja:

1. Definiranje znanstvenog problema;
2. Objašnjenje fenomena (problema) postavljanjem hipoteze;
3. Testiranje hipoteze prognoziranjem;
4. Zaključivanje o problemu temeljem testiranja hipoteze.

U znanstvenoj praksi znanstvena metoda sastoji se od sukcesivne i sustavne provedbe pojedinih faza istraživanja kroz obično sedam koraka:

1. Opažanje fenomena (pojava) ili procesa u prirodi;
2. Definiranje problema (postavljanje pitanja);
3. Istraživanje problema (prikupljanje informacija i primjena jedne ili više metoda znanstvenih istraživanja);
4. Dostavljanje hipoteze (definiranje metoda provjere i prognoziranje);
5. Testiranje hipoteze (provjera istinitosti prognoze, provedba eksperimenta, opažanja eksperimenta, procesa u prirodi, testiranje prognoze, analiza rezultata opažanja, odluka o prihvatanju ili odbacivanju hipoteze);
6. Zaključak (potvrda ili odbacivanje hipoteze, odluka o završetku ili nastavku istraživanja);
7. Stvaranje znanstvene teorije.

Pod opažanjem fenomena i/ili procesa u prirodi podrazumijeva se svaka informacija koja se može dobiti izravno pomoću osjetila ili neizravno zaključivanjem. Da bi se opažanje moglo upotrijebiti kao element znanstvene metode, ono mora biti ponovljivo (i drugi znanstvenici moraju imati mogućnost izvršiti jednako opažanje). Opažanja prirodnih fenomena i procesa potiču na postavljanje pitanja kojima definiramo znanstvene probleme (Milat, 2005).

Rješavanje kompleksnih problema zahtijeva usmjeravanje prema istinitim i provjerljivim informacijama o svim aspektima problema, što su zapravo odgovori na postavljena pitanja. Opažanje prirodnih fenomena može se ostvariti putem opisivanja ili analize kako kvalitativno tako i kvantitativno. Svako opažanje ima nužan kvalitativni aspekt budući da bi preskakanje tog koraka prije završetka procesa definiranja problema moglo dovesti do nedopuštene apstrakcije fenomena. Proces opažanja treba se odvijati kritički čime se eliminira subjektivnost i pristranost znanstvenika.

S ciljem povećanja objektivnosti, ponovljivosti i kontrole rezultata opažanja znanstvenici često primjenjuju kvantifikaciju fenomena putem preciznih mjerenja. Kvantifikacija omogućava kako kvalitativno, tako i kvantitativno opisivanje opažanja. Analiza numeričkih rezultata i statistička obrada omogućavaju stvaranje novih spoznaja o problemu koje bi vjerojatno prošle nezamijećeno prilikom isključive kvalitativne analize.

Unatoč provedenoj kvantifikaciji važno je biti svjestan mogućih pogrešaka direktnog opažanja, dok je prisutnost pogrešaka u razmišljanju i zaključivanju, poznatih kao pogreške mišljenja, česta. Te pogreške obuhvaćaju ustaljene sheme, procedure i šablone razmišljanja koje mogu ograničiti sagledavanje cjelokupnog značenja rezultata opažanja. Sve ključne pogreške u istraživanju suštinski su pogreške u mišljenju, čime se ističe nužnost primjene formalne logike u znanstvenim istraživanjima. Pri kvantifikaciji opažanja, preporuča se upotreba međunarodnog sustava jedinica kako bi se osigurala usporedivost i prenosivost rezultata.

4.1. Definiranje znanstvenog problema

Promatranje prirodnih procesa bez istodobnog propitivanja uzroka, razvoja, trajanja, učinaka, efekata i posljedica predstavljalo bi stjecanje dojma o prirodi i njezinim procesima (u ovom kontekstu to bi se moglo nazvati *zapažanjem*). Postavljanje pitanja o biti (prirodi) prirodnih procesa i pojava (fenomena) označava početak definiranja problema kao ključnog elementa u znanstvenoj metodi. Da bi pitanja o nekom prirodnom fenomenu mogla služiti kao početak znanstvenog istraživanja, moraju biti relevantna (od značaja u odnosu na zapažanja), a odgovori

na njih moraju biti mogući. Postupak postavljanja relevantnih pitanja i dolazak do mogućih odgovora predstavlja ključni korak u znanstvenoj metodi.

Definiranje znanstvenog problema smatra se najzahtjevnijim korakom u procesu znanstvenog istraživanja i primjene znanstvene metode, dok prepoznavanje mogućnosti poboljšanja označava najkreativniji korak u tom procesu. Gotovo svaki problem može se analizirati postavljanjem pitanja i definiranjem odgovora. Ako je problem preopćenit, jedino rješenje je razdvajanje složenog ili općenitog problema na podprobleme primjenom određenog kriterija. Tako se analizom i sintezom rješenja definiraju rješenja podproblema koja su relevantna unutar šireg konteksta problema.

Istraživanje problema, odnosno prikupljanje informacija, ključno je za odgovaranje na postavljena pitanja u procesu definiranja problema. Pribavljanje informacija može se provesti putem mjerenja, razgovora, proučavanja literature, posjeta muzejima, pretraživanja interneta pri čemu su eksperimenti i opažanja ključni izvori informacija. Važno je napomenuti da koraci prikupljanja informacija i definiranja problema često međusobno utječu jer novodobivene informacije mogu izazvati redefiniranje problema.

Informacije dobivene opažanjima mogu se principijelno podijeliti na kvantitativna (koja se mogu opisati brojčanim vrijednostima) i kvalitativna (koja pružaju opisne informacije o problemu). Iako je podjela uvjetna, jer je teško zamisliti kvantitativne podatke bez određenog kvalitativnog opisa, u stvarnom znanstvenom istraživanju informacije dobivene opažanjima dijele se na one koje su i kvalitativne i kvantitativne te na one koje su samo kvalitativne.

4.2. Postavljanje hipoteze

Nakon što se sintetizira dovoljan broj odgovora na postavljena pitanja kojima se definira znanstveni problem, pristupa se formuliranju hipoteza. Riječ „**hipoteza**“ dolazi od grčkih riječi „hipo“ (ispod) i „thesis“ (ideja), što bi doslovno značilo *podloga ideje ili podloga rješenja*.

U suvremenom znanstvenom jeziku, hipoteza predstavlja privremeno najvjerojatnije rješenje problema, odgovor na postavljena pitanja i osnovu na kojoj se temelji ideja o prirodnom procesu ili predmetu istraživanja. Postavljanje hipoteza znači definiranje privremenog i najvjerojatnijeg rješenja problema.

Tijekom znanstvenog istraživanja istraživač često može identificirati ne samo najvjerojatnije rješenje, već i rješenja koja su manje vjerojatna od odabrane hipoteze. Odabir početne hipoteze, koja će se dalje provjeravati, provodi se prema Ockhamovom principu. Ovaj princip potiče na

ekonomičnost i jednostavnost u znanstvenom istraživanju sugerirajući da složene pojave ne bi trebale biti nepotrebno komplicirane. Ockhamov princip, formuliran u 14. stoljeću, kaže da pojave ne treba nepotrebno komplicirati, a u odabiru početne hipoteze treba odabrati onu koja je jednostavnija sve dok se ne pojave novi dokazi. Ovaj princip ne određuje ispravnost hipoteza, već samo redoslijed provjere.

U praksi, početna hipoteza može biti ispravno rješenje problema u jednostavnijim istraživanjima. Kod kompleksnijih procesa ona se može pokazati kao nedovoljno dobro rješenje, što naglašava važnost provjerljivosti znanstvenih hipoteza. Ovo svojstvo hipoteze omogućuje da se odbaci ako se provjera dovede u pitanje.

U kompleksnim znanstvenim istraživanjima često se definira više hipoteza, od kojih se odabire najvjerojatnija prema dostupnim podacima. Testiranjem hipoteza i prikupljanjem novih informacija može doći do promjene najvjerojatnije hipoteze otvarajući put novim smjerovima istraživanja.

Bitna karakteristika znanstvene hipoteze njezina je sposobnost prognoziranja razvoja istraživnog prirodnog procesa ili fenomena. Ako hipoteza ne omogućuje prognoze, već samo potvrđuje činjenice, ona nije hipoteza, već činjenica.

Testiranje hipoteza uključuje prognoziranje razvoja prirodnog procesa, usporedbu prognoziranih i ostvarenih rezultata te identifikaciju varijabli i očekivanih rezultata unutar svake hipoteze.

Oblici hipoteza:

1. Hipoteza s direktnom vezom nezavisnih i zavisnih varijabli,
2. Hipoteze sa značajnim utjecajem vrijednosti nezavisne varijable na veličinu zavisne,
3. Hipoteze s direktnom zavisnošću zavisne varijable o nezavisnoj varijabli.

Ako je subjekt tretiran nezavisnom varijablom, tada će to rezultirati vrijednošću zavisne varijable. Ovo je ujedno i definicija prognoze kao dijela hipoteze koja se izražava rečenicom 'ako... onda,...' (ako je hipoteza točna, onda se može očekivati opažanje određenog rezultata).

Temeljna značajka hipoteza je i to da se ne mogu prognozirati protekli događaji, stoga se ni hipoteze vezane uz protekle događaje ne mogu testirati što znači da hipoteze koje se odnose na prošlost nisu znanstvene hipoteze jer im nedostaju obje temeljne značajke, a to su provjerljivost i prognoza. Protekli događaji mogu se samo hipotetski rekonstruirati, ali se ne mogu testirati.

Potvrđivanje prognoze (utvrđivanje ispravnosti prognoze) definirane hipotezom može se izvršiti na dva načina:

- eksperimentom (pokusom),
- provedbom daljnjih opažanja.

Eksperiment se može provesti samo ako se osigura većina uvjeta (sve bitne uvjete) za koje je definirana prognoza odvijanja neke pojave (prirodnog fenomena). O stupnju osiguranja uvjeta za koje je definirana hipoteza ovisi i stupanj pouzdanosti potvrde prognoze ili njenog odbacivanja.

Jedna od bitnih značajki eksperimenta je kvantifikacija rezultata eksperimenta što omogućava dodatnu analizu pojave upotrebom matematičkog alata, a posebno statističke analize dobivenih rezultata. U mnogim znanstvenim disciplinama ne mogu se osigurati uvjeti eksperimenta za potvrdu prognoze, čije bi se rezultate moglo smatrati pouzdanima, stoga se mogu koristiti neke druge znanstvene metode kao što su promatranje, opažanje, intervju i slično.

Eksperiment (pokus) organizirani je skup postupaka (procedura) koji se odnosi na prethodno definirane uvjete, a kojim se utvrđuje ispravnost prognoze. Definiran je hipotezom i ostvarenjem prognozirane uzročno-posljedične veze. Da bi eksperiment mogao definirati ispravnost prognoze, u okviru prognoze neophodno je definirati kontrolni događaj s kojim će se usporediti eksperimentalni događaj.

Prije nego što se donese prognoza za određeni događaj, hipoteza se kao osnova za prognozu postavlja na temelju promatranja samog događaja ili niza događaja. Takvi događaji, koji uključuju uvjete opažanja, redoslijed događaja, opažene uzročno-posljedične veze, kvantitativne značajke i odstupanja u rezultatima, definiraju se kao kontrolni događaji. Na taj način, uzorak se određuje kako bi se utvrdila točnost prognoze.

Izvođenjem eksperimenta ili niza eksperimenata provodi se postupak manipulacije nezavisnim varijablama i opažanja promjena zavisnih varijabli koje su bile predviđene. Podaci dobiveni ovim postupkom nazivaju se eksperimentalnim događajem. Usporedbom kontrolnog događaja s eksperimentalnim događajem potvrđuje se ili odbacuje prognoza čime se, nakon nekoliko neuspjelih prognoza, može revidirati i hipoteza.

Razumijevanje fenomena kao cjeline ostaje nedokučivopromatraču. To se može općenito definirati kao nešto čija je osnovna karakteristika promjena. Na početku razumijevanja pojma fenomena uzima se proces definiran promjenom bilo kakvih značajki nečega što se mijenja u

vremenu. Unatoč problemima s vremenom znanstveno istraživanje mora postaviti uvjete kako bi se razlikovalo od pseudoznanosti.

Ako se prihvati mogućnost opažanja samo dijelova promjena, umjesto cjelokupnih promjena, ostaje pitanje što i kako se može opažati kao fenomen prirode. Treba se fokusirati na značenje prirodnog fenomena i razumijevanje promjene prirodnog procesa koja se događa neovisno opromatraču .

Prihvaćanje mogućnosti definiranja promjena univerzalnog vremenskog tijeka postavlja pitanje vremena. Promatrač pristupa parcijalnostima postavljanjem pitanja koja proizlaze iz njegova znanja. Cjelokupna znanja promatrača mogu se analizirati kao znanje iz cjelokupnog znanstvenog područja, znanje iz pojedinih znanstvenih disciplina ili interdisciplinarna znanja.

Razumijevanje fenomena postaje interaktivni proces prirodne promjene primjenom znanstvenih metoda, znanja, hipoteza i teorija. Primjer takvog procesa može se prikazati kroz postupak mjerenja veličine koja se izdvaja iz prirodnog procesa.

Izmjeriti veličinu znači promatrati sredstvo mjere (mjerilo, metar) u prirodnom procesu. Rezultat mjerenja broj je jedinica mjere u jednom dijelu procesa. Zrcaljenje znanja i metoda znanstvene zajednice u prirodnom procesu predstavlja opisivanje, determiniranje i razumijevanje fenomena.

4.2.1. Prirodni fenomen

Prirodni fenomen predstavlja odraz promatračevih znanstvenih spoznaja, znanja i metoda unutar prirodnog procesa koji se odvija neovisno o samom promatraču.

Ključne implikacije razumijevanja fenomena obuhvaćaju sljedeće aspekte:

- Fenomen ne postoji samostalno, već je ovisan opromatraču.
- Fenomen je podložan promjenama u skladu s razvojem znanstvenih spoznaja, znanja i metoda.
- Ispravnost i znanstvena valjanost razumijevanja fenomena ovisi o točnosti postavljanja pitanja koja se eksperimentalno ispituju u prirodnom procesu, a ta pitanja moraju biti usklađena i dobro utemeljena u znanstvenim spoznajama. Treća ključna posljedica naglašava važnost znanstvene etike promatrača i etičnosti u postavljanju pitanja te primjeni znanstvenih znanja i metoda.

Eksperimentalni fenomen dolazi do izražaja kada prirodni procesi nisu pogodni za istraživanje zbog različitih razloga, kao što su nemogućnost opažanja, rijetki procesi, neekonomičnost izravnog opažanja, dugotrajni ili kratkotrajni procesi te nemogućnost izdvajanja fenomena iz cjeline. U takvim slučajevima prirodni proces reducira se na elemente koje žele istražiti, pri čemu se ti elementi prenose u kontrolirane uvjete opisane uvjetima prirodnih procesa. Ovaj postupak naziva se eksperimentom ili eksperimentalnom pojavom (eksperimentalnim fenomenom).

Da bi rezultati eksperimenta bili znanstveno relevantni, potrebno je:

1. Definirati prirodni fenomen iz cjeline znanstvenih znanja i spoznaja.
2. Izdvojiti bitne elemente fenomena za repliciranje u eksperimentalnim uvjetima.
3. Odrediti značajke eksperimentalnog događaja koje se kontroliraju unutar unaprijed definiranih granica te postaviti granice prihvatljivosti eksperimentalnog fenomena.
4. Kvantificirati promjene eksperimentalnog fenomena, statistički obraditi rezultate te utvrditi značaj i relevantnost obrađenih rezultata.
5. Interpretirati rezultate opažanja eksperimentalnog fenomena u terminima dobro utemeljenih znanstvenih spoznaja.

Navedeni elementi eksperimentalnog događaja ukazuju na povećani utjecaj promatračaili eksperimentatora na razumijevanje fenomena, osobito na rezultate opažanja. Promatračiz znanstvenih spoznaja i znanja ima ključnu ulogu u:

- Definiranju fenomena,
- Selekciji bitnih elemenata fenomena, odnosno suštinskog sadržaja fenomena,
- Određivanju uvjeta opažanja značajnih elemenata fenomena,
- Mjerjenju promjena eksperimentalnog fenomena,
- Interpretaciji rezultata eksperimenta,
- Ekstrapolaciji rezultata istraživanja eksperimentalnog fenomena na prirodni fenomen.

Ukoliko je eksperimentator korektno utemeljio eksperimentalni fenomen i definirao ga, a zatim ispravno izmjerio promjene u eksperimentu, na njemu je da u skladu s načelima znanstvene etike provede ostale aktivnosti od kojih je interpretacija rezultata ključna.

4.2.2. Simulirani fenomen

U većini istraživanja iz raznih razloga, kao što su nemogućnost neposrednog opažanja prirodnih procesa u stvarnom vremenu ili zbog ograničenja u provedbi, znanstvenici sve češće koriste računalne simulacije kao izvor kvalitativnih i/ili kvantitativnih podataka. U procesu definiranja simulacije prirodnog fenomena, poznatog kao *simulirani fenomen*, naglasak na ulozi promatrača dodatno raste stvarajući udaljenost između simuliranog fenomena i stvarnog prirodnog fenomena, što čini znanstvenu etiku istraživača ključnom.

Istraživanje prirodnog fenomena primjenom računalne simulacije ili drugih oblika simulacija može se razložiti kroz sljedeće korake:

1. Definiranje stvarnog prirodnog fenomena;
2. Identifikacija značajnih elemenata prirodnog fenomena koje istraživač odabire kao predmet istraživanja;
3. Određivanje ključnih elemenata prirodnog fenomena koje treba simulirati;
4. Odabir modela simulacije za svaki ključni element fenomena;
5. Provođenje simulacije reduciranog fenomena, simuliranog fenomena i tumačenje rezultata dobivenih putem simulacije;
6. Analiza rezultata opažanja simuliranog fenomena i utvrđivanje promjena u reduciranim elementima prirodnog fenomena;
7. Prijenos (ekstrapolacija) podataka o promjenama reduciranog prirodnog fenomena (sastavljenog od reduciranih elemenata prirodnog fenomena) na stvarni prirodni fenomen;
8. Interpretacija rezultata opažanja i istraživanja.

Svaki korak u istraživanju - opažanju primjenom metoda simulacije značajno ovisi o istraživaču, a razina znanstvene korektnosti i etičnosti koju osigurava istraživač ima presudan utjecaj kako na provedbu istraživanja, tako i na interpretaciju rezultata.

4.2.3. Zamišljeni fenomen (znanstvene priče)

Ovaj oblik prezentacije znanosti postaje sve popularniji. Predstavlja značajan aspekt znanstvene komunikacije. Funkcionira kao sredstvo popularizacije znanstvenih tema, često dobro prihvaćeno od šire publike, jer ne zahtijeva specifična predznanja kako bi čitatelj stekao dojam da razumije suštinu znanstvene priče. Iako se elementi znanstvene priče mogu pronaći i u

ozbiljnim znanstvenim istraživanjima koja su temeljena na provjerljivim i dokazanim metodama, važno je napomenuti da priče koje nisu čvrsto utemeljene na znanstvenim spoznajama često opstaju i dobivaju privremeno priznanje u znanstvenim krugovima.

Često se početak razvoja ovakvih narativa „znanosti“ događa kroz nastojanje da se, na osnovi dijelova znanstvenih rezultata, konstruira model, obično matematički, koji se zatim koristi kako bi se pokušalo objasniti prirodni fenomen. Glavni problem s ovakvim znanstvenim pričama leži u činjenici da, unatoč svojoj formi, ne predstavljaju pravu znanost. One se temelje na matematičkim modelima koji nisu relevantni u znanstvenom smislu, ne proizlaze iz znanstvenih spoznaja i ne pružaju rezultate koji su usporedivi s rezultatima pravih znanstvenih istraživanja.

Poseban izazov takvih priča je taj što se njihovi rezultati, kao i same priče, često ne mogu provjeriti ni ponoviti, čime gube svoju mogućnost potvrde ili opovrgavanja. Unatoč tome, vrijednost znanstvenih priča može se pronaći u njihovoj sposobnosti popularizacije znanosti te poticanju na postavljanje novih pitanja i poticanju stvarnih znanstvenih istraživanja.

Maštovitost igra ključnu ulogu u znanstvenom procesu, no mašta u znanosti također mora imati svoje granice. Razvoj znanstvenih priča može se opisati kroz sljedeće korake:

Razvoj znanstvenih priča može se opisati kroz nekoliko ključnih koraka. Ovi koraci pomažu autoru u strukturiranju priče pružajući čitateljima jasnu i uvjerljivu naraciju.

Prezentira se nekoliko koraka koji se mogu slijediti:

1. Istraživanje i priprema

- Treba proučiti temu kojom se želi baviti. Prikupljaju se relevantne informacije, činjenice i podatke.
- Potrebno je razmisliti o ključnim pitanjima koja se žele istražiti i odgovoriti u vlastitoj priči.

2. Postavljanje scenarija

- Definirati osnovne elemente priče, uključujući protagoniste, antagonista (ako postoji), okoliš i temeljne koncepte.
- Razmisliti o ključnim događajima i obrascima koji će činiti srž priče.

3. Uvod

- Postaviti ton i atmosferu priče u uvodu.
- Predstaviti glavne likove i postavke kako biste privukli čitatelje.

4. Razvoj likova

- Dati likovima dubinu i kompleksnost.
- Prikazati njihove motive, strahove, snove i izazove s kojima se suočavaju.

5. Sukobi i napetost

- Uvesti sukobe koji će održati interes čitatelja.
- Razvijati napetost kroz sukobe likova ili sukobe između likova i okoline.

6. Razvoj zapleta

- Potrebno je postepeno otkrivati ključne informacije i elemente priče kako bi se održala tajanstvenost i zanimanje.
- Povezati različite dijelove priče u koherentan i uvjerljiv narativ.

7. Vrhunac

- Dosegnuti kulminaciju priče, gdje se svi sukobi intenziviraju.
- Ključni trenuci otkrivanja ili akcije često se događaju tijekom vrhunca.

8. Rasplet

- Razriješiti glavne sukobe i odgovoriti na ključna pitanja koja su postavljena tijekom priče.
- Dati čitateljima osjećaj zaključenosti ili potpunosti.

9. Zaključak

- Završiti priču na način koji ostavlja dojam ili poruku.
- Razmisliti o ostavljanju prostora za interpretaciju ili razmišljanje.

10. Revizija

- Pregledati i urediti vlastitu priču kako bi se poboljšala dosljednost, stil i logika.
- Pitati druge za povratne informacije i biti spremni prilagoditi prema potrebama.

Slijedeći ove korake, može se kreirati dobro strukturirana i zanimljiva znanstvena priča.

4.3. Metodologija znanstvenog rada

„Epistemologija ili logika znanstvenog otkrića trebaju se identificirati s teorijom znanstvene metode.“ (Popper, 2003).

Metodologija znanstvenog rada (*methodos* grč. put, traženje; *a logos* grč. riječ, um, misao) znanost je o postupcima, tehnikama, sredstvima i principima rada znanstvenika.

Popper (2003), austrijski filozof znanosti, poznat je po svojoj epistemologiji koja se često naziva „kritičkim racionalizmom“ ili „falibilizmom“. Popper se posebno istaknuo svojom kritikom induktivnog razmišljanja, koje je smatrao nepouzdanim temeljem za znanstvenu metodologiju.

Navode se neki važni elementi Popperove epistemologije:

- Falsifikacija umjesto verifikacije – Popper je odbacio ideju da teorije mogu biti potvrđene putem induktivnog procesa. Umjesto toga, predložio je koncept falsifikacije. Prema njegovoj filozofiji, znanstvena teorija trebala bi biti postavljena na test putem pokušaja da se opovrgne. Ako teorija preživi pokušaje opovrgavanja, može se smatrati privremeno valjanom.
- Empirijska provjerljivost – Teorije koje nisu empirijski provjerljive, koje ne mogu biti podvrgnute iskustvenom testiranju, nisu za Poppera znanstvene. Znanstvena tvrdnja trebala bi biti postavljena na način da se može opovrgnuti putem iskustva.
- Problemi s induktivizmom – Popper je bio kritičan prema induktivizmu, prema kojem su općenite tvrdnje izvedene iz specifičnih iskustava. Tvrdio je da je induktivizam logički nedostatan jer ne može osigurati valjanost znanstvenih tvrdnji.
- Rastuća znanja – Popper je vjerovao u rastuće znanje i razvoj znanstvene misli kroz sukobe i odbacivanje nevaljalih teorija. Njegova je ideja bila da svaki neuspjeh u pokušaju falsifikacije doprinosi jačanju znanstvenog znanja.
- Metodološki racionalizam – Popper je bio zagovornik „metodološkog racionalizma“, prema kojem je razumna metoda ključna za napredak znanosti. Uprkos naglasku na kritičkom pristupu, Popper je isticao važnost pozitivnog stava prema znanstvenim teorijama koje su opstale testove falsifikacije.
- Socijalna dimenzija znanosti – Popper je pridavao važnost socijalnoj dimenziji znanosti. Smatrao je da je kritika bitna u znanstvenoj zajednici kako bi se potaknuo napredak. Popperova epistemologija imala je značajan utjecaj na filozofiju znanosti, a njegove ideje i danas se raspravljaju u kontekstu znanstvene metodologije.

Rasprava o metodologiji znanstvenog rada ponekad se smatra nepotrebnom s obzirom na tvrdnje da je vrijednije stjecanje znanstvenog iskustva od obilnih teoretskih razmatranja, stoga

se preporučuje izbjegavanje suvišnog teoretiziranja te poticanje znanstvenika da razvijaju vlastite metodološke pristupe za rješavanje konkretnih teorijskih i praktičnih izazova koristeći svoj intelektualni potencijal maksimalno. Ovakav pristup podrazumijeva ne gubljenje vremena na razmatranje same prirode znanosti, njezinog podrijetla, poželjnih karakteristika, primjene određenih metoda, svrhe ili postizanja konačnih ciljeva.

Podršku ovakvom razmišljanju pružaju i primjeri iz drugih kreativnih djelatnosti poput slikanja, komponiranja, pisanja pjesama, inovacija, političkih uspona, diplomatskih izazova, ratnih sukoba, sportskih natjecanja i slično. Ti primjeri ukazuju na to da izuzetni uspjesi nisu uvijek rezultat stroge primjene numeriranih, objektiviziranih, metodički definiranih i institucionaliziranih racionalnih pravila.

Dodatna potpora ovom pristupu može se pronaći i u drugim argumentima. Indikativna je usporedba metodologije znanstvenog rada s anatomijom (poznavanje anatomije nije presudno za svakodnevno korištenje vlastitih nogu). Pokušaj svjesne kontrole vlastitog kretanja, uz promišljanje brojnih anatomske činjenice, može biti kontraproduktivan za hodaње.

Važno je napomenuti da nisu svi aspekti znanstvene aktivnosti potpuno poznati te da ne postoji instantna znanstvena metoda kojom bi se, poput korištenja računala, jednostavno unosili podaci. Znanstvena metoda omogućava svjesno istraživanje svijeta povezujući teoriju i praksu, prethodna saznanja o objektu i racionalno tumačenje novih spoznaja. Ona pruža okvir za rješavanje izazova koji su previše kompleksni da bi se razumjeli samo zdravim razumom.

Metodologija znanstvenog rada ima teorijski, tehnički i organizacijski dio.

- *Teorijski dio metodologije* sastoji se od izučavanja logičke strukturiranosti znanstvenih zakona, teorija i hipoteza; promišljanja o znanstvenoj spoznaji, istini, slučaju, vjerojatnosti, otkrićima, izumima te o stilu, terminologiji itd.
- *Tehnički dio metodologije* posvećen je razmatranju postupaka, tehnika i opreme koji služe stjecanju znanstvenih podataka, njihovoj analizi i tumačenju.
- *Organizacijski dio metodologije* odnosi se na ustroj i rad znanstvenika i njihovih suradnika u raznim znanstvenim institucijama.

Rješavanje znanstvenih problema ostvaruje se nizom mješovitih *induktivno-deduktivnih postupaka*, koji su između procesa promatranja novog i korištenja već provjerenih činjenica. Točan postupak formalizira se kroz znanstvenu metodu koja se može zamisliti kao snažan i moćan sustav koji se kreće vrlo polako te radi temeljito, uporno, marljivo i sporo, ali nezaustavljivo. Uključuje zapisivanje svih podataka i formaliziranje svih pojedinosti, kako bi

se u svakom trenutku znalo od čega se krenulo. Zapisuje se opis problema, dosadašnja znanja, razne pretpostavke, pokusi, rezultati istraživanja i zaključci.

Postoje opći metodološki principi znanstvenog rada koji su zajednički svim znanostima, ali i svaka znanost (npr. medicina, fizika), kao i skupina znanosti (npr. prirodne i društvene), ima svoje specifične metodološke principe.

Preciznost pojma „**znanstvena metoda**“ dodatno se smanjuje činjenicom da se pod njim može podrazumijevati i metoda koja je specifična samo za neko znanstveno područje (npr. za fiziologiju ili astronomiju) pa čak i za neku skupinu istraživača ili pojedinog znanstvenika.

Postoje brojne znanstvene metode za određivanje nekog markera u tkivu mozga ili u krvi koje se nazivaju imenom osobe koja ju je tehnički razradila i uvela u praksu.

Belak, 2005. navodi „najčešće primijenjene metode znanstvenog istraživanja“:

- induktivna i deduktivna,
- metoda analize i sinteze,
- metoda apstrakcije i konkretizacije,
- metoda generalizacije i specijalizacije,
- metoda dokazivanja i opovrgavanja,
- metoda klasifikacije i metoda deskripcije,
- metoda kompilacije i komparativna metoda,
- statistička i matematička metoda,
- metoda modeliranja,
- kibernetička metoda,
- eksperimentalna metoda,
- dijalektička metoda,
- povijesna metoda, genetička metoda,
- teorija sustava kao metoda,
- aksiomska metoda,
- metoda idealnih tipova i empirijska metoda,
- metoda studija slučaja,
- metoda anketiranja i intervjuiranja,

- metoda opažanja,
- metoda brojenja i mjerenja,
- Delfi metoda,
- metoda „mozaika” i ostale znanstvene metode.

4.4. Metode znanstvenog istraživanja

Induktivna metoda

Induktivna metoda sustavna je primjena induktivnog načina zaključivanja kojim se na temelju analize pojedinačnih činjenica dolazi do zaključka o općem sudu, od zapažanja konkretnih pojedinačnih slučajeva dolazi do općih zaključaka.

Pouzdanost induktivnog zaključka izravno ovisi o: broju istraženih činjenica i slučajeva, reprezentativnosti analiziranih činjenica za određenu pojavu i stupnju pouzdanosti značenja činjenica. Analiza induktivne metode mora uključiti fundamentalni element svakog induktivnog zaključivanja (Dročić, 2013).

Prema istom izvoru, postoji više vrsta indukcije:

- **Potpuna indukcija** - zaključak na potpunom nabrojanju svih pojedinačnih slučajeva. U praksi se vrlo rijetko primjenjuje, a rezultat znači samo sistematiziranje znanja. Kod ove indukcije zaključak je potpuno istinit.
- **Nepotpuna indukcija** stvara zaključke na temelju analize ograničenog broja pojedinačnih pojava koji su primjenjivi na ostale pojave iste vrste. Češće se upotrebljava u znanstvenom istraživanju nego potpuna indukcija.
- **Predikativna indukcija** proces je mišljenja koje se odvija kroz zaključivanje od jedne klase pojava na drugu klasu, pri čemu se samo zaključivanje temelji na sličnosti klasa pojava.
- **Analogijska indukcija** temelji se na zaključivanju primjenom analogije, pri čemu se mišljenje kreće od pojedinačne na pojedinačnu pojavu.
- **Univerzalna indukcija** temelji se na zaključivanju od egzemplarne klase pojava na univerzalnu klasu.
- **Kauzalna indukcija** analizira uzročnu vezu između pojava koje prethode i pojava koje slijede čime se određuju uzročno-posljedični odnosi. Temelj za primjenu induktivnih metoda su opažanje, eksperiment i simulacija.

Deduktivna metoda

Deduktivna metoda sustavna je primjena deduktivnog načina zaključivanja u kojemu se iz općih sudova izvode posebni i pojedinačni zaključci. Dedukcija uvijek pretpostavlja poznavanje općih znanja na temelju kojih se spoznaje ono posebno ili pojedinačno. Najvažniji elementi deduktivne metode jesu postupci metoda analize, sinteze, apstrakcije, generalizacije i specijalizacije.

Deduktivna metoda u znanosti služi za objašnjenje činjenica i zakona, predviđanje budućih događaja, otkrivanje novih činjenica i zakona, dokazivanje postavljenih teza, provjeravanje hipoteza i za znanstveno izlaganje.

Poseban je oblik deduktivne metode je **aksiomatska metoda** koja se temelji na spoznajama, činjenicama ili načelima (aksiomi) koji se ne mogu dokazati ili koji ne zahtijevaju dokazivanje jer su očvidni ili su izravno očiti. Dedukcija vrijedi samo u okviru utemeljenosti na znanstvenim činjenicama.

Indukcija i dedukcija imaju zajednički opći predmet: to je spoznaja jedne pojave kao dijalektičkoga jedinstva općeg i posebnog. Indukcijom i dedukcijom saznaje se veza, odnos, jedinstvo posebnog i općeg i tim svojim obilježjima one su izrazito dijalektičke metode spoznaja. Indukcija je početni, a dedukcija završni proces u znanstvenim spoznajama jer spoznaja počinje pojedinačnom spoznajom posebnog, a završava deduktivnom sistematskom spoznajom posebnog na temelju općeg.

Metoda analize

Metoda analize postupak je znanstvenog istraživanja raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente. Analiza je, prema Hegelu, postupak mišljenja u kretanju od posebnoga k općem ili izvođenje teorema iz aksioma po utvrđenim pravilima. Analiza je proces redukcije nejednakoga na sve veću jednakost. Prema **gnoseološkoj funkciji** postoje dvije vrste analize: *deskriptivna*, kada se opisuju elementi neke cjeline i *eksplikativna*, kada se pokušava objasniti određena cjelina na temelju njezinih dijelova.

Metoda sinteze

Metoda sinteze postupak je znanstvenog istraživanja i objašnjavanja stvarnosti putem sinteze jednostavnih sudova u složenije. Sinteza je proces uopćavanja u kojemu nastaju sve apstraktniji pojmovi u uspoređivanju s prethodnim pojmovima.

Sinteza je način sistematiziranja znanja po zakonitostima formalne logike kao proces izgradnje teorijskog znanja u pravcu od posebnog k općem, odnosno od vrste prema rodu. Prema *gnoseološkoj* funkciji postoji deskriptivna i ekspukativna sinteza. Prema složenosti razlikuju se: elementarna, kauzalna i funkcionalna sinteza. Prema cilju, odnosno usmjerenosti spoznaja, sinteza može biti: genetička i strukturalna.

Metoda apstrakcije

Apstrakcija je misaoni postupak bilo kakvog odvajanja, bilo odvajanje općeg i eliminiranje posebnog, bilo misaoni postupak odvajanja posebnog i individualnog, zanemarivanje općeg. Apstrakcija ima dvostruki smisao: apstrakcija općeg ili apstrakcija posebnog. Apstrakcijom se odvajaju nebitni od bitnih elemenata pojave ili predmeta istraživanja. Apstrakcija počiva na analizi, ali analiza kao postupak nastavljanja, predstavlja i odvajanje, apstrakciju dijelova iz cjeline pojave.

Metoda konkretizacije

Konkretizacija je postupak suprotan apstrakciji. Konkretizacija može biti: shvaćanje jedinstva apstraktno-općeg u posebnom i individualnom, shvaćanje jedinstva apstraktno-posebnog s općim u svakom predmetu ili pojavi. Bilo da se određuje apstraktno-opće u posebnom ili apstraktno-posebno u općem, pomoću općeg vrši se konkretizacija jer se predmet istraživanja konkretno shvaća kao realno jedinstvo općeg i posebnog.

Metoda generalizacije

Metoda generalizacije misaoni je postupak uopćavanja kojim se od jednog posebnog pojma dolazi do općenitijeg koji je po stupnju viši od ostalih pojedinačnih. Od pojedinačnih opažanja izvode se uopćeni zaključci, koji su realni samo ako imaju oslonac u stvarnosti.

Metoda specijalizacije

Metoda specijalizacije postupak je kojim se od općeg pojma dolazi do novog pojma manjeg opsega a većeg sadržaja. Specijalizacija se temelji na analitičko-sintetičkoj metodi i apstraktno-konkretiziranoj metodi. Da bi se tom metodom došlo od općeg do posebnog, potrebno je izvršiti: konkretizaciju općeg u posebno, sintezu, apstrakciju posebnog iz općeg i analizu stvarnog općeg.

Metoda dokazivanja

Dokazivanje je jedna od najvažnijih znanstvenih metoda u kojoj su inkorporirane skoro sve metode i svi posebni metodički postupci: analiza i sinteza, generalizacija i specijalizacija,

indukcija i dedukcija, apstrakcija i konkretizacija. Svrha metode je utvrditi točnost neke spoznaje.

Metoda opovrgavanja

Suprotan postupak u odnosu na postupak dokazivanja je *opovrgavanje* ili *falsifikacija*. To je zapravo metodički postupak kojim se umjesto dokazivanja teze ona odbacuje i pobija. Ono se sastoji u dokazivanju pogrešnosti teze.

Izravno ili direktno opovrgavanje sastoji se u pobijanju teze ili argumentacije. Teza se izravno opovrgava onda kada se cijeli postupak pobijanja usmjerava na samu tezu ne uzimajući u obzir njezinu suprotnost, odnosno antitezu.

Neizravno ili indirektno opovrgavanje sastoji se od dokaza netočnosti teze neizravnim putem. O neizravnom opovrgavanju radi se onda kada se cijeli postupak usmjerava u dokazivanju da je antiteza ispravna umjesto da se kao u izravnom opovrgavanju usmjerava na samu tezu. Opovrgavanje teze pomoću dokazivanja točnosti antiteze naziva se apagogički dokaz. Kod opovrgavanja pretpostavlja se uzajamno isključivanje teze i antiteze, odnosno nemogućnost istodobne istinitosti oba suprotna stava (nemogućnost aporije).

Metoda klasifikacije

Metoda klasifikacije najstarija je i najjednostavnija znanstvena metoda. Klasifikacija je sistematska i potpuna podjela općega pojma na posebne u okviru opsega pojma. Znanost počinje klasifikacijom. Klasifikacija predstavlja sustave skupina predmeta ili raspodjele niza srodnih pojava. Tako se pojam znanosti klasificira na pojedinačne i univerzalne znanosti. Pojedinačne se klasificiraju u realne i formalne. Realne se dalje dijele u prirodne i kulturne.

Metoda deskripcije

Metoda deskripcije postupak je jednostavnog opisivanja ili očitavanja činjenica, procesa i predmeta u prirodi i društvu te njihovih empirijskih potvrđivanja odnosa i veza, ali bez znanstvenog tumačenja i objašnjavanja. Ova se metoda primjenjuje u početnoj fazi znanstvenog istraživanja. Ona ima veću vrijednost ako je jednostavno opisivanje povezano s objašnjenjima o uočenim važnijim obilježjima opisivanih činjenica, predmeta i procesa te njihovih zakonitosti i uzročnih veza i odnosa.

Metoda kompilacije

Metoda kompilacije predstavlja postupak preuzimanja tuđih rezultata znanstveno istraživačkog rada, odnosno tuđih opažanja, stavova, zaključaka i spoznaja. Metoda

kompilacije može se upotrijebiti u kombinaciji s drugim metodama u znanstvenoistraživačkom radu. Djelo nosi u što većoj mjeri osobni pečat autora kompilatora koji će uz osobni pristup pisanju znanstvenog ili stručnog djela korektno i na uobičajen način citirati sve ono što je od drugih preuzeo.

Komparativna metoda

Komparativna metoda postupak je uspoređivanja istih i srodnih pojava ili utvrđivanja njihove sličnosti u ponašanju i intenzitetu. Ova metoda omogućuje istraživačima da dođu do raznih uopćavanja, novih zaključaka koji obogaćuju spoznaju.

Statistička metoda

Statistička metoda može se nazvati i općeznanstvenom metodom; u novije vrijeme postala je jedna od najvažnijih znanstvenih metoda; često se koristi u znanstvenoistraživačkom radu u svim znanstvenim područjima.

Istraživanja u znanstvenim područjima društvenih i humanističkih znanosti nezamisliva su bez primjene statističke metode.

Prema Serdaru (1977.): „Statistika je znanost o metodama za istraživanje masovnih pojava pomoću brojčanog izražavanja.“ Čaval, 1981. ovako definira statističku metodu: „Statistika je znanost o metodama pomoću kojih analiziramo pojave koje nas okružuju, tako da pomoću grafikona i izračunatih pokazatelja otkrivamo njihove strukture, karakteristike i zakonitosti u pojedinim vremenskim intervalima te uzročno-posljedične veze između tih pojava.“

Statistička je metoda induktivno-generalizatorska jer se na temelju obilježja određenog broja elemenata neke skupine ili serije pojava izvodi opći zaključak o prosječnoj vrijednosti obilježja, devijaciji od srednje vrijednosti.

Važnost statističke metode je u tome što se jedino pomoću statističke metode mogu na prihvatljivo egzaktn način saznati opća određenost, pravilnosti i zakonitosti masovnih pojava. Najvažniji nedostaci statističke metode su kvantitativna, numerička određenost pojava i pitanje mogućnosti spoznaje općega na temelju pojedinačnog i posebnog.

Metoda uzoraka

Ispitivanje dijela skupa na temelju slučajnog izbora jedinica naziva se metoda uzoraka. Vrlo se često primjenjuje u znanstvenoistraživačkom radu. Bit metode uzoraka stav je da se relevantne statističke informacije o masovnoj pojavi mogu odrediti na temelju malog uzorka. Neki broj slučajno odabranih jedinica iz statističkog skupa naziva se uzorkom.

Problemi pouzdanosti metode uzoraka svode se na određivanje veličine uzorka i reprezentativnosti odabranih jedinica.

Matematička metoda

Matematička je metoda znanstveni sustavni postupak koji se sastoji u primjeni matematičke logike, matematičkih relacija, matematičkih simbola i matematičkih operacija u znanstvenoistraživačkom radu. Ta se metoda može primjenjivati u svim znanstvenim područjima i znanstvenim disciplinama. Pomoću matematičke metode na egzaktn način prikazuju se i objašnjavaju zakonitosti pojava pod uvjetom da je odabran pouzdan i adekvatan matematički model predmeta istraživanja.

Najčešće matematičke metode su matematički modeli i *metode simulacije*. Metode simulacije omogućavaju, uz uporabu računala, teorijsko simuliranje stvarnih pojava i procesa. Problem simulacija je u vjerodostojnosti geneze simulacijskog fenomena.

Metoda modeliranja

Metoda modeliranja istraživački je postupak pomoću kojega se generira znakovni sustav (model) koji može zamijeniti stvarnu pojavu i koji se eksperimentalno ili simulacijom može istraživati te prenositi dobivene podatke s modela na realnu pojavu. Modeliranje ima dvije poteškoće: adekvatnost modela realne pojave i ispravnost ekstrapolacije dobivenih rezultata s modela na realnu pojavu (Aganović i Veselić, 2014).

Modeli mogu biti:

- model stvarnog u idealnom (svaki pojam ili sud o realnim pojavama);
- model konkretnog u apstraktnom (apstraktni model predstavlja svaka generalizacija konkretnih pojmova, matematička formula);
- model idealnog u realnom (realne modele predstavljaju interpretacije pojmova, stavova, stvarnih funkcija i algoritama u čulno-opažajnim i fizičkim predmetima, sustavima, odnosima);
- model apstraktnog u konkretnom (konkretni modele predstavljaju sve konkretizacije i specijalizacije apstraktnih pojmova i stavova).

Modeli mogu biti:

- teorijski ili apstraktni modeli (logički i matematički modeli izraženi relacijama);
- praktični ili konkretni modeli (rezultati neke praktične djelatnosti);
- realni modeli (model kontejnerskog broda);

- idealni modeli (modeli koji na idealiziran način predstavljaju originalne predmete);
- jednostavni modeli;
- složeni modeli;
- modeli strukture (modeli koji predstavljaju strukturu pojave);
- funkcionalni modeli (predstavljaju funkcije dinamičkih sustava);
- djelomični modeli (modeli koji predstavljaju samo neka obilježja pojave);
- globalni modeli (modeli koji predstavljaju cjelinu pojave);
- analitički modeli (modeli koji se sastoje od skupa analitičkih relacija u obliku jednadžbi i nejednadžbi, kojima se matematički modeliraju dinamički procesi ili ponašanje složenih dinamičkih sustava);
- topološki i mrežni modeli (prostorni modeli procesa);
- deterministički modeli (potpuni i funkcionalno cjeloviti modeli) i stohastički i statistički modeli (modeli slučajnih i vjerojatnih događaja).

Kibernetička metoda

Pojam kibernetika potječe od grčke riječi *kybernao* što u slobodnom prijevodu znači 'upravljati, vladati'. U teoriju i praksu pojam kibernetike uveo je Norbert Wiener. Bit metode je teorija poruka i komunikacija. Kibernetika kao znanstvena metoda može biti teorijska ili opća kibernetika (opća načela i zakonitosti upravljanja na najvišoj razini apstrakcije) i primijenjena.

Eksperimentalna metoda

Eksperimentalna metoda postupak je promatranja pojave koja se ispituje pod točno određenim uvjetima koji dopuštaju da se prati tijek pojave i da se ona svaki puta uz ponavljanje tih uvjeta ponovno izazove. Ona se zasniva na eksperimentu kao znanstveno postavljenom pokusu. Znanstveni je eksperiment plansko, organizirano i metodsko proizvođenje, izvođenje ili samo mjerenje realnih pojava koji imaju za cilj otkrića nepoznatih činitelja, svojstava i odnosa pojava, odnosno provjeravanja hipoteza o tim činiteljima i njihovim svojstvima.

Ta metoda jedna je od najosnovnijih i najvažnijih znanstvenih metoda jedinstvenog teorijskog i praktično znanstvenog saznanja. Osnovni faktori eksperimentalne metode su: eksperimentator, eksperimentalna pojava (fenomen, događaj), sredstva eksperimenta, eksperimentalni postupak, prognoza i kontrolni eksperimentalni događaj, rezultati eksperimenta i potvrda hipoteze i ekstrapolacija rezultata u realne uvjete.

Razvoj znanosti, posebno u 20. stoljeću, temeljio se na eksperimentu kao metodi. Problem je eksperimenta vjerodostojnost određivanja eksperimentalnog fenomena.

Povijesna metoda

Povijesna metoda postupak je kojim se na temelju dokumenata i materijalnih ostataka ili dokaza, manje ili više, egzaktno rekonstruiraju događaji koji su se zbili u prošlosti.

Povijesna metoda uzima u obzir kronologiju, razvoj i uzročno-posljedične veze o predmetu istraživanja. Metoda se najčešće upotrebljava u društvenom i humanističkom znanstvenom području (povijest, filozofija), a rjeđe u drugim znanstvenim područjima.

Teorija sustava kao metoda

Teorija sustava novija je znanstvena disciplina. Nastala je u okviru kibernetike kao znanosti o upravljanju i informacijama. Pod pojmom **sustava** podrazumijeva se ukupnost međusobno, sinergijski povezanih i interaktivnih elemenata. Za teoriju sustava kao znanstvenu metodu značajno je da analizira cjelinu kao interakciju podsustava. Teorija sustava u novije vrijeme postala je determinanta mnogim znanstvenim područjima. Ona pomoću svojih osnovnih načela utvrđuje zakonitosti koje se javljaju u sustavima.

Osnova teorije sustava je sustavno mišljenje, a to je, zapravo, mišljenje prema kojemu se svaki problem, svaka pojava, svaki dio realnog svijeta promatra kao sustav. Sustavno je mišljenje utemeljeno na brojnim načelima na kojima se razvija suvremena teorija sustava.

Temeljna načela sustava:

- sve je sustav (sustav može predstavljati sve ono što je sastavljeno od najmanje dvaju dijelova pod uvjetom sinergije dijelova).
- svaki sustav istodobno je sustav više razine i sustav niže razine, sinergizam (od „syn“ = s, sa + „ergon“ = djelo) u usmjerenoj interakciji, dinamičko promatranje pojava (jedinstvo prostora i vremena funkcije sustava), relativnost svih pojava i odnosa,
- holističko (cjelovito) promatranje i rješavanje problema (od „holos“ - sav, potpun).

Aksiomska metoda

Aksiomska metoda razvila se iz klasične metode dedukcije, za razliku od eksperimentalne koja se razvila iz indukcije. Ova je metoda suvremeni oblik deduktivne metode, od koje se razlikuje po tome što aksiomska metoda koristi brojne i raznovrsne postupke formalizacije. Svrha je aksiomske metode postizanje korektnosti definicije i dokaza koji isključivo ovise o njihovim strukturama.

Temeljna aksiomska pravila:

- pravilo konzistentnosti (svi aksiomi jednog aksiomskog sustava moraju činiti logičan koherentan sustav);
- pravilo cjelovitosti (sustav aksioma mora biti cjelovit);
- pravilo neovisnosti aksioma (aksiomi jednog sustava aksioma moraju biti neovisni tako što ni jedan aksiom ne smije biti izveden iz drugih aksioma u sustavu).

Metoda idealnih tipova

Metoda idealnih tipova je misaona apstraktna konstrukcija jednostrano naglašenih svojstava neke pojave određenih s određenog teorijskog stajališta. Idealni tip jest apstraktni teorijski model određene vrste pojave. Metoda ima ograničenu primjenu u znanstvenoistraživačkom radu. Može se primjenjivati u filozofiji, politologiji, ekonomiji i drugim znanstvenim poljima društvenih i humanističkih znanosti.

Metoda brojanja i mjerenja

Brojanje je postupak kojim se utvrđuje broj elemenata ili članova nekog skupa ili klase. Brojanje nije moguće u okviru kontinuiranih cjelina. Moguće je samo u znanstvenom istraživanju skupova u kojima ima sličnih predmeta. To znači da brojanje pretpostavlja postojanje klasa, tj. postojanje predmeta koji su različiti, a ipak u nečemu slični. U rezultatu brojanja zanemarene su kvalitativne razlike među predmetima koji čine neki skup, a ostaje samo njihov broj. Kad je brojanje velikih skupina neizvedivo, primjenjuje se statistička metoda uzoraka. Brojanje je postupak znanstvenog otkrića jer se na taj način može doći do podataka potrebnih za tvorbu hipoteze.

Brojanje i mjerenje osnova su za sva mjerljiva istraživanja, a susreću se u svim područjima znanosti. G. Galilei je istaknuo: broji ono što se može brojiti, mjeri ono što se može mjeriti, a što nije mjerljivo, učini mjerljivim. I lord Kelvin je rekao: „Ako se ono o čemu govorite može izmjeriti, onda nešto o tome i znate. Ako to ne možete izmjeriti niti izraziti u brojkama, onda je vaše znanje mršavo i nezadovoljavajuće: to može biti tek početak znanja, ali vi po načinu mišljenja niste još doprli do znanstvene faze, ma o čemu da se radi“.

Mjerenje se definira kao postupak kojim se uz pomoć mjerila utvrđuje brojčana vrijednost nekog ekstenzivnog svojstva ili kao uspoređivanje dviju istovrsnih veličina, tako da se utvrdi njihov omjer. Za međusobnu usporedivost rezultata potrebno je odrediti mjernu jedinicu. *Mjerna jedinica* definirana je konstantna vrijednost fizikalne veličine, koja ima poseban naziv. Mjeriti znači odrediti koliko mjernih jedinica sadrži neka veličina. Izmjerena vrijednost je

vrijednost u granicama točnosti koja se može ostvariti. Razlika između izmjerene i stvarne vrijednosti fizikalne veličine naziva se apsolutna pogreška mjerenja. U praksi postoji i relativna pogreška kao omjer apsolutne pogreške i stvarne veličine.

U znanstvenoistraživačkom radu isključivo je u uporabi Međunarodni sustav mjernih jedinica (SI). Osnovna značajka tog sustava je potpuna koherentnost svih mjernih jedinica. SI sustav obuhvaća mjerne jedinice za sva znanstvena područja.

Delfi metoda

Delfi metoda je metoda za prognoziranje. Delfi metoda prvotno se najviše koristila za predviđanje budućih međunarodnih situacija i potencijalnih ratnih stanja, ali se ubrzo počela primjenjivati u prognoziranju tehničkog i tehnološkog razvoja.

Metoda se sastoji u organiziranom i sustavnom prikupljanju predviđanja tima eksperata, stoga predstavlja metodu sustavne primjene znanstvenog mišljenja u postupku donošenja važnih odluka o budućnosti različitih pojava i fenomena. Logika Delfi metode sustavno je korištenje mišljenja eksperata čime se simuliraju buduće pojave ili prilično pouzdanu projekciju budućih pojava.

Primjena matematičkih modela u istraživanju (poljoprivreda i tehnički sustavi)

Matematički modeli igraju ulogu u analizi, predviđanju i optimizaciji različitih aspekata poljoprivredne proizvodnje.

Područja u kojima se matematički modeli često koriste (Creswell, 2009):

- **Upravljanje resursima:** matematički modeli mogu se koristiti za optimizaciju upravljanja resursima kao što su voda, gnojiva i pesticidi. Ti modeli pomažu u određivanju optimalnih količina i vremena primjene smanjujući gubitke i negativan utjecaj na okoliš.
- **Agroklimatologija:** modeli klimatskih sustava pomažu u analizi i predviđanju klimatskih uvjeta te utječu na prinose i usjeve. Ti modeli pomažu poljoprivrednicima u prilagodbi svojih praksi promjenama u klimi.
- **Optimizacija uzgoja biljaka:** matematički modeli mogu simulirati rast biljaka uzimajući u obzir različite faktore poput vode, svjetlosti, temperature i hranjivih tvari. Ti modeli pomažu u identifikaciji optimalnih uvjeta za rast i prinose.
- **Genetsko inženjerstvo:** matematički modeli igraju ključnu ulogu u analizi genetskih podataka, simulaciji genskih interakcija i predviđanju svojstava novih genotipova. To pomaže u ubrzanju razvoja novih sorti biljaka.

- **Precizna poljoprivreda:** korištenjem tehnologija poput GIT/GIS i GNSS/GPS-a i senzora, matematički modeli pomažu u preciznom upravljanju poljoprivrednim strojevima i resursima, čime se smanjuje potrošnja i povećava učinkovitost.
- **Ekonomska analiza:** modeli ekonomske analize koriste se za procjenu troškova i dobiti u poljoprivredi. Oni pomažu poljoprivrednicima i istraživačima u donošenju informiranih odluka o najučinkovitijim pristupima poljoprivrednoj proizvodnji.
- **Vodeći modeli:** ovi modeli analiziraju dinamiku poljoprivrednih sustava i pomažu u razumijevanju kako različiti čimbenici utječu na produktivnost i održivost.
- **Modeli zaštite bilja:** matematički modeli koriste se za simulaciju širenja bolesti i štetnika te pružaju smjernice za učinkovite strategije zaštite bilja.

Korištenje matematičkih modela u agrobiotehnici omogućuje bolje razumijevanje kompleksnih interakcija unutar poljoprivrednih sustava, optimizaciju praksi i smanjenje negativnog utjecaja na okoliš. Ova interdisciplinarna primjena pomaže u postizanju održive poljoprivrede i poboljšava učinkovitost poljoprivredne proizvodnje.

5. ORGANIZACIJA ZNANSTVENOG ISTRAŽIVANJA

5.1. Prikupljanje literature

Kako bi se razvio teorijski okvir koji će biti polazište istraživanja, postavilo izazovne istraživačke ciljeve i hipoteze rada, usporedilo vlastite nalaze s nalazima drugih te povezal nalaze s teorijom, treba proučiti svu značajnu literaturu (Janović, 2009).

Pod značajnom literaturom podrazumijevaju se:

- temeljna djela iz nekog područja,
- djela ključnih autora iz nekog područja,
- najznačajnija djela u nekom području,
- aktualna djela iz nekog područja te
- djela iz područja koja su objavljena u Hrvatskoj.

Ocjenjivanje rada često je povezano s kvalitetom literature koja se koristi kao osnovni referentni okvir. Ova evaluacija obuhvaća proučavanje temeljnih djela iz određenog područja, tj. radova u kojima su postavljene početne teorije, modeli, definicije i slično. Primjerice, ako se istražuju teorije menadžmenta, preporuča se analiza radova klasičnih teoretičara poput Taylora ili Fayola kao početne točke. Nakon toga, trebalo bi istražiti radove autora koji su se bavili istraživanjem područja rada uključujući i ona koja sadrže značajne nalaze i zaključke.

Bitno je pratiti trenutne trendove istraživanja u određenom području uključujući najnovije radove objavljene na temu. Primjerice, u današnjem kontekstu upravljanja karijerom, istraživanje upravljanja talentima ima poseban značaj.

Vlastiti rad treba odražavati duboko razumijevanje radova hrvatskih autora te rezultata istraživanja provedenih u Hrvatskoj. Aktivno uključivanje u domaću literaturu i istraživanja dodatno će ojačati argumentaciju i doprinijeti sveobuhvatnosti rada.

Pri prikupljanju literature treba voditi računa i o najčešćim pogreškama koje umanjuju kvalitetu.

- izvori literature koji nisu povezani s područjem istraživanja,
- preopćeniti izvori literature (iz najšireg područja),
- popularna literatura iz šireg područja koja je rubno povezana s područjem,
- izostavljanje članaka (pisanje isključivo na temelju knjiga),
- zastarjeli izvori literature,

- izvori literature isključivo na hrvatskom jeziku,
- naprećac prikupljeni izvori literature,
- premalo izvora literature.

Jedna od čestih pogrešaka u procesu prikupljanja literature jest nedovoljan broj referenci. Kada se piše seminarski rad, preporučuje se koristiti barem 15 značajnih izvora, dok za diplomski rad ne bi trebalo biti manje od 30. Ako se piše specijalistički poslijediplomski rad, vjerojatno će biti potrebno proučiti oko 40 važnih izvora, odnosno čak 50 za magistarski rad. Konačno, za doktorski rad, vjerojatno će biti nužno pregledati ne manje od 150 relevantnih izvora kako bi se temeljito obradila tema.

S obzirom na to da nema područja o kojem nije pisano te da postoji puno povezanih istraživanja, glavni izazov često leži u tome kako izmijeniti „hrpu“ dostupnog materijala i izdvojiti bitno. Važno je naglasiti da kvaliteta rada značajno ovisi o kvaliteti proučavane literature. Da bi se istraživalo nešto novo, potrebno je prvo razumjeti ono već poznato. Da bi se napravio sveobuhvatan pregled postojeće literature i dostupnih nalaza, bit će potrebno pregledati značajan broj literaturnih izvora.

Kako bi se provelo metodološki „čisto“ istraživanje, treba proučiti kako su drugi istraživali koncepte koje se namjerava istražiti.

1. Određivanje ključnih riječi putem kojih će se pretraživati
2. Pretraživanje knjižnice
3. Pretraživanje elektronskih baza te pretraživanje ostalih internetskih stranica
4. Odluka o publikacijama koje treba dodatno nabaviti

Digitalne znanstvene baze predstavljaju ključnu infrastrukturu za pohranu, organizaciju i pristup znanstvenim podacima. Ove baze omogućuju istraživačima, akademskim zajednicama i drugim stručnjacima da pristupaju relevantnim informacijama za svoja istraživanja.

Dano je nekoliko popularnih digitalnih baza znanstvenih publikacija:

- **PubMed** je besplatan pretraživač medicinskih istraživanja i članaka. Pruža pristup velikom broju članaka iz područja biomedicine i povezanih znanosti.
- **IEEE Xplore** digitalna je biblioteka koja sadrži članke, konferencijske radove i standarde iz područja elektrotehnike, računarstva, inženjeringa i srodnih disciplina.

- **ScienceDirect**, izdavač *Elsevier*, pruža pristup velikom broju znanstvenih članaka iz različitih disciplina uključujući prirodne znanosti, biomedicinu i druge.
- **JSTOR** je digitalna biblioteka koja sadrži širok spektar znanstvenih radova, članaka i knjiga iz različitih disciplina uključujući humanističke znanosti, društvene znanosti i prirodne znanosti.
- **Scopus** izdavač je *Elsevier*, pruža pretraživač za znanstvene članke, knjige i konferencijske radove iz različitih disciplina.
- **Web of Science** pruža pristup citatima i sažecima znanstvenih članaka, pomažući istraživačima pratiti citate i utjecaj pojedinih radova.
- **arXiv** je repozitorij predtiskanih znanstvenih radova u području fizike, matematike, računarstva i drugih znanstvenih disciplina.
- **Nature Research Journals** obuhvaća niz časopisa koji pokrivaju širok spektar znanstvenih disciplina uključujući prirodne znanosti, biologiju, kemiju i druge.
- **SpringerLink** pruža pristup znanstvenim člancima, knjigama i konferencijskim radovima iz različitih disciplina, uključujući prirodne znanosti, inženjering, medicinu i druge.
- **ERIC** je baza podataka koja pruža pristup istraživanjima u području obrazovanja uključujući članke, knjige i izvještaje.

Ove digitalne znanstvene baze čine ključnu podršku istraživačima diljem svijeta, omogućujući im pristup relevantnim informacijama, praćenje najnovijih istraživanja i dijalog s drugim znanstvenicima u njihovu polju.

Određivanje ključnih riječi

Bez ključnih riječi nije moguće pretraživati elektronske baze (časopisa, knjiga, magistarskih radova, doktorskih disertacija itd.), predmetne kataloge (tiskane kartične odnosno digitalne kataloge na internetu ili drugim medijima), naručivati publikacije (knjige, članke itd.) preko interneta, pretraživati knjige i slično.

Ključne riječi su u pravilu: naziv područja, nazivi koncepata koji se stavljaju u odnos, geografsko područje od interesa, imena autora i slično.

Danas su programi za pretraživanje sve sofisticiraniji pa tako npr. „*Napredno pretraživanje*“ nudi pretraživanje putem ključnih riječi cijelog teksta, samo naslova, sažetka ili ključnih riječi publikacije, pretraživanje po časopisima, DOI i ISSN brojevima, kronološki itd. Čak i ako se pretraga ograniči na neki od ovih načina, treba paziti da pri određivanju ključnih riječi ne bude

preširokih, upiše li se, primjerice, kao ključnu riječ „financije“ ili „turizam“, prosječna će baza izlistati više od milijun referenci. Čak i ukoliko se pretraga ograniči na način da se traže reference kod kojih se ta riječ nalazi u naslovu rada, opet će se „dobiti“ bezbroj referenci.

Pretraživanje knjižnica

Nastavlja se pretraživanjem knjižnica (biblioteka) i to pretraživanjem njihovih kataloga te njihovom fizičkom pretragom. Pretraživanje kataloga knjižnica, dakle tiskanih i digitalnih, pojedinačnih ili skupnih kataloga knjižnica, omogućuje se dolazak do daljnjih bibliografskih referenci, odnosno informacija o objavljenim publikacijama (sekundarni izvori informacija).

Postoje različite vrste kataloga: katalozi knjiga, katalozi časopisa, katalozi materijala sa znanstvenih i stručnih skupova (npr. Index of Conference Proceedings Received, Directory of Published Proceedings), katalozi magistarskih radova (npr. Masters Abstracts International) te katalozi doktorskih radova (npr. Index of Theses, Dissertation Abstracts Online) itd.

Značajnim katalogom smatra se katalog Current Contents - CC koji navodi najznačajnije svjetske časopise iz različitih područja (unutar CC-a za područje društvenih znanosti od posebnog je interesa katalog Current Contents / Social & Behavioral Sciences).

U Hrvatskoj je zanimljiv i skupni katalog hrvatskih knjižnica CROLIST. Fizičko pretraživanje knjižnice smatra se vrlo korisnim jer pregledavanjem polica na kojima se nalaze knjige iz šireg područja kojim se bavite dobiva se širina, a prelistavanjem najnovijih brojeva ključnih časopisa saznaju se aktualne teme.

Pretraživanje elektronskih baza, pretraživanje ostalih internetskih stranica

Pretraživanjem interneta, odnosno elektronskih baza i drugih internetskih stranica, može se doći do najrazličitijih izvora literature i podataka.

Pretraga elektronskih baza jedan je od lakših koraka s obzirom na to da su elektronske baze dostupne, a mnoge od njih i besplatne. Baze podataka koje se mogu pretraživati baze su časopisa, elektronskih knjiga, magistarskih radova, doktorskih radova, bibliografske baze, baze statističkih podataka itd.

Pri odabiru elektronskih baza koje će se pretraživati potrebno je posavjetovati se s mentorom. On je najbolje upućen u baze u kojima su zastupljeni najznačajniji časopisi iz područja kojim se bavi kandidat.

Posebnu pozornost treba posvetiti pretraživanju najboljih svjetskih časopisa iz ciljanog područja, kao što su časopisi koji imaju visoke faktore odjeka, najcitiraniji časopisi (npr. zbog

toga što objavljuju zanimljiva istraživanja, daju izvrsne meta analize područja i sl.), časopisi kojih su urednici ugledni znanstvenici i slično.

Kako časopisi izlaze brže od knjiga, najnovija istraživanja mogu se pronaći upravo u njima. U člancima se, u pravilu, daju puno dublje analize područja te su zahvaljujući njihovoj lakšoj i češćoj digitalizaciji dostupniji od knjiga. Iz svih navedenih razloga, nezamislivo je pisati znanstveni ili stručni rad isključivo na temelju knjiga.

Kvaliteta znanstvenih i stručnih časopisa mjeri se tzv. faktorom odjeka (engl. **impact factor**). Faktor odjeka pokazatelj je vrijednosti (značajnosti, kvalitete) nekog časopisa jer, s obzirom na to da se izračunava na temelju toga koliko su puta neki časopis, odnosno članci u njemu citirani, pokazuje koji se časopisi (radovi) u svijetu smatraju značajnima.

Faktori odjeka časopisa u svijetu jednom se godišnje objavljuju u publikaciji **Journal Citation Reports**. Potrebno je pretražiti baze s tercijarnim izvorima informacija. Tercijarni izvori informacija, kao oni koji se bave citiranošću znanstvenih i stručnih djela, ukazuju na najznačajnija djela u nekom području. Ona djela koja se najviše citiraju, a upravo to ovi izvori informacija prate, zasigurno su najvrednija djela u području. Iz tog bi se razloga trebali potruditi do njih doći te ih koristiti u radu.

Najčešće korišteni tercijarni izvori informacija dostupni i u digitalnom obliku putem interneta i u tiskanom obliku su Science Citation Index (SCI), Social Science Citation Index (SSCI) i British Humanities Index.

Osim elektronskih baza, putem interneta pretražuju se i druge internetske stranice sa zanimljivim podacima, informacijama i publikacijama:

- internetske stranice organizacija svih vrsta,
- internetske stranice tiskovina (dnevni novina, tjednika),
- internetske stranice različitih građanskih, vladinih i globalnih inicijativa,
- online enciklopedije (najpoznatija *Wikipedia*),
- besplatne elektronske knjige (npr. *Google books*),
- online časopisi (časopisi koji izlaze samo u digitalnom obliku, kao npr. *Electronic Journal of Knowledge Management*),
- cjelovite verzije znanstvenih ili stručnih radova u pdf formatu koje autori objavljuju na vlastite internetske stranice,
- baze sa statističkim podacima različitih globalnih i državnih institucija (CROSTAT,

Hrvatski državni zavod za statistiku, Eurostat, LABORSTA).

Pri pretraživanju interneta treba imati u vidu da internet treba uzeti s rezervom. On, naime, ima dvije velike mane: veliki broj podataka i neselektivnost s obzirom na kvalitetu objavljenog materijala. To može dovesti do pretrpanosti informacijama sumnjive kvalitete.

Odluka o publikacijama koje je dodatno potrebno nabaviti

Pristup publikacijama može se ostvariti posuđivanjem iz knjižnica, putem međuknjižnične posudbe ili kupnjom u fizičkim ili online knjižarama.

British Library jedna je od najpoznatijih knjižnica na svijetu koja sudjeluje u međuknjižničnim razmjenama.

Online knjižara Amzom.com predstavlja jednu od najpoznatijih online platformi gdje se mogu kupiti raznovrsne publikacije poput knjiga, članaka i baza podataka.

Kako bi se pronašli novi relevantni izvori, preporučuje se analiza literature korištene u djelima koja se proučavaju s oprezom da to ne postane beskrajna zadaća. S obzirom na to da literaturni podaci iz jednog članka često upućuju na druge izvore, važno je imati na umu da svaki od njih ima vlastite izvore. Osim udžbenika i priručnika, koristite ih prvenstveno za osnovno upoznavanje s područjem, a ne kao glavne izvore za rad (Tkalac i suradnici, 2003).

Važno je razumjeti da nisu svi članci jednako „teški“. Članci u znanstvenim časopisima kategorizirani kao Q1 i Q2 imaju veću težinu od članaka u dnevnim tiskovinama ili stručnim časopisima. Starost publikacije nije nužno znak njezine zastarjelosti, a mnoga važna djela napisana su davno. Internet podatke valja pažljivo provjeriti jer nisu uvijek točni ili provjereni, a često su preuzeti iz drugih izvora bez označavanja izvora.

Kada se pretražuju relevantni literaturni izvori, korisno je ograničiti pretraživanje na članke s ključnim riječima u naslovu. Pri pretraživanju skupnih elektronskih baza, može se iskoristiti opcija istovremenog pretraživanja kako bi se povećale šanse za pronalazak traženog.

Treba pratiti novosti iz područja interesa putem listi novoobjavljenih publikacija koje objavljuju knjižnice u tiskanom ili digitalnom obliku, stoga je potrebno prijaviti se na internetske servise elektronskih baza.

Nakon što se pronađu relevantni izvori, treba racionalno pristupiti ispisivanju, izbjegavajući automatski ispis svake publikacije koja se pronađe. Prva selekcija treba se temeljiti na naslovu, godini objavljivanja i autoru, druga na sažetku i ključnim riječima, a treća na dijelovima teksta ili cjelokupnom sadržaju.

Vlastita knjižnica iz područja interesa trebala bi biti jedan od početnih koraka u prikupljanju literature, a sustavnu analizu literature olakšava vođenje bilješki tijekom proučavanja literature.

Bilješke čine građu na temelju koje se izrađuje analiza literature, ali su važne i zbog toga što će se nakon što se prikupila i proučila velika količina materijala, vjerojatno teško sjetiti gdje je nešto pročitano.

Pravljenje bilješki uključuje kako vađenje dijelova literarne građe koja će se koristiti u pisanju rada, tako i precizno bilježenje izvora. Posebno je važno zabilježiti otkuda je nešto izvađeno jer, protekom vremena, može se zaključiti da se radi o vlastitim mislima te tuđi tekst predstaviti kao vlastiti - *plagiranje*.

Najčešći načini izrade bilješki:

- bilježenje u literarnoj građi - podcrtavanje i označavanje teksta od značenja te bilježenje vlastitih razmišljanja na marginama publikacije koja se proučava,
- kartične bilješke - prepisivanje teksta, koji će se koristiti, na kartice koje se sortiraju prema područjima kojima pripadaju i jednostavno pregrupiraju te
- računalna izrada bilješki - prepisivanje teksta u računalne datoteke prema temama (danas olakšano zahvaljujući softverskim rješenjima).

Pri pravljenju bilješki važno je ne promijeniti značenje teksta koji se preuzima. Pri prevođenju, prepričavanju, kompiliranju teksta i slično nije rijedak slučaj da se nenamjerno promijeni smisao izvornog teksta.

Izvore bilješki uputno je navoditi odmah na način na koji će se navoditi korištena literatura. Tako se naporan i vremenski zahtjevan proces navođenja i izrade popisa korištene literature cijepa u manje, podnošljivije dijelove.

5.2. Definiranje ciljeva i istraživačkih pitanja

Ciljevi istraživanja služe tome da čitatelje informiraju o onome što se želi postići istraživanjem, stoga je ključno jasno i precizno formulirati ciljeve.

Studenti često definiraju ciljeve istraživanja ili previše općenito ili s prevelikim ambicijama, kao što je proučavanje uloge interneta u hrvatskim organizacijama. Takvi široko postavljeni ciljevi odražavaju nedostatak dubljeg razumijevanja područja istraživanja i često su neostvarivi.

Ciljevi istraživanja mogu (ali i ne moraju) biti podijeljeni na glavne i pomoćne.

Glavni cilj istraživanja predstavlja krajnje određenje smjera istraživanja. Primjerice, glavni cilj može biti komparativna analiza fiskalnih sustava u Republici Hrvatskoj i EU ili razvoj mjernog instrumenta za mjerenje zadovoljstva internom komunikacijom. Definiranjem glavnog cilja trebalo bi postati jasno što se istraživanjem želi istražiti ili otkriti.

Nakon što je glavni cilj postavljen, pomoćni ciljevi trebaju se odnositi na specifične aspekte teme koji su relevantni u okviru istraživanja. Ključno je da svi ciljevi, kako glavni tako i *pomoćni*, budu jezično jasni, nedvojbeno formulirani i sadrže akcijski orijentirane riječi poput 'odrediti', 'utvrditi', 'procijeniti', 'izmjeriti', 'istražiti' i slično.

Ciljevi istraživanja, bez obzira na vrstu istraživanja, trebali bi biti sročeni na način da jasno i cjelovito izraze namjeru. Primjerice, u opisnom istraživanju glavni cilj trebao bi jasno opisati svrhu istraživanja, dok bi u korelacijskom istraživanju cilj trebao uključivati varijable koje se povezuju. Ako se u istraživanju testiraju hipoteze, cilj bi trebao definirati predviđeni smjer povezanosti.

Istraživačko pitanje igra ključnu ulogu u istraživačkom procesu i određuje kvalitetu cjelokupnog projekta. Ono se postavlja na početku svakog istraživanja i predstavlja pitanje na koje se ne može jednostavno odgovoriti, a odgovor se očekuje kroz istraživanje. Razlika između ciljeva i istraživačkih pitanja leži u načinu na koji su formulirani. Dok su istraživačka pitanja doslovno pitanja, ciljevi ih pretvaraju u operativne zadatke koristeći akcijski orijentirane riječi poput 'pronaći', 'odrediti' ili 'analizirati'.

Neki istraživači preferiraju krenuti od ciljeva i oblikovati istraživačka pitanja, dok drugi koriste samo istraživačka pitanja bez ciljeva. Primjeri istraživačkih pitanja uključuju jesu li muški menadžeri (unutar određene populacije) zadovoljniji poslom od ženskih, kako djeca pamte elemente komunikacijske poruke u usporedbi s odraslima ili utječe li broj informacija u oglasu na pamtljivost tog oglasa.

Studenti najčešće nemaju dovoljno metodoloških znanja za kvalitetno definiranje istraživačkih pitanja, zato je taj zadatak vrlo težak. Pri definiranju istraživačkog pitanja potrebno je razgovarati s mentorom.

Proces definiranja istraživačkog pitanja sastoji se od niza koraka. Prolazak kroz navedene korake pretpostavlja određenu razinu znanja o širem području istraživanja.

Kratak pregled značajne literature pomaže u širenju baze znanja. Bez tog znanja teško je jasno i kvalitetno analizirati područje istraživanja.

Definiranje istraživačkog pitanja najuže je povezano s definiranjem područja istraživanja, teme istraživanja i ciljeva istraživanja.

Tablica 1. Primjeri pogrešno i ispravno definiranih istraživačkih pitanja

Pogrešno definirana istraživačka pitanje	Ispravno definirana istraživačka pitanja
Utječu li medijske objave na ponašanje ljudi?	Postoji li povezanost između frekvencije negativnih objava u medijima i stavova javnosti prema subjektu objava?
Jesu li žene bolji menadžeri?	Postoji li razlika u stavu podređenih prema spolu nadređenih, odnosno imaju li žene pozitivniji stav prema ženskim menadžerima, a muškarci prema muškim?

U ovom koraku trebalo bi se pitati: „Što je to što studenta zanima u definiranom području, odnosno potpodručju?“

Unutar odabranog potpodručja, prvo treba navesti sva pitanja na koja treba odgovoriti. Ukoliko se bude u situaciji u kojoj se može smisliti previše pitanja, ponovno treba proći kroz proces odbacivanja kao i u koraku broj 3.

1. identificirati,
2. razdijeliti,
3. odabrati,
4. oblikovati glavne i pomoćne ciljeve. Ciljevi proizlaze iz istraživačkih pitanja.
5. Potrebno je jasno procijeniti vlastite ciljeve, analizirati ih kako bi se procijenila njihova ostvarivost kroz istraživanje. Treba ih promotriti kroz potrebno vrijeme, resurse (financijske i ljudske) i tehničku podršku koja je na raspolaganju.
6. Nakon nekog vremena treba još jednom promisliti i donijeti zaključke; postoji li dovoljno zainteresiranosti za temu te postoje li odgovarajući resursi kako bi ih se istražilo.

5.2.1. Operacionalizacija

Istraživačko pitanje - treba precizno definirati područje koje će istraživanje obuhvatiti. U formiranju istraživačkog pitanja može se koristiti apstraktne pojmove koji su teško mjerljivi ili čije razumijevanje varira. U takvim situacijama posebno je važno razviti, definirati ili

uspostaviti pravila i mjere kojima se jasno određuje značenje tih pojmova. Ponekad je bitno precizno definirati populaciju iz koje se prikupljaju tražene informacije.

Primjerice, „Izmjeriti razliku u razini stresa kod muških i ženskih menadžera“, „Provjeriti razlike u percepciji obuhvata funkcije korporativnih komunikacija kod direktora marketinga i direktora odnosa s javnošću“, „Provjeriti uspješnost programa za obrazovanje računovođa“. Iako su navedeni ciljevi jasno definirali glavni smjer istraživanja, nisu dovoljno precizno definirali glavne varijable mjerenja. Važno je odrediti tko su muški i ženski menadžeri ili, primjerice, računovođe. Treba razjasniti obujam, odnosno je li riječ o svim menadžerima u Hrvatskoj ili samo onima u određenim veličinama poduzeća te na kojoj menadžerskoj razini rade itd. U ovakvim slučajevima potrebno je razviti *operacionalizacije*, odnosno operativne definicije varijabli koje se istražuju kao i definicije populacije koja se istražuje.

Ključni termini i varijable trebaju biti jasno definirani kako bi se izbjegle nejasnoće. Ovaj cilj postiže se razvojem operativnih, odnosno radnih definicija. Operativne definicije mogu se razlikovati od rječničkih definicija i svakodnevnih značenja. Iako se u svakodnevnom govoru često koriste pojmovi poput uspješnosti, stava ili stručnosti, u istraživanju ih je potrebno preciznije definirati. Operativne definicije pružaju jasno značenje koncepta i populacijama koje se istražuju. Samo jasnom definicijom korištenih postupaka može se vjerodostojno opisati, objasniti i provjeriti određena procedura, uz napomenu da ne postoje čvrsta pravila koja bi odlučivala o vjerodostojnosti operativne definicije (Sikavica, 2008).

5.3. Oblikovanje i vrste hipoteza

Nakon određivanja problema istraživanja sljedeći je korak formiranje hipoteza.

Hipoteza pridonosi jasnoći i preciznosti ciljeva istraživanja, no nije obavezna za provedbu istraživanja. Moguće je provesti valjano istraživanje i bez izrade formalne hipoteze. Unutar konteksta istraživanja može se sastaviti koliko god se hipoteza smatra potrebnim. Hipoteze proizlaze iz seta pretpostavki koje se testiraju u okviru istraživanja. Ako istraživanje nema određeni set pretpostavki, hipoteze nisu nužne (Tkalac i suradnici, 2003).

Naziv „hipoteza“ dolazi od grčkih riječi „*hypo*“ što znači ispod i „*thesis*“ što znači ideja. Doslovni prijevod bio bi „podloga ideje“ ili „podloga rješenja“.

Hipoteza je specifična tvrdnja u obliku predviđanja, koja često povezuje dvije varijable. Ona uvijek proizlazi iz ciljeva ili istraživačkog pitanja. Hipoteza je privremeni, provizorni odgovor na pitanje koji istraživanjem treba potvrditi ili odbaciti.

Na početku istraživanja nema unaprijed poznatog odgovora o tome kako neki fenomen, situacija ili program utječu na pojedince ili skupine iako se često kreće s određenim pretpostavkama. Te pretpostavke (hipoteze) testiraju se prikupljanjem informacija koje omogućuju zaključak jesu li bile točne ili ne. Postavljanje hipoteza obično slijedi nakon prikupljanja dovoljno odgovora na pitanja koja definiraju znanstveni problem.

Hipoteze nisu nužne za istraživanje, ali donose jasniji i precizniji smjer prema cilju istraživanja. One su pretpostavke, ideje ili sumnje o fenomenu, odnosu ili situaciji, čija se stvarnost ne poznaje te služe kao privremena objašnjenja određenih činjenica.

Testiranje hipoteza statistički je postupak kojim se određuje u kojoj mjeri raspoloživi podaci podržavaju postavljenu pretpostavku. Istraživač takve pretpostavke naziva hipotezama, a one čine osnovu istraživanja.

U većini slučajeva, hipoteze se temelje na prethodnim istraživanjima. Ključno je osigurati da hipoteze budu jasne, jednodimenzionalne i koriste jasno definirane i valjane operacionalne pojmove kako bi se omogućila vjerodostojna provjera. Nejasne su hipoteze teško empirijski provjerljive, stoga je važno da budu jednodimenzionalne, fokusirane samo na jedan odnos..

Primjeri:

Hipoteza: Prosječna dob muških studenata u skupini viša je od prosječne dobi ženskih studenata.

Navedena hipoteza je jasna, specifična i jednostavna za testiranje. Govori o tome što se želi provjeriti (prosječnu dob u skupini), koje se populacije uspoređuju (muška i ženska) i što se želi utvrditi (višu dob muških studenata) s druge strane.

Hipoteza: Ukupni uspjeh tijekom studija povezan je s dobi i spolom studenata.

Ova hipoteza je jasna, no nije jednodimenzionalna. Sto napraviti ako je uspjeh povezan s dobi, ali ne i spolom; hoće li hipotezu prihvatiti ili odbaciti? U takvim je slučajevima bolje navedenu hipotezu razdvojiti u dvije odvojene hipoteze. Time će se ujedno izbjeći pogreška „djelomičnog prihvatanja hipoteze“.

Hipoteza: Ukupni uspjeh tijekom studija povezan je s dobi studenata.

Hipoteze moraju biti specifične. Općenite hipoteze grandioznog opsega najčešće su neprovjerljive iako se čine impresivnima i vrijednima. Što je općenitija hipoteza, lakše je upasti u zamku korištenja selektivnih dokaza.

Hipoteza: Poduzeća koja provode upravljanje događanjima u svojim poduzećima ostvaruju veću konkurentsku prednost, koja se očituje u boljem prepoznavanju njihovih proizvoda, boljem plasmanu na tržištu i većom ostvarenom dobiti.

Ovakvu je hipotezu nemoguće provjeriti budući da govori o više različitih odnosa, a sastoji se od koncepata koje je teško pretvoriti u varijable i ne govori izričito i jednoznačno ni o kakvom odnosu. Nikada se ne smiju brkati teze od kojih istraživač polazi s hipotezama koje u načelu definiraju odnos između dviju varijabli.

Za razliku od prethodne hipoteze, ispravno bi bilo postaviti, primjerice, sljedeću hipotezu:

Hipoteza: Učestalost provođenja upravljanja događajima značajno je povezana i dobiti organizacije.

Hipotezu bi trebalo moći operacionalizirati i moći provjeriti. Ovo znači da je hipotezu potrebno izraziti u mjerljivim terminima. Ukoliko se hipoteza ne može izmjeriti, odnosno ne može biti testirana, iz nje se ne može izvući nikakav zaključak. Uz to, moraju postojati metode i tehnike za provjeru hipoteze.

Nema smisla sastavljati hipoteze koje je nemoguće provjeriti zato što za to ne postoje tehnike. Kako bi se provjerila sljedeća hipoteza?

Hipoteza: Poduzeća organiziraju događanja te primjenjujući elemente kreiranja doživljaja i proizvoda i događanja izravno utječu na diferencijaciju poduzeća i stvaranje konkurentске prednosti.

Svi koncepti u hipotezi moraju biti operacionalizirani, odnosno operativno definirani i oblikovani u varijable. Ako svi navedeni dijelovi hipoteze nisu jasno definirani, odnosno ukoliko nije definiran način kojim će se mjeriti, hipoteza ponovno postaje neprovjerljiva i time neispravna.

Hipoteza bi trebala biti povezana s postojećim znanstvenim spoznajama. Važno je da hipoteza izvire iz postojećih spoznaja i da ih širi budući da je to jedan od osnovnih ciljeva znanstvenog rada.

Nove znanstvene spoznaje moguće su samo ako su hipoteze istraživanja zasnovane na postojećim znanstvenim spoznajama.

Nakon sastavljanja hipoteze vlastitog istraživanja uvažavajući sva prethodna pravila, još jednom je potrebno provjeriti ima li svaka hipoteza sljedeća osnovna obilježja:

1. Uključuje (barem) dvije varijable,
2. Uspostavlja odnos među varijablama,
3. Ima oblik tvrdnje,
4. Logički je povezana s teorijskim okvirom i istraživačkim pitanjem,
5. Moguće ju je podvrgnuti provjeri statističke značajnosti.

5.3.1. Vrste hipoteza

Svaka pretpostavka koja se želi provjeriti putem ispitivanja naziva se **hipoteza**. Stoga, teorijski bi trebala postojati samo jedna vrsta hipoteze - hipoteza istraživanja, osnova rada. Zbog uobičajenih konvencija u znanstvenom istraživanju i zbog jezične konstrukcije u sastavljanju hipoteza hipoteze mogu biti klasificirane u jednu od više kategorija.

Prema istom izvoru, postoje dvije kategorije hipoteza; nulhipoteze i alternativne hipoteze. Nulhipoteza (najčešće se označava s H_0) hipoteza je prema kojoj ne postoji odnos među fenomenima, varijablama ili pojavama koje istražujemo. Alternativna hipoteza (najčešće se označava s H) hipoteza je prema kojoj postoji određena vrsta odnosa među fenomenima, varijablama ili pojavama koje istražujemo. Alternativna hipoteza može biti oblikovana na više načina (dvostrano, odnosno da postoji određena povezanost, ali smjer te povezanosti nije jasan ili jednostrano - smjer povezanosti unaprijed je definiran i tada se takva hipoteza naziva direktivnom hipotezom). Hipoteze se mogu izražavati na više različitih načina. Primjerice, želi li se istražiti odnos između različitih vrsta argumenata u poruci i kanala poruke na uspješnost te poruke.

Postoji nekoliko načina za oblikovanje hipoteze:

- Hipoteza: Ne postoji statistički značajna razlika između različitih kombinacija vrste argumenata u poruci i medija prenošenja poruke.
- Hipoteza: Kvalitetni argumenti postići će statistički značajno uspješniju poruku korištenjem perifernih kanala.
- Hipoteza: Kvaliteta argumenata dva puta više utječe na uspješnost prenošenja poruke od kanala poruke.

Želi li se istražiti uzroke pušenja u određenoj populaciji s obzirom na spol moguće su sljedeće hipoteze:

- Hipoteza: Ne postoji statistički značajna razlika u proporciji muških i ženskih pušača

u ispitivanoj populaciji.

- Hipoteza: U ispitivanoj populaciji veća je proporcija žena pušača od proporcije muškaraca pušača.
- Hipoteza: U ispitivanoj populaciji ukupni je postotak od 60 % muškaraca i 30 % žena koje puše.
- Hipoteza: U ispitivanoj populaciji dva puta je više ženskih pušača nego muških pušača.

U obama opisanim primjerima način na koji je prva hipoteza oblikovana označava da nema razlika među imenovanim varijablama, dakle za ispitivani odnos predstavlja nulhipotezu.

Druga hipoteza u obama primjerima pretpostavlja da postoji razlika ili u količini utjecaja ili u različitim modalitetima varijable.

Hipoteza kojom istraživač procjenjuje da će biti razlike, ali ne procjenjuje intenzitet te razlike naziva se hipoteza razlike. Ako istraživač dovoljno poznaje područje istraživanja da smatra kako može procijeniti intenzitet utjecaja, postavlja hipotezu koja se naziva hipoteza točke prevalencije. Četvrti tip hipoteze naziva se asocijativna hipoteza. Savjeti:

- Ne moraju sva istraživanja imati hipoteze.
- Istraživanje može imati jednu ili više hipoteza (ne postoji pravilo o ispravnom broju hipoteza).
- Cilj oblikovanja i provjere hipoteze najčešće je provjera teorije.
- Hipoteze nastaju dedukcijom iz teorije ili poopćavanjem empirijski opaženih pravilnosti.
- Formulacija hipoteze omogućava istraživanju da bude fokusirano.
- Hipoteza implicira koje specifične aspekte problema trebate istražiti.
- Hipoteza pomaže odabrati koje podatke trebate skupiti, a koje ne.
- Hipoteza povećava objektivnost istraživanja.
- Hipoteza može pomoći u oblikovanju teorije time što omogućava da specifično zaključite što je istinito, a što nije.
- Tvrdnje koje su logički nužno istinite ne mogu biti znanstvene hipoteze.

Pitanja na koja nije moguće odgovoriti kroz znanstveno opažanje ne mogu biti znanstvena.

5.4. Obrada i analiza podataka

Znanje statistike pretpostavka je za znanstveni i stručni rad. Četiri su razloga zbog kojih oni koji se bave znanstvenim ili stručnim radom trebaju poznavati statistiku:

- kako bi se moglo pratiti znanstvenu i stručnu literaturu,
- kako bi mogli planirati svoja istraživanja,
- kako bi znali obraditi podatke prikupljene istraživanjem u svrhu njihove analize te
- kako bi se moglo zaključivati o dobivenim rezultatima. Kvaliteta znanstvenog, odnosno stručnog rada posebice je ugrožena u trima slučajevima.

Ako istraživač ne poznaje statistiku u fazi postavljanja ciljeva i hipoteze rada, u kojem slučaju oni ne mogu biti ostvareni bez obzira na odabir statističke metode. Oni koji ne znaju statistiku naručuju obradu ne poznajući njezine mogućnosti ili kada oni kod kojih se naručuje obrada ne poznaju logiku procesa istraživanja za koje obrađuju podatke.

5.4.1. Osnovni statistički pojmovi i postupci

Deskriptivna statistika obuhvaća postupke grupiranja većeg broja informacija o jedinicama statističkih skupova (podskupova) i služi isključivo za sistematiziranje i opisivanje neke pojave, no ne i stavljanje varijabli u odnos (Petz, 1997). Ona omogućuje prikaz osnovnih nalaza istraživanja i pripremu, odnosno izračun vrijednosti potrebnih za analizu odnosa između varijabli.

Najčešće korišteni deskriptivni statistički postupci u znanstvenom ili stručnom radu su izračunavanje apsolutnih i relativnih frekvencija i kumulativnih nizova, izračuni srednjih vrijednosti te izračuni mjera disperzije (McClaver, 1994.; Cramer, 1997.; Bryman i Cramer, 1997.; Creswell, 2009.; Meyers i suradnici, 2005.).

Apsolutne i relativne frekvencije te izračuni kumulativnih nizova načini su uređenja i sažimanja podataka. Srednje vrijednosti (odnosno mjere centralne tendencije) konstante su kojima se predstavljaju nizovi varijabilnih podataka. Najčešće izračunavana srednja vrijednost zasigurno je aritmetička sredina, no tu su još i geometrijska sredina, harmonijska sredina, mod i medijan. Za uočavanje karakteristika podataka nije dostatno proučiti njihovu tendenciju gomilanja (srednje vrijednosti), već je značajna i informacija o njihovu stupnju varijabilnosti. Za to služe mjere disperzije, kao što su raspon varijacije, varijanca, standardna devijacija, koeficijent varijacije i druge.

Aritmetička sredina ($\bar{x}$ ili M) – omjer zbroja svih rezultata i broja rezultata numeričke varijable. Primjenjuje se kako bi se izračunala prosječna vrijednost, npr. prosječna plaća, prosječna prodaja i sl.

Geometrijska sredina (G) N -ti - korijen iz umnožaka vrijednosti numeričke varijable. Primjenjuje se npr. u analizi vremenskih nizova jer omogućuje izračunavanje prosječne stope promjene pojave.

Harmonijska sredina (H) - recipročna vrijednost aritmetičke sredine recipročnih vrijednosti varijable X . Primjenjuje se za izračunavanje prosjeka odnosa, npr. produktivnost rada mjerena utroškom vremena po jedinici,

Mod (dominantna vrijednost) (M_o) - najčešći modalitet kvalitativne ili kvantitativne varijable, odnosno modalitet s najvećom frekvencijom. Primjenjuje se za izračunavanje najčešće vrijednosti, kao na primjer najčešće vrijednosti prodajne cijene, najčešćeg broja djece i sl.

Medijan (centralna vrijednost) (M_e) - vrijednost koja se u nizu rezultata poredanih po veličini nalazi točno u sredini, dakle dijeli niz na dva jednakobrojna dijela. Primjenjuje se kada se želi ukazati ispod, odnosno iznad koje se vrijednosti nalazi polovica niza, kao na primjer da polovica kućanstava ima troškove života niže od X , a druga polovica veće od X .

Raspon varijacija (R_x) - razlika između najveće i najmanje vrijednosti.

Varijanca (σ^2) - aritmetička sredina kvadrata odstupanja vrijednosti numeričke varijable X od njezine aritmetičke sredine, koja ukazuje na razlike između vrijednosti numeričke varijable i njezine aritmetičke sredine.

Standardna devijacija (σ) - prosječno odstupanje vrijednosti numeričke varijable od njezine aritmetičke sredine. Pozitivni drugi korijen iz varijance.

Koeficijent varijacije (V) - omjer standardne devijacije i aritmetičke sredine pomnožen sa sto. Relativna mjera disperzije.

Inferencijalna (analitička, matematička, induktivna) statistika odnosi se na postupke kojima se pomoću dijela informacija (uzorka) donose sudovi o karakteristikama cjeline (populacije) na temelju teorije vjerojatnosti, a u svrhu definiranja odnosa između varijabli. Inferencijalna statistika dalje se dijeli na parametrijsku i neparametrijsku statistiku.

Parametrijska statistika - za razliku od neparametrijske, provodi se ukoliko su zadovoljena sljedeća tri uvjeta:


- da su varijable intervalne ili omjerne, odnosno više nego ordinalne,
- da je distribucija populacije normalna i
- da su varijance obje varijable jednake ili homogene.

Parametrijski statistički testovi pretpostavljaju da su podaci distribuirani prema normalnoj distribuciji. Neki znanstvenici smatraju da se parametrijski testovi mogu koristiti i za analizu ordinalnih varijabli s obzirom na to da se testovi odnose na brojeve, a ne na ono što oni predstavljaju.

Temelj za provedbu parametrijske statistike je prisutnost *normalne distribucije*. Normalna distribucija (Gaussova, zvonolika, simetrična) je distribucija neke pojave kod koje rezultati pokazuju tendenciju grupiranja oko jedne središnje vrijednosti i tendenciju raspršivanja oko te vrijednosti.

Ona ima sljedeće karakteristike:

- (1) simetrična je, što znači da su njezine mjere asimetrije jednake nuli,
- (2) vrijednosti aritmetičke sredine, medijana i moda su jednake,
- (3) vjerojatnost da se normalno distribuirana slučajna varijabla nađe u intervalu $\mu \pm 1\sigma$ 68,27 %, u intervalu $\mu \pm 2\sigma$ je 95,45 %, a u intervalu $\mu \pm 3\sigma$ 99,73 %. Slika 8. prikazuje normalnu distribuciju i intervale jedne, dviju ili triju standardnih devijacija od aritmetičke sredine.



Slika 8. Normalna distribucija i intervale jedne, dviju ili triju standardnih devijacija (<https://stedy.hr/distribucije/normalna-distribucija>)

Na temelju normalne distribucije najlakše je shvatiti kada se hipoteze prihvaćaju, odnosno odbacuju. Područje prihvatanja nul-hipoteze, dakle hipoteze da ne postoje razlike između skupina, ishoda ili slično, središnje je područje, dok su područja odbacivanja rubna područja. Područje odbacivanja nul-hipoteze određeno je razinom značajnosti na kojoj se testira. Uspoređujući teorijsku razinu značajnosti (onu koju smo odredili kao vjerojatnost pogreške na koju pristajemo) i empirijsku razinu značajnosti (izračunatu na temelju podataka iz uzorka), prihvaća se, odnosno odbacujemo hipoteze.

U pravilu se hipoteze testiraju na razini značajnosti od 1 % ili 5 % (razina značajnosti od 1 % znači da je vjerojatnost da smo pogriješili samo 1 %). Uz stroži kriterij (1 %) izlaže se riziku da se neke razlike ne proglase značajnom iako ona zapravo postoji (pogreška tipa II.), a uz blaži kriterij (5 %) izlaže se riziku da neku razliku proglasimo značajnom, a da ona zapravo ne postoji (pogreška tipa I.).

Najčešće provedeni inferencijalni statistički postupci, osobito u društvenim istraživanjima, zasigurno su hi-kvadrat test, analiza varijance, korelacijska analiza i linearna regresija.

Hi-kvadrat (χ^2) test - test kojim se utvrđuje povezanost između dviju varijabli kvalitativnog tipa čije distribucije značajno odstupaju od normalne.

Analiza varijance - analiza koja se upotrebljava kada se želi utvrditi postoje li razlike između nekoliko aritmetičkih sredina, dakle npr. više skupina ispitanika.

Korelacijska analiza - analiza međusobne zavisnosti, odnosno povezanosti dviju varijabli.

Linearna regresija - analitički izraz odnosa između dviju pojava, u kojem vrijednosti pojave čije se varijacije objašnjavaju predstavljaju vrijednosti zavisne varijable Y, dok stvarne vrijednosti pojave kojom se objašnjava varijacija prve pojave predstavljaju vrijednost nezavisne varijable X.

5.5. Postupak obrade kvantitativnih podataka

Postupak obrade kvantitativnih podataka u širem smislu sastoji se od četiriju koraka:

1. odabira računalnog alata za obradu podataka,
2. unosa podataka,
3. odabira prikladnih metoda za obradu podataka i
4. statističke analize podataka.

5.5.1. Odabir računalnog alata za obradu podataka

Danas je obrada podataka značajno olakšana zahvaljujući tabličnim kalkulatorima (npr. Microsoft Office Excel) i statističkim programima (npr. SPSS, SAS, Statistika, Minitab, STATA, TSP). Tablični kalkulatori omogućuju provođenje različitih matematičkih, statističkih, financijskih, logičkih i drugih operacija nad prikupljenim podacima, kako na temelju ponuđenih formula tako i na temelju formula koje sami kreirate, te izradu različitih vrsta grafičkih prikaza. Statistički programi omogućuju provođenje svih poznatih statističkih metoda nad podacima te također izradu različitih vrsta grafičkih prikaza (Bryman i Cramer, 1997).

Odabir računalnog alata za obradu podataka ovisi o više elemenata, kao što su: dostupnost računalnog programa, blizina osobe koja se može uputiti u korištenje programa, dostupnost priručnika za korištenje, jednostavnost upotrebe, saznanje koji se program najčešće koristi u obradi podataka iz područja istraživanja, zahtjev od strane institucije/mentora itd.

5.5.2. Unos podataka

Podaci se trebaju unijeti uz pomoć računalnog programa u dokument tabličnog tipa (tablični kalkulator ili statistički program).

Zahvaljujući sve većoj kompatibilnosti računalnih programa, podatke možete preuzeti i iz postojeće digitalne baze te unijeti u program za statističku obradu podataka.

Prije unosa podataka u bazu potrebno je šifrirati protokol unosa i dokumente, putem kojih su prikupljeni podaci (anketni upitnici, zapisnici s intervjua i slično). Redoslijed unosa podataka potrebno je odrediti i zapisati (najbolje na prvom dokumentu iz kojeg se podaci unose u bazu), kako bi se svi podaci unosili istim redoslijedom te za lakše snalaženje u bazi. Dokumente iz kojih se unose podaci također je potrebno označiti. Označavaju se brojevima od I do n kako bi se uvijek moglo provjeriti koji se podaci u bazi odnose na koji od njih. Ovo je posebice važno kako bi se mogli provjeriti izvorni podaci (ako su podaci u bazi nelogični, očigledno je da su krivo uneseni), što je potrebno učiniti u skoro svakom istraživanju.

Varijabla se najčešće dodjeljuje kratak naziv koji se piše u zaglavlju tablice u koju se upisuju podaci te puni naziv koji se piše u za to predviđeno mjesto. Za potrebe obrade potrebno je kodirati nominalne varijable i ordinalne varijable koje nisu na skali od 1 do n. Kodirati nominalne varijable podrazumijeva da se svakoj mogućoj inačici varijable (npr., muško, žensko) dodijeli kod, tj. brojčanu vrijednost kojom će se označavati inačice (npr. muško = 1, žensko = 2). Ordinalne je varijable potrebno kodirati ukoliko se radi o skali koja kreće od minus

vrijednosti (npr., -7, -6 itd.). Pri kodiranju varijabli savjetuje se koristiti brojeve od 1 do n. Nulu se ne savjetuje koristiti, a najvećim brojem treba kodirati odgovore „ne znam“, „nemam informacija“ i sl. Podaci se upisuju po redovima, što znači da svaki red predstavlja podatke jednog ispitanika (jednog anketnog upitnika, jednog zapisnika s intervjua i slično).

5.5.3. Odabir prikladnih metoda za obradu podataka

Statističke metode moraju biti sukladne ciljevima i hipotezama istraživanja, a ovise o vrstama varijabli koje se analiziraju. Računalni programi za statističku obradu podataka obrađuju unesene podatke nevezano uz to jesu li oni „kvalitetni“ ili ne. „I najsloženije statističke analize moguće je kreirati na temelju veličina cipela ili veličina konfekcijskih brojeva zaposlenika različitih pogona nekog poduzeća, no ima li to ikakvog smisla?“ (Creswell, 2009).

Ako je cilj opisati neku pojavu, koristit će se statističke metode deskriptivne statistike. Ukoliko je cilj istražiti odnose između varijabli, odabir statističkih metoda koje će se koristiti ovisit će o tome što želite istražiti i koliko je varijabli uključeno u analizu.

Istraživači najčešće istražuju povezanost između varijabli, postojanje razlika između skupova ili agregiranju varijable (npr. koristeći faktorsku ili klaster analizu) te ovisno o broju istraživanih varijabli provode bivarijatne (dvije varijable) ili multivarijatne analize (tri i više varijabli).

Prema metodama koje se koriste, važno je koje su prirode varijable (McClave i Benson, 1994 i Šošić i Serdar, 1997).

Faktorska analiza - statistička metoda za analizu međuodnosa između velikog broja varijabli, objašnjavanje tih varijabli u smislu njihovih zajedničkih obilježja/dimenzija (faktora).

Višestruka (multipla) regresija - statistička metoda za predviđanje promjene zavisne varijable u odnosu na promjene nezavisne varijable, prikladna kada problem istraživanja uključuje jednu kvantitativnu (intervalnu ili omjernu) zavisnu varijablu za koju se pretpostavlja da je povezana s dvjema ili više kvantitativnih nezavisnih varijabli.

Višestruka (multipla) diskriminacijska analiza - statistička metoda koja se koristi kako bi se razumjele razlike između grupa i predvidjela vjerojatnost da jedan entitet (pojedinaac ili objekt) pripada nekoj grupi s obzirom na s njim povezane kvantitativne nezavisne varijable. Nju je prikladno koristiti kada je zavisna varijabla kvalitativna (nominalna ili ordinalna), a nezavisne varijable kvantitativne (intervalne ili omjerne).

Multivarijatna analiza varijance i kovarijance - statistička tehnika koja se koristi kako bi se istovremeno istražio odnos između više nominalnih nezavisnih varijabli i dviju ili više kvantitativnih zavisnih varijabli. Multivarijatna analiza kovarijance koristi se u kombinaciji s multivarijatnom analizom varijance kako bi se odstranio (nakon eksperimenta) utjecaj nekontroliranih kvantitativnih nezavisnih varijabli na zavisne varijable.

Kanonička korelacija - statistička metoda uz pomoć koje se istovremeno u odnos stavlja više kvantitativnih (intervalnih ili omjernih) zavisnih varijabli i više kvantitativnih nezavisnih varijabli.

Klaster analiza - analitička tehnika za određivanje smislenih podgrupa entiteta (pojedinaца ili objekata).

Multidimenzionalno skeniranje - statistička metoda sa svrhom pretvaranja mišljenja ispitanika u udaljenosti u multidimenzionalnom prostoru koja rezultira percepcijskom mapom koja pokazuje relativne položaje objekata.

Analiza podudarnosti - kompozicijski pristup percepcijskom mapiranju koji u odnos stavlja kategorije izkontingencijske tablice te u većini slučajeva rezultira percepcijskim mapama koje prikazuju i objekte i njihove atribute.

Linearni modeli vjerojatnosti - vrsta statističke analize u kojoj se jedna ili više kvalitativnih (nominalnih ili ordinalnih) ili kvantitativnih (intervalnih ili omjernih) nezavisnih varijabli koriste za predviđanje jedne kvalitativne zavisne varijable.

Modeliranje strukturnim jednadžbama - statistička metoda koja spaja višestruku regresiju i faktorsku analizu u svrhu istovremenog procjenjivanja/određivanja više međusobno povezanih zavisnih odnosa.

Većina statističkih metoda omogućuje istražiti postojanje povezanosti između varijabli, ali ne i uzročno-posljedični odnos između njih.

Primjerice, na temelju korelacijske analize može se zaključiti da postoji povezanost između uspjeha organizacije i razvijenosti menadžmenta ljudskih potencijala, no ne i da je organizacijski uspjeh posljedica velike brige za ljude. U drugom bi slučaju organizacije samo trebale poraditi na zadovoljavanju potreba zaposlenika i odmah bile uspješnije, što nije slučaj u praksi. Tako je potrebno u naslovu rada umjesto riječi „utjecaj“ (npr. Utjecaj MLJP-a na financijski uspjeh organizacija) koristiti riječ „povezanost“ (npr. Povezanost MLJP-a s financijskim uspjehom organizacija).

Statistička analiza podataka - zadatak je metodološki ispravno pristupiti obradi podataka, no nikako je ne učiniti samoj sebi svrhom.

Statistička analiza podataka najčešće se odvija u tri dijela: provjera o kojoj se vrsti distribucije radi, provođenje deskriptivne analize i provođenje statističkih obrada više razine.

Osim normalne distribucije, koja je pretpostavka za provođenje parametrijskih testiranja, poznatije distribucije varijabli još su i binomna, Poissonova, Studentova t-distribucija, F-distribucija i hi-kvadrat (χ^2) distribucija.

Kako bi se odredilo o kojoj je distribuciji riječ, ponekad je potrebno izbaciti ekstremne vrijednosti. Ekstremne vrijednosti ponekad je potrebno izbaciti i kako ne bi utjecale na rezultate statističkih analiza, kao što su izračuni srednjih vrijednosti i regresijske jednadžbe. Moguće ih je zamijetiti u grafičkim prikazima (npr., u Tukeyjevom B-P dijagramu). Još ih je bolje izbaciti s obzirom na njihovo odstupanje od prosjeka, odnosno standardnu devijaciju. Tako se kod manjih uzoraka ($n < 80$) savjetuje iz daljnje obrade izbaciti sve vrijednosti koje od prosjeka odstupaju više od 2.5σ , a kod većih uzoraka ($n > 80$) vrijednosti koje od prosjeka odstupaju više od 3 ili 4 σ .

Metode deskriptivne statističke analize, kao npr. neke prethodno ukratko opisane, služe kako za sumiranje i osnovno opisivanje pojava, tako i za pripremu podataka za potrebe zahtjevnijih statističkih analiza. Zahtjevnije statističke obrade, od koje je na neke također prethodno ukazano, provode se kako bi se istražilo povezanost između varijabli, uzročno-posljedične odnose, razlike između skupova, za agregiranje varijabli itd. Upravo su one temelj za prihvaćanje, odnosno odbacivanje postavljenih hipoteza te za zaključivanje o znanstvenom doprinosu vašeg istraživanja.

5.5.4. Interpretacija kvantitativnih nalaza

Kvantitativna, odnosno statistička obrada podataka provodi se u svrhu njihove analize. Obradeni podaci ne znače ništa ako ih se ne objasni. Prikupljeni i obrađeni podaci samo su materijal za analizu na temelju koje se donose zaključci, odnosno interpretiraju nalazi.

Interpretacija obrađenih podataka – rezultata odnosi se na:

1. dovođenje rezultata u vezu s hipotezama koje su postavljene,
2. razmišljanje o razlozima prihvaćanja/odbacivanja hipoteza.
3. utvrđivanje ograničenja istraživanja koja proizlaze iz prikupljenih podataka ili iz

postupaka primijenjenih u istraživanju,

4. dovođenje rezultata u vezu s rezultatima sličnih istraživanja,
5. planiranje budućih istraživanja, odnosno argumentiranje zašto i koja je daljnja istraživanja moguće ili potrebno provesti,
6. povezivanje prakse s teorijom, odnosno dovođenje u vezu provjerenih hipoteza s početnom teorijom.

Zahtijeva se kritičnost prema vlastitim hipotezama, prema metodama istraživanja, prema prikupljenim podacima te prema dobivenim rezultatima.

Statističke metode opisuju činjenice, ali ne objašnjavaju uzroke. Statističke se metode ne bave se dokazima, već vjerojatnošću. Pri interpretaciji rezultata ne treba biti kategoričan, već indikativan.

5.5.5. Obrada i analiza kvalitativnih podataka

Kvalitativna analiza pretvara podatke u informacije. Istraživač treba velike količine „sirovih“ podataka sažeti u interpretativne informacije na način da odvoji važne od manje važnih, otkrije značajne obrasce i predloži okvir kojim će komunicirati smisao i značenje informacija. Navedeno zahtijeva određena znanja, vještine i uvježbanost istraživača čemu mogu pridonijeti proučavanje postojećih istraživanja (osobito dijelovi vezani uz analizu i interpretaciju) te osobna i iskustva drugih (Creswell, 2009).

Svako je kvalitativno istraživanje jedinstveno i ovisno o istraživaču - analitičaru. To znači da će i proces obrade i analize biti jedinstven. Analitičar ima (etičku i istraživačku) obvezu što vjernije opisati postupke kojima je obradio i analizirao podatke.

Prije analize treba znati:

1. Analiza ovisi o svrsi istraživanja. Ukoliko je istraživanje akademskog karaktera, očekuje se da se formalno i rigorozno pristupi analitičkim procedurama. Istraživači s većim iskustvom mogu si dopustiti više slobode u analizi kvalitativnih podataka. Treba se dobro informirati o metodi koja se primjenjuje i načinima analize podataka koje su prikladne.
2. Analiza ovisi o kvaliteti, dubini i detaljnosti bilješki prikupljenih tijekom prikupljanja kvalitativnih podataka. U kvantitativnim istraživanjima procesi prikupljanja i analize podataka mogu se vrlo lako razgraničiti.

3. U kvalitativnim istraživanjima prikupljanje podataka zapravo je i početna faza njihove obrade i analize. Dodatne bilješke o atmosferi, ponašanju ili drugim specifičnostima obogatit će nalaze. Detaljnost bilješki dodat će značenje podacima i utjecati na kvalitetu tumačenja jer će dati odgovor na pitanje „zašto se nešto (nije) dogodilo?“.
4. Podatke treba organizirati u cjelinu i promatrati ih kao elemente cjeline. Istovremeno je potrebno uočavati obrasce, kako unutar jednog promatranja, slučaja ili intervjua, tako i među njima. Neki će podaci biti „isključivi“ ili bitno različiti od uočenog obrasca pa ih svakako treba dodatno analizirati i protumačiti. U osnovi, podaci nisu posebne kategorije (bas kao što „nitko nije otok“).

Postoje različiti načini organiziranja i prikazivanja kvalitativnih podataka. Oni ovise o tipu i svrsi istraživanja, a u nastavku predložene mogućnosti nisu međusobno isključive. U analizi i interpretaciji može se koristiti više mogućnosti. Kvalitativne podatke moguće je organizirati i prikazati na različite načine.

5.6. Prikaz rezultata istraživanja

Pri strukturiranju nalaza potrebna je kreativnost u njihovom opisivanju te dosljednost u njihovom grafičkom i tabličnom prikazivanju. Komentare rezultata treba ostaviti za raspravu. Prikazivanje rezultata izazovan je zadatak iz više razloga.

- Potrebno je sustavno prikazati veliku količinu informacija. S ovim se posebno „bore“ istraživači koji nemaju iskustva u pisanju radova. Rezultate koji se žele prikazati treba grupirati u logičke cjeline, koje su s jedne strane dovoljno velike da imaju smisla, a s druge strane dovoljno male da ih je moguće pratiti.
- Treba izbacivati nevažne informacije. Potrebno je prikazati isključivo podatke koji su u najužoj vezi s problemom rada. Osnovni kriterij za uključivanje dobivenih rezultata u tekst rada mora biti njihova značajnost. U njemu nema mjesta za digresije. On mora biti usko usmjeren na problem koji se istražuje.
- Treba prikazati samo smislene podatke na smislen način. Besmisleno je, primjerice, govoriti o postocima ili grafički prikazivati razlike u uzorku od 10 ispitanika.
- S obzirom na to da su rezultati glavni dio nove informacije koja se predočava znanstvenoj javnosti, oni moraju biti prikazani jasno, točno, pregledno i u potpunosti.

Pri iznošenju i opisivanju rezultata treba pisati razumljivim jezikom. Veću preglednost onoga što se prikazuje postići će se kombinacijom opisnog, tabličnog i grafičkog prikazivanja podataka, logičnim grupiranjem materije u podcjeline (potpoglavlja) te korištenjem dekadskog sustava označavanja dijelova rada.

- Rezultate je potrebno prikazati cjelovito. Potrebno je iznijeti sve značajne nalaze i ilustrativno ih prikazati (slikama i tablicama), opisati sve nalaze koje nije dostatno isključivo brojčano prikazati, uvrstiti sve brojčane podatke koji su potrebni kako bi informacija bila cjelovita. Potpunost prikazanih rezultata ne znači njihovo ponavljanje. Nepotrebno je detaljno opisivati ono što je jasno vidljivo u slikama i tablicama.
- Rezultate je potrebno prikazati logičnim redoslijedom za problem koji se izučava.

Tako je podatke moguće prikazivati:

- od najvažnijih do onih manje važnih.
- redoslijedom kojim su pobrojane hipoteze vašeg rada,
- kronološkim slijedom ili
- sukladno redoslijedu pitanja u instrumentu koji ste koristili pri istraživanju.

Tablice i slike dvije su vrste ilustracija, tj. priloga koji ilustriraju tekst.

Pod tablicama se podrazumijevaju mreže stupaca i redaka kojima se preglednije i na kraći način prikazuju najčešće brojčani podaci, ali i druge vrste podataka.

Slikama se nazivaju sve druge vrste ilustracija: grafikoni, sheme (dijagrami, organigrami i sl.), fotografije, crteži, karte itd.

Tablice i slike doprinose kvaliteti rada. One se ne izrađuju radi razbijanja monotonije, ne predstavljaju dodatak, već su zbog toga što omogućuju jasnije, sažetije i jednostavnije prikazivanje podataka, jednako važne kao i tekst rada.

Cilj pri izradi tablica i slika treba biti samodostatnost svake tablice odnosno slike. Čitatelj koji poznaje područje kojim se bavite, trebao bi moći razumjeti što prikazuje svaka vaša ilustracija bez čitanja ostatka teksta.

5.6.1. Tablično prikazivanje podataka

Tablice se koriste kako bi se sažeto prikazale velike količine podataka. U njima se najčešće prikazuju brojčani podaci koji su rezultat statističkih analiza - statističkih praćenja (kao na

primjer tablice u statističkim godišnjacima), deskriptivne statističke analize, provedenih statističkih testiranja i slično.

Osim brojčanih podataka, tablično se često prikazuju i deskriptivni, kvalitativni podaci, odnosno tekst. Tako se tablično sumiraju dosadašnja istraživanja iz nekog područja, navode prednosti i nedostaci nekog koncepta, daju objašnjenja brojčanih podataka i slično.

Tablice su pretežita vrsta ilustracija u znanstvenim časopisima. Tako se, primjerice, za prikazivanje obilježja uzorka ne koriste površinski grafikoni poput strukturnih krugova i stupčastih grafikona, već se profil uzorka prikazuje tablično. Razlog je za to prvenstveno što zauzimaju manje mjesta, odnosno što je u tablicama na manjoj površini moguće prikazati više podataka.

5.6.2. Grafičko prikazivanje podataka

Sve podatke grupirane u tablicama može se i grafički prikazati. Odluka o tome hoće li se podaci prikazati tablicom ili grafikonom treba ovisiti isključivo o tome koja je svrha ilustracije koje su upotrijebljene. Treba znati koje vrste grafikona uopće stoje na raspolaganju, znati i koje su vrste grafikona prikladne za prikazivanje kojih vrsta podataka. Uputno je pažljivo razmisliti što i zašto se nešto želi prikazati, a tek onda odabrati grafikon.

Nominalne podatke prikladno je grafički prikazivati površinskim grafikonima, i to strukturnim krugovima i polukrugovima, jednostrukim, dvostrukim ili višestrukim stupcima (uspravnim ili položenim), strukturnim stupcima, ali i drugim vrstama grafičkih prikaza, kao razdijeljenim stupcima i linijskim grafikonima.

Za prikazivanje ordinalnih podataka najčešće se primjenjuju površinski grafikoni jednostavnih stupaca, dok se za uspoređivanje više nizova primjenjuju višestruki stupci, razdijeljeni stupci, strukturni krugovi, polukrugovi, ali i druge vrste grafikona.

Numerički podaci grafički se prikazuju linijskim i površinskim grafikonima. Velike skupove numeričkih podataka posebice dobro vizualno prikazuju histogrami (površinski grafikoni), za prikazivanje pojedinačnih vrijednosti prikladan je Tukeyjev S-L dijagram, dok su za prikazivanje vremenskih serija najprihvatljiviji linijski dijagrami.

5.7. Rasprava

Svrha rasprave ili diskusije je interpretirati dobivene rezultate u kontekstu prethodnog znanja o istraživanju i objasniti novo razumijevanje problema nakon analize rezultata.

Rasprava se mora povezati uvodom, ciljevima, hipotezama i korištenom literaturom, ali ne smije biti samo ponavljanje prethodno navedenog. Glavni cilj rasprave je istaknuti doprinos istraživanja i pomak u odnosu na uvodni kontekst.

Organizacija rasprave trebala bi pratiti faze istraživanja i slijed analize rezultata. Važno je osvrnuti se na rezultate drugih istraživanja kako bi se podržali rezultati.

Pitanja koja se trebaju razmatrati u raspravi:

1. Nude li rezultati odgovore na postavljene hipoteze? Ako da, kako se ti rezultati objašnjavaju? Ako ne, kako objasniti te rezultate?
2. Slažu li se rezultati s rezultatima prethodnih istraživanja? Ako ne, postoje li alternativna objašnjenja ili metodološki problemi?
3. Kakvo se novo razumijevanje problema može ponuditi? Što bi bio sljedeći korak? Rezultate treba povezati s rezultatima drugih istraživanja, uključujući vlastita prethodna istraživanja, te razmotriti sličnosti i razlike. Važno je razmisliti kako rezultati drugih istraživanja mogu doprinijeti novom viđenju problema. Rasprava treba naglasiti zaključke iz vlastitih rezultata, ponuditi smjernice za buduća istraživanja i ne uvoditi nove podatke, tablice ili slike, koji nisu prikazani u prethodnim dijelovima rada.

5.8. Zaključak

U zaključku znanstvenog rada ukratko se navodi sve ono što je u radu otkriveno i na osnovi dobivenih podataka zaključilo. Objedinjavaju se svi rezultati teksta i navode se konačni zaključci izvedeni u istraživanju.

Zaključak bi trebao sadržavati kratak i jasan opis rezultata provedenog istraživanja. Zaključak rada piše se uvijek nakon što je ostatak rada gotov i nakon što je odgovoreno na sva pitanja/probleme postavljene u radu.

U zaključku se nudi ukupni pregled rada (članka, diplomskog, magistarskog ili doktorskog) u cjelini, određuju se točke usporedbe i neslaganja s drugim autorima i radovima. Nadalje, prikazuje način na koji je postignut doprinos vlastitim radom boljem razumijevanju područja koja su bila predmet istraživanja.

U zaključku se nikada ne smiju iznositi dodatne, odnosno nove informacije ili materijali budući da je to samo sažetak onoga što je otkriveno u radu i glavnih zaključaka koje su na osnovi toga izvedeni.

Zaključak nije mjesto za iznošenje novih ideja ili izvora literature. Zaključak, također, može biti mjesto na kojem se ukazuje na ograničenja vlastitog rada ili se nude mogući napuci za buduća istraživanja.

Među ograničenja rada spadaju svi metodološki, ali i drugi nedostaci rada na koje se potrebno osvrnuti. Preporuke istraživanja proizlaze iz zaključka, odnosno sugeriraju što još treba učiniti, tko to treba učiniti i kako to treba učiniti.

Gotovo svako istraživanje u određenoj mjeri ukazuje na nove probleme i otvara neka nova pitanja. Svaki student, pa i profesionalni znanstvenik, najčešće je ograničen vremenom i resursima, stoga ne može riješiti sva pitanja povezana s područjem istraživanja. Zato se očekuje prijedlog načina na koje je moguće unaprijediti vlastiti rad. Ono što se napiše u ovom dijelu ukazuje na promišljanja o području kojim se istraživač bavi, odnosno na činjenicu da se o temi promislilo dublje i šire no što je konkretnim istraživanjem obuhvaćeno.

Preporuke u istraživanjima:

- smjer budućih istraživanja koji bi riješio eventualne nedostatke vlastitog rada,
- smjer budućih istraživanja koji bi popunio nedostatke u postojećim saznanjima,
- smjer budućih istraživanja u srodnim područjima.

5.9. Jezik i stil pisanja

Od izrazite je važnosti naglasiti nekoliko ključnih pravila u oblikovanju jezika i stila pisanja znanstvenog i stručnog rada. Većina mentora, recenzenata ili drugih značajnih čitatelja neće pristati na raspravu o sadržajnim elementima rada ukoliko ono nije napisano ispravnim „znanstvenim“ jezikom.

Znanstveni stil pisanja uključuje korištenje preciznog jezika kako bi se izrazile određene ideje. On mora biti gramatički ispravan i formalniji je od stila kojim se pišu novele, novine, neformalne prepiske ili stila kojim se služi u svakodnevnom govoru.

Jezik mora biti jasan i jednostavan. To ne znači da jezik koji se koristi smije biti složen, pompozan i suh.

Znanstveni stil je objektivan, stoga je potrebno služiti se oblicima koji su neosobni u tonu i rječniku. Iako je stil pisanja uvijek u određenoj mjeri osobno obojen, takva je „osobnost stila“ najmanje prihvatljiva u znanstvenom tekstu.

To, naravno, ne znači da su svi znanstveni tekstovi stilski jednaki, već upravo suprotno - da je potrebno iskustvo i vještina za stvaranje zanimljivog i dinamičnog teksta unutar relativno strogo određenih pravila. Tu vještinu i iskustvo nije moguće prenijeti, a ponekad ga uspješno ne savladaju niti oni koji se znanstvenim radom bave godinama.

Postoje radovi (i autori) koji unatoč dugogodišnjem iskustvu pišu teško, nečitko i pompozno.

Važniji elementi stila pisanja:

Gramatička pravila i pravopis - sasvim je jasno da se u pisanju znanstvenog teksta moraju poštivati gramatička i pravopisna pravila hrvatskog jezika. Ono što možda treba dodatno naglasiti je dosljednost kojom se ova pravila moraju slijediti, a ona mora biti potpuna. Nikada se ne predaje tekst upozoravajući na to da će se pravopisne greške ispraviti naknadno.

Čitatelji tekstova koji su najčešće profesori specifičnih područja niti mogu, niti trebaju trošiti svoje vrijeme na ispravljanje gramatičkih pogrešaka. Ukoliko postoji osjećaj da se ne vlada dovoljno dobro pravopisom i gramatikom, treba zamoliti nekoga da pregleda tekst prije no što se predaje mentoru na čitanje.

Glagolsko vrijeme - prošlo vrijeme koristi se u znanstvenom stilu za opisivanje onih događaja koji su se već zbili. Postoje situacije u kojima je bolje koristiti sadašnje vrijeme. Primjerice, u tekstu je bolje napisati „iz tablice 1. je vidljivo“, nego „iz tablice 1. je bilo vidljivo“. S druge strane, opis korištene metodologije mora biti u prošlom vremenu, budući da opisuje nešto što se već napravilo.

Lice u kojem se piše (i korištenje aktiva, odnosno pasiva) - postoje dvije strategije u odabiru lica u kojem će se napisati tekst, kao i glagolskog oblika u kojem izražavate korake rada.

Jedan dio autora smatra da je bolje tekstove učiniti osobnijima i prirodnijima korištenjem aktivnog glagolskog oblika te zamjenica u prvom licu (jednine ili množine). Ovakav pristup doprinosi jasnijem i uspješnijem izražavanju.

Neprimjereno je koristiti takozvani *pluralis modestiae* (kada jedan autor o sebi govori u prvom licu množine). Prema spomenutom pristupu, bolje je reći „utvrdio sam“ no „utvrđeno je“ ili „utvrdili smo“ (naravno, ukoliko je riječ o samo jednom autoru). Tradicionalni pristup zagovara korištenje *pasivnog glagolskog oblika*, odnosno neosobnog jezika.

U sklopu ovog stila izbjegavaju se osobne zamjenice poput ja/mi/vi/mene ili nas. Također se preporučuje korištenje jezičnih struktura poput „istraživanje je pokazalo“, a ne „pokazao/la sam“. Još jedan način održavanja objektivnog tona je pretvaranjem glagola u imenicu i

reorganizacijom rečenice u neosobnom stilu. Primjerice, „Ispitanicima smo prikazali oglas... “ se pretvara u „Ispitanicima je prikazan oglas...“.Pri odabiru jednog od ovih dvaju stilova preporučuje se konzultiranje s mentorom.

Korištenje kratica - pri korištenju kratica preporučuje se da kada se spominju prvi put, napiše se cijeli izraz zajedno s kraticom u zagradi nakon čega se u ostatku teksta može koristiti kratica. Ovo se pravilo ne odnosi na standardne kratice poput „itd.“.

Neka od pravila za korištenje kratica: kraticu nikada ne treba navoditi u naslovu; kratice treba izbjegavati u sažetku te nije potrebno skraćivati naziv koji se koristi svega nekoliko puta;

Žargon i strane riječi (izrazi na stranim jezicima) - relativno mlada znanstvena područja u kojima se najveći broj izvora literature može naći na engleskom jeziku, obiluju engleskim pojmovima koje je nekada teško prevesti. Ukoliko se radi o izrazima specifičnim za područje, uvijek treba ponuditi neki pojam na hrvatskom jeziku, makar opisni.

Nikada ne treba „hrvatizirati“ strane termine (primjerice „brandiranje“) i ne treba izmišljati nove termine za već postojeće. Osim na prevođenje stručnih pojmova, treba paziti i da se uvijek koriste hrvatske riječi u izvornom hrvatskom obliku, odnosno izbjegavati tuđice gdje god je to moguće.

Stil pisanja – u znanstvenom je tekstu, možda čak i više nego inače, vrlo važno biti jasan, precizan i jednoznačan. U znanstvenim radovima nema nimalo mjesta za jezične bravure, kićenje i sl.

Nikada se ne treba koristiti literarnim ili novinarskim stilom, poetskim metaforama ili subjektivnim opisima i doživljajima.

Svaku misao ili podatak najbolje je prenijeti sa što manje riječi i što jednostavnije.

Natuknice i nabranje - važno je da je tekst što jasniji i sažetiji, a treba izbjegavati korištenja pretjeranih nabranja i natuknica.

Svaka podjela ili nabranje mora ukazivati na nešto što se spominje u radu i mora biti detaljno razjašnjeno.

5.10. Navođenje literature i sustav navođenja

Korištenje i navođenje radova drugih autora ni najmanje ne umanjuje vrijednost vlastita rada. Na svaki tuđi dio rada, bez obzira na to je li iznesen u upravnom ili neupravnom govoru ili je interpretiran, autor se mora pozvati. Koncepti, ideje, mišljenja, zaključci, podaci, informacije,

ilustracije itd. mogu se preuzeti od drugih, ali se uvijek treba navesti iz kojeg su bibliografskog izvora preuzeti.

Treba voditi računa da je izvore potrebno navesti i kada se citira (tekst preuzima od riječi do riječi) i kada se tuđi tekst parafrizira (prepričava vlastitim riječima) i kada se tuđi tekst interpretira (tuđe koncepte, nalaze i zaključke tumači vlastiti način).

Citiranje je preuzimanje teksta iz drugih izvora od riječi do riječi, u kojem slučaju je preuzeti tekst potrebno staviti u navodne znakove („...“), U slučaju izostavljanja dijelova izvornog teksta, umjesto izostavljenog, ali još uvijek unutar navodnika, stavlja se trotočje (...).

Parafriziranje je prepričavanje teksta drugih vlastitim riječima. Koristi se u slučaju kada se želi preuzeti veći dio teksta jer se sumiranjem i oblikovanjem vlastitim riječima on svodi na manji obujam. Pri parafriziranju je važno paziti da se zadrži smisao izvornog teksta.

Interpretiranje je tumačenje tuđih koncepata, mišljenja, nalaza, zaključaka i sl. na vlastiti način, odnosno dodavanje vrijednosti radu drugih.

Neoznačavanje dijelova rada preuzetih od drugih, dakle predstavljanje rada drugih kao vlastitog, naziva se **plagijatom**. Plagijat je svako književno, znanstveno ili drugo djelo nastalo prisvajanjem tuđeg rada prepisivanjem u cjelini, u bitnim ili u prepoznatljivim dijelovima, a plagiranje prisvajanje tuđeg autorskog djela.

U znanstvenom i stručnom radu plagijatom se smatra namjerno (apsolutno neetično) ili nenamjerno doslovno preuzimanje nečijeg teksta bez navođenja o čijem se tekstu radi, a tako i prepričavanje teksta drugih bez navođenja čiji je tekst prepričan.

Plagiranje podliježe moralnim i zakonskim sankcijama.

- Uvijek treba koristiti sustav navođenja literature (pozivanja na literaturu i izrade popisa literature) propisan od strane institucije za koju pišete znanstveni/stručni rad,
- Poželjno je biti dosljedan u primjeni odabranog sustava.
- Ne treba miješati više sustava navođenja literature.

Savjeti za izbjegavanje plagiranja:

- Kada se rade bilješke, obavezno je odmah zapisati njihov izvor.
- Pri pravljenju bilješki koristiti navodnike („...“) za obilježavanje doslovno preuzetog teksta kako se kasnije ne bi dogodilo da se misli da su to vlastite riječi.
- Ne treba navoditi da je nešto čitano u izvorniku ako nije. Takve se znanstvene neistine razotkrivaju na mnoge banalne načine, kao što je krivo napisano prezime autora u

izvoru, navođenje članka do kojeg autor, od kojeg se prepisuje, zna da niste mogli doći (npr. Potrebno je dopisivati se s autorom, rasprodana publikacija) i slično. Smatra se da je maksimalna prihvatljiva dužina jednog citata u tekstu pet redova.

- Ukoliko je potrebno citirati cijeli paragraf, citirajte ga na način da se posebno označi (uobičajeno je pisati drugom bojom, manjim fontom i proredom, uvučeno i odvojeno od ostatka teksta).
- Postoje računalni programi za utvrđivanje je li tekst preuzet s interneta ili kopiran iz radova drugih (studenata, istraživača i sl.).
- ***ne zaboraviti navesti otkuda je nešto preuzeto.***

Pozivanje/upućivanje na izvore vrlo je zbunjujuće za početnike. U literaturi se naime učestalo pojavljuju četiri značajno različita načina, odnosno sustava navođenja literature, a unutar svakog od njih bezbrojne su varijacije, tj. stilovi. Razlog za to je što niti jedan od sustava navođenja literature nije univerzalno prihvaćen, već postoje oprečna mišljenja o tome koji je od njih najbolji pri pisanju znanstvenih i stručnih radova.

Treba koristiti onaj sustav navođenja literature koji traži mentor, obrazovna institucija ili izdavač. Ipak, različite sustave navođenja literature treba poznavati kako bi se znalo interpretirati informacije vezane uz izvore literature koji su korišteni u publikaciji koja se proučava te kako bi se ispravno koristilo bilo koji sustav.

Izvore literature može se naznačiti u samom tekstu rada, u bilješkama na kraju poglavlja ili cjelokupnog rada u bilješkama na dnu stranice ili pozivanjem na abecedni popis literature na samom kraju rada.

U suvremenoj su literaturi najčešća sljedeća četiri sustava navođenja literature (redoslijedom njihove učestalosti):

- sustav navođenja literature prezime-godina,
- sustav navođenja literature korištenjem endnota,
- sustav navođenja literature korištenjem fusnota te
- numeričko-abecedni sustav navođenja literature.

Sustav prezime-godina, koji se još naziva i sustavom navođenja u tekstu, odnosno u zagradama (engl. *author-date referencmg svstem, name-dare referencing system, in-text references, parenthetical references*), sastoji se od navođenja izvora u tekstu i popisa korištene literature na kraju rada. Izvori se u tekstu navode tako da se u zagradi iza teksta koji je preuzet navodi:

(1) prezime/na autora odvojena zarezima (bez inicijala imena ili imena), (2) godina kada je objavljeno djelo na koje se poziva te (3) broj stranice/a na kojoj/ima se nalaze preuzete informacije ukoliko se citira, parafrizira ili interpretira s određene stranice. Ako se želi naglasiti ime autora koji je nešto istražio, zaključio i sl., njegovo se prezime može navesti u tekstu rečenice, dok se godina kada je objavljeno djelo na koje se poziva i stranica na kojoj se nalazi preuzeto stavljaju u zagradu pored autorova imena.

Sustav prezime-godina sustav je kojim se piše najveći broj znanstvenih i stručnih radova danas te sustav s najvećim brojem varijacija stilova (razvijenih za potrebe raznih znanstvenih i stručnih časopisa, institucija itd.). Najpoznatije varijacije, tj. stilovi navođenja literature prema sustavu prezime-godina su: Harvardski stil (engl. *Harvard style of referencing*) i Stil Američkog psihološkog društva (engl. *American Psychological Association (APA) style of referencing*).

Sustav navođenja literature korištenjem endnota, odnosno krajnjih bilješki (engl. *endnotes referencing system*) koji se naziva i „citiranjem po redoslijedu pojavljivanja“. To je sustav prema kojem se u tekstu rada redoslijedom pojavljivanja eksponent brojkama od 1 do n označava redni broj bilješke na kraju poglavlja ili cjelokupnog rada na koju se poziva, a u kojoj su navedeni podaci o izvoru literature preuzeti dijelovi označavaju se brojkama. U krajnjim bilješkama se pod istim brojem nalaze podaci o izvoru literature.

Podaci o izvorima literature navode se prema pravilima izrade popisa literature te se dodaje broj stranice s koje je nešto preuzeto. Ukoliko se u radu već pozivalo na neko djelo, a želi se ponovno na njega pozvati, nije potrebno ponovno pisati sve podatke o djelu, već se uz ime/na autora piše „op. cit.“ (kratica od lat. *opus citatum*, što znači „navedeno djelo“) koja označava da se navodi već prethodno navedeno djelo, a na kraju navodi broj stranice s koje je preuzet navod.

Ako se poziva na djelo koje je na istoj stranici navedeno u prethodnoj endnoti, dakle endnoti koja se nalazi neposredno prije endnote koja se navodi na istoj stranici, piše se kratica „Ibid.“ (skraćeno od lat. *ibidem*, što znači „na istom mjestu“) koja označava da se radi o istom djelu, nakon koje također slijedi broj stranice s koje je preuzet navod. Ovaj sustav je dominantno prisutan u udžbenicima, monografijama i drugim vrstama knjiga u kojima se ne želi tekst opterećivati podacima o izvorima literature s obzirom na to da su u tim vrstama publikacija to informacije nižeg reda.

Ukoliko će se navoditi vlastite literature prema sustavu endnota, može se dodatno izraditi i abecedni popis korištene literature. On se u pravilu ne izrađuje ako je riječ o članku, ali se

izrađuje ako je riječ o knjizi, kako bi se vidjelo koji su sve izvori literature korišteni u radu (posebice ako su endnote izrađivane za svako poglavlje zasebno).

Sustav navođenja literature korištenjem fusnota, odnosno bilješki na dnu stranice (engl. footnotes referencing system) sustav je kod kojeg se u tekstu rada redoslijedom pojavljivanja eksponent brojkama od 1 do n (za pojedino poglavlje ili za tekst u cijelosti) označava u kojoj su bilješki na dnu stranice (ispod teksta) navedeni podaci o izvoru literature.

Iz izvora literature preuzete informacije označavaju se rednim brojevima istovjetnima rednim brojevima fusnota u kojima su ti izvori navedeni. Fusnota u znanstvenom, odnosno stručnom radu mora biti bar toliko koliko se na popisu literature nalazi bibliografskih jedinica, odnosno ne bi smjelo biti obrnuto: više bibliografskih jedinica u popisu korištene literature nego svih fusnota u nekom djelu.

Izvori se u fusnotama pišu na isti način kao i u popisu korištene literature te se na kraju navoda dodaje broj stranice s koje je preuzet citat, podatak, ideja ili slično. Ukoliko se u radu već pozivalo na neko djelo, a želi se ponovno na njega pozvati, nije potrebno ponovno pisati sve podatke o djelu, već se uz ime/na autora piše „op. cit.“ (kratica od lat. opus citatum, što znači „navedeno djelo“) koja označava da se navodi već prethodno navedeno djelo, iza čega slijedi broj stranice s koje je preuzet navod. Ako se poziva na djelo koje je na istoj stranici navedeno u prethodnoj fusnoti, dakle fusnoti koja se nalazi neposredno prije fusnote koja se navodi na istoj stranici, piše se kratica Ibid,“ (skraćeno od lat. ibidem, što znači „na istom mjestu“) koja označava da se radi o navodu iz istog djela, nakon koje također slijedi broj stranice s koje je preuzet navod.

Numeričko-abecedni sustav navođenja literature, koji se skraćeno naziva numeričkim sustavom navođenja literature (engl. numeric referencing system), sustav je prema kojem se u zagradi (najčešće kosoj, ali može i u običnoj ili uglastoj -151, (5) ili []) u tekstu, na mjestu gdje se želi ukazati na korištenu literaturu, navodi broj veličine istovjetne tekstu dodijeljen izvoru literature u abecednom popisu izvora na kraju rada.

U tekstu se na mjestima gdje se poziva na izvore navode brojevi dodijeljeni tim izvorima u abecednom popisu literature. Ovaj sustav podrazumijeva da se, kada se na više mjesta u radu koristi isti izvor, uvijek upisuje isti broj. Ukoliko se pak želi ukazati na točnu stranicu s koje je nešto preuzeto, u zagradi se uz broj koji označava izvor dodaje broj koji označava stranicu.

5.10.1. Izravno navođenje (citiranje)

Izravno navođenje ili ***citiranje*** standardizirani je postupak u akademskom pisanju kojim se u matični tekst umeće neki drugi tekst pri čemu se navodi *uputa (referenca)* na bibliografski izvor odakle je preuzet.

Izravno navođenje ili citiranje umetanje je drugog teksta (tuđeg ili vlastitog) u akademski tekst. To je jedan od najuobičajenijih i najvažnijih postupaka u akademskom pisanju. Tekst koji se umeće, a koji se naziva *navod* ili *citata*, mora biti *istaknut* kako bi se jasno razlikovao od matičnog teksta.

Isticanje se postiže na dva načina:

(a) stavljanjem citiranog teksta u *navodnike*; ili

(b) *izdvajanjem* citiranog teksta u zaseban odlomak, zatim uvlačenjem tog odlomka prema desnoj margini (u pravilu 1 do 2 cm u odnosu na matični tekst) te smanjivanjem veličine slovnog znaka (*fonta*).

Prvi postupak isticanja primjenjuje se ako je citirani tekst kraći od *tri do pet redaka*. Ako je duži od tri do pet redaka, primjenjuje se drugi postupak. U oba se slučaja obavezno navodi *uputa (referenca)* na izvor citata.

Uputa ili *referenca* na izvor citata navodi se u samom tekstu, neposredno ispred ili neposredno iza citiranog teksta, ovisno o vrsti citata, ali i strukturi teksta, tj. ovisno o tome gdje je autoru najprikladnije spomenuti prezime citiranog autora.

Uputa ili *referenca* sadrži tri elementa: (a) prezime citiranog autora ili citirane autorice, odnosno prezimena citiranih autora ili autorica, zatim (b) godinu izdavanja publikacije iz koje je preuzet citat (odnosno, za netiskani izvor, godina ili neka druga identifikacijska oznaka) te broj stranice ili stranica (u slučaju da se i unutar samog citiranog teksta pojavljuju navodnici, ti navodnici moraju biti drugačiji od navodnika koji označavaju citat) s koje (ili s kojih) je citat preuzet (ako je riječ o tiskanom izvoru). Element (a) i (b) odvojeni su zagradom ili zarezmom, a elementi (b) i (c) dvotočkom. Budući da se prezime (a ponekad i ime) citiranog autora obično spominje u tekstu koji prethodi citatu, godina izdavanja (objave) i broj stranice navode se u zagradi uz njegovo prezime. Ponekad se, ovisno o načinu citiranja, sva tri navedena elementa navode u zagradi.

U slučaju da se u akademskom tekstu citiraju dva teksta (ili više njih) istog autora i iste godine izdavanja (što znači da su prva dva elementa upute na izvor identična), uputi se uz godinu

izdavanja dodaje još i malo slovo abecede, i to prema abecednom redu za svaki novo citirani tekst (npr. za prvocitirani tekst: 2006a, za drugocitirani tekst: 2006b, itd.).

U slučaju da se citira tekst dvoje ili troje autora, u uputi (referenci) na izvor tog teksta navode se prezimena svih autora i to redoslijedom kojim su navedeni u izvoru. U slučaju da je riječ o više od troje autora, u uputi se navodi samo prezime prvog autora iza čega slijedi oznaka «et al.», dok se prezimena svih autora navode u odgovarajućoj bibliografskoj jedinici na kraju akademskog teksta.

Referenci se (uputi) uz svaki pojedinačni citat, u popisu literature na kraju teksta pridružuje odgovarajuća bibliografska jedinica koja sadrži cjelovite podatke o izvoru citata. Ako se više puta poziva na isti izvor (tj. navodimo više referenci na isti izvor), u literaturi za taj izvor navodimo jednu bibliografsku jedinicu.

U slučaju da se citirani tekst citira prema «nematičnom» izvoru, tj. ako se preuzima od autora koji nije autor dotičnog teksta (nego ga je i sam citirao), tada se u zagradi navode prezimena oba autora: i prezime citiranog autora i prezime autora publikacije prema kojoj je tekst citiran, s time da se ispred prezimena prethodno spomenutog autora dodaje oznaka «prema» s dvotočkom (a iza prezimena opet godina objave i broj stranice). U popisu literature navode se dvije bibliografske jedinice (bilješke): jedna za publikaciju citiranog autora, a druga za publikaciju autora prema kojoj je tekst citiran.

Primjeri:

- *Primjer 1:* označavanje citata navodnicima, Prema Dennettovom shvaćanju (1991: 207), «sam je ljudski um artefakt koji nastaje kada memi preustroje ljudski mozak kako bi od njega učinili bolje stanište za meme».
- *Primjer 2:* označavanje citata izdvajanjem u zaseban odlomak. Veća privlačnost gradskih životnih navika i ideja (gradskih «mema») od onih seoskih može se ovako objasniti: kada gradski ljudi odu na selo, zbog manje gustoće naseljenosti oni sreću manje seoskih ljudi te preuzimaju manje ruralnih mema zato što ih manje i postoji; no kada seoski ljudi odu u grad, oni susreću mnogo gradskih ljudi i mnogo novih ideja. Posljedica je memetički pritisak za životom u gradu. (Blackmore, 2005).
- *Primjer 3:* citiranje navodnicima prema nematičnoj publikaciji. Definicija etike koju daje Albert Schweitzer (1929), švicarski liječnik i jedan od najvećih dobrotvora prošlog stoljeća, glasi: «Etika [...] se sastoji u tome da ja spoznajem nužnost [...] jednakog strahopoštovanja pred svakom voljom za životom kao i pred svojom

vlastitom. Time već imam potrebno temeljno načelo moralnosti. Dobro je održavati i njegovati život; *zlo* je uništavati i sprječavati život.» (prema: Singer, 2002: 212). Citirani tekst ne mora biti kontinuirano (neprekinuto) citiran. Prema potrebi ga se može prekidati: bilo umetanjem jedne ili nekoliko riječi u citat (čak i unutar iste rečenice) bilo ispuštanjem dijela citiranog teksta (jedne ili više riječi, čitave rečenice ili više njih). Umjesto ispuštenog dijela teksta umeću se tri točke u zagradama (...), a dijelovi necitiranog (dodanog) teksta unutar citata stavljaju se u zagradu. Ispušteni tekst može se nalaziti na bilo kojem mjestu u citiranoj rečenici. Ako se nalazi na samom kraju rečenice, onda nakon triju točki u zagradama opet slijedi točka (za kraj rečenice).

- U slučaju da se u citiranom tekstu želi istaknuti neka riječ ili više njih, ta se riječ, odnosno te se riječi pišu kurzivom, a na kraju citata se u zagradi iza godine i broja stranice dodaje napomena «moje isticanje», čime se čitatelju daje na znanje da istaknute dijelove citata nije istaknuo njihov autor, već autor koji ih je citirao.
- *Primjer 4:* isprekidani citat s umetanjem vlastita teksta. Jedan od najvećih teoretičara biološke evolucije u 20. stoljeću, Ernst Mayr (1983a: 326), smatra da se istraživači koji «pokušavaju utvrditi je li [neko obilježje] proizvod prirodnog odabiranja ili slučaja [...] suočavaju s epistemološkom dvojmom.» Dvojba proizlazi iz činjenice što bi «[s]koro bilo koja promjena tijekom evolucije mogla biti proizvod slučaja». «Može li se to ikada dokazati?», pita se Mayr, te pokazuje da ne može. Ono što se, prema njemu može pokazati je «kako bi posjedovanje [...] osobine moglo imati selekcijski povoljan učinak.».
- *Primjer 5:* isprekidani citat s vlastitim isticanjem. Navodi se još jedan citat koji je po mišljenju mnogih povjesničara znanosti najbliži načelu inercije: Salviati: Ne izgleda mi da je ovo pravo vrijeme za ispitivanje uzroka ubrzanja prirodnog gibanja o kome su razni filozofi davali razna mišljenja. [...] Sve ove fantazije, a i neke druge trebalo bi razmotriti, ali na to ne vrijedi trošiti vrijeme. U ovom trenutku je cilj autora samo da ispituje i dokaže neke osobine ubrzanog gibanja [ma kakav bio uzrok ubrzanja] [...]. (citirano prema: Mladenović, 1986: 135, kurziv dodan).

Iz svih pet primjera navod (citat) ne umeće se u matični tekst bez prethodne najave. Čitatelja je na citat potrebno pripremiti. To se postiže tako da navodu prethodi jedna ili više rečenica ili

barem nekoliko riječi, koje imaju za cilj uspostaviti smislenu vezu između citata i matičnog teksta, čime se postiže retorički efekt, ali i olakšava razumijevanje citata.

5.10.2. Neizravno navođenje (parafraziranje)

Neizravno navođenje (parafraziranje) standardizirani je postupak u akademskom pisanju kojim se (prepričavanjem, sažimanjem, tumačenjem i sl.) u matični tekst unosi zaštićeni informacijski sadržaj preuzet s nekog bibliografskog izvora, pri čemu se (osim ako je riječ o općepoznatom sadržaju) navodi uputa (referenca) na taj izvor.

Za razliku od izravnog navođenja ili citiranja - doslovnog preuzimanja nekog teksta - neizravnim navođenjem ili parafraziranjem vlastitim se riječima prenosi ideja, otkriće, teorija, objašnjenje, hipoteza, argument, dokaz, interpretacija nekog drugog autora, primjenjuje neka tuđa metoda ili se općenito u akademskom tekstu na relevantan način koristi tuđi informacijski sadržaj. Budući da je taj sadržaj u pravilu zaštićen, njegova reprodukcija ne podliježe samo obvezi upućivanja (referiranja) na izvor, nego i obvezi vjerodostojnog prenošenja njegova informacijskog sadržaja. Za razliku od prenošenja teksta (rečenica i dijelova rečenica), prenošenje informacijskog sadržaja teksta, tako da se na jasan način zadovolji zahtjev vjerodostojnosti, nije uvijek lak zadatak. Autori se često suočavaju s optužbama da su «pogrešno prikazali» nečije stajalište, argument ili teoriju, da su «iskrivili» nečije riječi, da su nečije tvrdnje protumačili na «subjektivan način» i sl.

Tuđi akademski tekst najtipičniji je i najčešći izvor zaštićenog informacijskog sadržaja u akademskom pisanju. Kada se prepričava tuđi tekst, nije presudno hoće li se potpuno vjerno reproducirati strukturu teksta, od rečenice do rečenice, nego je važno hoće li se vjerno prenijeti logički sadržaj utjelovljen u tekstu. Logički sadržaj tuđih misli potrebno je prenijeti jasno i vjerodostojno, ali vlastitim riječima i vlastitim stilističkim sredstvima u skladu s ciljem vlastita teksta.

Tipičan je slučaj da se misli nekog autora parafraziraju kako bi se njima pojasnilo stajalište tog autora o nekom pitanju ili kako bi se to stajalište kritiziralo. Imajući to u vidu jasno je da parafrazirani tekst ne mora biti jednake dužine kao izvorni tekst; njegova će dužina ovisiti o cilju parafraziranja. Ako je cilj detaljno komentirati ili kritizirati izvorni tekst, onda parafraza može biti i duža od izvornog teksta. Ako je cilj sažeto prikazati nečije stajalište ili nečiji argument, onda će ona u pravilu biti kraća od izvornog teksta.

Čest je slučaj da se izravno i neizravno navođenje kombiniraju: jedan dio preuzetog teksta izravno se citira, a drugi dio tog teksta se parafrazira.

Pri svakom neizravnom citiranju (parafraziranju) navodi se uputa (referenca) na izvor čiji se sadržaj parafrazira. To se čini na potpuno isti način kao i pri izravnom citiranju: pri prvom spominjanju prezimena autora čiji se misaoni sadržaj prenosi u vlastiti tekst, navodi se godina objave publikacije (ili bilo kojeg drugog izvora kojim smo se služili), a iza broja godine, odvojen dvotočkom, broj stranice u izvoru (ako postoji). Ti se podaci, u pravilu, navode u zagradama uz ime autora, ali se mogu navesti i u bilješci na dnu stranice (efusnoti»). Ako se parafrazira misaoni sadržaj nekog autora prema izvoru koji ne potječe od tog istog autora, tada se u uputi (referenci) navodi i prezime autora čijim izvorom smo se služili, a ispred prezimena naznaka «vidi» ili «usporedi».

Nakon prezimena autora slijede uobičajeni podaci: godina izdavanja i broj stranice - naravno, ako je riječ o izvoru za koji ti podaci postoje. Kao i u slučaju izravnog citiranja, potpuni podaci o izvoru u parafraziranju nalaze se u literaturi na kraju akademskog teksta, tako da svakoj uputi (referenci) danoj u tekstu ili u bilješci odgovara neka bibliografska jedinica u literaturi. Različitim uputama na isti izvor odgovara uvijek ista bibliografska jedinica.

Pri prenošenju tuđeg sadržaja potrebno je osobitu pozornost obratiti na to da čitatelju u svakom trenutku bude jasno je li odlomak akademskog teksta koji trenutno čita napisan sa stajališta autora matičnog teksta ili se u tom odlomku prepričava tuđi tekst odnosno tuđi misaoni sadržaj. Za razliku od izravnog citiranog teksta koji je grafički odvojen od matičnog teksta, neizravno citirani (parafrazirani) tekst nije moguće vizualno odvojiti od ostatka teksta.

Gdje god postoji opasnost da dođe do zabune oko perspektive iz koje je neki dio akademskog teksta napisan, potrebno je tu perspektivu jasno naznačiti.

I neizravan navod potrebno je pripremiti, odnosno najaviti: parafraziranom tekstu treba prethoditi jedna ili više rečenica ili barem nekoliko riječi, koje imaju za cilj uspostaviti logičku i retoričku vezu između dijela teksta u kojem se prepričava tuđi misaoni sadržaj i dijela teksta koji ovome prethodi. Postoje različiti načini da se to postigne, a najjednostavniji način je da se u jednoj rečenici, koja služi kao najava parafraze, čitatelja upozori da će u tekstu koji slijedi biti prepričan neki tuđi misaoni sadržaj. U toj će rečenici tipično stajati ime autora tog sadržaja te naznaka o kojem se sadržaju radi - spomenut će se teorija koja se kani izložiti, navest će se tvrdnja koja se kani kritizirati (ili braniti), kratko će se opisati argument koji se želi analizirati, dat će se izvor podataka koji se kani komentirati i sl. U pravilu, ta rečenica će sadržavati (u zagradi ili u bilješci na dnu stranice) uputu na bibliografski izvor teksta ili sadržaja koji se parafrazira.

Primjer parafraziranja u akademskom tekstu

- *Primjer 6.* sažetak knjige drugog autora u jednom odlomku: kako sukladno svom zakonski definiranim cilju svaka korporacija mora nepopustljivo i bez izuzetka djelovati u vlastitu korist, Joel Bakan (2006) tvrdi da je svaka korporacija patološka institucija. Njegova knjiga *Korporacija*: „Patološka težnja za profitom i moći u svrhu razlaganja te teze dijeli se u pet poglavlja u kojima autor nastoji odgovoriti na pitanja kako je korporacija postala ono što je danas, kakva je priroda i koje su implikacije njezina patološkog karaktera i njezine vlasti nad društvom i na kraju što bi trebalo i što se može učiniti kako bi se smanjio njezin štetni potencijali“.
- *Primjer 7.* parafraziranje (prepričavanje) tuđeg teksta s uputom na izvor u bilješci na dnu teksta; U drugoj rečenici svog metodološkog uvoda u spis *O duši* Aristotel kaže da je poznavanje duše korisno za spoznaju općenito, a ponajviše za spoznaju prirode, čime jasno smješta spis *O duši* u okvir filozofije prirode. Nakon toga slijedi glavno metodološko pitanje: kako sustavno obraditi dušu? Aristotel odgovara da dušu treba obraditi tako da se objasni njena bit baš kao i njene glavne značajke. Potrebno je objasniti ne samo što duša jest, nego i što sve ona omogućuje živome biću.

5.10.3. Pisanje bibliografskih jedinica (sastavljanje popisa literature)

Bibliografska jedinica pojedinačna je bilješka u literaturi na kraju akademskog teksta na koju se odnosi uputa ili referenca u tekstu i koja sadrži sve relevantne podatke za točnu identifikaciju bibliografskog izvora s kojega je preuzet citirani tekst, odnosno zaštićeni informacijski sadržaj.

Popis literature navodi se na kraju teksta i sadrži bibliografske jedinice na koje prethodno upućuju reference u tekstu. Jedinice se navode abecednim redom, prema prezimenu prvog autora, a za izvore bez autora prema prvom slovu naslova. Za izvore istog autora najprije se navode bibliografske jedinice ranije godine izdavanja (objavljivanja), a u slučaju da je riječ o izvorima istog autora i iste godine izdavanja (objavljivanja), najprije se navode oni koji su ranije citirani, tj. oni čijoj godini izdanja (objavljivanja) je pridruženo slovo bliže početku abecede.

Za svaki od tih izvora dan je po jedan primjer.

U primjerima treba obratiti pozornost na:

1. standardan način navođenja elemenata u bibliografskoj jedinici,
2. redoslijed tih elemenata unutar bibliografske jedinice,

3. način grafičkog isticanja pojedinih elemenata (kurziv, navodnici),
4. interpunkcijske znakove kojima su elementi odvojeni jedan od drugoga (točka, zarez, dvotočka, točka-zarez itd.).


Često se događa da poneki element ne postoji (ili nije naveden) u izvoru kojim se autor služio pri pisanju rada, tako da se ne može navesti ni u bibliografskoj jedinici u popisu literature. Ipak, kada su u pitanju ključni elementi bibliografske jedinice (prezime autora, naslov rada, odnosno knjige, godina i mjesto objave, svezak časopisa) to se događa relativno rijetko. Ako se ipak dogodi, u bibliografskoj jedinici navode se postojeći elementi i to propisanim redoslijedom.

Tiskani izvori (knjige, časopisi i dr.) služe kao bibliografski predložak za elektroničke izvore. To znači da bibliografska jedinica za knjigu ili časopis u elektroničkom obliku uglavnom sadrži iste ključne elemente kao i bibliografska jedinica za knjigu ili časopis u tiskanom obliku.

Jedina specifičnost elektroničkog izvora je adresa internetske stranice kao ključan element identifikacije takvog izvora.


Bibliografska jedinica za knjigu



- Prezime i prvo slovo imena autora ili urednika (ur.);
- Godina izdavanja knjige;
- Naslov i podnaslov knjige (*kurziv*);
- Naslov serije ili pojedinačnog sveska;
- Broj izdanja (ako nije prvo);
- Mjesto izdavanja;
- Izdavač (nakladnik).



Bibliografska jedinica za poglavlje ili članak u knjizi ili za rad u zborniku


- Prezime i prvo slovo imena autora;
- Godina izdavanja knjige ili zbornika;
- Naslov i podnaslov poglavlja ili članka u knjizi ili rada u zborniku (navodnici);
- Prezime i ime urednika knjige / zbornika (ur.);
- Naslov knjige / zbornika (kurziv);
- Broj izdanja (ako nije prvo);
- Mjesto izdavanja;
- Izdavač (nakladnik).

Pisanje bibliografske jedinice za poglavlje (članak) u knjizi


Pisanje bibliografske jedinice za članak u zborniku radova*Pisanje bibliografske jedinice za enciklopedijski članak*

Bibliografska jedinica za rad u časopisu

- Prezime i prvo slovo imena autora;
- Godina objave časopisa;
- Naslov i podnaslov rada (navodnici);
- Naslov časopisa (kurziv);
- Broj sveska (volumena ili godišta);
- Broj sveščića (pojedinačnog broja) i raspon stranica.

Pisanje bibliografske jedinice za članak u znanstvenom časopisu***Bibliografska jedinica za novinski članak***


- Prezime i prvo slovo imena autora;
- Godina objavljivanja novina;
- Naslov i podnaslov članka (navodnici);
- Naslov novina (kurziv);
- Broj pojedinačnog izdanja novina;
- Datum objave pojedinačnog izdanja novina;
- Broj stranica.





Bibliografska jedinica za tekst na internetskoj stranici

- Prezime i prvo slovo imena autora;
- Godina objave teksta (ili godina postavljanja teksta na internetsku stranicu);
- Naslov i podnaslov teksta (kurziv ili navodnici);
- Vrsta materijala;
- Izdavač;
- Internetska stranica;
- Datum posjete mrežnoj stranici.

Pisanje bibliografske jedinice za internetski izvor bez autora



Pisanje bibliografske jedinice za osobni materijal objavljen na internetskoj stranici**Pisanje bibliografske jedinice za elektronički časopis na engleskom jeziku**

Popis korištene literature izrađuje se kako bi se navelo potpune bibliografske podatke o svakom djelu koje je korišteno pri pisanju rada. Popis izvora prilaže se na kraju rada, izrađuje abecednim redom prema prezimenima autora publikacija te se u pravilu numerira. Rjeđa su strukturna na

način da se izrađuje abecedni popis posebno za svaku vrstu publikacije (knjige, članci, izvještaji, internetske stranice, leksikoni i rječnici itd.).

Popis literature potrebno je izrađivati usporedno s pisanjem rada. Kako se koji izvor koristi u tekstu, tako ga odmah treba u potpunosti navoditi u popisu literature. Na taj način zahtjevan zadatak izrade popisa literature postaje jednostavniji nego kada se cjelokupni popis literature izrađuje odjednom. Izradu popisa literature može olakšati korištenje nekog od računalnih programa za navođenje literature (engl. *referencing software*, *reference management software*).

Knjige se u popisu literature navode na način da se navode sljedeći elementi:

1. Ime/na autora knjige. Uobičajeno se navode prezime i inicijali imena autora. Kada autor djela nije jedna osoba, nego članovi ustanove, naziv ustanove dolazi umjesto imena autora. Titule autora se ne pišu.
2. Godina objavljivanja djela.
3. Naslov knjige.
4. Broj izdanja knjige u slučaju kada se radi o knjizi koja je doživjela više izdanja.
5. Naziv izdavačke kuće koja je izdala knjigu.
6. Sjedište izdavačke kuće odnosno mjesto u kojemu je knjiga izdana.

Ukoliko je riječ o knjizi izdanoj u SAD-u, osim mjesta izdavanja navodi se i skraćeni naziv države u kojoj se nalazi mjesto izdavanja. Ako je pak u knjizi navedeno više gradova u kojima se nalazi izdavač, što je slučaj kada se radi o velikim ili međunarodnim izdavačkim kućama, navodi se samo prvo navedeno sjedište.

Članci se navode na sličan način kao i knjige, dakle navode se sljedeći elementi:

1. Ime autora članka.
2. Godina objavljivanja članka. Pri tome je važno naglasiti da se, ukoliko se radi o članku s interneta, navodi godina kada je članak napisan, a ne godina kada je objavljen na internetu ili kada je „skinut“ s interneta.
3. Naziv članka.
4. Medij u kojemu je članak objavljen (časopis), knjiga ili internetska stranica:
 - kada je članak objavljen u časopisu, navodi naziv časopisa, godište, odnosno volumen časopisa u kojem je članak objavljen, broj časopisa u kojem je članak

objavljen te stranice.

- kada je članak objavljen u knjizi, navode se svi elementi navođenja knjige te se na kraju dodaju stranice na kojima se nalazi dotični članak.
- kada je članak objavljen na internetu, potrebno je navesti adresu internetske stranice s koje je članak preuzet, stranice na kojima se članak proteže (najčešće od 1 jer članak nije dio publikacije) te kada je članku pristupljeno.

Ukoliko su podaci korišteni u radu pronađeni na nekoj internetskoj stranici, a nisu dio članka objavljenog na internetu, koji se navodi kako je prethodno opisano, potrebno je navesti naziv i adresu internetske stranice koju se koristilo u radu.

6. RAZVOJ ZNANOSTI O TEHNIČKIM SUSTAVIMA U POLJOPRIVREDI

„Moderna tehnika i tehnologija te njihov napredak neosporno su proizvod kumulativnog znanstvenog razvoja. Kada se pokuša sagledati znanstveno i tehničko-tehnološki razvoj te dovođenje u vezu s društvenim napretkom, nastaju poteškoće u objašnjavanju te veze. Jedni tu vezu vide kao znanstveno-tehničku revoluciju, a drugi kao proces proučavanja. U suvremenoj znanosti rasprostranjeno je gledište koje društveni napredak vidi kao pravocrtno napredovanje, ali pod isključivim utjecajem znanosti i njezine tehničko-tehnološke primjene u procesima rada i organiziranja društva. Znanstvenici za taj, sveopće prihvaćeni utjecaj znanosti i tehnike na društvene procese i razvoj pronalaze zajedničku sintagmu kao znanstveno-tehnološka / znanstveno-tehnička revolucija“ (Milošević, 2014.).

„Tehničko-tehnološki napredak prvenstveno nastaje zbog ekonomskih rezultata, ali širenjem individualnih i društvenih potreba, kao i potreba za racionalno korištenje tehnike i ljudskog rada, sjedinjuje znanost proizvodnju i upravljanje na svim razinama. Kvalitativni napredak proširuje se investiranjem u znanstveno-istraživački rad“ (Žužul, 1990.).

6.1. Povijest razvoja znanosti o tehničkim sustavima

U pronađenim spisima starih civilizacija ne može se izlučiti nikakav spomen o začecima znanosti. Vjerovanje je da je znanost započela neposrednom primjenom raspoloživih osjetila, odnosno razvojem svijesti i svjesne spoznaje prirode i odnosa u prirodi.

Počeci shvaćanja vode k prvim primitivnim pretpostavkama, hipotezama, primitivnim analizama i zaključcima. Unatoč izrazito primitivnim metodama one ipak vode u početak sustavnog razmišljanja, stjecanju znanja i razvoju znanosti. U periodu ljudske povijesti za koji postoje relevantni podatci razvoj znanosti najbolje je vidljiv.

Razvojem znanosti razvijaju se i znanstvene metode potrebne za provjeru pouzdanih, provjerljivih i relevantnih znanja.

Razlikuju se tri metodološka pristupa:

- empirizam,
- racionalizam i
- skepticizam.

Empirijske znanstvene metode uvode ograničenja i na njima temeljene dokaze upotrebljive u znanosti. Ova metoda zahtjeva da sva znanja i dokazi u znanosti, moraju imati svoju ponovljivost čime se ujedno osigurava provjerljivost, a sva znanja ograničava na empirijska znanja i empirijske dokaze jer samo oni imaju takve značajke.

Empirijski dokazi su sve ono što se može neposredno vidjeti, čuti, opipati, okusiti ili omirisati ili posredno izmjeriti te time potvrditi i kvantificirati. Prikupljanje empirijskih dokaza koji se mogu izmjeriti i potvrditi svoju primjenu pronalazi kroz povijest u napretku razvoja tehnike i napretku simbioze poljoprivrede kroz primjenu tehnike.

Racionalističke znanstvene metode proizlaze od racionalizma kao filozofskoga pravca, a temelji se na stavu da se spoznaja stvarnosti može realizirati samo kroz racionalno mišljenje, stanje uma ili općenito intelekt. Ovakav pristup, definiran racionalizmom, razvija logiku kao znanstvenu disciplinu koja se bavi zakonitostima i pravilima mišljenja.

Određena vrsta dokaza koji se mogu upotrebljavati u znanosti (iako s problematičnom vrijednošću i iskoristivošću), a posebno često se upotrebljavaju u obrazovanju i društvenom životu, su autoritarni dokazi.

Znanstveni skepticizam pojavljuje se kao temelj primjene tih autoritarnih dokaza u znanosti. Poljoprivredni tehnički sustavi pomažu pojedincima u njihovu radnom okruženju poljoprivredne proizvodnje. Primjena saznanja i spoznaja proizašlih iz znanstvenih istraživanja vodi k rješavanju problema oko pravilne i učinkovite primjene.

Skica proučavanja razvoja tehnike i tehničkih sustava bila bi nepotpuna bez spomena Leonarda da Vincia (1452.-1519.), koji je već tada prepoznao strojeve, njihove elemente i mehanizme te ih proučavao kao pojedinačne. Već tada je u svojim rukopisima (Madrid Codices I–II) formulirao dva interesantna postulata o strojevima:

- Knjiga o sastavnim dijelovima (podrijetlo strojeva mora biti napisano prije nego ih se počne upotrebljavati).
- Mehanizmi su beskonačan izvor za matematičku znanost jer je matematika potaknuta radom mehanizama.

Razmatrane teme uključuju mehaniku, statiku, geometriju i izgradnju utvrda. Leonardo da Vinci prepoznat je kao genij svojega vremena te je bio jedan od rijetkih koji je mogao prihvatiti i provoditi razvoj znanosti općenito.

Izučavanje dijelova strojeva, mehanike i tehničkih sustava sveukupno se nastavilo početkom i tijekom 19. stoljeća. Tada dolazi do značajnijeg razvoja tehnike u poljoprivredi i općenito, ali nisu utvrđene proizvodne regulative, predlošci i zajednički dijelovi.

Od 1957. do 1968. godine dr. Vladimir Hubka tijekom rada u čehoslovačkoj industriji pokreće razvoj sveobuhvatne znanosti o dizajnu tehnike općenito. Prvi je prepoznao potrebu za eksplicitnom teorijom o tehničkim sustavima (TTS) jer teorija dopušta razvijanje odgovarajućih metoda istraživanja (Hubka, 1984.). Glavni dijelovi TTS-a uzimaju u obzir modeliranje i transformaciju tehničkih sustava te generaliziraju životni ciklus i svojstva sustava. Motivacija je bila koordiniranje teorijama o modeliranju i transformacijama tehničkih sustava (TS) te briga o adekvatnoj prilagodbi znanja o tehničkim sustavima radi dobivanja primjenjivih podataka za projektantske inženjere (Mejovšek, 2008.).

Vladimir Hubka pokretač je prve međunarodne konferencije o inženjerskom projektiranju (*ICED - international conference on engineering design*). Prva međunarodna konferencija o inženjerskom projektiranju održana je 1981. godine u Rimu, a rezultirala je nizom sastanaka znanstvenika i inženjera zainteresiranih za projektiranje inženjerstva, razvoj teorije i metodologije te rasprave u krugu pitanja vezanih uz inženjerske znanosti.

6.2. Uvod u znanost o tehničkim sustavima u poljoprivredi

„U primitivnim društvima nove ideje se rađaju kao plod pojedinačnog iskustva u lokalnoj zajednici, a oruđa za rad (alati) nastaju kao potreba čovjeka da „potpomogne” svoja tjelesna ograničenja. Dok se u razvijenim civilizacijama ideje rađaju, a oruđa nastaju pod utjecajem pretežno kulturoloških činitelja (znanosti, umjetnosti, obrazovanja) i kao rezultat specifičnih djelatnih grupa (zanimanje i profesija). To ne znači da se u razvijenim civilizacijama ne oslanjaju na primarno pojedinačno iskustvo i utjecaj tjelesnih predispozicija čovjeka na razvijanje novih ideja i na oblikovanje raznih tehničkih novina. Oni samo zajednički koriste sistematske teorije i tehničko-tehnološke sustave organiziranja rada“ (Milošević, 2014.).

Svaka znanost istražuje fenomen koji već postoji s ciljem dobivanja novih spoznaja, a ponekad i samo radi dobivanja znanja. Istraživanje i formuliranje teorija usko je povezano sa znanstvenim aktivnostima. Prema Oxfordskom rječniku iz 1984., riječ „znanost“ koristi se u širem smislu tumačenja akumuliranog i sistematiziranog znanja, a posebno kada se odnosi na vanjski fizički svijet. „Teorija“ označava opća načela izvučena iz bilo kojeg čina ili činjenice kao produkta u znanosti.

Prema Ederu, 2008. istraživanje ljudskih aktivnosti, kreiranje znanja i znanstvenih teorija, slijedi pet paralelnih putova:

1. *Klasični eksperimentalni način*, empirijski način neovisnog promatranja (pomoću proučavanja protokola, eksperimenata, opisivanje, apstrahiranje, modeliranje i formuliranje hipoteza i teorija). Opažanja mogu zahvatiti mali dio razmišljanja, u kratkim vremenskim razmacima.
2. *Participativno promatranje*, gdje je promatrač član projektnog tima i sudjeluje u promatranom procesu. Po Halesu, 1991. tako interpretirana opažanja mogu biti pristrana od promatrača sudjelovanja u procesu.
3. *Rekonstruktivni*, istraživačko - detektivski način praćenja prošlih događaja i obrada rezultata tražeći tragove na različitim mjestima. Po Nevali, 2005. rekonstrukcije događaja nikada ne mogu u potpunosti rekonstruirati izvorne događaje, ljudska memorija je ograničena. Informacije o događajima pohranjuju se u posebnim "komadima" na različitim mjestima u mozgu te se trebaju ponovno okupiti za rekonstituiranje.
4. *Spekulativni, reflektirajući*, filozofski način formuliranja hipoteza, teorija, modeliranje i testiranje te prijenos i povezivanje praktičnog iskustva i znanosti.

U dizajniranju i projektiranju empirijski način uključuje elemente samostalnog i nepristranog zapažanja istraživanih eksperimentalnih pojava i predmeta.

Samostalna i nepristrana promatranja i zapažanja ne bi trebala obuhvaćati samo ljudsku aktivnost, nego i konačni proizvod dizajniranja i projektiranja, bez obzira na to je li taj proizvod umjetničko djelo ili tehničko tehnološki proces, sustav ili kombinacija tih proizvoda. Nijedan od tih puteva empirijskog proučavanja ne može biti samodostatan i obavezno mora biti usklađen kako bi se postigla unutarnja konzistentnost i vjerodostojnost.

Empirijski način deskripcije jednostavan je postupak opisivanja i očitavanja činjenica, procesa i predmeta te njihovih empirijskih potvrđivanja odnosa i veza, bez znanstvenog objašnjavanja. Ova se metoda primjenjuje u početnoj fazi znanstvenog istraživanja, a ima veću vrijednost ako je jednostavno opisivanje povezano s objašnjenjima o uočenim važnijim obilježjima opisivanih činjenica, predmeta i procesa, njihovih zakonitosti i uzročnih veza i odnosa.

Hipoteze koje nastaju iz teorije empirijski opaženih vrijednosti omogućavaju da istraživanje bude fokusirano, odnosno upućuje koje specifične aspekte problema trebate istražiti.

Kod projektiranja poglavito inženjerstva u tehničkim sustavima, Eder, 2005. i 2008., smatra se da će najbolje sustav biti potvrđen od strane vanjskih operatera (tehnički sustav, ljudski faktor, i aktivno okruženje).

Tehnički sustav (TS) u radu uz prisustvo operatera, može djelovati i reagirati (interno – u predviđenim granicama i preko predviđenih granica TS). To upućuje na potrebu posebnog proučavanja ponašanja procesa i operatera te ukazuje na to kako različite simulacije mogu pomoći u istraživanju predviđenog sustava. Takav način proučavanja omogućuje prilikom projektiranja progresivno sužavanje granica istraživanog tehničkog sustava u podsustave, na koji djeluju operater i funkcije šireg tehničko tehnološkog procesa.

Društveni napredak sa stanovišta proučavanja vrednuje se kao realniji i znanstveno prihvatljiviji od pogleda na društveni napredak isključivo kao posljedice tehničko-tehnološkog napretka. Na ovaj se način sociološko obrazloženje jasno ograđuje od znanstvenog utjecaja tehničko-tehnološkog istraživačkog procesa i jednostranog utjecaja na društveni razvoj.

Dinamički sustavi poput poljoprivredne proizvodnje i utjecaja tehnike, stanja i karakteristika tla, klime, koji se stalno mijenjaju, čine jedan kaotični i živi sustav. Takvi će kompleksni sustavi optimalno funkcionirati kao cjelina samo u slučaju usklađenosti u radu svih njegovih pojedinačnih dijelova.

Svaki od segmenata sustava zahtjeva istraživanje, ali tek analitički pristup i obrada podataka dobivenih istraživanja ponudit će pretpostavke za optimalno funkcioniranje sustava. Ovakvim se pristupom interes cjeline stavlja iznad pojedinačnih sustava. Mišljenje je ovdje okarakterizirano sagledavanjem utjecaja pojava i predmeta kao dijelova sustava koji su u stalnoj interakciji s okolinom. Tako nastaju znanstvene discipline poput opće teorije sustava, ekologije, upravljačkih znanosti, teorije o tehničkim sustavima (TTS), itd. S druge strane, potiče se multidisciplinarni timski rad koji unaprjeđuje komunikaciju i suradnju među znanstvenicima različitih usmjerenja kako bi se ispitala zajedničke osobitosti neke zakonitosti, teorije i modeli u različitim znanstvenim disciplinama. Potiče se stvaranje teorijskih modela u području znanosti sustava da smanje usporedna istraživanja u različitim znanostima.

Definirani su osnovni **stavovi u znanosti**:

- Treba isticati uzajamnu povezanost i ovisnost pojedinih elemenata sustava, ali ih ne valja istraživati posebno, već kao cjeloviti sustav.

Primjer: prinos poljoprivredne kulture bio je samo 5 t/ha zbog neravnomjerno raspoređenih oborina tijekom vegetacije i antropogeno zbijenog sloja tla na koji su utjecali agrotehnički zahvati, itd.

- Svaki je sustav element nekog većeg sustava, ali se i sam sastoji od skupine manjih sustava.

Primjer: pogonski je motor podsustav traktora, dok je istovremeno razvod ventila, koljenasto vratilo, brizgaljke ili crpka goriva podsustav pogonskog motora.

- Pojedinačni elementi sustava imaju tendenciju specijalizacije i dodatnog unaprjeđivanja.
- Sustav je usmjeren prema načelu svrhe postojanja, ali je ujedno obilježen interakcijom elemenata sustava prema ostvarivanju cilja.
- Uspješnost postojanja nekog sustava može se iskazati kao odnos i transformacija ulaznih i izlaznih vrijednosti.

Primjer: utrošak goriva, radnih sati, gnojiva ili zaštitnih sredstava na tvorbu prinosa poljoprivrednih kultura.

Cilj definiranja osnovnih stavova u znanosti jest razumijevanje složenih odnosa unutar cijelog sustava i među pojedinim dijelovima sustava. Ova kompleksnost sustava dodatno se opisuje prema općenito prihvaćenoj hipotezi koja tvrdi da su živa bića „samoizgrađiva“, potpuno prilagodljiva i sposobna za „samorazmnožavanje“, dok se strojevi mogu konstruirati isključivo stvarima koje su jednostavnije od njih samih.

Postoji sumnja u postojanje sveobuhvatne ili jedinstvene znanstvene teorije. Znanstveni filozof J. Dupre suprotstavlja se uvriježenom vjerovanju znanstvenika da je znanost homogeno jedinstvo, iznoseći stajalište da je znanost „labava i heterogena zbirka više ili manje uspješnih istraživanja... koje variraju od visoko plauzibilnih do potpuno nevjerojatnih, od izrazito vrijednih do potpuno štetnih“. Stav da se svijet može hijerarhijski klasificirati, odnosno da su zakonitosti na višim razinama nadređene i izvedene iz onih nižih, proglašava se redukcionističkim.

6.2.1. Znanstveni problem

Nije svaki problem ujedno i znanstveni problem niti problem istraživanja. Problem istraživanja je samo onaj problem za koji je potrebno provesti znanstveno istraživanje kako bi se došlo do

novih spoznaja. Znanstveni problem je neka činjenica ili pojava koja je neshvatljiva, nepoznata, odstupa ili se potpuno razlikuje od dosadašnjih znanja.

Osnovni je zadatak znanstvenog istraživanja rješavanje znanstvenih problema koristeći teorijska ili praktična pitanja za dobivanje odgovarajućih rješenja. Najteži korak u nekom znanstvenom istraživanju upravo je definiranje znanstvenog problema.

Postavljanje odgovarajućih pitanja u postupku definiranja problema omogućit će pribavljanje potrebitih informacija neophodnih u procesu zaključivanja.

Potrebne informacije mogu se prikupiti:

- mjerenjima,
- razgovorima (ankete),
- proučavanjem dosadašnjih istraživanja,
- proučavanjem stručne literature,
- pretraživanjem interneta.

U biotehničkim i tehničkim znanostima, gdje pripadaju i tehnički sustavi u poljoprivredi, najvažniji izvori informacija su eksperimenti i mjerenja pojava kao osnova stvaranja baze podataka i spoznaja potrebnih za definiranje odgovora na postavljeni znanstveni problem.

Prikupljene informacije mogu se podijeliti na kvantitativne, odnosno opisane brojčanim vrijednostima i kvalitativne, odnosno opisne informacije o istraživanom problemu. Teško je zamisliti kvantitativne informacije koje nemaju kvalitativni opis pa tako realno znanstveno istraživanje informacije dijeli na one koje su i kvalitativne i kvantitativne i na one koje su samo kvalitativne.

6.2.2. Metode znanstvenog istraživanja

Metodologija znanstvenog rada znanost je o postupcima, tehnikama, sredstvima i principima rada znanstvenika. Znanstvena metoda predstavlja istraživanje kombinirajući pri tome teorijska znanja, praksu, dosadašnja istraživanja i znanja o objektu te racionalnu obradu rezultata novih spoznaja.

Metodologija znanstvenog rada obavezno sadrži svoj teorijski, tehnički i organizacijski dio:

- *Teorijski dio* sastoji se od proučavanja znanstvenih zakona, teorija i hipoteza, znanstvenih spoznaja, vjerojatnosti, otkrića i do sada provedenih istraživanja, odnosno raspoložive literature.

- *Tehnički dio* metodologije znanstvenog rada posvećen je postupcima, tehnici i opremi potrebnoj za prikupljanje znanstvenih podataka, analizi podataka i prezentaciji istih.
- Organizacijski dio odnosi se na organizaciju provedbe istraživanja, rad znanstvenika te njegovih suradnika.

Belak (2005) u svojoj knjizi „Uvod u znanost“ navodi najčešće primijenjene metode znanstvenog istraživanja:

- induktivna i deduktivna metoda,
- metoda analize i sinteze,
- metoda apstrakcije i konkretizacije,
- metoda dokazivanja i opovrgavanja,
- metoda generalizacije i specijalizacije,
- metoda klasifikacije i deskripcije,
- metoda komparacije,
- statističke i matematičke metode,
- metoda modeliranja,
- kibernetičke metode,
- eksperimentalne metode,
- dijalektičkih metoda,
- povijesnih metoda,
- teorija sustava kao metoda,
- aksiomatskih metoda, metoda idealnih tipova,
- empirijskih metoda,
- metoda studija slučaja,
- metoda anketiranja i metoda intervjuiranja,
- metoda opažanja,
- metoda brojenja,
- metoda mjerenja,
- Delfi metoda, itd.

Proučavanje značajnije literature iz područja istraživanja predstavlja teorijski dio metodologije znanstvenog rada i kao takvo treba biti polazište vašeg istraživanja. Na taj način istraživač je u

mogućnosti postaviti izazovan istraživački cilj i hipotezu rada, usporediti svoje potencijalno istraživanje s drugim već provedenim istraživanjima.

Značajnom literaturom smatraju se temeljna, aktualna i najznačajnija djela iz nekog područja te djela važnih autora iz toga područja ili regionalno povezana djela.

Kvaliteta proučene i upotrijebljene literature u radu predstavlja jedan od elemenata za ocjenu pa se proučavanje značajne literature smatra obaveznim.

Cilj istraživanja

Cilj istraživanja sveobuhvatno će odrediti smjer i tehnički dio metodologije znanstvenog istraživanja. Za definiranje istraživačkog pitanja i tehnike potrebne za istraživanje potrebno je proučavanje literature i razgovor sa znanstvenikom na području proučavanja (mentorom). Nakon formuliranja glavnih i pomoćnih ciljeva proizašlih iz istraživačkih pitanja potrebno je za iste procijeniti njihovu tehničku ostvarivost. Pod ovim pojmom tehničke ostvarivosti smatra se procjena potrebno/raspoloživo vrijeme, raspoloživi resursi (ljudski, financijski) te raspoloživu tehniku.

Hipoteza

Zelenika (2000) postavlja suvremenu definiciju hipoteze: **hipoteza** je znanstvena pretpostavka postavljena za objašnjenje neke pojave koju treba provjeriti i dokazati (ili opovrgnuti) kako bi postala vjerodostojna znanstvena teorija ili znanstveni zakon.

Postupku postavljanja hipoteze pristupa se nakon prikupljanja dovoljnog broja odgovora na postavljena pitanja kojima je definiran znanstveni problem. Hipoteza nije nužna za istraživanje te se ono može provesti bez i jedne hipoteze, ali ona donosi jasniji i precizniji put prema cilju istraživanja. Hipoteza bi bila privremeno najvjerojatnije rješenje problema kao odgovora na postavljena pitanja i kao podloga na kojoj se temelji ideja o predmetu istraživanja.

Istraživač je u mogućnosti definirati i druga rješenja koja su manje vjerojatna od prvotno odabranog rješenja - hipoteze. Rješenje koje odgovara ciljevima postavljenim na početku istraživanja smatraju se kao potvrđivanje postavljene hipoteze. Dobra hipoteza je samo ona koja je adekvatna predmetu istraživanja. Takva hipoteza je provjerljiva i potvrđljiva određenim teorijskim i praktičnim metodama. Testiranje hipoteze usporedba je predviđenih rezultata i ostvarenih rezultata.

Hipoteza sadrži subjekt (proces ili pojavu) koji se testira, varijable koje su promjenjive (nezavisne varijable), varijable koje se mjere (zavisne varijable) te očekivani prognozirani

rezultat. Potvrđivanje ispravnosti prognoze koja je definirana hipotezom vrši se eksperimentalno, odnosno postavljanjem pokusa ili provedbom daljnjih opažanja i istraživanja. Većinom su hipoteze zasnovane na nekim dosadašnjim istraživanjima. Vrlo je važno da hipoteza bude jasna i jednodimenzionalna. Hipoteze ne smiju biti nejasne zbog nemogućnosti empirijske provjere. Upoznatost istraživača s područjem istraživanja pomoći će u lakšem sastavljanju hipoteze.

Primjer: *Koliko različiti tlakovi pneumatika i sustavi primijenjene obrade utječu na zbijanje tla ili kako primijenjena brzina sjetve utječe na sklop nasada?*

Postavljena hipoteza treba imati sljedeća obilježja:

- da ima dvije i više varijabli,
- poveznicu među odnosima varijabli,
- da je formulirana kao oblik tvrdnje,
- poveznicu s teorijom i istraživačkim pitanjem,
- mogućnost statističke provjere.

Obrada podataka istraživanja

Poznavanje statistike i statističkih metoda važna je za znanstveno-istraživački rad.

Osnovni razlozi zašto svi oni koji se bave znanošću trebaju znati statistiku je:

- planiranje istraživanja,
- pronalazak i praćenje znanstvene i stručne literature,
- obrada i analiza podataka prikupljenih u provedenom istraživanju te
- iznošenje zaključaka iz dobivenih rezultata.

Znanstveni rad, odnosno njegova kvaliteta mogu biti ugroženi ako istraživač ne poznaje statistiku prilikom postavljanja ciljeva i hipoteze istraživanja. Nepoznavanje mogućnosti ili logike statističkog procesa može odvesti prema neprimjerenoj obradi podataka prikupljenih istraživanjem.

Za sistematiziranje i opisivanje neke pojave, grupiranja informacija o statističkih skupovima i pod skupovima koristi se deskriptivna statistika. Ona ne stavljanje varijable u odnos, ali omogućuje prikaz osnovnih nalaza istraživanja i radi izračun vrijednosti potrebnih za analizu odnosa između varijabli.

Deskriptivni statistički postupci u znanstvenom ili stručnom radu su najčešće:

- izračun apsolutnih i relativnih frekvencija,
- izračuni srednjih vrijednosti te
- izračuni mjera disperzije.

Aritmetička sredina zasigurno je najčešći izračunavani način dobivanja srednje vrijednosti. Za uočavanje karakteristika podataka nije dovoljna samo srednja vrijednost, već je potrebna i informacija o stupnju varijabilnosti prikupljenih podataka. Ovdje se koriste mjere disperzije poput raspon varijacije, varijanca, koeficijent varijacije, standardna devijacija.

Hipoteza se prihvaća ili odbacuje analizom podataka uspoređujući pritom teorijsku razinu značajnosti i empirijsku razinu značajnosti (izračunatu na temelju podataka). Hipoteze se uglavnom testiraju na razini značajnosti od 1 % ili 5 % (LSD = *Least significant difference*).

Obrada kvantitativnih podataka sastoji se od:

- odabira računalnog programa za obradu podataka,
- unosa podataka, tako da budu lako obradivi odabranim programom,
- odabira prikladne metode za obradu podataka,
- odgovarajuće statističke analize podataka.

U dvadesetom stoljeću statistička metoda postaje jednom od važnijih znanstvenih metoda. R. Zelenika (2000) ovu metodu naziva opće znanstvenom metodom jer se vrlo često koristi u znanstvenoistraživačkom radu u svim znanstvenim područjima i znanstvenim disciplinama.

Ne zadirući dublje u kritičku kvalitativnu analizu Serdar (1977) statistiku definira kao „Znanost o metodama za istraživanje masovnih pojava s pomoću brojčanog istraživanja“. Znatno kompleksnije ju definira Čaval (1977) kao: „Znanost o metodama pomoću kojih analiziramo pojave koje nas okružuju, tako da iz grafikona i izračunatih pokazatelja otkrivamo njihovu strukturu, karakteristike i zakonitosti u vremenskim intervalima te uzročno-posljedične veze između istraživanih pojava“.

Statističke metode uglavnom omogućuju istraživanje povezanosti između varijabli, ali ne i uzročno-posljedični odnos između varijabli.

Prikazivanje rezultata istraživanja i rasprava

Prikazivanje **rezultata** istraživanja predstavlja vrlo kompleksan zadatak. Ovdje je zadatak istraživača sustavno, sveobuhvatno i razumljivo prikazati dobivene rezultate. Nedostatak iskustva istraživača može mu prouzrokovati puno problema prilikom pokušaja da prikaže

veliku količinu prikupljenih podataka. Napredni istraživači savjetuju grupiranje rezultata u manje logične cjeline radi lakšeg i jednostavnijeg praćenja. Potrebno je bazirati se na rezultate koji su u najužoj vezi s predmetom istraživanja te ih prikazati na smislen način.

Pri opisivanju rezultata potrebno je koristiti jednostavan i razumljiv jezik kako bi se izbjegla dvosmislenost prikazanih podataka.

Bolja preglednost prikazanih rezultata može se postići ako istraživač primjeni tablično, grafičko i opisno prikazivanja podataka.

Rezultati se mogu prikazivati nekim logičnim redoslijedom za predmet istraživanja primjerice: od važnih prema manje važnima, prema redoslijedu postavljenih hipoteza, kronološki ili prema redoslijedu promatranih pojava. Tablicama se na kraći i pregledan način prikazuju najčešće numerički podaci, dok pod slikama svrstavamo grafove, shematske prikaze, fotografije i crteže. Slike i tablice koriste se kao ilustracijski prilog opisnom prikazu rezultata. Osim tablicama, numerički podaci mogu se prikazati grafički i to linijskim ili površinskim (2D ili 3D).

U **raspravi** interpretiraju se rezultati te se pojašnjava novo razumijevanje predmeta istraživanja nakon što se obrade rezultati. Rasprava se nadovezuje na uvod, cilj i postavljenu hipotezu. Ponavljanje ranije navedenog i već opisanog u analizi rezultata u raspravi nije prihvatljivo. Glavni je zadatak u raspravi naglasiti na koji način su rezultati istraživanja pridonijeli pomaku u odnosu na postavljene hipoteze. Vlastita istraživanja u raspravi potrebno je povezati s rezultatima drugih istraživanja uključujući i vlastita prethodna istraživanja te slična istraživanja drugih autora. U raspravi može se ponuditi smjer budućih istraživanja.

Zaključak

Zaključak je sinteza rezultata istraživanja u kojem istraživač svojim riječima iznosi najvažnije rezultate provedenog istraživanja. Citiranje i spoznaje drugih istraživača ili rezultate koji nisu proizašli iz stvarno provedenog konkretnog istraživanja u zaključku nije potrebno navoditi.

Iz poglavlja „Znanost o tehničkim sustavima u poljoprivredi“ može zaključiti:

Stvaralačka djelatnost ljudskog roda objedinjava spretne prste, dobru memoriju i mogućnost razumijevanja problema. Ideje i sredstva za olakšavanje rada i življenja nastaju kao rezultat tog objedinjavanja. Civilizacije su i nastale kao akumulacija dobrih ideja i sredstava rada koja su podmirivali potrebe ljudi u određenom povijesnom periodu.

Novi izumi i ispravan znanstveni razvoj mogu se ostvariti korištenjem postojećih informacijskih osnova za projektiranje i dizajniranje tehničkih sustava u poljoprivredi i

općenito. To uključuje razvoj biotehničkih znanosti, inženjerske znanosti, informacije o kulturi, društvenoj organizaciji, ekonomiji, razvoju tržišta i drugim područjima.

Udjel državnih proračunskih sredstava za istraživanje i razvoj u BDP-u u 2016. iznosio je 0,7 % (Državni zavod za statistiku, 2017.). Istovremeno ostale zemlje članice Europske unije za istraživanje i razvoj prosječno izdvajaju 2 % BDP-a. Mitološko veličanje znanosti, tehnološke uniformnosti i ljudskog konformizma bilo je sadržano i u natpisu na ulazu na svjetsku izložbu „Vijek napretka“, u Chicagu 1933. godine: „Znanost istražuje, tehnologija izvršava, čovjek se prilagođava“ (Mumford, 1993).

Otkriće konačne teorije u nekoj grani znanosti i nije baš izgledno iz razloga što fenomeni, odstupanja i turbulentnost promjena te različita interpretacija znanstvenikovih misli uvijek ostavljaju dovoljno mjesta za novo istraživanje.

6.3. Tehničke upute za pisanje rada

Tehničko je oblikovanje znanstvenih i stručnih radova važno kako bi oni bili pregledniji, sustavniji i razumljiviji, odnosno kako bi čitatelji lakše pratili autorov tijek misli, lakše se snalazili u radu te kako čitateljevu pozornost od materije ne bi odvlačili tehnički nedostaci rada. Tehnički nedostaci rada umanjuju vrijednost sadržajno kvalitetnog rada. Iz tog razloga, tehničkom oblikovanju rada trebate posvetiti punu pozornost. U nastavku su opisani najčešće primjenjivani tehnički normativi i pravila za tehničko oblikovanje znanstvenih i stručnih radova. Ne treba zaboraviti da je svaka institucija (fakultet, poslovna škola, časopis) slobodna u određivanju vlastitih normativa i pravila. Prije početka pisanja rada, dobro je upoznati se s tehničkim aspektima pisanja rada koje trebate slijediti (upute za autora).

Obrazovne institucije, odnosno njihovi nastavnici propisuju ili savjetuju koliko stranica teksta minimalno i/ili maksimalno smije imati neki znanstveni ili stručni rad. Svi znanstveni i stručni časopisi ograničavaju broj stranica koje članci za objavu smiju imati. Pod stranicama teksta najčešće se podrazumijevaju tzv. „kartice teksta“. Kartice teksta stranice su na kojima broj redaka ne prelazi 32 retka po stranici, odnosno stranice s 1 800 do 2 000 znakova.

Proizlazi da nije ispravno karticu teksta poistovjećivati sa stranicom teksta. Kartica je isto što i stranica teksta isključivo ukoliko se slijede normativi navedeni u sljedećem okviru.

Kartica teksta

- Format papira; A4 (21,0 cm x 29,7 cm)

- Margine (praznine od tekstualnog sloga do ruba papira); 2,5 cm (1 inč) sa svih strana (gore, dolje, lijevo, desno)
- Prored teksta; 1,5 redak
- Vrsta slova: Times New Roman
- Veličina slova; 12 (tipografskih točaka)

Dok većina visokoškolskih ustanova prihvaća navedene normative stranice teksta, nisu rijetki časopisi koji propisuju svoja pravila za oblikovanje teksta kroz „veličinu“ stranice. Prije nego što se počne pisati rad u računalnom programu koji se koristi za pisanje rada, putem funkcija „Postava stranice“, „Odlomak“ i odabirom potrebnog oblika i veličine slova, postavite stranicu, odnosno uskladite je s propozicijama.

Preglednost rada i lakše snalaženje u njemu postiže se broječanim označavanjem njegovih elemenata. U znanstvenim i stručnim radovima redni se brojevi dodjeljuju stranicama rada, poglavljima i potpoglavljima, popisu korištenih izvora, slikama i tablicama te prilogima. Na koji će se način brojčano označiti navedene elemente, ovisit će naravno o pravilima oblikovanja rada koje treba slijediti. Tako, na primjer, neki časopisi hijerarhiju u naslovima postižu različitim grafičkim oblikovanjem naslova i podnaslova te propisuju da se popis korištenih izvora piše bez numeracije.

Izvjesno je da se rad mora grafički oblikovati sukladno uputama (u slučaju pisanja rada u sklopu obrazovnog programa), odnosno uputama autorima (u slučaju pisanja rada za objavu u znanstvenom ili stručnom časopisu). Ukoliko upute nisu dovoljno precizne, treba koristiti predložak grafičkog oblikovanja časopisa iz područja ili slijediti tzv. dobru praksu.

Tehnička ispravnost teksta doprinosi razumijevanju informacija, ideja i dokaza koje se iznose u radu. Ona neće dodati vrijednost radu, no osigurat će da on ne izgubi na vrijednosti zbog toga što ga čitatelji ne mogu dekodirati. Ozbiljni istraživači ne dopuštaju da njihov rad izađe u javnost (bude predan mentoru, povjerenstvu za ocjenu rada, izdavaču časopisa, organizatoru konferencije i si.) prepun tehničkih pogreški. Potrebno je pažljivo pročitati cijeli rad, naravno, prvenstveno kako bi pronašli suštinske pogreške kao što su nerazumljiv tekst, nejasne ilustracije (slike/tablice) i ponavljanje teksta te ispravili pravopisne i tehničke pogreške, ali isto tako kako bi se ispravilo i tehničke pogreške.

Treba predvidjeti i odvojiti potrebno vrijeme za uređivanje, pregledavanje i ispravljanje pogrešaka u radu. Poželjno je da prođe neko vrijeme nakon završetka konačne verzije rada i vraćanja na njega radi provjere cjelokupnog teksta. Treba koristiti računalne programe za

obradu teksta koji olakšavaju postupak ispravljanja teksta kako u pravopisnom tako i u tehničkom smislu.

6.4. Mentorstvo i suradnja

Kako bi suradnja s mentorom bila što bolja, potrebno je obratiti pozornost na važne sastavnice pri odabiru, suradnji i vođenju kroz znanstveni rad u cjelosti.

Odabir i dužnosti mentora

Odabir mentora gotovo je jednako težak zadatak kao odabir područja ili teme rada. Većina je studenata sklona odabrati mentora koji im se svidio tijekom nastave ili neke druge vrste suradnje, bilo kao stručnjak u svom području, bilo kao osoba. Oba su kriterija iznimno važna i komplementarna.

Mentor bi trebao posjedovati specifična znanja iz područja interesa. Na taj način moći će voditi kroz područje, dati vrijedne informacije i kritike te biti vjerodostojan u procjeni doprinosa određenoj temi. S mentorom se surađuje kroz dulje vremensko razdoblje, stoga je poželjno slaganje i komplementarnost u komunikaciji. Jednostavna i svrsishodna komunikacija učinit će pisanje rada (što je ponekad vrlo težak zadatak) jednostavnijim. „Atraktivni“ mentori možda će biti prezauzeti, što može pokvariti planove. Stoga, poželjno da se o vlastitu radu počne razmišljati dovoljno rano kako bi se na vrijeme dogovorili s potencijalnim mentorom. Treba uzeti kao moguće da mentor može odbiti prijedlog zbog nedostatka vremena ili interesa za temu rada.

Mentor se (određenom fakultetskom odlukom ili jednostavno opisom posla) obvezuje da će studenta/studenticu voditi u procesu izrade seminarskog, diplomskog, specijalističkog poslijediplomskog, magistarskog ili doktorskog rada na visokoj razini stručnosti i etičnosti.

Mentorova je općenita zadaća pomoći studentu/studentici u oblikovanju naslova, problema ili u slučaju drugih nejasnoća, po potrebi ispraviti njegov/njezin rad te dati mišljenje i ukupnu ocjenu rada. Svaki mentor ima svoj način suradnje s kandidatima pa je korisno unaprijed se raspitati (kod kolega ili potencijalnog mentora osobno) i utvrditi odgovara li vam taj način suradnje.

Mentor nije dužan definirati područje, temu, naslov, ciljeve, hipoteze i ostale dijelove rada. To je zadaća studenta/studentice. Time on/ona pokazuje da je u stanju i na visini zadatka diplomirati, magistrirati ili doktorirati. Mentor nije dužan osigurati literaturu iako može uputiti na ključne autore ili naslove.

Konzultacije s potencijalnim mentorom

Poželjno je da se na prve konzultacije s mentorom dođe s prijedlogom područja od interesa jednom ili više tema koje se predlažu. Treba obrazložiti mentoru odabir i dogovoriti osnovni smjer razrade teme. Nije poželjno doći na prve konzultacije bez ideje o bilo čemu prethodno opisanom.

Dolaskom bez pripreme zapravo se gubi vrijeme, kao i vrijeme ostalih kolega koji su ga mogli kvalitetnije iskoristiti.

Za sljedeće konzultacije mentor će vjerojatno zatražiti prvi, inicijalni koncept rada. Treba proučiti dostupne izvore literature, popisati najvažnije autore i članke/knjige iz navedenog područja/teme. Potrebno je učiniti osnovni nacrt empirijskog istraživanja koje bi se provelo. Važno je proučiti prethodna istraživanja na tu temu. Važno je i dogovoriti termin konzultacija s mentorom telefonski ili elektroničkom poštom te mu/joj (po želji mentora) unaprijed poslati dvije-tri stranice kao pripremu za taj razgovor.

Nije poželjno doći mentoru s rečenicom: „Možete li mi biti mentor? Pitala sam tog i tog i tu i tu i... i svi su me odbili!“. Ove rečenice neće izazvati pozitivne emocije u potencijalnom mentoru, nego sasvim suprotno. (S pravom) će si postaviti pitanja zašto su vas odbili te zašto bi vas on/ona trebao/trebala primiti kada su vaš treći ili četvrti (ili n-ti) izbor.

Mentori u pravilu žele znati planove vezane uz pisanje rada kako bi se moglo planirati vrijeme predodređeno za druge kandidate. Osim toga, možda će postavljeni rokovi motivirati pa će dinamika pisanja rada biti bolja nego bez ikakvog dogovorenog plana.

Uobičajen je susret prilikom prvog (po potrebi i drugog, trećeg) dogovora o temi, prilikom predaje rada, nakon čitanja i savjeta mentora te pri usmenoj obrani rada. Po potrebi susreta može biti i više. Neki mentori preferiraju osobne susrete, neki komunikaciju telefonom ili elektroničkom poštom ili nekim društvenim mrežama i komunikatorima. Treba utvrditi dinamiku i način komunikacije s mentorom na početku suradnje. Poželjno bi bilo uvažiti radni ritam i (ostale) obveze mentora u svakoj fazi rada.

Ne treba očekivati odgovor s mentorove strane istoga dana, jer (nažalost). Treba dopustiti mentoru nekoliko dana prije odgovora na elektroničku poštu.

Radna verzija, prva, prije lektoriranja, bez izvora i fusnota s tipfelerima i sl. to su sve imena različitih verzija različitih vrsta radova koje su studenti skloni donositi mentoru na čitanje.

Mentor u pravilu čita zadnju verziju rada. To znači da rad treba imati sve sastavne dijelove, sadržavati pravilno navedene izvore literature (u tekstu i popisu izvora na kraju rada), biti gramatički i pravopisno ispravno napisan s konsektivno označenim brojem stranica i, bez tiskarskih pogrešaka.

Poželjno je dostaviti ispisan i uvezan rad, a ne da ga se šalje elektroničkom poštom (osim u dogovoru s mentorom). Mentor ne bi trebao trošiti vrijeme na ispisivanje rada. Treba se pripremiti da će biti veći broj primjedbi i savjeta nego što je očekivano. Ovo iskustvo ponekad može biti neugodno za kandidata, ali treba pokušati to gledati s vedrije strane: nakon unošenja ispravaka rad će sigurno biti kvalitetniji.

Potrebno je provjeriti što mentor misli o ostalim članovima povjerenstva. Članovi povjerenstva za ocjenu rada odabrani su od strane fakulteta zbog svojih znanja, stoga mogu pridonijeti kvaliteti rada. U tom smislu, korisno ih je pitati za mišljenje tijekom izrade rada. Službena procedura nalaže da se kopije rada predaju u referadu koja ih službenim kanalima prosljeđuje članovima povjerenstva.

Ukoliko je mentor zauzet drugim obvezama treba računati na minimalno tjedan do dva dana za pregled rada. Student/studentica treba brinuti o vremenu koje za pisanje i obranu rada, ne mentor pa nije poželjno da se mentor požuruje. Treba uvažiti da zakonski rok u kojem je mentor (a kasnije i povjerenstvo) dužan dati mišljenje o radu iznosi (obično) 60 dana.

Usmena obrana rada - savjetovanje s mentorom oko usmene obrane

Usmena obrana je službeni i stvarni završetak istraživačkog rada i zahtijeva određenu formu.

Može postojati izvjesno nezadovoljstvo jer se ne komunicira onako kako je očekivano. U tom slučaju treba naći način da se komunikacija unaprijedi.

Ukoliko postoji nezadovoljstvo mentorovom stručnošću, dva su potencijalna problema. Prvo, pretpostavka je da je odabrani mentor stručan u području. Nije li onda naknadna procjena zapravo pogrešna? Ako je mentor imao negativno mišljenje o onome što je napisano, ne znači da on/ona nije stručan/stručna. Drugo, ukoliko se mentor koji je (i formalno) stručan pokazao se lošim izborom, treba razmisliti tko bi bio dobra zamjena.

6.5. Usmena obrana rada

Usmena obrana službeni je i stvarni završetak istraživačkog rada. To je trenutak u kojem se izlaže i prezentira znanstveni rad pred povjerenstvom i gostima.

- Struktura izlaganja (prezentacije) - na slajdovima se iznose najvažnije informacije o istraživačkom problemu, pitanjima, ciljevima, hipotezama, ključnim teorijskim pravcima i autorima, metodologiji, nalazima i zaključcima.
- Prije izlaganja potrebno je predstaviti se i pozdraviti članove povjerenstva, po želji i druge prisutne na usmenoj obrani rada, kratko treba objasniti način izlaganja te navesti očekivano trajanje prezentacije. Slajdovi trebaju biti čitljivi i jednostavni. Stoga, ne treba opterećivati tekstom, izbjegavati šarene i zanimljive pozadine te vizualne i audio efekte. Treba koristiti neutralnu pozadinu (svijetlosivu, blijedoplavu, bež i slično) i boje na kojoj prezentirate rad. Podloga i tekst trebaju biti u kontrastu kako bi tekst bio čitljiviji. Veličina slova treba biti odgovarajuća, dakle niti prevelika niti premala. Uobičajeno je da je veličina slova u naslovu od 28 do 40 pt, a veličina ostalog teksta od 16 do 24 pt.
- Broj slajdova u prezentaciji - ukoliko se neke informacije trebaju prikazati u većem obuhvatu, izlaganje može imati i veći broj slajdova. Treba postići ravnotežu između prikaza teorijskih i empirijskih spoznaja u istraživanju. Broj slajdova u izlaganju ograničen je i predviđenim trajanjem usmene obrane. Treba pokušati svesti na relativno maleni broj (po načelu „manje je bolje“). Članovi povjerenstva ciljani su publika, stoga treba procijeniti što je ključno iznijeti u usmenoj obrani.
- Trajanje prezentacije - mentor i povjerenstvo uputit će kandidata koliko je predviđeno trajanje usmenog izlaganja u postupku usmene obrane. U pravilu je to 15-ak minuta za specijalističke poslijediplomske i magistarske radove te 30-ak minuta za doktorske disertacije.
- Usmeno izlaganje prezentacije - prilikom slaganja treba odrediti informacije koje će se navesti na slajdu te tekst koji će se uz pojedine slajdove govoriti. Nije dobro izlagati isključivo ono što je napisano na slajdu, kao što nije dobro zadržati se nekoliko minuta na samo jednoj riječi koja je istaknuta na slajdu.

Treba pokušati prezentaciju izvesti u nešto kraćem vremenu jer će ona u stvarnim okolnostima zbog treme i drugih čimbenika vjerojatno trajati malo dulje.

Pri izlaganju treba pokušati ne čitati prezentaciju niti sa slajda niti iz vlastitih bilješki. Jednostavno treba izložiti vlastitu spoznaju i pritom izbjegavati „održati predavanje“.

Važno je pokušati postići dobar omjer između stručnosti i prirodnosti u izlaganju. Izlaganje napamet naučenog teksta (kao da se recitira) izgleda „umjetno“. Povjerenstvo je tu upravo kako bi poslušalo izlaganje i postavilo pitanja, stoga ovakav završetak nije primjeren.

Ovo je završetak velikog posla i važan dan za kandidata, njegovu obitelj i prijatelje.

7. SASTAVNICE ZNANSTVENIH I STRUČNIH RADOVA

Znanstveni i stručni članci prate određene standarde i strukturu. Prije početka pisanja, važno je proučiti smjernice institucije ili časopisa koji će objaviti rad i utvrditi obavezne dijelove. Bitno saznati željeni opseg teksta i broj stranica. Institucije propisuju minimalni i/ili maksimalni broj stranica, uključujući sve od uvoda do zaključka, popise literature, slike, tablice i priloge. U slučaju nedostatka specifičnih smjernica, važno je slijediti načelo da veći broj riječi ili stranica nije nužno pokazatelj visoke kvalitete.

Znanstveni i stručni radovi sastoje se od tehničkih i sadržajnih dijelova.

Tehnički dijelovi:

- (1) naslovnu stranicu,
- (2) sadržaj,
- (3) popis literature,
- (4) popis slika,
- (5) popis tablica,
- (6) popis kratica i simbola te
- (7) životopis.

Važno je napomenuti da svi radovi ne moraju uključivati sve ove dijelove, ovisno o vrsti rada.

Naslovna stranica

Naslovna stranica mora sadržavati sve podatke koji određuju neki rad, odnosno odgovarati na sljedeća osnovna pitanja: o kakvom se radu radi? Kojim se područjem rad bavi? Tko je autor rada? Na kojoj se znanstvenoj ili stručnoj instituciji rad piše? Kada je rad napisan? Mora biti odgovarajuće grafički oblikovana.

Elemente i način oblikovanja naslovne stranice treba uskladiti s propisima institucije na kojoj se piše rad odnosno časopisa za koji se piše rad.

Sadržaj

Sadržaj je popis svih dijelova rada i stranica na kojima oni započinju. U njemu se popisuju tehnički dijelovi rada kao što su sam sadržaj, popis literature, slika, tablica, kratica i simbola i životopis te sva poglavlja, potpoglavlja itd. sadržajnog dijela rada.

Sadržaj je standardni dio svih vrsta znanstvenih i stručnih radova koji se pišu u sklopu obrazovnog procesa, knjiga, zbirki radova i monografija, priručnika i skripti, no nije dio znanstvenih ili stručnih članaka.

Osnovna pravila oblikovanja sadržaja rada su: smješta se iza predgovora (ukoliko postoji), a prije uvoda, dakle na samom početku rada. Nije ga ispravno smjestiti na kraju rada jer je on svojevrsan putokaz.

Stranica/e sa sadržajem rada numerira/ju se rimskim brojevima (I., II., itd.). Ako rad nema predgovor, prva stranica sadržaja numerira rimskim brojem I, a ukoliko rad ima npr. predgovor od jedne stranice, prva stranica sadržaja numerira rimskim brojem II., s obzirom na to da se i predgovor numerira rimskim brojevima.

Na prvoj stranici sadržaja velikim se podebljanim slovima gore na sredini stranice piše naslov SADRŽAJ. Pri izradi sadržaja važno je voditi računa da je konačni sadržaj rada točan, dakle da su u njemu navedene točne stranice na kojima započinju dijelovi rada, da su svi naslovi poglavlja i potpoglavlja istovjetni naslovima u tekstu i slično. Navedeno neće biti problem ako se koristi računalna opcija automatske izrade sadržaja.

Popis literature

Popis literature popis je svih primarnih izvora na koje se u radu poziva. U popisu literature navode se ona djela koja su korištena u tekstu rada. U njemu se ne navode djela koja su također proučavana, ali nisu spomenuta u radu, izvore koje su preuzeti od drugih te nikako sve pročitane publikacije.

Popis literature obavezni je dio svakog znanstvenog i stručnog rada. Pravila oblikovanja popisa literature su: smješta se iza zaključka rada, započinje na novoj te posebnoj stranici. Stranica/e s popisom literature numeriraju se arapskim brojevima koji se nastavljaju na prethodnu numeraciju. Na stranici na kojoj započinje popis literature velikim se podebljanim slovima na sredini gore piše LITERATURA.

Popis slika i tablica

Ukoliko u sklopu obrazovnog programa uključuje slike, obavezno je izraditi njihov popis što nije praksa kod pisanja članaka.

Popis slika uključuje: (1) redne brojeve slika, (2) naslove slika i (3) stranice na kojima se slike nalaze, a služi za lakše pronalaženje grafičkih prikaza.

Pravila oblikovanja popisa slika su:

- Smješta se iza popisa literature.
- Započinje na novoj, posebnoj stranici.

Stranica/e s popisom kratica i simbola numeriraju se arapskim brojevima koji se nastavljaju na prethodnu numeraciju. Na stranici na kojoj započinje popis slika velikim se podebljanim slovima na sredini gore piše POPIS SLIKA.

Ukoliko rad u sklopu obrazovnog programa (ne i ako se radi o znanstvenom ili stručnom članku) sadrži tablice, izradit ćete njihov popis. Popis tablica koji služi za lakše pronalaženje željenih tablica od strane čitatelja, obavezno mora sadržavati: (1) redne brojeve tablica, (2) nazive tablica i (3) stranice na kojima se tablice nalaze.

Pravila oblikovanja popisa tablica su:

- Smješta se iza popisa slika.
- Započinje na novoj, zasebnoj stranici.

Stranica/e s popisom kratica i simbola numeriraju se arapskim brojevima koji se nastavljaju na prethodnu numeraciju. Na stranici na kojoj započinje popis tablica velikim se podebljanim slovima na sredini gore piše POPIS TABLICA.

Popis kratica i simbola

Ukoliko se u radu koristi veći broj kratica i simbola, što je vjerojatno ako se piše rad iz makroekonomije, mikroekonomije, ekonomske matematike i slično, uputno je izraditi njihov popis. Čitatelja se ne bi trebalo ostaviti u nedoumici što koja kratica ili simbol znače.

Pravila oblikovanja popisa kratica i simbola su: smješta se iza popisa tablica i započinje na novoj, posebnoj stranici. Stranica/e s popisom kratica i simbola numeriraju se arapskim brojevima koji se nastavljaju na prethodnu numeraciju. Na stranici na kojoj započinje popis kratica i simbola velikim se podebljanim slovima na sredini gore piše POPIS KRATICA I SIMBOLA.

Životopis

Navode se opći biografski podaci, podaci o obrazovanju i radnom iskustvu te podaci o dodatnim znanjima, vještinama i interesima. Životopis je sastavni dio svakog diplomskog rada, specijalističkog poslijediplomskog rada, magistarskog rada i doktorske disertacije. Pravila oblikovanja stranice/a sa svim podacima o autoru: smješta se na kraju rada, iza svih ostalih

dijelova rada. Započinje na novoj, posebnoj stranici. Nadalje, numerira se arapskim brojevima koji se nastavljaju na prethodnu numeraciju. Na stranici na kojoj započinje životopis velikim se podebljanim slovima na sredini gore piše ŽIVOTOPIS. Sadržajnim dijelovima znanstvenih i stručnih radova u širem smislu Naslov, Predgovor, Sažetak i Ključne riječi.

Struktura 1.

Uvod

1.1. Ciljevi, istraživačka pitanja i hipoteza

1.2. Izvori i metode prikupljanja podataka

1.3. Struktura rada

2. Teorijski okvir

3. Empirijsko istraživanje

3.1. Metodologija istraživanja

3.2. Rezultati istraživanja

3.2.1....

3.x. Ograničenja istraživanja

4. Rasprava

5. Zaključak

Struktura 2.

1. Uvod

2. Ciljevi i istraživačka pitanja

3. Teorijski okvir

3.1....

4. Hipoteze

3. Metodologija istraživanja

6. Rezultati istraživanja

6.1....

7. Rasprava

8. Zaključak

U nastavku su ukratko opisani navedem sadržajni elementi znanstvenih i stručnih radova, pri čemu treba imati na umu da odgovor na pitanje hoće li rad uključivati sve navedene dijelove ovisi o vrsti rada. Dok znanstveni magistarski radovi i doktorske disertacije u pravilu sadrže sve opisane dijelove, sasvim je razumljivo zašto ih seminarski radovi i kritički prikazi nemaju.

Naslov

Uloga naslova rada je informirati o radu. Iz tog razloga on mora biti indikativan, odnosno ukazivati na sadržaj rada te biti jasan i jednoznačan. Adekvatnost naslova posebice je važna za svrstavanje rada u ispravno područje u digitalnim i drugim bibliografskim bazama, bez kojeg je njegovo pretraživanje nemoguće. Naslov rada ne smije biti niti predugačak niti prekratak, odnosno nije poželjno niti da je previše detaljan niti da je preopćenit. Iako se smatra da naslov mora biti privlačan, odnosno zaintrigirati čitatelja da pročita rad, on ne smije obmanjivati. Naslov mora odgovarati sadržaju, a ne najavljivati nešto o čemu se u radu ne može pročitati. Isto se tako pogreškom smatra kvalitetnoj materiji ne dodijeliti naslov koji ukazuje na to da se radi o radu koji dodaje vrijednost, a ne o već više puta obrađivanoj temi. U okviru u nastavku navedeno je što ne bi trebalo biti u naslovu rada.

Predgovor

Svrha predgovora je upoznati čitatelja s okolnostima pisanja rada. U predgovoru se opisuju osnovni motivi pisanja rada, uvjeti u kojima je rad pisan te eventualne poteškoće pri tome, izražava zahvalnost onima koji su na bilo koji način pomogli u radu (mentor, kolege, ispitanici, recenzenti, obitelj, i sl.) redoslijedom značaja njihove pomoći (a ne njihovih titula ili položaja u društvu) te ukazuje na to kome je djelo namijenjeno.

Predgovor po svojem sadržaju značajno se razlikuje i treba razlikovati od uvoda. Predgovor u pravilu imaju sva opsežna znanstvena ili stručna djela, kao što su magistarski radovi, doktorske disertacije, udžbenici, priručnici, monografije, no on nije njihov obavezan dio.

Pravila oblikovanja predgovora:

- Smješta se prije uvoda.
- Započinje na novoj stranici.
- Stranice predgovora numeriraju se rimskim brojevima (od I. do n).
- Na stranici na kojoj započinje predgovor velikim se podebljanim slovima na sredini gore piše PREDGOVOR.

Sažetak i ključne riječi

Sažetak je kratki prikaz cjelokupnog rada. Njegova je svrha prvenstveno bibliografska, dakle kako bi u tiskanim i digitalnim sekundarnim publikacijama rad bio dodijeljen ispravnom znanstvenom ili stručnom području. Na temelju njega čitatelji odlučuju radi li se o radu koji im je koristan i koji će pročitati u cijelosti i slično.

Sažetekom je potrebno obuhvatiti četiri područja:

1. Područje istraživanja te ciljeve i hipoteze rada,
2. Metodologiju istraživanja,
3. Osnovne nalaze,
4. Ključne zaključke.

Sažetak se piše na jeziku na kojem je napisan rad te na jednom svjetskom jeziku. Pri njegovom pisanju treba dosljedno slijediti upute o njegovoj maksimalnoj dužini. Znanstveni i stručni časopisi propisuju maksimalan broj riječi sažetka, najčešće 100 ili 250 riječi, dok je npr. za magistarske i doktorske radove primjeren sažetak od jedne stranice. U znanstvenim i stručnim člancima sažetak se u pravilu nalazi nakon naslova, a prije rada, odnosno uvoda.

Tehnička pravila oblikovanja sažetka:

- Sažetak se smješta nakon predgovora ukoliko ga rad ima, a prije uvoda,
- Na posebnoj stranici na kojoj započinje sažetak na hrvatskom jeziku velikim podebljanim slovima u sredini gore piše SAŽETAK.
- Na posebnoj stranici na kojoj započinje sažetak na nekom svjetskom jeziku velikim podebljanim slovima u sredini gore piše „sažetak“ na tom jeziku (npr. ABSTRACT ili SUMMARY na engleskom jeziku).

Ključne su riječi one koje opisuju kojim se područjima neki rad bavi. Važne su jer se na temelju njih pretražuju radovi u tiskanim i digitalnim bazama publikacija.

Pišu se na jezicima na kojima se piše i sažetak rada.

Znanstveni i stručni časopisi najčešće propisuju da je potrebno navesti tri do pet ključnih riječi, dok specijalistički poslijediplomski, magistarski i doktorski rad mogu imati i značajno više ključnih riječi, često sve riječi koje se odnose na koncepte kojima se rad bavi. Ključne riječi se smještaju nakon sažetka, pod podnaslovom Ključne riječi, odnosno *Key words* na engleskom jeziku.

Uvod

Uvod služi kako bi se opisao razlog istraživanja. Ključni dio uvoda zasigurno je dio u kojem se obrazlaže teorijska i praktična vrijednost vlastitog istraživanja, odnosno ukazuje na značajnost teme. U tom je dijelu potrebno dati i kratku ocjenu dosadašnjih istraživanja s obzirom na to da tema te ciljevi i hipoteze rada moraju proizlaziti odnosno nastavljati se upravo na dosadašnje spoznaje. Radi se isključivo o kratkoj ocjeni prethodnih istraživanja, ne i njihovom detaljnom opisivanju, što je dio teorijskog okvira u sklopu razrade teme.

Uvod se smatra najvažnijim dijelom svakog pisanog materijala s obzirom na to da „postavlja pozornicu“ za ono što slijedi te određuje hoće li čitatelj nastaviti s čitanjem ili ne. Iz tog razloga on mora biti dobro strukturiran i jasan. Ne smije biti ni prekratak ni predug. Dobra praksa nalaže da uvod nije duži od 10 % ukupne dužine rada. Tako je kod opsežnijih znanstvenih ili stručnih radova (npr. magistarski i doktorski radovi) opseg uvoda od pet do petnaest stranica, dok je kod kraćih radova (npr. članci i seminarski radovi) opsega jedne do dvije stranice.

Tehnička pravila oblikovanja uvoda:

- Smješta se nakon sadržaja rada.
- Započinje na novoj stranici.
- Numerira se arapskim brojevima od 1 do n.
- Na stranici na kojoj započinje uvod velikim se podebljanim slovima lijevo gore označava da je uvod prvo poglavlje rada, dakle piše 1. UVOD.

Razrada teme

Tema znanstvenog ili stručnog rada sustavno se raspoređuje i obrađuje u tri dijela:

1. povijesno teorijski, retrospektivni ili eksplikativni dio,
2. analitičko-eksperimentalni dio i
3. perspektivni dio.

Razrada teme sastoji se, u pravilu, od teorijskog okvira, opisa primarnog istraživanja koje je provedeno i rasprave.

U teorijskom okviru zadatak je iznijeti teoriju koja je polazište za empirijsko istraživanje. U tom dijelu određuju se osnovni pojmovi nekog područja te posebice varijable koje će se operacionalizirati za potrebe primarnog istraživanja.

Potrebno je sistematizirati područje od interesa istraživanja koristeći nalaze, mišljenja i zaključke drugih, detaljno opisati dosadašnja istraživanja.

Opis primarnog istraživanja sastoji se od detaljnog opisa metodologije istraživanja, prikaza rezultata istraživanja te analize dobivenih rezultata. Opis metodologije istraživanja uključuje opise korištenih metoda istraživanja, instrumenata istraživanja, načina prikupljanja podataka, populacije i uzorka istraživanja, ispitanika u istraživanju, obrade podataka i slično. Metodologiju istraživanja potrebno je detaljno opisati kako bi se istraživanje moglo provjeriti, a opisani postupci ponoviti. Za razliku od toga, standardni istraživački instrumentarij (metode istraživanja, statističke metode i sl.) nije potrebno opisivati.

U teorijskom okviru treba iznijeti teoriju koja je polazište za empirijsko istraživanje. Određuju se osnovni pojmovi nekog područja te posebice varijable koje će se operacionalizirati za potrebe primarnog istraživanja, sistematizirati područje koristeći nalaze, mišljenja i zaključke drugih, detaljno opisati dosadašnja istraživanja i rezultate vezane uz predmet rada i slično.

Opis primarnog istraživanja sastoji se od detaljnog opisa metodologije istraživanja, prikaza rezultata istraživanja te analize dobivenih rezultata. Opis metodologije istraživanja uključuje opise korištenih metoda istraživanja, instrumenata istraživanja, načina prikupljanja podataka, populacije i uzorka istraživanja, ispitanika u istraživanju, obrade podataka i slično.

Sve važne rezultate istraživanja potrebno je iznijeti, odnosno prikazati. Analiza rezultata važan je dio svakog znanstvenog i stručnog rada. Dobivene rezultate nije dostatno opisati, potrebno ih je analizirati, ući u njihovu bit te na temelju toga iznijeti svoje zaključke, mišljenja i ideje korisne za rad drugih.

Zaključak

Zaključak treba kratko i jasno rezimirati. To znači:

1. ponoviti što je bio istraživački zadatak,
2. ukratko prepričati osnovne nalaze te
3. iznijeti sveukupni dojam o istraživanom području.

Osim odgovora na postavljena pitanja i završnih konstatacija, u zaključku se može navesti i što se smatra da bi još ili dalje trebalo istražiti te koji su konkretni napuci za praksu koji proizlaze iz rada.

Pri pisanju zaključka treba se voditi mišlju da zaključak nije niti sadržaj niti sažetak, već sinteza vlastitog rada. U njemu se ne prepričava ono o čemu je pisano u tekstu rada. U njemu se ne iznose nove činjenice, dokazi, podaci i slično. U zaključku se ne savjetuje niti navode drugi autori. Gornja granica opsega zaključka je 5 % ukupnog opsega rada.

Tehnička pravila oblikovanja zaključka:

- Zaključak je zadnje poglavlje u radu, dakle smješta se nakon razrade teme.
- Numerira se arapskim brojevima koji slijede nakon numeracije zadnjeg poglavlja.
- Započinje na novoj stranici.
- Na stranici na kojoj započinje zaključak velikim se podebljanim slovima lijevo gore piše riječ ispred koje se piše broj zaključnog poglavlja (npr. „8. ZAKLJUČAK“).

Prilozi

Prilozi odnosno dodaci dijelovi su rada koji se prilažu osnovnom tekstu rada. To su različiti dokumenti i detaljna objašnjenja, odnosno materijali koji su ili manje važni za rad ili previše detaljni, stoga ih nije prikladno iznositi u tekstu rada jer ga nepotrebno opterećuju.

U priloge se uobičajeno stavljaju instrumenti istraživanja korišteni u radu, tablice s detaljnim statističkim podacima koji su u agregatnom obliku prikazani u tekstu rada (npr. detaljna obilježja uzorka, korelacijske matrice), različiti crteži i fotografije koji dodatno oslikavaju materiju rada, službeni dokumenti ili njihovi dijelovi:

- Smještaju se iza popisa literature, odnosno popisa slika i tablica ukoliko ih rad ima. Numeriraju se arapskim brojevima od 1 do n.
- Svaki prilog započinje na novoj stranici.
- Na stranici na kojoj započinje svaki od priloga velikim se podebljanim slovima lijevo gore piše riječ prilog i njegov broj (npr. PRILOG 1).
- U tekstu rada potrebno je ukazati na priloge na način da se pozove na broj priloga na koji se tekst odnosi. Ukoliko prilog sadrži slike, tablice i sl., najčešće se slike/tablice numeriraju na način da numeracija započinje brojem koji slijedi iza broja zadnje slike/tablice u tekstu rada.

U nastavku ukratko su opisane osnovne vrste znanstvenih i stručnih radova koji su dio obaveza na preddiplomskim, diplomskim i poslijediplomskim studijima: seminarski rad, kritički prikaz, diplomski rad, specijalistički poslijediplomski rad, magistarski rad, doktorski rad te radovi koji se pišu u svrhu iznošenja nalaza znanstvenog i stručnog rada: znanstveni i stručni članak. Pri njihovoj izradi obavezno je dodatno proučiti pravila postavljena od strane obrazovne institucije.

7.1. Seminarski rad

Seminarski rad kraći je stručni rad u kojem se samostalno obrađuje odabrana tema. Izrada seminarskog rada standardna je obaveza na visokoškolskim institucijama u svrhu produbljivanja znanja iz područja kolegija iz kojeg se izrađuje.

Izradom seminarskog rada treba se dokazati sposobnost promišljanja i zaključivanja o odabranoj stručnoj temi te je adekvatno obraditi na teorijskoj i/ili empirijskoj razini.

Na teorijskoj razini očekuje se sistematizacija spoznaje vezane uz neko uže stručno područje na temelju stručne literature. Na empirijskoj razini očekuje se da se istraži neko stručno područje u praksi. Seminarskim radom treba pokazati da se zna pronaći i koristiti literatura, poznavanje osnove provođenja primarnih istraživanja (ukoliko se empirijski istražuje područje) te da se općenito poznaju pravila izrade stručnog rada. Tema seminarskog rada dogovara se s nastavnikom. Poželjno je da se predloži tema koja je zanimljiva ili bliska. Na taj način razvija se osjetljivost za probleme u području struke te pokazuje interes za kolegij i područje.

Postupak izrade i ocjenjivanja seminarskog rada:

1. Izrada preliminarnog sadržaja rada koji je okosnica za pisanje rada.
2. Predaja prve verzije seminarskog rada nastavniku na uvid.
3. Uvažavanje nastavnikovih primjedbi na rad, odnosno naputaka.
4. Izrada završne verzije rada.
5. Predaja jednog primjerka uvezanog rada (plastičan uvez) nastavniku na ocjenjivanje.
6. Upis ocjene iz seminarskog rada u prijavnicu za seminarski rad.

Preporučeni opseg seminarskog rada je 10 do 15 stranica, a njegovi su uobičajeni dijelovi:

1. Naslovna stranica
2. Sadržaj
3. Uvod i razrada teme
4. Zaključak
5. Popis literature
6. Popis slika, tablica i priloga.

7.2. Kritički prikaz

Kritički prikaz stručni je rad u kojem se iznosi vlastito mišljenje o izabranom znanstvenom ili stručnom djelu u svrhu proširivanja i produbljivanja znanja.

Izrada kritičkog prikaza standardna je obaveza na diplomskim i poslijediplomskim studijima te nerijetko jedna od obaveza iz kolegija na preddiplomskim studijima,

Cilj je kritičkog prikaza osposobljavanje za kritičko, objektivno i znanstveno prosuđivanje, vrednovanje i ocjenjivanje tuđeg djela.

U tom obliku očekuje se:

1. ukratko prepričati o čemu se radi odnosno iznijeti osnovne nalaze/zaključke,
2. proučiti djelo i pozicionirati ga u odnosu na ostala teorijska promišljanja o nekom području (odrediti vrijednost i aktualnost),
3. obrazložiti korisnost proučavanog djela za suvremenu praksu te
4. iznijeti vlastito mišljenje o djelu odnosno svoje pozitivne i/ili negativne kritike na djelo u smislu njegove korisnosti za teoriju i praksu.

Važno je da su svi zaključci i mišljenja koja se iznose dobro utemeljeni i obrazloženi. U kritičkom prikazu ne iznose se kritike djela u literarnom smislu. Razumljivost jezika kojim je pisano, sustavnost i jasnoća iznošenja materije od strane autora teksta i slično nisu predmet kritičkog prikaza.

Okosnica za izradu kritičkog prikaza može biti bilo koji znanstveni ili stručni tekst - članak, knjiga, poglavlje u knjizi, izvještaj itd.

Prije pristupanja izradi kritičkog prikaza temu kritičkog prikaza treba dogovoriti s predmetnim nastavnikom.

Jedan primjerak uvezanog kritičkog prikaza (plastičan uvez) predaje se nastavniku na ocjenu. Ocjena iz kritičkog prikaza na preddiplomskom studiju u pravilu ulazi u konačnu ocjenu iz kolegija, dok se na diplomskim i poslijediplomskim studijima upisuje u prijavnicu.

Preporučeni opseg kritičkog prikaza je 5 do 7 stranica, a njegovi su uobičajeni dijelovi:

1. Naslovna stranica

2. Sadržaj
3. Uvod
4. Prikaz djela
5. Kritički osvrt
6. Zaključak
7. Popis literature

7.3. Završni i diplomski (magistarski) rad

Završni i diplomski rad koji se piše na završetku dodiplomskog (preddiplomskog), odnosno diplomskog studija, opširniji je stručni rad u kojem se samostalno u pisanom obliku obrađuje odabrana tema. Svrha mu je proširivanje i produbljivanje znanja iz područja kolegija iz kojeg se izrađuje.

Izradom završnog i diplomskog rada dokazuje se sposobnost promišljanja i zaključivanja o odabranoj stručnoj temi na način da se obrađuje i teorijski i empirijski.

Na **teorijskoj razini** očekuje se da na se na temelju literature sistematiziraju činjenice, spoznaje, nalazi itd. vezane uz temu. Na empirijskoj razini očekuje se da se odabrana tema istraži na temelju dostupnih sekundarnih podataka ili na temelju primarnih podataka.

Teorijskim dijelom rada dokazuje se sposobnost kritičkog odabira značajne literature, njezino razumijevanje te sposobnost zaključivanja o nekom teorijskom problemu.

Empirijskim dijelom rada dokazuje se poznavanje znanstvene metodologije prikupljanja primarnih i sekundarnih podataka.

U praksi nisu rijetki isključivo teorijski završni i diplomski radovi, dakle oni koji odabranu temu obrađuju isključivo na temelju literature. Osim zahtjevnih, rijetko obrađivanih tema, diplomski rad trebao bi imati i empirijski dio, dakle dio u kojem obrađivanu problematiku sagledavate i iz drugog ugla.

Poželjno je da kandidati predlože temu što bi trebalo, a što ne biti temom koja je zanimljiva ili bliska, odnosno tema završnog i diplomskog rada.

Faze izrade i obrane završnog i diplomskog rada, koje u dijelu obrane obrazovne institucije formaliziraju, su:

1. Izrada preliminarnog sadržaja rada (nakon dogovora s mentorom - usuglašena tema rada), nakon što ju mentor odobri, biti okosnica za pisanje rada. Uz preliminarni sadržaj rada treba priložiti i popis inicijalne literature, kako bi mentor uvidio krećete li se u dobrom smjeru.
2. Predaja prve verzije završnog ili diplomskog rada mentoru na uvid.
3. Dorada završnog ili diplomskog rada na temelju mentorovih primjedbi na rad, odnosno naputaka što doraditi, dodati, izbaciti itd.,
4. Predaja završne verzije rada mentoru u svrhu obrane rada.
5. Obrana završnog ili diplomskog rada pred povjerenstvom.

Preporučeni opseg diplomskog rada je 40 do 60 stranica, a njegovi su uobičajeni dijelovi:

1. Naslovna stranica
2. Sažetak i ključne riječi
3. Sadržaj
4. Uvod
5. Razrada teme
6. Zaključak
7. Popis literature
8. Popis slika
9. Popis tablica
10. Prilozi
11. Životopis

7.4. Specijalistički poslijediplomski rad

Specijalistički poslijediplomski rad opširan je stručni/znanstveni rad u kojem poslijediplomski student samostalno, u pisanom obliku, obrađuje odabranu temu u svrhu stjecanja titule sveučilišnog specijalista (univ. spec.). Izradom specijalističkog poslijediplomskog rada

pokazuje se sposobnost samostalnog istraživanja i rješavanja složenijih praktičnih problema iz područja specijalizacije, kako na teorijskoj tako i na empirijskoj razini.

Na **teorijskoj se razini** očekuje se sveobuhvatno i sustavno opisivanje teme za rad na temelju značajne literature. Na **empirijskoj razini** uočavanje za struku značajnih problema, njihovo istraživanje primjenom adekvatnih istraživačkih metoda te zaključivanje o prikupljenim nalazima uz davanje preporuka za poboljšanje odnosno upravljanje istraživanim pojavom.

Temu specijalističkog poslijediplomskog rada predlaže kandidat, vodeći se sklonostima prema nekom području, a imajući u vidu da tema rada treba biti usmjerena prema iznalaženju rješenja konkretnog problema iz područja specijalizacije te dostupnost potrebnih podataka, dokumentacije i slično. Tema može proizlaziti i iz poslovnog problema točno određene organizacije, no ime organizacije ne smije biti navedeno u naslovu rada.

Osnovne faze izrade i obrane specijalističkog poslijediplomskog rada su:

1. Izrada sadržaja rada (nakon odobrenja teme od strane mentora), na temelju prikupljanja i proučavanja literature koja je temelj za strukturiranje postojećih teorijskih rješenja praktičnog problema koji se istražuje i za dolaženje do ideje kako empirijski istražiti problem.
2. Izrada prijave rada (nakon što je mentor odobrio sadržaj rada).
3. Prihvaćanje prijave specijalističkog poslijediplomskog rada od strane nadležnog tijela.
4. Izrada prve verzije rada koja se daje mentoru na uvid.
5. Dorada rada na temelju mentorovih primjedbi.
6. Službena predaja rada na ocjenu.
7. Prihvaćanje rada i izvještaja o radu napisanog od strane povjerenstva za obranu rada.
8. Javna obrana rada pred povjerenstvom.

Preporučeni opseg specijalističkog poslijediplomskog rada je 70 do 100 stranica, a njegovi su uobičajeni dijelovi:

1. Naslovna stranica
2. Sažetak (na hrvatskom i jednom svjetskom jeziku)

3. Ključne riječi (na hrvatskom i jednom svjetskom jeziku)
4. Sadržaj
5. Uvod
6. Razrada teme
7. Zaključak
8. Popis literature
9. Popis slika
10. Popis tablica
11. Prilozi
12. Životopis

Teorijske i praktične nalaze specijalističkog postdiplomskog rada moguće je objaviti u stručnom časopisu u obliku stručnog članka. Na taj se način s teorijskim i empirijskim rješenjima problema s kojima se svakodnevno susreće praksa.

7.5. Doktorska disertacija

Doktorska disertacija izvorni je znanstveni rad u kojem poslijediplomski (doktorski) student samostalno u pisanom obliku obrađuje odabranu temu u svrhu stjecanja titule doktora znanosti (dr. sc.), a koji se piše kako bi se dokazala sposobnost djelovanja kao samostalnog istraživača u znanstvenom području za koje se dodjeljuje doktorat znanosti (McMiilan i Weyers, 2007).

Obilježja kvalitetne doktorske disertacije:

- bavi se relativno neistraženim ili nedostatno istraženim znanstvenim područjem,
- ima značajan znanstveni doprinos, dakle rezultira novim spoznajama i u teorijskom i u empirijskom smislu, kao što su nove teorije, novi modeli, nove zakonitosti i slično.
- njezini nalazi i zaključci doprinose prvenstveno razvoju fundamentalnih znanosti, ali imaju i primijenjenu te, po mogućnosti, i razvojnu komponentu.

Svi dijelovi doktorske disertacije, od određenja teme, ciljeva i hipoteza istraživanja i razvoja teorijskog okvira, preko istraživačke metodologije pa sve do rasprave i zaključaka moraju biti izrađeni prema najvišim standardima izrade znanstvenog rada, dakle ukazivati na zavidna akademska znanja i vještine.

Doktorska disertacija trebala bi biti rezultat višegodišnjeg teorijskog i praktičnog znanstvenog istraživanja.

Za temu doktorske disertacije savjetuje se odabrati područje kojim se student bavi dulji niz godina jer je to najbolja pretpostavka za stvarni znanstveni doprinos.

Samo u području koje se jako dobro poznaje može se znati što još nije, a trebalo bi i moglo biti istraženo, odnosno gdje postoji prostor za dodavanje vrijednosti.

Obrazovne institucije predviđaju najčešće sljedeće faze izrade i obrane disertacije:

1. Razrada detaljnog sadržaja disertacije (nakon prihvaćanja teme od strane mentora).
2. Izrada prijave disertacije (nakon što je sadržaj disertacije odobren od strane mentora).
3. Prihvaćanje prijave doktorske disertacije od strane nadležnog tijela.
4. Izrada disertacije i njezina predaja mentoru koji je pregledava te daje svoje primjedbe.
5. Otklanjanje primjedbi mentora.
6. Službena predaja disertacije na ocjenu.
7. Prihvaćanje rada i izvještaja o radu napisanog od strane povjerenstva za obranu rada.
8. Javna obrana disertacije pred povjerenstvom.

Preporučeni opseg doktorske disertacije je 150 do 200 stranica.

Njezini su dijelovi:

1. Naslovna stranica
2. Sažetak (na hrvatskom i jednom svjetskom jeziku)
3. Ključne riječi (na hrvatskom i jednom svjetskom jeziku)
4. Sadržaj
5. Uvod

6. Razrada teme
7. Zaključak
8. Popis literature
9. Popis slika
10. Popis tablica
11. Prilozi

Dijelove doktorske disertacije savjetuje se objaviti u jednom ili više (ovisno o opsežnosti, broju koncepata koji su istraživani i si.) znanstvenih članaka kako bi njezini rezultati, nalazi i zaključci bili dostupni široj znanstvenoj javnosti i doprinosili ukupnom fondu znanja iz nekog znanstvenog područja.

Potrebno je navesti da se članak/članci temelje na doktorskoj disertaciji.

7.6. Stručni članak

Stručni je članak onaj koji doprinosi razvoju struke iznoseći rezultate teorijskih i empirijskih stručnih istraživanja. On ne sadrži originalne poglede i rezultate, već se u njemu obrađuje poznato, već opisano, što znači da, za razliku od znanstvenog članka, ne doprinosi razvoju znanosti, odnosno nema znanstveni doprinos.

Stručni članak može prikazivati rezultate primarnog istraživanja koje je provedeno u svrhu unapređenja djelovanja u praksi, no može sustavno opisivati neko stručno područje na temelju isključivo sekundarnih podataka, dakle na temelju nalaza, mišljenja i ideja drugih davati naputke i preporuke za djelovanje.

Standardni dijelovi stručnog članka:

1. Naslovna stranica, u pravilu, sadrži naslov članka, imena autora, osnovne podatke o autorima (institucija s koje dolaze, adresa, broj telefona, elektronička pošta itd.)
2. Sažetak na jeziku na kojem je napisan rad
3. Uvod
4. Razrada teme

5. Zaključak

6. Popis literature

S obzirom na to da se pri izradi stručnog članka također primjenjuje metodologija znanstvenog rada i istraživanja, ponekad je vrlo teško razlučiti radi li se o stručnom ili o znanstvenom članku. Ovo uvelike ovisi o čitatelju. Tako se nerijetko događa da isti rad jedan recenzent ocijeni kao stručni rad jer se smatra da razina prikazane teorije, vrsta i metode istraživanja ili sama problematika koja se istražuje nije znanstvena, dok drugi recenzent rad ocijeni kao znanstveni.

7.7. Znanstveni članak

Znanstveni članak je takav koji doprinosi razvoju znanosti iznoseći rezultate istraživanja provedenih primjenom metodologije znanstvenog istraživanja.

Znanstveni je članak moguće objaviti u:

- Znanstvenom, odnosno znanstveno-stručnom tiskanom ili elektronskom časopisu,
- zborniku radova znanstvenog, odnosno znanstveno- stručnog skupa,
- zbirci radova, odnosno kao poglavlje u knjizi, i slično.

Vrste znanstvenih radova:

1. *Izvorni znanstveni radovi* (engl. *original scientific papers*) – znanstveni radovi koji iznose rezultate izvornih znanstvenih istraživanja (istraživanja znanstvene problematike provedena metodologijom znanstvenih istraživanja koja imaju znanstveni doprinos) koji nigdje prije toga nisu objavljeni, a kojih je istraživanje moguće ponoviti i na taj način provjeriti točnost.
2. *Prethodna priopćenja* (engl. *preliminary Communications*) – znanstveni radovi koji iznose rezultate ili dijelove rezultata znanstvenih istraživanja koja su u tijeku.

Radi se o radovima koji zahtijevaju brzu objavu kako njihovi nalazi ne bi zastarjeli, iz kojeg razloga ne moraju uključivati dovoljno pojedinosti kako bi se u njima opisana istraživanja mogla ponoviti.

3. *Pregledni radovi* (engl. *reviews*) znanstveni su radovi koji daju sveobuhvatan i sustavan pregled nekog znanstvenog područja na kritički način (analizirajući, diskutirajući, kritizirajući itd.) koje karakterizira veliki broj značajnih izvora

literature, dakle radovi koji zaokružuju neko već poznato područje.

Svaki rad koji se želi objaviti u znanstvenom časopisu mora proći kroz anonimni recenzentski postupak.

Na temelju recenzentskog postupka rad može biti:

- (1) prihvaćen za objavljivanje u izvornom obliku, što znači da recenzenti nisu tražili nikakve izmjene, dorade i slično, što je vrlo rijedak slučaj,
- (2) prihvaćen po otklanjanju primjedbi recenzenata ili
- (3) odbijen.

Svrha recenzije je višestruka: (1) odluka o kvaliteti rada, odnosno njegovoj prikladnosti za objavljivanje u nekom časopisu, (2) unapređenje rada u smislu njegove jasnoće, sustavnosti, potpunosti, doprinosa i slično i (3) kategorizacija rada - radi li se o stručnom ili znanstvenom radu te o kojoj kategoriji znanstvenog rada.

Primjedbe recenzenata na rad, čak i u slučaju kada je rad odbijen, treba shvatiti konstruktivno. Njihovim uvažavanjem rad je zasigurno moguće unaprijediti, a one, od njih koje su posljedica nesporazuma ili nerazumijevanja od strane recenzenata, ne smiju uvrijediti kandidata.

Sve izmjene trebaju biti unesene u rad i biti obilježene u samom radu ili objašnjene u popratnom pismu uredništvu časopisa. Treba argumentirati i razloge eventualnog neuvažavanja primjedbi recenzenata koje će ukoliko su smisleni, svaki stručni urednik uvažiti (Zelenika, 2000).

Duljina znanstvenog rada, u pravilu, određena je od strane časopisa za koji se rad piše, u čijem je slučaju potrebno slijediti minimalna i maksimalna ograničenja.

Dijelovi znanstvenog članka, u pravilu, nisu striktno određeni, no najčešća forma je sljedeća:

1. Naslovna stranica, u pravilu, sadrži naslov članka, imena autora, osnovne podatke o autorima (institucija s koje dolaze, adresa, broj telefona, elektronička pošta itd.).
2. Sažetak na jeziku na kojem je napisan rad.
3. Ključne riječi na jeziku na kojem je napisan rad.
4. Sažetak na engleskom ili nekom drugom svjetskom jeziku ukoliko članak nije napisan na engleskom odnosno tom drugom svjetskom jeziku.
5. Ključne riječi na engleskom ili nekom drugom svjetskom jeziku ukoliko članak nije

napisan na engleskom, odnosno tom drugom svjetskom jeziku.

6. Klasifikacija rada s obzirom na područje (npr. JEL klasifikacija).
7. Uvod (u kojem se definiraju područje, ciljevi i hipoteze istraživanja te teorijski okvir).
8. Teorijski okvir (ukoliko on nije dio uvoda).
9. Metodologija istraživanja.
10. Rezultati istraživanja.
11. Rasprava.
12. Zaključak.
13. Popis literature.
14. Prilozi (ukoliko ih ima).

8. SUVREMENE ZNANSTVENE METODE I TRENDOM

Budućnost znanosti i znanstvenih metoda obuhvaća niz perspektiva i trendova, a neki od ključnih aspekata uključuju:

- Interdisciplinarnost - očekuje se daljnji rast interdisciplinarnih istraživanja, gdje će znanstvenici značajnije surađivati između različitih disciplina kako bi rješavali kompleksne probleme. Povezivanje znanja iz različitih područja može dovesti do inovacija i novih otkrića.
- Napredak tehnologije - rapidan razvoj tehnologije, kao što su napredak u području umjetne inteligencije, kvantnih računala i tehnologija povezivanja, može značajno utjecati na istraživanje. To može ubrzati procese analize podataka, simulacija i eksperimenata.
- Big Data i analitika - s povećanjem količine dostupnih podataka, važno je razvijati napredne metode analize, dubokog učenja i umjetne inteligencije kako bi se dobile smislene informacije iz ogromnih skupova podataka.
- Otvorena znanost - trend otvorene znanosti potiče dijeljenje podataka, rezultata istraživanja i metoda kako bi se omogućila transparentnost i suradnja između istraživača. Otvorena znanost, također, potiče uključivanje šire zajednice u istraživačke procese.
- Eksperimentalni pristupi - razvoj novih eksperimentalnih metoda, uključujući napredne tehnike mjerenja i instrumentaciju, omogućuje istraživačima istraživanje fenomena na načine koji nisu bili mogući prije.
- Etika i transparentnost - porastom važnosti etičkih pitanja u znanstvenom istraživanju, očekuje se jači naglasak na etičkim smjernicama, integritetu istraživanja i transparentnosti u komunikaciji rezultata.
- Globalna suradnja - znanstvena zajednica sve više postaje globalna, s istraživačima iz različitih dijelova svijeta koji surađuju na projektima. Ova globalna suradnja može pridonijeti bržem napretku u rješavanju globalnih izazova.
- Edukacija i popularizacija znanosti - važnost obrazovanja i popularizacije znanosti raste kako bi se potaknula opća javnost na razumijevanje i podršku znanstvenim istraživanjima.

Ovi trendovi zajedno oblikuju budućnost znanosti, a dinamičnost znanstvenog polja znači da će se vjerojatno pojaviti i drugi važni aspekti kako se tehnologija i društvo dalje razvijaju.

Suvremene znanstvene prezentacije i metode

Suvremene prezentacije i njezine metode često uključuju korištenje naprednih tehnologija i pristupa koji omogućuju jasnije, interaktivnije i efikasnije prijenos znanja.

Dano je nekoliko ključnih elemenata suvremenih znanstvenih prezentacija i metoda:

1. Multimedija

- Grafički elementi: korištenje grafika, dijagrama, slika i drugih vizualnih elemenata može pomoći u jasnom prikazu rezultata i podataka.
- Multimedijски sadržaj: integracija videozapisa, animacije ili zvuka može dodatno poboljšati razumijevanje materijala.

2. Interaktivnost

- Radionice i demonstracije: omogućavanje sudionika da aktivno sudjeluju kroz radionice ili demonstracije povećava angažman i razumijevanje.
- Q&A sesije: interaktivne sesije pitanja i odgovora omogućuju publici da postavlja pitanja i raspravlja o prezentiranim informacijama.

3. Digitalne platforme

- Online prezentacije: korištenje virtualnih platformi za održavanje webinarima ili online prezentacija omogućuje dostupnost širokom spektru sudionika bez fizičkih ograničenja.
- Prezentacijski alati: korištenje alata poput Microsoft PowerPoint, Google Slides ili drugih sličnih omogućuje stvaranje dinamičnih prezentacija.

4. Znanost o podacima i Analitika

- Analiza podataka: primjena analize podataka i statističkih metoda za istraživanje rezultata.
- Vizualizacija podataka: upotreba vizualizacija podataka kako bi se olakšalo razumijevanje kompleksnih informacija.

5. Korištenje društvenih mreža

- Diseminacija informacija: dijeljenje rezultata istraživanja putem društvenih mreža pomaže u širenju informacija i povećava vidljivost rada.
- Online diskusije: organizacija online diskusija ili foruma može potaknuti dodatnu analizu i razmjenu ideja.

6. Timski rad

- Kolaboracija: poticanje suradnje među istraživačima i stručnjacima može dovesti do inovativnih rješenja i perspektiva.
- Projektni pristup: organizacija prezentacija oko projektnog pristupa može poboljšati razumijevanje procesa i rezultata.

7. Edukacija i popularizacija znanosti

- Jednostavan jezik: pokušaj izbjegavanja nepotrebnog stručnog žargona i kompliciranih termina kako bi se materijali učinili pristupačnijima širem auditoriju.
- Outreach aktivnosti: organiziranje radionica, predavanja ili drugih događanja za širu javnost kako bi se popularizirala znanost.

Ove su metode i pristupi samo neki od mnogih koji se koriste u suvremenim znanstvenim prezentacijama. Važno je prilagoditi strategije prema publici, vrsti istraživanja i dostupnim tehnologijama.

Znanstvene metode usmenih prezentacija uključuju različite strategije i tehnike koje pomažu prenijeti znanstvene informacije na jasan, uvjerljiv i razumljiv način.

Dano je nekoliko ključnih elemenata i savjeta za uspješne znanstvene usmene prezentacije:

1. Jasna struktura

- Uvod: treba početi s jasnim uvodom koji privlači pažnju, definira ciljeve prezentacije i postavlja kontekst istraživanja.
- Središnji dio: potrebno je razraditi ključne aspekte istraživanja koristeći logički redoslijed. Korisno je podijeliti materijal na tematske dijelove kako bi publika mogla lakše pratiti sadržaj.
- Zaključak: završiti prezentaciju sa sažetkom glavnih nalaza, njihovim značajem te otvorenim pitanjima ili mogućnostima za daljnja istraživanja.

2. Vizualna podrška

- Grafički elementi: treba koristiti dijagrame, grafikone, slike i druge vizualne elemente kako bi se ilustrirale ključne točke. Trebaju biti jasni i lako razumljivi.
- PowerPoint ili slični alati: koristiti alate poput PowerPointa kako biste strukturirali i vizualno podržali prezentaciju. Ne treba pretrpavati slajdove informacijama.

3. Jezik i komunikacija

- Jednostavan jezik: izbjegavati nepotrebno kompliciranje jezika. Koristiti jednostavan, jasan i razumljiv jezik, posebno ako se prezentira pred heterogenom publikom.
- Pauze i naglasak: koristiti pauze i naglasak kako bi se istaknule važne točke i omogućilo publici da bolje prati prezentaciju.

4. Povezivanje s publikom

- Očni kontakt: održavajte kontakt s publikom kako bi se izgradila veza i pokazalo samopouzdanje.
- Prilagodba tempa: treba prilagoditi brzinu govora i dubinu informacija prema razini poznavanja publike. Paziti na reakcije publike kako bi se prilagodila prezentacija.

5. Demonstracije i primjeri

- Praktični primjeri: Treba koristiti konkretne primjere ili studije slučaja kako bi se ilustrirale vlastite tvrdnje.
- Demonstracije: ako je moguće, uključiti praktične demonstracije kako bi se dodatno ilustrirali zaključci.

6. Pitanja i odgovori

- Otvorena vrata za pitanja: Važno je potaknuti publiku da postavlja pitanja kako bi se potaknula rasprava i produbilo razumijevanje teme.
- Priprema na pitanja: dobro je razmisliti unaprijed o mogućim pitanjima i pripremiti se na njihove odgovore.

7. Vještine prezentacije

- Govor tijela: paziti na svoje tijelo i geste kako biste dodali dodatnu dimenziju vašoj prezentaciji.
- Ton glasa: varirati ton glasa kako bi se održavao interes i naglašavalo ključne točke.

8. Vježba

- Treba proučiti prezentaciju: prije samog dana prezentacije, bitno je temeljito proučiti materijal kako biste bili dobro upoznati s temom.
- Vježba pred publikom: ako je moguće, treba vježbati pred manjom skupinom kako bi se dobile povratne informacije i poboljšalo vještine prezentacije.

Vještina prezentacije ključna je za uspješno dijeljenje znanstvenih spoznaja s kolegama, stručnjacima i širom zajednicom.

Dano je nekoliko savjeta koji mogu pomoći u poboljšanju vještine prezentacije:

1. Priprema

- Temeljito proučiti rad: razumijevanje teme i rezultata ključno je za uvjerljivu prezentaciju.
- Definiranje poruke: unaprijed identificirati glavne poruke koje se žele prenijeti publici i usredotočiti se na njih.

2. Struktura prezentacije

- Uvod: jasan uvod s postavljanjem problema, ciljevima istraživanja i važnost.
- Metode: kratak pregled korištenih metoda i pristupa.
- Rezultati: prezentacija ključnih rezultata istraživanja.
- Diskusija: interpretacija rezultata, usporedba s prethodnim istraživanjima te impliciranje nalaza.

3. Vizualna podrška

- Korištenje grafikona i slika: ilustrirati rezultate pomoću grafikona, dijagrama ili slika radi boljeg razumijevanja.
- Jednostavnost i jasnoća: treba koristiti jasne naslove i oznake.

4. Govorničke vještine

- Govoriti polako i jasno: osigurati lako praćenje riječi.
- Održavati kontakt s publikom: treba često provjeravati reakcije.
- Vježba pred ogledalom ili prijateljima: poboljšava samopouzdanje.

5. Prilagodba publici

- Prilagodba razini publike: ako je prezentacija pred stručnjacima, može se koristiti tehnički jezik.
- Odgovarati na pitanja: treba biti spreman na pitanja i odgovore kako bi se pokazalo duboko razumijevanje.

6. Vještine upravljanja vremenom

- Održavati ritam: paziti na vrijeme kako bi se stiglo do svih ključnih točaka.

- Vrijeme za pitanja: ako je prezentacija na skupu, provjere se pravila.

7. Samopouzdanje

- Vježbajte: što je više vježbi, više se osjeća sigurnost i samopouzdanje.
- Prihvatiti nervozu: nervoza je normalna, ali je važno naučiti je kontrolirati.

Svi ovi elementi zajedno će pomoći stvoriti prezentaciju koja će jasno komunicirati vlastite znanstvene radove i zadržati pozornost publike.

8.1. Ekspertni računalni sustavi

Baza podataka u ekspertnom računalnom sustavu predstavlja ključnu komponentu koja sadrži relevantne informacije, pravila i znanje potrebno za donošenje odluka ili rješavanje problema unutar specifičnog domena ili područja. Ova baza podataka obično sadrži strukturirane informacije koje su organizirane na način koji omogućuje efikasno pretraživanje, izvlačenje i korištenje podataka u procesu donošenja odluka ili rješavanja problema. Podaci u bazi mogu uključivati faktografske informacije koje opisuju karakteristike ili svojstva entiteta unutar domena, poput simptoma u medicinskom ekspertnom sustavu ili karakteristika kvarova u sustavu za dijagnosticiranje kvara u vozilima. Također, baza podataka može sadržavati pravila koja opisuju logičke uvjete i odgovarajuće akcije ili zaključke, kao što su pravila za identifikaciju rizičnih transakcija u ekspertnom sustavu za upravljanje rizicima u financijskom sektoru. Osim toga, strukturirani podaci mogu biti organizirani u određene strukture, poput tablica ili grafova, radi olakšanog pristupa i manipulacije, što omogućuje bolje razumijevanje kompleksnih odnosa unutar domena ekspertnog sustava. Uz to, znanje eksperta može biti integrirano u bazu podataka kako bi podržalo proces donošenja odluka ili rješavanja problema, što može uključivati pravila, strategije ili iskustvo stručnjaka iz određenog područja. Ova kombinacija informacija, pravila i znanja omogućuje ekspertnom sustavu da učinkovito analizira, procjenjuje i donosi odluke unutar svog specifičnog domena primjene.

Računalna aplikacija „AgBase – Priručnik za ekološki uzgoj bilja – opća načela i agrotehnika (tehnologija) ekološkog uzgoja bilja“, predstavlja primjer baze podataka ekspertnog sustava za ekološki uzgoj povrća i ratarskih kultura. Sadrži kompaktnu tehnologiju (agrotehniku) koja se temelji na ekološkim načelima, uključujući opća načela integrirane proizvodnje bilja, temeljna načela biodinamičke poljoprivrede te opća načela uzgoja bilja na ekološki prihvatljiv način (Jurišić i sur., 2021). Aplikacija obuhvaća informacije o dozvoljenim sjetvenim – sadnim materijalima, vrstama gnojiva i bio–eko preparatima koji se mogu koristiti u ekološkom uzgoju,

a ove liste su verificirane od strane Ministarstva. Poseban naglasak stavljen je na agrotehničke mjere ekološkog uzgoja, skrb i zaštitu bilja od bolesti, štetnika i korova primjenom biološke kontrole, te žetvu i tehnološku kvalitetu. Svi tehnički podaci proizašli su iz različitih literarnih izvora, vlastitih i drugih znanstvenih i stručnih saznanja i iskustava u suvremenom uzgoju bilja.

Ova računalna aplikacija razvijena je u CSS-u prema standardu CSS3 te Java script programskom jeziku, prilagođena je web sučelju. Ovaj pristup, široko korišten u svijetu, omogućuje jednostavan i inovativan pristup informacijama o ekološkom uzgoju bilja na internetskim sučeljima. Korisnicima pruža brz pristup saznanjima o novim sortama, agrotehničkim mjerama i drugim korisnim informacijama o ekološkom uzgoju bilja, uzimajući u obzir ekološke aspekte.

U procesu izrade aplikacije korištena je široka paleta domaće i inozemne stručne literature, kao i rezultati prethodnih istraživanja. Razvijena je digitalna baza podataka o ekološkom uzgoju i osnovnim načelima ekološke proizvodnje bilja, uključujući biodinamičku poljoprivredu, koja je poslužila kao temelj za izradu digitalnih priručnika.

Aplikacija pruža sveobuhvatne informacije o ključnim aspektima ekološkog uzgoja i pristupima ekološkom uzgoju bilja. Uključuje teme poput integrirane proizvodnje, biodinamičkih načela, popisa dozvoljenih sredstava u ekološkoj proizvodnji te zakonskih akata vezanih uz ekološku proizvodnju. Grafičko sučelje aplikacije olakšava pristup raznim temama putem izbornika i padajućih izbornika. Testirana je u praksi i u stvarnim situacijama kako bi se osigurala njezina funkcionalnost i korisnost (vrijedan metodološki doprinos kao baza podataka pri obavljanju raznih zadataka, poput prijave i izvođenja projekata, elaborata i drugih važnih djelatnosti).

Upotreba računalnih aplikacija u ekonomiji, posebno u sektorima poput poljoprivrede, ima značajan utjecaj na pojednostavljenje procesa donošenja odluka, povećava učinkovitost te smanjuje vrijeme potrebno za rješavanje problema. Ova tehnologija omogućuje integraciju stručnih znanja iz različitih disciplina, primjenjujući načelo interdisciplinarnosti, što značajno smanjuje rizik od ljudske pogreške.

Prezentirani materijal, ključan za ekološki uzgoj bilja u Republici Hrvatskoj, dostupan je u jednostavnom, bogato ilustriranom i digitalnom formatu (Slika 9, Slika 10). Sav sadržaj, u HTML formatu, spremljen je na USB i druge medije pružajući laku uporabu u menadžmentu, marketingu te ostalim aspektima ekonomije, posebno u poljoprivredi i praksi dobre poljoprivredne prakse.


Dugoročne prednosti kreiranja ovakve digitalne baze podataka, programiranja i razvoja aplikacije ekspertnog sustava uključuju konverziju raznolikih podataka u digitalni format ili standard. Ova praksa značajno pojednostavljuje procese upravljanja i vođenja. Brza i pouzdana akvizicija te obrada podataka omogućuju efikasniju kontrolu tehnoloških procesa. Svi podaci pohranjeni u bazi podataka, kao i ekspertni sustav i aplikacija, imaju digitalni oblik omogućujući njihovo lako proširivanje, transformaciju, prikazivanje u različitim formatima, od kartografskih prikaza do tekstualnih informacija. Ti podaci mogu se dijeliti putem izvješća ili internetskog objavljivanja, čime se omogućuje relativno brza distribucija (Slika 11, Slika 12).




Slika 9. Početni prilaz AgBase IV (Opća načela i agrotehnika organskog uzgoja bilja - povrća).



Slika 10. Početni prilaz AgBase V (Opća načela i agrotehnika organskog uzgoja bilja – ratarskih kultura).



Slika 11. Općenite informacije o uzgoju češnjaka u AgBase-u IV.



Slika 12. Agroekološki uvjeti za uzgoj suncokreta u AgBase-u V.

Ispustiti iskustva razvijenih zemalja i prethodne projekte sugerira da je integracija informacijskih sustava, uz korištenje geoinformacijskih tehnologija i GIS-a, investicija koja se višestruko isplati.

Sve struke koje se bave upravljanjem prirodnim resursima trebale bi razmotriti uvođenje ovakvih sustava kao ključnog temelja za pravilno vođenje i upravljanje, posebno u kontekstu ekološke proizvodnje i korištenje digitalnih baza podataka, kao što je ova metoda elaborirana ranije.

Prethodna ispitivanja primjene geoinformacija s ekspertnim sustavima za konvencionalnu poljoprivredu ukazala su na mogućnost postizanja značajnih ekonomskih dobitaka (primjeri drugih sustava koji su već primijenili ili primjenjuju slične metodologije i GIT/GIS).

8.2. Strojno i duboko učenje

Strojno učenje, grana umjetne inteligencije, predstavlja revolucionarnu paradigmu u računalnom znanju i donosi transformacije u različite aspekte društva i industrije (Zhou, 2021). Ovaj uvod predstavlja temeljne koncepte strojnog učenja, njegovu povijest, osnovne tehnike i opće implikacije na način kako se percipira i integrira s tehnologijom.

Strojno učenje predstavlja računalni pristup učenju iz podataka, omogućujući računalima da identificiraju uzorke, donose odluke i poboljšavaju performanse s minimalnim ljudskim uplitanjem.

Osnovni koncept leži u sposobnosti sustava da se prilagodi izloženosti novim podacima te da optimizira svoje ponašanje kako bi ostvario zadanu svrhu.

Centralna ideja strojnog učenja temelji se na konceptu „**učenja iz podataka**“, gdje računala analiziraju informacije kako bi stekla znanje i sposobnost donošenja predviđanja ili odluka u budućnosti (predikcija). Učenje se može ostvariti kroz različite pristupe uključujući nadzirano (gledano), nenadzirano (nenadgledano) i pojačano učenje, svaki prilagođen određenim tipovima problema.

Povijest strojnog učenja proteže se kroz različite epohe, a ključni događaji oblikovali su njegovu evoluciju. Raniji pristupi poput linearnih regresija i Bayesovih metoda postavili su temelje, dok je pojava neuronskih mreža, posebice u 20. stoljeću, označila važnu fazu razvoja. Razvoj računalne snage tijekom vremena omogućio je korištenje kompleksnijih modela, poput dubokih neuronskih mreža, koje su postigle iznimne uspjehe u raznim područjima.

Pojavom velikih količina podataka i napretkom u računalnim resursima, strojno učenje doživjelo je eksplozivni rast podržan inovacijama u algoritmima i tehnologijama.

Danas strojno učenje obuhvaća širok spektar disciplina od računalnog vida i obrade prirodnog jezika do prediktivne analize i autonomnih sustava (Jordan i Mitchell, 2015).

Strojno učenje koristi različite tehnike kako bi postiglo svoje ciljeve. Nadgledano učenje uključuje treniranje modela na označenim podacima, gdje je cilj modela naučiti kartiranje između ulaza i izlaza. Nenadgledano učenje, s druge strane, radi s neoznačenim podacima

tražeći uzorke i strukture unutar podataka bez unaprijed zadanih oznaka. Pojačano učenje uključuje interakciju agenata s okolinom kako bi postigli određene ciljeve uz nagrađivanje ili kažnjavanje za određena ponašanja.

Duboko učenje, kao podskup strojnog učenja, koristi neuronske mreže s puno slojeva (dubokim arhitekturama) kako bi postiglo visoku razinu apstrakcije i predstavljanje podataka. Ova tehnika postigla je iznimne uspjehe u područjima poput računalnog vida, prepoznavanja govora i prirodnog jezika (Kelleher, 2019).

Primjene strojnog učenja proširile su se na gotovo sve sektore društva. U medicini, strojno učenje igra ključnu ulogu u dijagnozi bolesti, identifikaciji genetskih uzoraka i personaliziranoj medicini. U financijskom sektoru, modeli strojnog učenja koriste se za analizu tržišta, predviđanje cijena i upravljanje rizicima. U industriji, optimizacija proizvodnih procesa, predviđanje otkaza opreme i upravljanje lancem opskrbe koriste se strojnim učenjem kako bi se postigli bolji rezultati.

Strojno učenje predstavlja granu **umjetne inteligencije (AI)** koja omogućuje računalima da uče iz iskustva, identificiraju uzorke u podacima te donose odluke ili predviđaju buduće događaje. Ova tehnologija koristi algoritme i statističke modele kako bi omogućila računalima da poboljšaju svoje performanse s vremenom bez eksplicitnog programiranja.

Razumijevanje osnovnih principa strojnog učenja ključno je za uspješnu primjenu ove tehnologije u istraživanju, poljoprivredi i tehnici. Ove metode nude snažan alat za rješavanje složenih problema, ali istovremeno zahtijevaju pažljivo upravljanje kako bi se osigurala pravilna primjena i minimizirali potencijalni rizici.

Nadzirano učenje predstavlja temeljni koncept u području strojnog učenja, pružajući računalima mogućnost učenja iz označenih podataka. Ovaj pristup omogućuje računalu da identificira uzorke u podacima i donosi predviđanja na temelju tih uzoraka. Ključna je karakteristika nadziranog učenja upotreba skupa podataka koji sadrže ulazne podatke i pripadne izlazne oznake omogućujući računalu da nauči vezu između njih.

8.2.1. Nadzirano učenje

Nadzirano je učenje vrsta strojnog učenja u kojoj računalu uči iz označenih podataka, gdje su ulazni podaci povezani s određenim izlaznim oznakama. Ovaj proces uključuje treniranje modela na skupu podataka koji sadrže parove ulaza i očekivanih izlaza. Cilj je naučiti model


kako pravilno kartirati ulaz na izlaz kako bi mogao donositi ispravne predikcije na novim, nepoznatim podacima.

U nadziranom učenju, računalo se „trenira“ koristeći skup podataka koji predstavlja parove ulaznih i izlaznih podataka. Primjerice, u kontekstu prepoznavanja slika, ulazni podaci mogu biti slike životinja, dok su izlazne oznake pripadajuće kategorije životinja (npr. mačka, pas, ptica). Tijekom treninga, algoritam prilagođava svoje parametre kako bi minimizirao razliku između stvarnih izlaza i predviđanja modela (Jordan i Mitchell, 2015).

Različiti algoritmi koriste se u nadziranom učenju, ovisno o vrsti problema. Linearna regresija primjer je algoritma koji se koristi za predviđanje kontinuiranih vrijednosti, dok se klasifikacija koristi za predviđanje diskretnih klasa. Složeniji algoritmi, poput podržanih vektora ili neuronskih mreža, mogu se koristiti za rješavanje kompleksnijih problema (Slika 13).

Označeni podaci, tj. podaci koji imaju pripadajuće izlazne oznake, ključni su za nadzirano učenje. Kvaliteta i raznolikost ovih podataka direktno utječu na performanse modela. Nedostatak dovoljnog broja označenih podataka može ograničiti sposobnost modela da općenito vrijedi na novim, nepoznatim podacima. Stoga je prikupljanje i priprema kvalitetnih označenih podataka jedan od ključnih izazova u primjeni nadziranog učenja.

Proces treniranja u nadziranom učenju uključuje iterativno prilagođavanje parametara modela kako bi se smanjila pogreška između stvarnih i predviđenih izlaza. Ovaj proces zahtijeva određeni broj epoha ili iteracija tijekom kojih se model prilagođava podacima. Važno je pratiti performanse modela na skupu za provjeru kako bi se izbjeglo prenaučenje (engl. *overfitting*), tj. situacija u kojoj model postaje previše prilagođen trening podacima i gubi sposobnost generalizacije na novim podacima (Zhou, 2021).




Slika 13. Predikcija pogodnosti poljoprivrednog zemljišta temeljena na strojnom učenju

Unatoč uspjesima, nadzirano učenje suočava se s određenim izazovima. Nedostatak označenih podataka, pristranost podataka, kompleksnost modela i interpretabilnost rezultata samo su neki od problema s kojima se susrećemo. Rješavanje tih izazova zahtijeva inovacije u prikupljanju podataka, razvoju robusnih modela i implementaciji etičkih smjernica.

Nadzirano učenje predstavlja ključni pristup u strojnom učenju omogućujući računalima da uče iz iskustva i obavljaju zadatke temeljene na prethodnom znanju. Razumijevanje ovog koncepta važno je za svakoga tko se bavi primjenom strojnog učenja u istraživanju, poljoprivredi, tehnici ili bilo kojem drugom području. Ovaj pristup otvara vrata inovacijama i rješavanju složenih problema uz istovremeno suočavanje s izazovima koje donosi.

8.2.2. Nenadzirano učenje

Nenadzirano učenje, s druge strane, uključuje treniranje modela na podacima koji nisu označeni (Hastie i sur., 2009). Cilj je ovog pristupa identificirati uzorke, strukture ili grupiranja unutar podataka bez prethodnih informacija o izlazima. Tipične metode uključuju klasteriranje, gdje se identificiraju slični skupovi podataka, i smanjenje dimenzionalnosti, koje pomaže u reprezentaciji podataka na manjem broju dimenzija (Slika 14).



Slika 14. Način rada nenadzirane klasifikacije u n-dimenzionalnom sustavu (<https://www.geeksforgeeks.org/clustering-in-machine-learning/>)

Nenadzirano učenje predstavlja ključnu granu strojnog učenja koja se usredotočuje na otkrivanje uzoraka i struktura unutar podataka bez prethodnih informacija o izlazima. Za razliku od nadziranog učenja, gdje se algoritam trenira na označenim podacima, nenadzirano učenje koristi neoznačene podatke potičući računalo da samoorganizira informacije i otkrije inherentne značajke skupa podataka.

Jedna od osnovnih tehnika nenadziranog učenja je klasteriranje, gdje algoritam grupira slične podatke u skupine ili „klustere“ na temelju sličnosti. Primjerice, u analizi potrošačkih navika, može se koristiti klasteriranje kako bi se identificirale skupine kupaca sličnih preferencija. Ovaj

pristup omogućava stvaranje boljeg razumijevanja unutar skupa podataka bez potrebe za unaprijed označenim kategorijama (Hastie i sur., 2009).

Nenadzirano učenje također uključuje smanjenje dimenzionalnosti, proces kojim se reducira broj značajki u skupu podataka. Ova tehnika pomaže u suočavanju s „prokletstvom dimenzionalnosti“, gdje višedimenzionalni podaci mogu postati teški za analizu. Metode poput analize glavnih komponenti (PCA) omogućuju projektiranje podataka na manji broj dimenzija, zadržavajući pritom ključne informacije.

Asocijativna su pravila još jedan važan aspekt nenadziranog učenja, često korišten u analizi potrošačkih ponašanja i preporučiteljskim sustavima. Ova pravila otkrivaju veze između različitih atributa u skupu podataka, što omogućuje bolje razumijevanje povezanosti među pojedinim elementima.

Generativni modeli tehnika su nenadziranog učenja koja se koristi za stvaranje novih podataka koji sliče onima u skupu podataka na kojem su modeli trenirani. Ovi modeli ključni su u područjima poput generativne umjetne inteligencije, gdje se koriste za stvaranje realističnih slika, glazbe ili teksta.

Samopoučavanje predstavlja pristup u kojem modeli uče reprezentacije podataka bez eksplicitnih oznaka. To je posebno korisno kada su označeni podaci ograničeni ili skupi. Algoritmi samopoučavanja, poput autoenkodera, uče reprezentacije podataka kroz proces enkodiranja i dekodiranja identificirajući ključne značajke podataka.

Nenadzirano učenje ima široku primjenu u različitim područjima. U medicinskoj dijagnostici klasteriranje može pomoći identificirati sličnosti među pacijentima, a smanjenje dimenzionalnosti može olakšati analizu kompleksnih medicinskih podataka. U poslovnom svijetu asocijativna pravila koriste se za analizu potrošačkih navika, dok generativni modeli mogu stvarati nove proizvode ili sadržaje.

Iako nenadzirano učenje donosi prednosti, suočava se s određenim izazovima. Interpretacija rezultata može biti kompleksna, budući da algoritmi automatski otkrivaju uzorke bez jasnih oznaka. Osim toga, nenadzirano učenje može biti osjetljivo na šum u podacima te kvaliteta rezultata ovisi o odabiru odgovarajućih tehnika i parametara.

Nenadzirano učenje ima obećavajuću budućnost, pogotovo s porastom količine dostupnih podataka. Razvoj novih tehnika, kao što su generativni modeli dubokog učenja, otvara vrata novim mogućnostima u stvaranju i razumijevanju podataka. Također, rastući interes za umjetnu inteligenciju potiče istraživanje i razvoj u području nenadziranog učenja.

Kao i svaka tehnologija, nenadzirano učenje nosi sa sobom etičke izazove. Pitanja privatnosti podataka, pristranosti algoritama te mogućnost zloupotrebe rezultata postaju sve važnija. Stoga je važno razvijati i primjenjivati etičke smjernice kako bi se osigurala odgovorna i održiva uporaba nenadziranog učenja.

8.2.3. Pojačano učenje

Pojačano učenje paradigmatički je različit pristup u kojem računalno uči donošenjem odluka putem interakcije s okolinom. Model, poznat kao agent, donosi određene akcije kako bi postigao određeni cilj, a zatim prima povratnu informaciju u obliku nagrade ili kazne. Cilj je naučiti optimalnu strategiju koja će maksimizirati ukupnu nagradu tijekom vremena.

Pojačano učenje predstavlja fascinantno pristup u području strojnog učenja, gdje algoritmi uče donošenjem odluka putem interakcije s okolinom. Inspirirano načinom na koji živa bića uče iz iskustva, pojačano učenje naglašava proces donošenja odluka kako bi se postigao određeni cilj, uz dobivanje povratne informacije u obliku nagrada ili kazni. Ovaj pristup omogućuje sustavu da samostalno prilagodi svoje ponašanje kako bi maksimizirao ukupnu nagradu tijekom vremena.

U osnovi pojačanog učenja leži **agent**, entitet koji donosi određene akcije kako bi postigao cilj u određenoj okolini. Okolina reagira na akcije agenta pružajući povratne informacije u obliku nagrada ili kazni. Cilj agenta je naučiti optimalnu strategiju, tj. niz akcija koje će maksimizirati ukupnu nagradu tijekom vremena. Ovaj proces učenja temelji se na principima *trial-and-error*, gdje agent eksperimentira s različitim akcijama kako bi identificirao najučinkovitije.

Markovski proces odlučivanja (MDP) ključni je formalni model u pojačanom učenju. MDP opisuje interakciju između agenta i okoline kroz niz diskretnih vremenskih koraka. Svi relevantni podaci za donošenje odluke sadržani su u stanjima i akcijama. Ovaj model pruža okvir za razumijevanje i rješavanje problema pojačanog učenja omogućujući agentu da prilagodi svoje ponašanje kako bi maksimizirao kumulativnu nagradu.

Različiti algoritmi koriste se u pojačanom učenju kako bi agent naučio optimalnu strategiju.

Q-learning, jedan od klasičnih algoritama, koristi tablicu Q-vrijednosti kako bi procijenio vrijednost svakog stanja – akcija para. Drugi pristupi, poput dubokog pojačanog učenja, koriste duboke neuronske mreže za aproksimaciju Q-funkcije omogućujući rješavanje problema velikim prostorom stanja i akcija.

Funkcije nagrade i kazne igraju ključnu ulogu u pojačanom učenju. Nagrada je pozitivna povratna informacija koju agent prima kada donese dobru odluku, dok je kazna negativna povratna informacija za loše odluke. Pravilno oblikovanje ovih funkcija ključno je za uspješno učenje jer agent koristi informacije o nagradi i kazni kako bi prilagodio svoje ponašanje.

Jedan od ključnih izazova u pojačanom učenju ravnoteža je između ispitivanja novih akcija i iskorištavanja poznatih akcija. Ako agent stalno iskušava nove stvari, može propustiti optimalne strategije koje već poznaje. S druge strane, ako se previše drži poznatih strategija, može propustiti bolje rješenje. Rješavanje ovog problema zahtijeva pažljivo upravljanje istraživanjem i eksploatacijom.

Pojačano učenje ima široku primjenu u raznim područjima. U robotici, agenti se mogu učiti upravljati robotskim rukama ili autonomnim vozilima. U financijskom sektoru, algoritmi pojačanog učenja mogu se koristiti za donošenje odluka o ulaganju. U igrama, pojačano učenje često se primjenjuje za stvaranje računalnih igrača koji se prilagođavaju igračevim potezima.

Unatoč velikim uspjesima, pojačano učenje suočava se s određenim izazovima. Problem „prokletstva prostora stanja“ nastaje kada je prostor stanja ili akcija izuzetno velik, što otežava učenje optimalne strategije. Također, postavljanje odgovarajuće funkcije nagrade može biti izazov, pogotovo ako je sustav u stvarnom svijetu gdje nagrade mogu biti odgođene ili nejasne.

8.2.4. Duboko učenje


Duboko učenje ili duboke neuronske mreže, predstavlja podskup strojnog učenja koji koristi arhitekture s više slojeva kako bi modelirao visoko apstraktne uzorke u podacima. Ove mreže sposobne su automatski izdvajati značajke iz podataka, što je od posebnog značaja u analizi slika, zvuka i prirodnog jezika (Kelleher, 2019).

Duboko učenje predstavlja evolucijski korak u području strojnog učenja, fokusirajući se na korištenje dubokih neuronskih mreža kako bi se modelirali kompleksni uzorci u podacima. Ova grana strojnog učenja pokazala je izuzetnu učinkovitost u raznim zadacima, od prepoznavanja slika do obrade prirodnog jezika. Ovo poglavlje istražiti će osnovne principe i primjene dubokog učenja u različitim sektorima uključujući istraživanje, poljoprivredu i tehniku.

Duboko učenje koristi arhitekture s više slojeva neuronskih mreža kako bi se stvorila hijerarhija apstrakcija iz podataka (Slika 15).

Ovi slojevi, poznati kao neuronski slojevi, postupno transformiraju ulazne podatke na način koji omogućuje modeliranje sve složenijih značajki. Duboko učenje često koristi koncepte

poput konvolucijskih neuronskih mreža (CNN) u zadacima obrade slika i rekurentnih neuronskih mreža (RNN) za obradu sekvencijalnih podataka (Kelleher, 2019).



Slika 15. Struktura neuronske mreže u dubokom učenju (<https://towardsdatascience.com/why-deep-learning-is-needed-over-traditional-machine-learning-1b6a99177063>)

U znanstvenom istraživanju, duboko učenje revolucionizira analizu podataka i donošenje zaključaka. Primjerice, u biomedicinskom istraživanju, duboko učenje koristi se za prepoznavanje obrazaca u genetskim podacima ili analizu medicinskih slika. Mogućnost modeliranja složenih značajki omogućuje brže otkrivanje uzoraka i pomaže istraživačima u generiranju novih hipoteza.

U poljoprivredi, primjena dubokog učenja dovodi do povećanja učinkovitosti i održivosti. Sustavi za prepoznavanje uzoraka iz satelitskih slika omogućuju praćenje stanja usjeva i identifikaciju područja koja zahtijevaju poseban tretman. Pametne tehnologije, poput autonomnih dronova opremljenih kamerama, koriste se za nadzor i analizu poljoprivrednih površina.

U tehničkim sektorima, duboko učenje unapređuje mnoge aspekte, uključujući dijagnostiku, kontrolu procesa i vizualno prepoznavanje. U proizvodnji sustavi za vizualnu inspekciju temeljeni na dubokom učenju koriste se za otkrivanje nedostataka na proizvodima, čime se

povećava kvaliteta i smanjuju troškovi. Također, u autonomnim sustavima, poput autonomnih vozila ili robota, duboko učenje omogućuje preciznu obradu informacija iz okoline.

Transferno učenje predstavlja ključnu komponentu u dubokom učenju. Ova tehnika omogućuje modelima prenošenje znanja iz jednog zadatka na drugi, čime se smanjuje potreba za velikim skupovima podataka za svaki zadatak. U istraživanju, transferno učenje može značiti prepoznavanje uzoraka naučenih na jednom području primjene (npr. prepoznavanje objekata na slikama) i primjenu tih saznanja na drugom području (npr. analiza medicinskih slika).

Unatoč impresivnim postignućima, duboko učenje suočava se s određenim izazovima. Veliki broj parametara u dubokim modelima može zahtijevati velike skupove podataka za treniranje. Pronalaženje optimalnih arhitektura mreža i parametara također je izazovan proces. Osim toga, interpretacija rezultata dubokih modela ostaje otvoreno pitanje, posebno u područjima gdje je potrebno objašnjenje odluka, poput medicinske dijagnostike.

Budućnost dubokog učenja obećava daljnje inovacije i primjene. Razvoj efikasnijih modela, integracija s drugim granama umjetne inteligencije poput obrade prirodnog jezika i razvoj metoda transfornog učenja otvaraju nove horizonte u rješavanju složenih problema. Interdisciplinarni pristup i suradnja između znanstvenika, inženjera i etičara ključni su za oblikovanje pozitivne i održive budućnosti dubokog učenja.


8.2.5. Hibridni pristupi u strojnom učenju

Hibridni pristupi u strojnom učenju predstavljaju kombinaciju različitih tehnika i modela kako bi se postigla veća fleksibilnost, preciznost i primjenjivost u rješavanju složenih problema. Ovo poglavlje istražuje osnove hibridnih pristupa, primjere njihove uporabe u različitim sektorima te izazove s kojima se susreću.

Hibridni pristupi uključuju kombinaciju različitih metoda strojnog učenja, statističkih modela ili čak tradicionalnih heurističkih pristupa kako bi se postigla bolja učinkovitost u rješavanju problema. Ova kombinacija može uključivati više vrsta modela ili tehnika u okviru istog sustava stvarajući sinergiju koja nadilazi pojedinačne metode.

Jedan od često korištenih hibridnih pristupa kombinacija je nadziranog i nenadziranog učenja. Ova kombinacija omogućuje modelu da iskoristi prednosti obaju pristupa. Primjerice, može se koristiti nadzirano učenje za treniranje modela na označenim podacima, dok se nenadzirano učenje koristi za istraživanje i modeliranje skrivenih uzoraka u neoznačenim podacima.

Ensemble metode još su jedan čest oblik hibridnih pristupa (Slika 16). Ove metode kombiniraju predviđanja više modela kako bi se postigla bolja generalizacija i smanjio rizik od prenaučavanja. Primjeri ensemble metoda uključuju *Random Forests*, gdje se kombiniraju rezultati više stabala odlučivanja ili metode poput AdaBoost-a, koje prilagođavaju težine instanci kako bi se fokusirale na teže klasificirane primjere (Radočaj i sur., 2023).



Slika 16. Predikcija svojstava tla temeljem ensemble metode

Hibridni pristupi često uključuju kombinaciju simboličkog i subsimboličkog pristupa. Simbolički pristup koristi eksplicitna pravila i logiku, dok subsimbolički pristup koristi neuronske mreže ili druge tehnike koje uče implicitne reprezentacije. Kombinacija ovih pristupa može donijeti bolje interpretabilne rezultate i istovremeno zadržati sposobnost modela da uči kompleksne uzorke.

U medicinskoj dijagnostici hibridni pristupi često se koriste za kombiniranje podataka iz različitih medicinskih izvora. Primjerice, kombinacija genetskih podataka s podacima o slikama iz medicinskih skenova može poboljšati preciznost dijagnoze.

Integracija simboličkih pristupa, poput medicinskih pravila, sa subsimboličkim, poput dubokog učenja, omogućuje bolje razumijevanje kompleksnih medicinskih podataka.

U području računalnog vida i analize teksta hibridni pristupi kombiniraju vizualne podatke s podacima iz prirodnog jezika kako bi dobili cjelovitu sliku. Primjerice, u prepoznavanju objekata na slikama modeli mogu koristiti informacije iz opisa teksta kako bi bolje razumjeli kontekst i veze između objekata.

Iako hibridni pristupi donose značajne prednosti, suočavaju se s određenim izazovima. Integracija različitih modela i tehnika zahtijeva pažljivo podešavanje kako bi se postigla optimalna sinergija. Interpretacija rezultata može biti kompleksna kada se koriste različite metode, što čini važnim razvoj metoda za objašnjavanje odluka hibridnih modela.

Etički aspekti hibridnih pristupa postaju ključni s porastom njihove primjene u osjetljivim područjima, poput medicinske dijagnostike ili analize podataka o korisnicima. Pitanja privatnosti, transparentnosti i odgovornosti postaju još važnija kada se koriste kompleksni modeli koji kombiniraju različite tehnike.

Budućnost hibridnih pristupa obećava daljnji napredak u integraciji različitih tehnika kako bi se stvorili moćniji i prilagodljiviji modeli. Razvoj novih algoritama i metoda koji omogućuju efikasnu kombinaciju različitih pristupa bit će ključan za daljnji uspjeh hibridnih modela. Interdisciplinarni pristup koji uključuje eksperte iz različitih područja bit će ključan za oblikovanje održivih i inovativnih rješenja.

Unatoč velikim uspjesima strojno učenje suočava se s nizom izazova. Jedan od ključnih problema pitanje je pristranosti modela, gdje algoritmi mogu reproduktirati i čak pojačati postojeće društvene nejednakosti. Etička pitanja, privatnost podataka i odgovornost u donošenju odluka također postaju sve važniji aspekti razvoja strojnog učenja.

8.2.6. Primjena strojnog učenja u agrobiotehničkim znanostima


Poljoprivreda predstavlja vitalnu komponentu globalnog gospodarstva, a primjena strojnog učenja u ovom sektoru donosi inovacije koje poboljšavaju produktivnost, održivost i praćenje usjeva.

Ovo poglavlje istražuje različite aspekte primjene strojnog učenja u poljoprivredi, od preciznog poljoprivrednog upravljanja do analize velikih količina podataka za unaprjeđenje uzgoja.

Precizno poljoprivredno upravljanje koristi tehnologiju, uključujući strojno učenje, za prilagodbu poljoprivrednih praksi prema specifičnim uvjetima u polju.

Senzori za praćenje tla, klimatskih uvjeta i vegetacije omogućuju prikupljanje podataka u stvarnom vremenu. Algoritmi strojnog učenja analiziraju ove podatke kako bi pružili

poljoprivrednicima precizne preporuke o optimalnom vremenu sadnje, navodnjavanja, gnojidbe i prskanja pesticidima (Slika 17).




Slika 17. Karte u preciznoj poljoprivredi temeljene na strojnom učenju
(<https://www.sciencedirect.com/science/article/pii/S258972172030012X#f0020>)

Uz pomoć strojnog učenja poljoprivrednici mogu analizirati velike količine podataka kako bi bolje razumjeli uzgoj biljaka. Ovo uključuje praćenje rasta biljaka, identifikaciju bolesti, štetnika i korova te predviđanje prinosa. Kombinacija podataka o tlu, klimi i genetici biljaka omogućuje izradu modela koji pomažu u optimizaciji uzgoja i prilagodbi promjenjivim uvjetima.

Strojno učenje igra ključnu ulogu u autonomnim sustavima i robotici, koji se koriste u poljoprivredi. Samostalni traktori, bespilotne letjelice i druge robotske platforme opremljene su senzorima i kamerama koji prikupljaju podatke o stanju usjeva. Algoritmi strojnog učenja obrađuju ove podatke kako bi autonomni sustavi mogli izvršavati zadatke poput sjetve, žetve ili zaštite bilja s visokom preciznošću.

Prediktivna analiza, temeljena na strojnom učenju, omogućuje poljoprivrednicima anticipirati buduće događaje i donositi informirane odluke. Primjerice, modeli mogu predviđati rast biljaka, pojavu štetočinja (bolesti, štetnika i korova) te utjecaj klimatskih promjena na usjeve (Slika 18). Ove prognoze pomažu poljoprivrednicima u pravovremenom donošenju odluka kako bi se optimizirao prinos i smanjili gubici.



Slika 18. Određivanje volumena usjeva iz trodimenzionalnog oblaka točaka (<https://agrifetoday.tamu.edu/2017/10/21/3-d-crop-imaging-helps-agriculture-estimate-plant-height/>)

Strojno učenje, također, primjenjuje se u praćenju kvalitete tla i vode. Senzori i sustavi za praćenje prikupljaju podatke o različitim parametrima poput pH vrijednosti tla, razine hranjivih tvari ili zagađenja vode. Algoritmi strojnog učenja analiziraju ove podatke kako bi identificirali potencijalne probleme ili trendove te pružili preporuke za održivo upravljanje resursima.

Strojno učenje ima ključnu ulogu u postizanju održive poljoprivrede. Praćenje potrošnje resursa, upravljanje otpadom i smanjenje negativnih utjecaja poljoprivrednih praksi na okoliš mogu se postići pomoću preciznih modela temeljenih na strojnom učenju. Algoritmi mogu optimizirati korištenje vode, smanjiti emisije stakleničkih plinova i prilagoditi uzgoj biljaka kako bi se očuvala biološka raznolikost.

Uzgoj otpornijih i produktivnijih biljaka postaje izazov u uvjetima promjenjive klime. Strojno učenje integrira se s genetikom biljaka kako bi identificiralo genetske uzorke povezane određenim karakteristikama, poput otpornosti na bolesti ili većeg prinosa. Ovi modeli pomažu u ubrzanju procesa selekcije biljaka i razvoju sorti prilagođenih specifičnim uzgojnim uvjetima.

Unatoč brojnim prednostima primjena strojnog učenja u poljoprivredi suočava se s izazovima. Velike količine podataka koje generiraju senzori i druge tehnologije zahtijevaju moćne računalne resurse za obradu. Također, prilagodba tehnologije malim poljoprivrednim gospodarstvima ili onima u razvoju može biti ograničena ekonomskim i infrastrukturnim faktorima.

Jedna od najpoznatijih i široko primijenjenih tehnoloških primjena strojnog učenja računalni je vid. Ovi sustavi omogućuju računalima da analiziraju, interpretiraju i razumiju vizualne informacije poput slika i videozapisa. Primjene računalnog vida obuhvaćaju prepoznavanje objekata, detekciju lica, praćenje pokreta, medicinsku dijagnostiku putem slikovnih zapisa i puno toga.

Tehnike dubokog učenja, poput konvolucijskih neuronskih mreža, igraju ključnu ulogu u postizanju visoke preciznosti u ovom području.

Obrada prirodnog jezika (OPJ) koristi se za analizu, interpretaciju i generiranje ljudskog jezika. Strojno učenje u ovom kontekstu omogućuje računalima da prepoznaju i razumiju složene jezične strukture. Aplikacije u OPJ uključuju automatsko prevođenje jezika, analizu sentimenta u tekstu, prepoznavanje govora i generiranje prirodnog jezika. Modeli temeljeni na rekurentnim neuronskim mrežama, transformers arhitekturi i druge napredne tehnike omogućuju računalima da razumiju i generiraju jezične uzorke s visokom razinom složenosti.

Strojno učenje igra ključnu ulogu u razvoju autonomnih vozila. Sustavi za prepoznavanje objekata, praćenje prometa, planiranje ruta i upravljanje vozilima koriste različite tehnike strojnog učenja. Senzori poput radara, lidara i kamera omogućuju vozilima prikupljanje podataka o okolini, dok duboko učenje omogućuje precizno prepoznavanje i interpretaciju tih podataka. Ova tehnologija potiče razvoj sigurnijih i učinkovitijih transportnih sustava.

U industriji, strojno učenje primjenjuje se za optimizaciju proizvodnih procesa, predviđanje otkaza opreme i održavanje preventivnih mjera. Analiza velikih količina podataka iz senzora u proizvodnom okruženju omogućuje identifikaciju uzoraka koji ukazuju na potencijalne probleme. Prediktivna analiza omogućuje tvrtkama da planiraju održavanje opreme unaprijed minimizirajući neplanirane prekide u proizvodnji i smanjujući troškove održavanja.

8.3. Računalna vizualizacija i kartografija

Računalna vizualizacija rezultata znanstvenih istraživanja postala je neizostavan dio istraživačkog procesa u mnogim disciplinama omogućavajući istraživačima da prepoznaju obrasce, identificiraju trendove i bolje razumiju kompleksnost svojih podataka.

Istraženo je kako digitalna kartografija te osnovna tehnika računalne vizualizacije pridonosi poboljšanju interpretacije rezultata istraživanja. Dan je naglasak značenja na primjenu u poljoprivredi i tehnici te će se u nastavku objasniti osnovna načela rada ovog moćnog alata.

Digitalna kartografija predstavlja modernu evoluciju klasične kartografije gdje su podaci predstavljeni na digitalan način. Ova tehnika omogućuje stvaranje interaktivnih i dinamičnih karata koje se lako mogu prilagoditi specifičnim potrebama istraživača. Kroz digitalnu kartografiju znanstvenici mogu vizualizirati prostorne i temporalne aspekte svojih podataka na jasan i intuitivan način (Radočaj i sur., 2021).

Digitalna kartografija, kao ključni aspekt računalne vizualizacije u znanstvenim istraživanjima, ima korijene u potrebi za evolucijom tradicionalne kartografije koja se oslanjala na papir i tintu. S pojavom računala početkom 20. stoljeća razvile su se prve digitalne tehnike kartografije zamjenjujući tradicionalnu papirnatu formu. Ovaj prijelaz omogućio je pristupačniju, precizniju i šire primjenjivu digitalnu kartografiju.

Georeferenciranje osnovni je korak u digitalnoj kartografiji. To je proces povezivanja podataka s njihovim stvarnim geografskim položajem. Kroz ovaj postupak, svaki podatak dobiva prostorni kontekst omogućujući istraživačima precizno pozicioniranje elemenata na karti. Geografski informacijski sustavi (GIS) igraju ključnu ulogu u omogućavanju istraživačima rada s različitim sustavima koordinata prilagođavajući ih specifičnim potrebama njihovih istraživanja.

Vektorski i rasterski modeli predstavljaju temelje digitalne kartografije. Vektorski model koristi geometrijske objekte poput točaka, linija i poligona, dok rasterski model koristi mrežu piksela za opisivanje prostornih informacija. Ove dvije metode omogućuju fleksibilnost u radu s različitim vrstama prostornih podataka.

U suvremenim tehnologijama digitalne kartografije ističe se 3D kartografija, koja omogućava korisnicima istraživanje prostora u trodimenzionalnom okruženju. Ova tehnologija pruža dublje razumijevanje reljefa, prostornih odnosa te simuliranje stvarnih prostornih situacija. Interaktivnost je ključna u sučeljima temeljenim na webu, koja omogućuju korisnicima pristup

digitalnim kartama putem internetskog preglednika. Ova interaktivnost omogućava istraživačima i javnosti prilagodbu vizualizacija, primjenu filtera te proučavanje podataka u realnom vremenu.

Senzorski podaci i Internet stvari (IoT) dodatno obogaćuju digitalnu kartografiju. Povećanje dostupnosti senzorskih podataka omogućuje prikupljanje stvarnih informacija o okolini, od meteoroloških promjena do prometa. Integracija senzorskih podataka s digitalnom kartografijom omogućuje bolje praćenje promjena u stvarnom vremenu pružajući relevantne informacije za različite znanstvene discipline.

Primjene digitalne kartografije kao znanstvene metode u znanstvenim su istraživanjima raznolike. U ekologiji i biologiji istraživači koriste digitalnu kartografiju za praćenje kretanja životinja, analizu promjena u ekosustavima i očuvanje bioraznolikosti. Integracija prostornih podataka omogućava bolje razumijevanje migracijskih uzoraka, staništa i utjecaja ljudskih aktivnosti na prirodne ekosustave.

Uporaba digitalne kartografije u agrobiotehničkim znanostima pruža širok spektar prednosti i mogućnosti za analizu, planiranje i upravljanje poljoprivrednim sustavima. Digitalna kartografija omogućuje izradu detaljnih karata tla koje prikazuju različite karakteristike poput teksture, pH vrijednosti, sadržaja hranjivih tvari i drenažnih svojstava. Ove karte omogućuju razumijevanje varijabilnosti tla unutar poljoprivrednih parcela te prilagodbu uzgojnih praksi kako bi se maksimizirao prinos i očuvala kvaliteta tla. Nadalje, digitalna kartografija se koristi za izradu hidroloških karata koje prikazuju obrasce protoka vode, podzemne vode i poplavnih područja, što pomaže u planiranju sustava za navodnjavanje, upravljanju odvodnjom i zaštiti od poplava. Također, digitalne karte omogućuju poljoprivrednicima bolje planiranje rasporeda i vrsta usjeva, identifikaciju optimalnih lokacija za kulture te praćenje i predviđanje širenja štetnika i bolesti. Kroz integraciju različitih prostornih podataka, digitalna kartografija podržava održivo planiranje krajolika, identificiranje područja visoke bioraznolikosti i zaštitu prirodnih resursa unutar poljoprivrednih pejzaža.

S obzirom na stalni napredak tehnologije, digitalna će se kartografija i dalje razvijati kako bi zadovoljila rastuće potrebe različitih sektora. Integracija novih tehnologija i koncepta poput umjetne inteligencije omogućava analizu velikih količina prostornih podataka, identifikaciju uzoraka i automatsko generiranje kartografskih prikaza. Proširena stvarnost (AR) postaje sveprisutna u digitalnoj kartografiji pružajući korisnicima doživljaj stvarnog prostora s dodanim digitalnim informacijama.

Napredak senzora, poput senzora visoke razlučivosti, termalnih kamera ili senzora za mjerenje specifičnih parametara, dodatno unapređuje mogućnosti digitalne kartografije. Ovi senzori pružaju visokokvalitetne podatke poboljšavajući preciznost analiza i vizualizacija.

Računalna vizualizacija rezultata znanstvenih istraživanja postala je neizostavan dio istraživačkog procesa u mnogim disciplinama omogućavajući istraživačima prepoznavanje obrazaca, identifikaciju trendova i bolje razumijevanje kompleksnosti svojih podataka.

Osnovna tehnika računalne vizualizacije pridonosi poboljšanju interpretacije rezultata istraživanja. Dan je poseban naglasak na primjenu u agrobiotehničkim sustavima.

Digitalna kartografija predstavlja modernu evoluciju klasične kartografije, gdje su podaci predstavljeni na digitalan način. Ova tehnika omogućuje kreiranje interaktivnih i dinamičnih karata koje se lako mogu prilagoditi specifičnim potrebama istraživača. Kroz digitalnu kartografiju znanstvenici mogu vizualizirati prostorne i temporalne aspekte svojih podataka na jasan i intuitivan način.

8.3.1. QGIS

QGIS predstavlja moćan alat u digitalnoj kartografiji pružajući slobodno dostupno rješenje za analizu i vizualizaciju prostornih podataka. Kroz ovo poglavlje istražiti ćemo ključne značajke QGIS-a, njegovu ulogu u istraživanju, tehnologiji i primjenama u raznim područjima, od znanosti do poljoprivrede (Radočaj i sur., 2021).


QGIS je proizvod zajednice ljudi koji su razvili otvoreni kod i nastao je s ciljem pružanja visokokvalitetnog alata za geografske informacijske sustave (GIS) dostupnog svima. Kroz godine QGIS doživio je značajan razvoj postajući robustan GIS alat koji se koristi širom svijeta. Otvorena zajednica doprinosi njegovu stalnom poboljšanju čineći ga sveprisutnim u akademskim, istraživačkim i profesionalnim krugovima.

QGIS se ističe svojom jednostavnom instalacijom i korisničkim prijateljskim sučeljem (Slika 19). Bez obzira na razinu korisnika početnici mogu brzo savladati osnovne funkcije. Nudi intuitivnu navigaciju, a bogatstvo alata i mogućnosti postupno se otkriva kako korisnici napreduju u radu s programom.


Jedna od ključnih značajki QGIS-a je sposobnost manipulacije i vizualizacije raznovrsnih prostornih podataka. Omogućuje uvoz podataka u različitim formatima uključujući shapefile, GeoJSON i druge. Onda korisnici mogu primijeniti različite stilove, legende i etikete kako bi

kreirali vizualno privlačne karte. QGIS podržava i 3D vizualizaciju, dodajući dubinu analizi prostornih podataka.

QGIS nudi širok spektar alata za analizu prostornih podataka. Korisnici mogu provoditi prostorno ispitivanje, raditi s prostornim upitima, izrađivati prostorne analize i modelirati prostorne odnose (Slika 20). Od identificiranja klastera do proučavanja povezanosti između prostornih entiteta QGIS omogućuje korisnicima dublje razumijevanje prostornih fenomena.



Slika 19. Primjer izrade digitalne karte u QGIS-u



Slika 20. Mogućnosti prilagodbe elemenata vizualizacije u QGIS-u

Automatizacija je ključna u GIS-u, a QGIS pruža moćne alate za geoprocesiranje. Modelar grafičkog korisničkog sučelja omogućuje korisnicima stvaranje složene radne tijekove automatizirajući niz prostornih operacija. Ova značajka čini QGIS fleksibilnim alatom ne samo za ručnu analizu već i za učinkovito upravljanje velikim skupovima podataka.

QGIS podržava širok raspon GIS formata omogućujući korisnicima integraciju s drugim platformama i softverima. To je posebno važno u multidisciplinarnim istraživanjima gdje se koriste različite GIS platforme. Otvorenost formata i interoperabilnost čine QGIS prikladnim za suradnju i integraciju u različite radne okoline.

QGIS ima široku primjenu u raznim područjima. U znanstvenim istraživanjima koristi se za analizu prostornih odnosa u ekologiji, geologiji, meteorologiji i drugim disciplinama. U urbanističkom planiranju QGIS pomaže u optimizaciji prostornih resursa i planiranju infrastrukture. U poljoprivredi koristi se za praćenje i optimizaciju poljoprivredne proizvodnje.

Zajednica korisnika QGIS-a doprinosi njegovom kontinuiranom razvoju. Razmjena znanja putem foruma, radionica i online resursa olakšava korisnicima rješavanje problema, dijeljenje iskustava i učenje novih tehnika. Ova otvorena suradnja čini QGIS dinamičnim alatom koji se neprestano prilagođava potrebama korisnika.

QGIS aktivno podržava korištenje slobodnih i otvorenih podataka. Korisnici mogu integrirati podatke iz različitih izvora, uključujući OpenStreetMap i druge globalne inicijative otvorenog pristupa prostornim informacijama. Ova podrška doprinosi demokratizaciji pristupa prostornim podacima i potiče raznolikost korištenja QGIS-a.

U budućnosti, QGIS se usmjerava na daljnje inovacije i održivost. Razvoj novih alata, integracija naprednih tehnologija poput umjetne inteligencije te kontinuirana podrška zajednici ključni su elementi. Očekuje se da će QGIS nastaviti igrati ključnu ulogu u slobodnom pristupu geoinformacijama postajući još snažniji i prilagodljiviji alat u digitalnoj kartografiji.

8.3.2. Geoprostorna analiza

Digitalna kartografija omogućuje geoprostornu analizu podataka što znači da istraživači mogu analizirati podatke u prostornom kontekstu. To je ključno u mnogim znanstvenim istraživanjima, posebice u agrobiotehnici, gdje se prostorne informacije o tlu, vodi i klimatskim uvjetima mogu kombinirati za bolje razumijevanje usjeva i planiranje poljoprivrednih aktivnosti. Geoprostorna analiza predstavlja ključni segment digitalne kartografije pružajući

moćan instrument za istraživanje, interpretaciju i donošenje informiranih odluka temeljenih na prostornim podacima (Jurišić i sur., 2021).

Geoprostorna analiza započinje procesom povezivanja prostornih podataka. To obuhvaća identifikaciju, prikupljanje i integraciju raznolikih prostornih informacija koje se mogu odnositi na geografski položaj, topografiju ili neke druge prostorne karakteristike. Ovaj je korak ključan za stvaranje baze podataka koja će poslužiti kao temelj za daljnje analize.

Preciznost u geoprostornoj analizi često ovisi o radu s određenim sustavima koordinata. GIS ili geografski informacijski sustavi pružaju temeljne alate za manipulaciju, analizu i vizualizaciju prostornih podataka. Ovi sustavi omogućuju korisnicima precizno pozicioniranje i interpretaciju prostornih informacija, čime pridonose dubljem razumijevanju geografskih fenomena.

Geoprostorna analiza uključuje širok spektar metoda i tehnika, a neke od osnovnih uključuju prostorno ispitivanje, interpolaciju, analizu pravaca kretanja i analizu klastera. Prostorno ispitivanje omogućuje proučavanje odnosa između prostornih entiteta, dok interpolacija pomaže u stvaranju glatkih površina na temelju ograničenih podataka.

Analiza pravaca kretanja često se primjenjuje u logističkom planiranju ili proučavanju migracija životinja, dok analiza klastera identificira koncentracije podataka na određenim lokacijama. Napredne metode geoprostorne analize uključuju prostorno modeliranje, koji se koristi za simuliranje raznih scenarija na temelju prostornih podataka te geoprostornu statistiku, koja pruža kvantitativne alate za analizu prostornih distribucija.

Geoprostorna analiza ima izuzetno široku primjenu u raznim disciplinama. U ekologiji istraživači koriste ove tehnike za modeliranje migracija životinja, analizu utjecaja ljudskih aktivnosti na ekosustave te praćenje promjena u bioraznolikosti. U poljoprivredi, geoprostorna analiza pomaže u optimizaciji poljoprivredne proizvodnje uzimajući u obzir klimatske uvjete i kvalitetu tla.

U urbanističkom planiranju geoprostorna analiza koristi se za optimizaciju prostornih resursa, planiranje prometne infrastrukture te analizu gustoće stanovništva.

Razvoj tehnologije, posebno GNSS/GPS sustava, dodatno je unaprijedio geoprostornu analizu. Globalni sustav pozicioniranja (GPS) omogućuje precizno lociranje objekata na Zemlji pružajući visokokvalitetne podatke za geoprostornu analizu. Uz to, napredni senzori poput Lidara, termalnih kamera ili radara dodatno obogaćuju skupove podataka pružajući detaljnije informacije o okolini.

S obzirom na ubrzan tehnološki napredak, budućnost geoprostorne analize donosi nove mogućnosti. *Umjetna inteligencija* sve više postaje sastavni dio geoprostorne analize. Algoritmi strojnog učenja mogu analizirati velike količine prostornih podataka, identificirati obrasce i automatizirati procese interpretacije. *Proširena stvarnost* predstavlja još jedan aspekt budućnosti geoprostorne analize (Slika 21). Kombinacija digitalnih informacija s fizičkim svijetom pruža novi način vizualizacije prostornih podataka.



Slika 21. Proširena stvarnost korištenjem pametnog telefona
(<https://www.forbes.com/sites/forbestechcouncil/2021/12/10/the-state-of-augmented-reality/>)

8.3.3. Geostatistika

Geostatistika predstavlja moćan set metoda za analizu prostornih podataka omogućujući znanstvenicima dublje razumijevanje prostornih uzoraka, varijacija i povezanosti u podacima (Webster i Oliver, 2007). Geostatistika se temelji na prepoznavanju važnosti prostora kao ključnog faktora u analizi podataka. Razumijevanje prostornih odnosa i varijacija ključno je za dublje uvide u prostorne fenomene. Kroz ovo poglavlje istražiti će se osnovne koncepte geostatistike naglašavajući ulogu prostora u analizi podataka i kako geostatistički pristupi pridonose boljem razumijevanju prostornih uzoraka.

Prostor je osnovni kontekst u kojem se događaju i distribuiraju podaci. Ovaj prostorni kontekst odnosi se na geografski položaj podataka, a geostatistika prepoznaje da prostorne varijacije nisu nasumične, već imaju svoje obrasce i strukture.

Prostorni podaci često sadrže informacije koje se mijenjaju s lokacijom, bilo da se radi o temperaturi tla, koncentraciji tvari u zraku ili distribuciji biljnih vrsta.

Jedan od osnovnih preduvjeta geostatistike je prepoznavanje variabilnosti u prostornim podacima.

Variabilnost se odnosi na promjene u vrijednostima podataka na različitim lokacijama. Geostatistika pretpostavlja da ove varijacije nisu nasumične, već sadrže informacije o prostornim odnosima. Razumijevanje kako i zašto se ove varijacije javljaju ključno je za modeliranje prostornih podataka. Variogrami i korvariogrami predstavljaju ključne alate u geostatistici. Variogram opisuje kako variabilnost prostornih podataka varira s razdaljinom, dok korvariogram pruža informacije o povezanosti između lokacija. Ovi modeli omogućuju identifikaciju prostornih zavisnosti, što je ključno za predviđanje nepoznatih vrijednosti na nekim lokacijama na temelju poznatih vrijednosti na drugim lokacijama.

Kriging je jedna od najčešće korištenih tehnika u geostatistici. Ova metoda koristi variograme za interpolaciju nepoznatih vrijednosti između uzorkovanih mjesta. Kriging pruža prostorno kontinuirane procjene uzimajući u obzir prostorne zavisnosti i varijacije. To je izuzetno korisno u mnogim znanstvenim disciplinama uključujući geologiju, meteorologiju i ekologiju.


Anizotropija je još jedan ključni koncept u geostatistici. Ova karakteristika uzima u obzir promjene u prostornim zavisnostima ovisno o smjeru. Razmatranje anizotropije posebno je važno u područjima gdje su prostorne strukture podložne promjenama s obzirom na smjer, primjerice, u geološkim formacijama ili tokovima podzemnih voda.

Geostatistika pruža rješenja za izazove neorganiziranih prostornih podataka. Dok tradicionalne statističke metode često zahtijevaju pretpostavke o normalnosti i homogenosti, geostatistika je otpornija na takve pretpostavke. To čini geostatistiku snažnim alatom za analizu podataka koji nisu ravnomjerno raspoređeni ili imaju kompleksne prostorne zavisnosti.

Geostatistika ima široku primjenu u znanstvenim istraživanjima (Webster i Oliver, 2007). U ekologiji može se koristiti za modeliranje staništa i praćenje populacija. U geologiji geostatistika pomaže u kartiranju ruda i proučavanju geoloških formacija. U epidemiologiji geostatistika je korisna za praćenje i predviđanje širenja bolesti. Ove primjene ilustriraju svestranost geostatistike u raznim znanstvenim disciplinama.

U poljoprivredi geostatistika pridonosi preciznom poljoprivrednom upravljanju. Analiza prostornih podataka omogućuje identifikaciju varijacija u tlu, vlazi i drugim faktorima koji utječu na usjeve (Slika 22).

Korištenjem geostatistike poljoprivrednici mogu optimizirati raspored sadnje, primijeniti gnojdbu i navodnjavanje na precizniji način te poboljšati prinos i održivost poljoprivredne proizvodnje (Jurišić i sur. 2020).



Slika 22. Prikaz variograma za potrebe predikcije komponenta teksture tla u kontinentalnoj Hrvatskoj

Geostatistika se kontinuirano razvija, posebno s napretkom tehnologija poput senzora, satelita i tehnika strojnog učenja. Integracija ovih naprednih tehnologija s geostatističkim metodama omogućuje još preciznije i informiranije analize prostornih podataka.

8.3.4. Vremenska analiza

Osim prostornih informacija digitalna kartografija olakšava i vizualizaciju podataka kroz vrijeme. Time istraživači mogu pratiti promjene u vremenskim uvjetima, prinosima usjeva ili drugim važnim parametrima kroz duže vremensko razdoblje (Karger i sur., 2016).

Vremenska analiza predstavlja ključni aspekt digitalne kartografije koji omogućuje istraživačima, planerima i znanstvenicima bolje razumijevanje dinamike promjena kroz vrijeme. Digitalna kartografija integrira vremenske dimenzije, analizira temporalne podatke i pruža relevantne uvide za širok spektar disciplina.


Digitalna kartografija neizostavno se razvija kako bi odražavala dinamiku promjena kroz vrijeme. Dodavanje vremenskih slojeva na prostorne karte omogućuje korisnicima praćenje evolucije pojava, od meteoroloških uvjeta do društvenih promjena. Ova integracija dimenzije vremena pridonosi dubljem razumijevanju prostornih odnosa u kontekstu temporalnih dinamika.

Razvoj temporalnih geografskih informacijskih sustava (TGIS) omogućuje analizu prostornih podataka uzimajući u obzir i vremensku dimenziju. TGIS pruža alate za povezivanje prostornih i vremenskih podataka, čime istraživačima omogućuje praćenje promjena, identifikaciju uzoraka i prognoziranje budućih scenarija. Ovi sustavi predstavljaju ključnu infrastrukturu za vremensku analizu u digitalnoj kartografiji.

Vizualizacija vremenskih podataka ključna je komponenta vremenske analize. Dinamičke karte omogućuju korisnicima praćenje promjena kroz različite vremenske periode, dok animacije pružaju dinamičan prikaz evolucije prostornih pojava. Ove tehnike olakšavaju identifikaciju uzoraka, promjena i anomalija kroz vrijeme.

Vremenska analiza obuhvaća različite aspekte promjena u vremenu. Analiza trendova istražuje dugoročne promjene u podacima, dok proučavanje sezonskih varijacija identificira ponavljajuće obrasce unutar određenih vremenskih intervala (Slika 23).

Posebna pozornost usmjerena je i prema ekstremnim događajima omogućavajući istraživačima bolje razumijevanje i anticipaciju izuzetnih meteoroloških, ekoloških ili društvenih situacija. Jedna od ključnih primjena vremenske analize u digitalnoj kartografiji je u meteorologiji. Praćenje klimatskih promjena, analiza oborina, temperatura i vjetra kroz vremenske slojeve omogućuje bolje razumijevanje dinamike vremenskih uvjeta. Ovi podaci ključni su za pravilno upravljanje rizicima od ekstremnih vremenskih događaja poput uragana, poplava ili dugotrajnih suša (Karger i sur., 2016).



Slika 23. Prikaz godišnjih padalina temeljen na multitemporalnoj analizi (<https://chelsa-climate.org/>)

Vremenska analiza igra ključnu ulogu u mnogim znanstvenim disciplinama. U ekologiji istraživači prate promjene u staništima i migracije životinja kroz vremenske dimenzije. U zdravstvu analiza vremenskih podataka pomaže u predviđanju sezonskih epidemija i planiranju javnozdravstvenih intervencija. U poljoprivredi praćenje vremenskih uvjeta važno je za optimizaciju poljoprivredne proizvodnje.

Tehnološki napredak dodatno je unaprijedio vremensku analizu. Globalna pokrivenost satelita omogućuje prikupljanje podataka o vremenskim uvjetima u stvarnom vremenu, dok senzori na tlu pružaju visokokvalitetne informacije. *Big Data* tehnologije omogućuju pohranu i analizu ogromnih količina vremenskih podataka, čime istraživačima pružaju sveobuhvatan uvid u promjene kroz vrijeme.

U budućnosti, vremenska analiza će vjerojatno iskoristiti potencijal umjetne inteligencije (UI) i naprednih modela za prognoziranje. UI algoritmi mogu analizirati kompleksne vremenske podatke i identificirati uzorke koji bi inače bili teško uočljivi. Prognoziranje ekstremnih vremenskih događaja postat će preciznije s integracijom naprednih modela koji simuliraju scenarije na temelju povijesnih podataka.

8.3.5. Interaktivnost

Ključna prednost digitalne kartografije je interaktivnost. Istraživači mogu istraživati podatke, zumirati, pomicati se kroz karte i primjenjivati različite filtre kako bi dobili detaljan uvid u svoje rezultate.

Interaktivnost predstavlja ključni element digitalne kartografije transformirajući statične karte u dinamična sučelja koja omogućuju korisnicima aktivno sudjelovanje u istraživanju i interpretaciji prostornih podataka.

U nastavku ovog razmatranje, bit će dani osnovni aspekti interaktivnosti, što znači razumjeti njenu važnost i istražiti kako doprinosi bogatstvu iskustva korisnika.

Interaktivnost u digitalnoj kartografiji odnosi se na sposobnost korisnika da aktivno sudjeluju u procesu istraživanja prostornih podataka. Umjesto da budu pasivni promatrači, korisnici mogu interagirati s kartama, prilagođavati vizualizacije, primjenjivati filtre i istraživati podatke u realnom vremenu. Ova dinamičnost otvara vrata raznolikim mogućnostima pružajući korisnicima fleksibilnost i personalizaciju.

Interaktivnost u digitalnoj kartografiji može se manifestirati kroz različite razine složenosti. Na jednostavnoj razini korisnici mogu pomicati, zumirati i rotirati kartu kako bi istraživali određeno područje. Korisnici mogu primjenjivati filtere kako bi istražili specifične dijelove podataka, usredotočiti se na određene slojeve ili čak dodavati vlastite podatke. Složenije analize, poput prostorne statistike ili modeliranja, također su moguće putem interaktivnih sučelja.

Web karte predstavljaju jedan od ključnih kanala za interaktivnost u digitalnoj kartografiji. Korisnici mogu pristupiti kartama putem internetskog preglednika eliminirajući potrebu za instalacijom posebnih programa. Ova dostupnost omogućuje širok pristup prostornim podacima, bez obzira na lokaciju ili tehničke resurse.

Alati za interaktivnost uključuju širok raspon funkcionalnosti (Slika 24). Pored osnovnih kontrola pomicanja i zumiranja korisnici mogu koristiti alate za crtanje, mjerenje udaljenosti, označavanje ključnih točaka ili čak dodavanje vlastitih bilješki na karti. Te mogućnosti proširuju kapacitete digitalne kartografije i omogućuju korisnicima izražavanje svojih specifičnih potreba i interesa.

Jedan od ključnih aspekata interaktivnosti vizualna je prilagodba. Korisnici mogu prilagođavati izgled karata prema vlastitim preferencijama, mijenjati boje, stilove i oznake. Ova prilagodba pomaže korisnicima fokusirati se na specifične informacije čime se poboljšava razumijevanje prostornih odnosa.

Jedan od najmoćnijih aspekata interaktivnosti je sposobnost analize podataka u stvarnom vremenu. Korisnici mogu primjenjivati različite analitičke alate kako bi otkrili skrivene uzorke

ili identificirali trendove. Analiza prostornih podataka postaje dinamičan proces, omogućavajući brze i informirane odluke.



Slika 24. Interaktivno sučelje na ARKOD-u

Razvoj mobilnih aplikacija dodatno proširuje dosege interaktivnosti u digitalnoj kartografiji. Korisnici mogu istraživati prostorne podatke na terenu koristeći GPS funkcionalnosti svojih uređaja. Mobilne aplikacije omogućuju stvarno vrijeme praćenja i prilagodbu vizualizacija, čime se kartografija približava stvarnom životu.

Senzorski podaci iz različitih izvora, poput IoT uređaja ili satelita, integriraju se s interaktivnim kartama. Ovi podaci dodaju stvarne informacije o okolini od meteoroloških uvjeta do prometnih tokova. Korisnici mogu istraživati ove podatke u realnom vremenu stvarajući most između digitalnog i fizičkog svijeta.

9. POPIS LITERATURE

Abazović, D. (2021). Društvo i religija. In Razumijevanje društva (pp. 166-174). Fakultet političkih nauka-Univerzitet u Sarajevu.

Aganović, I., Veselić, K. (2014). Matematički modeli i metode, Sveučilište Josipa Jurja Strossmayera u Osijeku, Odjel za matematiku, Osijek, 2014.

American Psychological Association. (2010). Publication manual of the American psychological association. American Psychological Association.

Baban, L., Ivić, K., Jelinić, S., Lamza-Maronić, M., & Šundalić, A. (2000). Primjena metodologije stručnog i znanstvenog istraživanja. Ekonomski fakultet u Osijeku, Osijek.

Belak, S. (2005). Uvod u znanost. Visoka škola za turistički menadžment, Šibenik.

Bronowski, J. (1974). The Ascent of Man, London (British Broadcasting Corporation) 1973. Also published in USA by Little, Brown and Company, 314.

Bryman, A., & Cramer, D. (1997). Quantitative data analysis with SPSS for Windows: A guide for social scientists. Routledge.

Creswell, J. W. (2009). Research design: Qualitative and mixed methods approaches. London and Thousand Oaks: Sage Publications.

Čaval, Josipa (1981). Statističke metode, udžbenik, Sveučilište u Rijeci, Rijeka.

Dročić, J. (2013). Metode povijesne znanosti, Diplomski rad, Sveučilište Josipa Jurja Strossmayera u Osijeku, Filozofski fakultet Osijek.

Dumičić, K., & Knežević, S. (2007). Anketno istraživanje prakse predviđanja promjena u vlastitome poslovanju i u poslovnome okruženju hrvatskih poduzeća. Ekonomski pregled, 58(3-4), 158-180.

Dupre, J. (2023). A Modest Defence of Philosophical Respectability. Journal of Dialectics of Nature, 45, 26-32.

Dupré, J. (2023). The Disunity of Science and the Unity of the World Presidential Address, PSA 2022. Philosophy of Science, 1-22.

Goldstein, K. (1967). Selected writings. ed., Aron Gurwitsch, Else M. Goldstein.

Hastie, T., Tibshirani, R., Friedman, J., Hastie, T., Tibshirani, R., & Friedman, J. (2009). Unsupervised learning. *The elements of statistical learning: Data mining, inference, and prediction*, 485-585.

Hrvatska enciklopedija, mrežno izdanje. Leksikografski zavod Miroslav Krleža. Pristupljeno 13. 12. 2023.

Hodkin, Alan L. (1963). Alan L. Hodgkin – Biographical. NobelPrize.org. Nobel Prize Outreach AB 2024. <https://www.nobelprize.org/prizes/medicine/1963/hodgkin/biographical/>

Janović, T. (2009). Citiranje, parafraziranje i upućivanje na izvore u akademskim tekstovima. Sveučilište u Zadru, Zadar.

Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.

Jurišić, M., Radočaj, D., Krčmar, S., Plaščak, I., & Gašparović, M. (2020). Geostatistical analysis of soil C/N deficiency and its effect on agricultural land management of major crops in eastern Croatia. *Agronomy*, 10(12), 1996.

Jurišić, M., Glavaš, J., Plaščak, I., Antonić, O., Radočaj, D. (2021). Geoinformacijske tehnologije GIS u ekonomiji. Osijek: Ekonomski fakultet Sveučilišta Josipa Jurja Strossmayera u Osijeku.

Karger, D. N., Conrad, O., Böhrer, J., Kawohl, T., Kreft, H., Soria-Auza, R. W., ... & Kessler, M. (2016). CHELSA climatologies at high resolution for the earth's land surface areas (version 1.0).

Kelleher, J. D. (2019). Deep learning. MIT press.

Kumar, R. (2018). Research methodology: A step-by-step guide for beginners. *Research methodology*, 1-528.

Kutleša, S. (2013). Kutleša – iz povijesti hrvatske filozofije i znanosti, Matica Hrvatske, Zagreb.

Lauc, A. (2000). Metodologija društvenih znanosti. Sveučilište JJ Strossmayera, Pravni fakultet.

McClave, J. T., Benson, P. G., & Sincich, T. (1994). Statistics for business and economics. Pearson Education.

- McMiilan, K., Weyers, J. (2007). *How to write Dissertations & Project Reports*, Pearson Education Limited, Harlow.
- Mejovšek, M. (2008). *Metode znanstvenog istraživanja: u društvenim i humanističkim znanostima*. Slap.
- Milat, J. (2005). *Osnove metodologije istraživanja*, Školska knjiga, Zagreb, pp. 88.
- Milošević, M., & Ristić, I. (2016). Nov metodološki pristup studijama kreativnosti. In *medias res: časopis filozofije medija*, 5(8), 1237-1250.
- Pašalić, M. (2004). *Osnovi statističke analize kroz primjere*, Savremena administracija, Beograd.
- Pravilnik o uvjetima za izbor u znanstvena zvanja (NN 28/2017, NN 111/2022).
- Pacton, M. Q. (2002.). *Qualitative Research & Evaluation Methods*. Sage Publications, Inc., Thousand Oaks, CA.
- Petz, B. (1997.). *Osnovne statističke metode za nematematičare*, III. dopunjeno izdanje, Naklada Slap Jastrebarsko.
- Radočaj, D., Jurišić, M., Plaščak, I. (2021). *Geoinformacijske tehnologije GIS u poljoprivredi i zaštiti okoliša - Praktikum*. Osijek: Fakultet agrobiotehničkih znanosti Sveučilišta Josipa Jurja Strossmayera u Osijeku.
- Radočaj, D., Jurišić, M., & Tadić, V. (2023). The Effect of Bioclimatic Covariates on Ensemble Machine Learning Prediction of Total Soil Carbon in the Pannonian Biogeoregion. *Agronomy*, 13(10), 2516.
- Serdar, V. (1977). *Udžbenik statistike, udžbenik*. Školska knjiga, Zagreb.
- Silobrić, V. (1989.). *Kako sastaviti i objaviti znanstveno djelo*, 2. izdanje Juraena, Zagreb.
- Sikavica, P., Bahtijarević-Siber, F., Pološki Vokić, N. (2008.). *Temelji menadžmenta*, Školska knjiga, Zagreb.
- Simonić, A. (2001). *Znanost: najveća avantura i izazov ljudskoga roda*. Medicinska naklada.
- Šošić, I., & Serdar, V. (1997). *Uvod u statistiku*. Školska knjiga, Zagreb.
- Tkalac, A. (2003). *Odnosi s javnošću u formiranju ipromjeni stavova; primjena situacijske teorije komunikacijskog ponašanja i stavova*, Doktorska disertacija, Ekonomski fakultet, Zagreb.

- Vujević, M. (2000): Uvod u znanstveni rad u području društvenih znanosti, Školska knjiga, Zagreb.
- Webster, R., & Oliver, M. A. (2007). Geostatistics for environmental scientists. John Wiley & Sons.
- Zelenika, R. (2000.): Metodologija i tehnologija izrade znanstvenog i stručnog djela, 4. izdanje, Ekonomski fakultet Sveučilišta u Rijeci i Ekonomski fakultet Univerze u Ljubljani, Rijeka.
- Zhou, Z. H. (2021). Machine learning. Springer Nature.
- Žugaj, M. (1996). Teorija kaosa i organizacija, Fakultet organizacije i informatike Varaždin. Zbornik radova 21(1996).
- Žužul, J. (1990). Tehničko-tehnološki progres i upravno djelovanje. Journal of Information and Organizational Sciences, (14), 169-188.
- Waldrop, M. (1995). The Emerging Science at the Edge of Order and Chaos, Audible Audiobook – Unabridged, 1994.

