

UNIVERZITET SINGIDUNUM
DEPARTMAN ZA POSLEDIPLOMSKE STUDIJE

DOKTORSKE AKADEMSKE STUDIJE
Studijski program: Inteligentno softversko inženjerstvo

Tema:

**RAZVOJ I EVALUACIJA PREDIKTIVNIH MODELA
ZA ANALIZU OBRAZACA LJUDSKOG PONAŠANJA
KORIŠĆENJEM DUBOKOG UČENJA
U SAVREMENOM POSLOVNOM OKRUŽENJU
– DOKTORSKA DISERTACIJA –**

Mentor:

dr Marina Marjanović

Kandidat:

Milena Nikolić

Broj indeksa: 480136/2022

Beograd, 2026. god.

UNIVERSITY OF SINGIDUNUM
BELGRADE

DEPARTMENT OF POSTGRADUATE STUDIES

DOCTORAL ACADEMIC STUDIES

Study programme: Intelligent Software Engineering

Topic:

**DEVELOPMENT AND EVALUATION OF PREDICTIVE
MODELS FOR THE ANALYSIS OF HUMAN
BEHAVIORAL PATTERNS USING DEEP LEARNING
IN THE CONTEMPORARY BUSINESS ENVIRONMENT
– DOCTORAL DISSERTATION –**

Mentor:

dr Marina Marjanović

Candidate:

Milena Nikolić

Student ID: 480136/2022

Belgrade, 2026

Sadržaj

1	Uvod	7
1.1	Problem istraživanja	9
1.2	Predmet istraživanja	10
1.3	Ciljevi istraživanja	11
1.4	Istraživačka pitanja	12
1.5	Hipoteze istraživanja	13
1.5.1	Opšta hipoteza	13
1.5.2	Specifična hipoteza	13
1.5.3	Pojedinačne hipoteze	13
1.6	Naučni doprinos disertacije	15
1.6.1	Metodološki doprinos	15
1.6.2	Empirijski doprinos	15
1.6.3	Doprinos interpretabilnosti i odgovornoj primeni	15
1.6.4	Aplikativni doprinos	15
1.7	Empirijski domeni kao prostori evaluacije modela	16
1.8	Metodološki pristup	17
1.9	Interpretabilnost, pristrasnost i odgovorna primena modela	18
1.10	Publikaciona i empirijska osnova disertacije	18
1.11	Ograničenja i granice istraživanja	19
1.12	Struktura disertacije	20
1.13	Zaključna razmatranja uvodnog poglavlja	21
2	Pregled literature i razvoj istraživačkog okvira	22
2.1	Uloga pregleda literature u strukturi disertacije	22
2.2	Prediktivno modelovanje ljudskog ponašanja	23
2.2.1	Specifičnost ljudskog ponašanja kao prediktivnog zadatka	23
2.2.2	Taksonomija prema tipu podataka	24
2.2.3	Taksonomija prema istraživačkom zadatku	24
2.3	Duboko učenje za sekvencijalne i tekstualne podatke	25
2.3.1	Rekurentne neuronske mreže	26
2.3.2	Transformer arhitekture	26

2.3.3	Konvolucione neuronske mreže za tekst i bihevioralnu analizu . . .	27
2.3.4	Vektorske reprezentacije i kontekstualni modeli	27
2.3.5	Prednosti i ograničenja dubokog učenja	28
2.4	Tradicionalni modeli mašinskog učenja	28
2.4.1	Linearni i logistički modeli	28
2.4.2	SVM i Naive Bayes modeli	29
2.4.3	Slučajne šume i gradijentno pojačavanje	30
2.4.4	Uloga tradicionalnih modela kao referentnih pristupa	30
2.5	Pristrasnost i pravičnost u prediktivnim modelima	31
2.5.1	Izvori pristrasnosti	32
2.5.2	Neravnoteža klasa i posledice na evaluaciju	32
2.5.3	Metrike pravičnosti	33
2.5.4	Pristrasnost u jeziku i tekstualnim modelima	34
2.5.5	Strategije smanjenja pristrasnosti	34
2.6	Interpretabilnost modela i objašnjiva veštačka inteligencija	35
2.6.1	Strukturno interpretabilni i post-hoc objašnjivi modeli	35
2.6.2	Lokalna i globalna objašnjenja	36
2.6.3	Interpretabilnost u tekstualnim modelima	37
2.6.4	Dokumentovanje podataka kao deo interpretabilnosti	37
2.7	Multimodalno učenje i integracija heterogenih izvora	38
2.7.1	Strategije fuzije podataka	38
2.7.2	Multimodalnost u empirijskim domenima disertacije	40
2.8	Održivo mašinsko učenje i green AI	40
2.8.1	Računarska zahtevnost modelovanja	41
2.8.2	Održivost kao kriterijum izbora modela	41
2.8.3	Veza sa održivim razvojem i softverskom implementacijom	42
2.9	Pregled domenski relevantne literature	42
2.9.1	Turizam i hotelijerstvo	42
2.9.2	Transportni sistemi	43
2.9.3	Internet trgovina i parfemska industrija	44
2.9.4	Društveno odgovorna poslovna komunikacija	45
2.9.5	Obrazovanje i generativni modeli	46
2.9.6	Održivi razvoj i analitičko izveštavanje	47
2.10	Naučni izazovi i motivacija istraživanja	48
2.11	Razvoj istraživačkog okvira disertacije	49
2.11.1	Veza između okvira i hipoteza	49
2.11.2	Veza između okvira i domenskih poglavlja	51
2.12	Zaključna razmatranja poglavlja	51

3	Metodološki okvir istraživanja	52
3.1	Istraživački dizajn i zajednički protokol	53
3.1.1	Zajednički istraživački protokol	53
3.1.2	Eksperimentalna i komparativna logika	53
3.2	Podaci, priprema i podela skupova	54
3.2.1	Priprema i kontrola kvaliteta podataka	55
3.2.2	Podela skupova i sprečavanje curenja informacija	56
3.3	Reprezentacija podataka i konstrukcija obeležja	56
3.4	Modeli i logika poređenja	57
3.4.1	Grupe modela	58
3.4.2	Optimizacija hiperparametara	58
3.5	Evaluacija, analiza grešaka i interpretabilnost	59
3.5.1	Evaluacione metrike	59
3.5.2	Analiza grešaka i segmentna evaluacija	60
3.5.3	Interpretabilnost modela	60
3.6	Odgovornost, reproducibilnost i granice tumačenja	61
3.7	Zaključna razmatranja metodološkog poglavlja	62
4	Turizam i hotelijerstvo	63
4.1	Digitalni podaci o korisnicima u turizmu i hotelijerstvu	63
4.2	Online recenzije kao izvor podataka o zadovoljstvu gostiju	64
4.2.1	Struktura hotelske recenzije	66
4.2.2	Izazovi u korišćenju recenzija	67
4.3	Detekcija anomalija i nekonzistentnosti u hotelskim recenzijama	67
4.3.1	Tipovi anomalija	67
4.3.2	Dijagnostika nekonzistentnosti i pouzdanosti za modelovanje	68
4.3.3	Nekonzistentne recenzije	69
4.4	Sentiment analiza i prepoznavanje negativnih recenzija	70
4.4.1	Definisanje negativne recenzije	71
4.4.2	Modeli za sentiment analizu	71
4.4.3	Poslovno značenje negativnih recenzija	72
4.5	Predikcija hotelskih ocena na osnovu tekstualnih karakteristika recenzija	73
4.5.1	Formulacija regresionog zadatka	74
4.5.2	Eksperimentalni protokol i sprečavanje curenja informacija	74
4.5.3	Referentni modeli i duboko učenje	75
4.5.4	Rezultati modela i doprinos zadatka predikcije ocena	75
4.6	Transformer modeli za analizu sentimenta i kategorija pritužbi gostiju	77
4.6.1	Kategorije pritužbi	78

4.6.2	Arhitektura modela za pritužbe	78
4.6.3	Doprinos detekcije pritužbi	79
4.7	Multimodalno modelovanje zadovoljstva korisnika hotelskih usluga	80
4.7.1	Formalni prikaz multimodalnog modela	80
4.7.2	Strategije fuzije podataka	81
4.7.3	Prednosti i rezultati multimodalnog pristupa	81
4.8	Procena dugoročne vrednosti korisnika u hotelijerstvu	82
4.8.1	Formalni prikaz CLV	83
4.8.2	Bihevioralna i emocionalna komponenta CLV	84
4.8.3	Modeli za CLV procenu	84
4.9	Predikcija otkazivanja rezervacija kao hotelski bihevioralni rizik	85
4.10	Pouzdanost ulaznih signala u hotelskoj prediktivnoj analitici	88
4.11	Objašnjivost modela i primena rezultata u hotelskom menadžmentu	89
4.11.1	Globalna objašnjenja	90
4.11.2	Lokalna objašnjenja	90
4.11.3	Menadžerska upotreba rezultata	90
4.12	Sinteza nalaza u oblasti turizma i hotelijerstva	91
5	Transportni sistemi	93
5.1	Transportni sistemi kao domen prediktivne analitike	93
5.2	Obrasci rizičnog ponašanja u kopnenom saobraćaju	95
5.3	Detekcija agresivne vožnje pomoću dubokog učenja	96
5.3.1	Formulacija zadatka i ulazni signali	96
5.3.2	DNN/MLP arhitektura i evaluacija	97
5.3.3	Značenje grešaka i odgovorna primena	97
5.4	Sekvencijalna analiza obrazaca u vožnji pomoću LSTM mreža	99
5.5	Predikcija cena avionskih karata pomoću ansambl modela	100
5.5.1	Obeležja ruta i regresiona formulacija	101
5.5.2	Ansambl modeli kao osnova analitike cena	101
5.6	Objašnjivost cenovnih faktora u avio-saobraćaju	102
5.7	Pouzdanost sistema za procenu zadovoljstva putnika	104
5.7.1	Podaci, modeli i performanse	104
5.7.2	Segmentna evaluacija i lažno negativni ishodi	104
5.8	Nedeljna asimetrija rasporeda letova po tipu prevoznika	106
5.9	Zavisnost destinacija od prevoznika na evropskim avio-rutama	107
5.9.1	Indeks zavisnosti povezanosti i profili rizika	107
5.9.2	Mogućnosti i ograničenja podataka o evropskim avio-rutama	109
5.10	Sinteza nalaza u oblasti transportnih sistema	110

6	Internet trgovina i parfemska industrija	112
6.1	Potrošačko ponašanje u internet trgovini	112
6.2	Parfemi kao proizvodi zasnovani na ličnom doživljaju i preferencijama . . .	114
6.3	Podaci i reprezentacija parfemskog domena	115
6.3.1	Pregled skupova podataka	115
6.3.2	Nedostajuće ocene i alternativno vrednovanje proizvoda	116
6.4	Modelovanje mirisne strukture i popularnosti parfema	119
6.4.1	Grupisanje mirisnih nota i analiza sličnosti proizvoda	119
6.4.2	Predikcija popularnosti parfema kroz vremenske obrasce	120
6.4.3	Emocionalna analiza korisničkih recenzija parfema	122
6.5	Reprezentaciono učenje za objašnjenje tržišne vrednosti proizvoda	125
6.6	Fuzzy kategorizacija potrošačkih recenzija u internet trgovini	126
6.7	Provera kvaliteta recenzija i nesklad između ocene i teksta	128
6.8	Integrisana arhitektura neuronskog modelovanja parfema	130
6.9	Interpretabilnost i poslovna vrednost parfemske analitike	133
6.10	Sinteza nalaza u oblasti internet trgovine i parfemske industrije	133
7	Društveno odgovorna poslovna komunikacija	135
7.1	Skupovi podataka, domenske granice i pretprocesiranje	141
7.1.1	Pretprocesiranje društveno osetljivog teksta	142
7.1.2	Problem anotacije i domenske prenosivosti	143
7.2	Modeli za detekciju diskriminatornog jezika	143
7.2.1	Binarna, višeklasna i višelabelna formulacija	144
7.2.2	Funkcija gubitka, neravnoteža klasa i pragovi	145
7.3	Eksperimentalni pravci i evaluacija modela	147
7.3.1	RoBERTa za poslovni diskurs	147
7.3.2	EDOS i EXIST kao osnova za odgovornu evaluaciju	148
7.3.3	Prioritizacija za ljudsku proveru	149
7.4	Lažno pozitivni i lažno negativni ishodi u društveno osetljivim sistemima .	150
7.4.1	Prag odlučivanja i zone rizika	151
7.4.2	Ograničenja procene nesigurnosti pomoću softmax funkcije	151
7.5	Stručna kontrola, odgovorno odlučivanje i etička primena modela	153
7.6	Veza sa inkluzivnim radnim okruženjem i održivim razvojem	154
7.7	Sinteza nalaza u oblasti društveno odgovorne poslovne komunikacije	156
8	Održivi razvoj, projektno odlučivanje i izveštavanje	157
8.1	Analitika održivog turizma i hotelskih podataka	158
8.1.1	Poslovna inteligencija i generativni modeli u održivom turizmu . . .	158
8.1.2	Operativni indikatori održivosti u hotelskim podacima	160

8.1.3	Evaluacija automatski generisanih analitičkih narativa	160
8.2	Projektna analitika i strateško odlučivanje	164
8.2.1	Horizon Europe projekti	164
8.2.2	Klasifikacija projekata iz oblasti zelenih tehnologija	165
8.2.3	Istraživački portfolio i strateško mapiranje tema	168
8.3	Napomena o održivosti softverske implementacije	171
8.4	Sinteza nalaza u oblasti održivog razvoja i projektnog odlučivanja	173
9	Obrazovanje u eri generativnih modela	175
9.1	Generativni modeli u visokoškolskom obrazovanju	175
9.2	Promena ponašanja studenata u nastavi programiranja	177
9.3	Analiza i procena studentskih radova pomoću NLP i mašinskog učenja . . .	178
9.3.1	Nadgledana klasifikacija i interpretabilnost	179
9.3.2	Klasterovanje i anomalije u studentskim radovima	179
9.3.3	Detekcija prekomernog oslanjanja na generativne alate	181
9.4	LLM pristupi i obrazovna prediktivna analitika	182
9.4.1	LLM pristupi u analizi grešaka i edukativnih sadržaja	182
9.4.2	Analiza uspeha studenata na osnovu anonimizovanih podataka . . .	182
9.5	Pouzdanost, etika i pedagoške implikacije	185
9.5.1	Bibliografske halucinacije i pouzdanost izvora	185
9.5.2	Etičke implikacije upotrebe generativnih modela u nastavi	189
9.6	Sinteza nalaza u oblasti obrazovanja i studentskih ishoda	190
10	Integrativna sinteza rezultata i naučnih doprinosa	191
10.1	Povezivanje empirijskih domena disertacije	191
10.2	Poređenje domena prema tipu podataka i istraživačkom zadatku	192
10.3	Poređenje modela i uslova njihove najbolje primene	193
10.4	Interpretabilnost, pouzdanost i pravičnost rezultata po domenima	195
10.5	Naučni, metodološki i aplikativni doprinosi disertacije	197
10.6	Odnos rezultata prema postavljenim hipotezama	200
10.7	Zaključna razmatranja integrativne sinteze	202
11	Industrijska primena i poslovni uticaj rezultata	203
11.1	Primena rezultata u poslovnim, društvenim i obrazovnim sistemima	204
11.2	Mogućnosti komercijalizacije i razvoja softverskih rešenja	204
11.3	Ograničenja praktične primene i uslovi implementacije	206
11.4	Zaključna razmatranja o industrijskoj primeni	208
12	Zaključak	209

1. UVOD

Savremeno poslovno okruženje sve više se zasniva na digitalnim interakcijama između korisnika, organizacija, platformi, uređaja i inteligentnih softverskih sistema. Aktivnosti koje su ranije bile teško merljive, kao što su zadovoljstvo korisnika, subjektivni doživljaj proizvoda, obrazac pritužbi, rizik u ponašanju, komunikacioni ton ili način rešavanja studentskog zadatka, danas ostavljaju digitalne tragove u obliku tekstualnih recenzija, numeričkih ocena, transakcionih zapisa, vremenskih serija, senzorskih podataka, logova, komentara, studentskih radova i drugih podataka nastalih u realnim sistemima. Takvi podaci predstavljaju osnovu za razvoj prediktivnih modela kojima se može analizirati, predvideti i objasniti ponašanje korisnika u različitim poslovnim i društvenim kontekstima.

Digitalna transformacija ne podrazumeva samo uvođenje novih tehnologija u postojeće poslovne procese, već menja način na koji organizacije prikupljaju podatke, razumeju korisnike, kreiraju vrednost, reaguju na pritužbe i donose odluke. U literaturi se digitalna transformacija posmatra kao višedimenzionalni proces koji utiče na korisničko iskustvo, operativne procese, poslovne modele i organizacione sposobnosti [1]. U takvom okruženju veštačka inteligencija i mašinsko učenje postaju važni instrumenti za obradu velikih i heterogenih skupova podataka, ali istovremeno otvaraju pitanja pouzdanosti, interpretabilnosti, pristrasnosti i odgovorne primene.

Naslov ove doktorske disertacije, *Razvoj i evaluacija prediktivnih modela za analizu obrazaca ljudskog ponašanja korišćenjem dubokog učenja u savremenom poslovnom okruženju*, određuje istraživački fokus ka razvoju, evaluaciji i interpretaciji modela u različitim poslovnim i društvenim kontekstima. Domeni koji se razmatraju u disertaciji zato imaju ulogu empirijskih prostora u kojima se proverava ista osnovna istraživačka ideja: kako se heterogeni digitalni tragovi ljudskog ponašanja mogu pretvoriti u pouzdane, objašnjive i poslovno upotrebljive prediktivne modele.

U disertaciji se analiziraju domeni turizma i hotelijerstva, transportnih sistema, internet trgovine i parfemske industrije, društveno odgovorne poslovne komunikacije, održivog razvoja i projektnog odlučivanja, kao i obrazovanja u eri generativnih modela. Međutim, njih povezuje ista metodološka osnova: svaki domen obuhvata aktere čije ponašanje ostavlja podatke, ishod koji se može predviđati, klasifikovati ili procenjivati, potrebu za evaluacijom kvaliteta modela i zahtev da se rezultati objasne na način koristan za donošenje odluka.

U turizmu i hotelijerstvu obrasci ponašanja ispoljavaju se kroz online recenzije, numeričke ocene, pritužbe, zadovoljstvo gostiju i procenu dugoročne vrednosti korisnika. U transportu se analiziraju obrasci rizične vožnje, zadovoljstvo putnika, izbor prevoznika, cene avionskih karata i struktura rasporeda letova. U internet trgovini i parfemskoj industriji ponašanje korisnika ogleda se u preferencijama, emocionalnim reakcijama, recenzijama, popularnosti proizvoda i tržišnoj vrednosti. U poslovnoj komunikaciji predmet analize čine diskriminatori, mizogini i rodno pristrasni obrasci jezika. U održivom razvoju analiziraju se podaci koji podržavaju izveštavanje, projektno odlučivanje i strateško mapiranje istraživačkih tema. U obrazovanju se razmatraju promene studentskog ponašanja, studentski radovi, prolaznost i uticaj generativnih modela na proces učenja. Zajedničko svim navedenim domenima jeste da se digitalni tragovi ponašanja prevode u merljive indikatore koji omogućavaju predikciju, objašnjenje i odgovorniju primenu modela.

Aktuelnost teme proizilazi iz činjenice da organizacije sve češće koriste prediktivne modele ne samo za tehničku automatizaciju, već i za odlučivanje o korisnicima, studentima, putnicima, zaposlenima i potrošačima. Takva primena zahteva modele koji su precizni, ali i razumljivi, etički prihvatljivi i prilagođeni kontekstu. Savremena istraživanja o pravičnosti i odgovornoj primeni mašinskog učenja ukazuju da tehnička performansa modela mora biti povezana sa društvenim, poslovnim i organizacionim posledicama njihove primene [2]. Zbog toga ova disertacija ne tretira duboko učenje samo kao skup algoritama, već kao deo šireg istraživačkog okvira koji povezuje podatke, modele, evaluaciju, interpretabilnost i primenu.

Polazna pretpostavka disertacije jeste da se ponašanje korisnika ne može potpuno razumeti pomoću jednog indikatora ili jedne vrste modela. Ljudsko ponašanje u digitalnim sistemima je višedimenzionalno, promenljivo i često nejednoznačno. Jedna hotelska recenzija može istovremeno sadržati pohvalu i pritužbu. Isti proizvod može izazvati različite emocionalne reakcije kod različitih potrošača. Agresivna vožnja može se razlikovati od opravdane reakcije na iznenadnu opasnost. Studentski rad može biti rezultat samostalnog učenja, saradnje ili prekomernog oslanjanja na generativne alate. Zbog toga se u disertaciji razvija integrativan pristup koji povezuje više tipova podataka, više klasa modela i više nivoa evaluacije.

Integrativni pristup disertacije pruža osnovu da se različiti oblici ljudskog ponašanja analiziraju kroz isti istraživački tok: definisanje digitalnog traga ponašanja, konstrukciju reprezentacije, izbor modela, evaluaciju, analizu grešaka, interpretabilnost i procenu primenljivosti. Domeni rada zato predstavljaju komplementarne prostore za proveru istog metodološkog principa. Njihovo poređenje daje osnovu za izvođenje opštijih zaključaka o uslovima u kojima duboko učenje, tradicionalni modeli i interpretabilna analitika daju najveću vrednost u savremenom poslovnom okruženju.

1.1 Problem istraživanja

Osnovni problem istraživanja može se formulisati na sledeći način: kako razviti i evaluirati prediktivne modele koji mogu pouzdano analizirati obrasce ljudskog ponašanja u savremenom poslovnom okruženju, kada su podaci heterogeni, neuravnoteženi, kontekstualno zavisni i često opterećeni šumom, pristrasnošću ili nekonzistentnošću.

Ovaj problem ima nekoliko međusobno povezanih dimenzija. Prva dimenzija odnosi se na heterogenost podataka. Podaci o ponašanju korisnika mogu biti tekstualni, numerički, kategorijalni, vremenski, sekvencijalni, mrežni ili multimodalni. U pojedinim domenima dominira tekst, kao u analizi recenzija ili poslovne komunikacije. U drugim domenima važniji su vremenski i sekvencijalni signali, kao u analizi vožnje ili dinamike cena. U trećim domenima potrebno je kombinovati tekstualne, numeričke i kontekstualne podatke, kao kod analize zadovoljstva gostiju ili vrednosti proizvoda.

Druga dimenzija problema odnosi se na kvalitet podataka. Podaci nastali u realnim sistemima retko su potpuno čisti i uravnoteženi. Online recenzije mogu sadržati nepotpune iskaze, ekstremno kratke komentare, kontradiktorne ocene, ponavljanja ili anomalije. Skupovi podataka za detekciju društveno osetljivih obrazaca mogu imati neravnomernu distribuciju klasa. Obrazovni podaci mogu biti osetljivi na institucionalni kontekst i način ocenjivanja. Transportni podaci mogu zavisiti od uređaja, okruženja i trenutnih uslova. Zbog toga se pitanje kvaliteta podataka ne može posmatrati kao tehnički korak pre modelovanja, već kao deo istraživačkog problema.

Treća dimenzija odnosi se na izbor modela. Tradicionalni modeli mašinskog učenja često su stabilni, jednostavniji za interpretaciju i efikasni na strukturisanim podacima. Nasuprot tome, modeli dubokog učenja mogu bolje obuhvatiti složene nelinearne odnose, sekvencijalne zavisnosti i semantičke strukture u tekstu. Ipak, njihova primena zahteva više podataka, više računarskih resursa i pažljiviju interpretaciju. Savremena literatura ukazuje da se mašinsko učenje i duboko učenje ne mogu posmatrati kroz jednostavnu podelu na zastarele i napredne metode, već kroz odnos između tipa podataka, zadatka, performansi i objašnjivosti [3]. Pored toga, novija istraživanja pokazuju da modeli zasnovani na stablima i ansambl pristupima često ostaju izuzetno konkurentni na tipičnim tabularnim skupovima podataka, zbog čega svaka tvrdnja o prednosti dubokog učenja mora biti empirijski proverena, a ne pretpostavljena [4].

Četvrta dimenzija problema odnosi se na evaluaciju. U mnogim istraživanjima modeli se ocenjuju pomoću jedne dominantne metrike, najčešće tačnosti, F1 mere ili prosečne greške. Međutim, kod analize ljudskog ponašanja takav pristup može biti nedovoljan. Model može imati visoku ukupnu tačnost, ali slabe rezultate na manjinskim klasama. Model može imati nisku prosečnu grešku, ali praviti velike greške kod najvažnijih korisnika. Model može dobro klasifikovati većinu primera, ali sistematski grešiti kod osetljivih grupa. Zbog toga evaluacija mora uključiti više metrika, analizu grešaka, segmentnu procenu i domensku interpretaciju.

Peta dimenzija odnosi se na interpretabilnost i odgovornu primenu. Prediktivni modeli se sve češće koriste u sistemima u kojima rezultati mogu uticati na poslovne odluke, korisničko iskustvo, bezbednost, reputaciju organizacije, obrazovni proces ili radno okruženje. Zbog toga nije dovoljno da model proizvede rezultat; potrebno je razumeti faktore koji su do tog rezultata doveli. Metode objašnjive veštačke inteligencije, uključujući SHAP i LIME, omogućavaju povezivanje predikcija sa doprinosima pojedinačnih obeležja, ali se njihova primena mora prilagoditi tipu podataka, modelu i domenskom značenju rezultata [5].

Na osnovu toga, istraživački problem ove disertacije nije samo pitanje da li se duboko učenje može primeniti na određeni skup podataka, već pitanje kako razviti celovit metodološki okvir koji omogućava da se različiti modeli primene, uporede, objasne i kritički procene u više empirijskih domena. Takav pristup povezuje pojedinačne domenske analize u fokusirano istraživanje, usmereno na razvoj i evaluaciju prediktivnih modela za analizu obrazaca ljudskog ponašanja.

1.2 Predmet istraživanja

Predmet istraživanja ove doktorske disertacije jeste razvoj, primena, evaluacija i interpretacija prediktivnih modela za analizu obrazaca ljudskog ponašanja korišćenjem dubokog učenja i srodnih metoda mašinskog učenja u savremenom poslovnom okruženju.

U užem smislu, predmet istraživanja obuhvata:

- analizu tekstualnih podataka nastalih kroz korisničke recenzije, poslovnu komunikaciju, studentske radove i analitičke narative;
- analizu numeričkih i kategorijalnih podataka koji opisuju ocene, cene, karakteristike proizvoda, tipove korisnika, kategorije pritužbi i ishode ponašanja;
- analizu sekvencijalnih i vremenskih podataka koji opisuju promene ponašanja, dinamiku popularnosti, obrasce vožnje i raspored transportnih aktivnosti;
- razvoj modela za klasifikaciju, regresiju, detekciju anomalija, procenu sentimenta, procenu dugoročne vrednosti korisnika i predikciju ishoda;
- primenu tradicionalnih modela mašinskog učenja, ansambl metoda, rekurentnih neuronskih mreža, LSTM modela, transformer arhitektura i multimodalnih pristupa;
- evaluaciju modela pomoću standardnih i domenski relevantnih metrika;
- interpretaciju rezultata pomoću metoda objašnjive veštačke inteligencije;
- razmatranje etičkih, pedagoških, organizacionih i poslovnih posledica primene prediktivnih modela.

U metodološkom smislu, predmet istraživanja može se posmatrati kao problem povezivanja heterogenih ulaznih podataka o ponašanju sa ciljnim ishodima koji se predviđaju, klasifikuju ili objašnjavaju. Ulazni podaci mogu obuhvatati tekst, ocene, cene, vremenske signale, senzorske zapise, metapodatke i druge digitalne tragove, dok ciljni ishodi mogu predstavljati numeričku vrednost, kategoriju, verovatnoću pripadnosti klasi, indikator rizika, procenu sentimenta ili drugi relevantan rezultat.

Formalna notacija i operativni način predstavljanja podataka, modela i evaluacije dati su u metodološkom poglavlju. Uvod zato zadržava konceptualno određenje predmeta istraživanja, dok se matematički zapis i eksperimentalni protokol sistematski razrađuju u okviru metodologije. Ključna ideja ostaje da najbolji model nije nužno onaj koji ostvaruje minimalnu grešku, već onaj koji uspostavlja opravdan odnos između tačnosti, stabilnosti, složenosti, interpretabilnosti i mogućnosti odgovorne primene.

1.3 Ciljevi istraživanja

Opšti cilj ove disertacije jeste razvoj i evaluacija prediktivnih modela za analizu obrazaca ljudskog ponašanja korišćenjem dubokog učenja i srodnih metoda mašinskog učenja u savremenom poslovnom okruženju. Iz opšteg cilja proizilaze sledeći posebni ciljevi:

1. definisati integrativni metodološki okvir za analizu ponašanja korisnika na osnovu heterogenih digitalnih podataka;
2. ispitati mogućnosti primene tradicionalnih modela mašinskog učenja, ansambl metoda, sekvencijalnih modela dubokog učenja i transformer arhitektura u različitim domenskim zadacima;
3. analizirati ulogu tekstualnih, numeričkih, kategorijalnih, vremenskih i multimodalnih karakteristika u predikciji relevantnih poslovnih i društvenih ishoda;
4. razviti i evaluirati modele za detekciju anomalija, klasifikaciju sentimenta, predikciju ocena, procenu zadovoljstva, procenu dugoročne vrednosti korisnika, detekciju rizičnih obrazaca i analizu društveno osetljive komunikacije;
5. uporediti modele prema standardnim metrikama evaluacije, uključujući tačnost, preciznost, odziv, F1 meru, AUC, MAE, RMSE i R^2 ;
6. ispitati uticaj kvaliteta podataka, pristrasnosti, neravnoteže klasa, šuma i nekonzistentnosti na performanse modela;
7. primeniti metode interpretabilne veštačke inteligencije radi objašnjavanja rezultata i povezivanja predikcija sa domenski razumljivim faktorima;

8. proceniti mogućnosti praktične primene razvijenih modela u hotelijerstvu, transportu, internet trgovini, poslovnoj komunikaciji, održivom razvoju i obrazovanju;
9. formulisati naučne, metodološke i aplikativne doprinose disertacije kroz integrativnu sintezu rezultata.

Ciljevi istraživanja uspostavljaju jasnu vezu između metodološkog okvira, empirijske provere i interpretacije rezultata u više domenskih okruženja. Disertaciju usmeravaju ka centralnom pitanju: kako iz složenih digitalnih tragova ponašanja izvesti predikcije koje su tačne, objašnjive i primenljive u realnim sistemima. Naglasak je na modelima kao sredstvu za razumevanje ponašanja i donošenje utemeljenih zaključaka o složenim digitalnim procesima.

1.4 Istraživačka pitanja

U skladu sa predmetom i ciljevima istraživanja, istraživačka pitanja su formulisana tako da obuhvate ključne dimenzije prediktivnog modelovanja ponašanja: izbor modela, strukturu podataka, kvalitet reprezentacije, pouzdanost rezultata, interpretabilnost i mogućnost primene u različitim empirijskim domenima.

- IP1:** U kojoj meri modeli dubokog učenja unapređuju predikciju obrazaca ljudskog ponašanja u odnosu na tradicionalne modele mašinskog učenja?
- IP2:** Koji tipovi podataka i reprezentacija najviše doprinose kvalitetu predikcije u tekstualnim, numeričkim, sekvencijalnim i multimodalnim zadacima?
- IP3:** Kako kvalitet podataka, anomalije, nekonzistentnost, pristrasnost i neravnoteža klasa utiču na performanse prediktivnih modela?
- IP4:** Koje metode interpretabilnosti najefikasnije povezuju rezultate modela sa poslovnim i društvenim značenjem predikcija?
- IP5:** U kojim empirijskim domenima duboko učenje daje najveću prednost, a u kojim domenima tradicionalni modeli ostaju konkurentni ili praktičniji?
- IP6:** Kako se rezultati iz različitih domena mogu objediniti u integrativni okvir za prediktivnu analizu ponašanja korisnika?

Istraživačka pitanja usmeravaju dalju strukturu disertacije. Poglavlje o metodologiji daje opšti okvir za njihovu proveru, domenska poglavlja pružaju empirijske rezultate, dok integrativna sinteza povezuje rezultate sa postavljenim pitanjima i hipotezama. Važno je da se istraživačka pitanja ne proveravaju izolovano u jednom domenu, već kumulativno, kroz poredenje nalaza iz različitih tipova podataka i različitih modelskih pristupa.

1.5 Hipoteze istraživanja

1.5.1 Opšta hipoteza

Polazna istraživačka pretpostavka disertacije jeste da se obrasci ljudskog ponašanja mogu preciznije analizirati primenom odgovarajućih prediktivnih modela, što se formuliše kroz sledeću opštu hipotezu:

OH: Odgovarajuće izabrani i evaluirani prediktivni modeli, uključujući duboko učenje i tradicionalne metode mašinskog učenja, mogu unaprediti analizu obrazaca ljudskog ponašanja u savremenim poslovnim i društvenim kontekstima.

1.5.2 Specifična hipoteza

Iz opšte istraživačke pretpostavke proizlazi specifična hipoteza koja naglašava značaj poređenja različitih klasa modela, kvaliteta reprezentacije i interpretabilnog tumačenja rezultata. Njena svrha je da proveri da li se bolja predikcija obrazaca ponašanja postiže samo primenom složenijih arhitektura ili pažljivim usklađivanjem modela, podataka, evaluacije i objašnjenja rezultata.

SH: Kombinovanjem tradicionalnih modela, ansambl metoda, dubokog učenja i metoda interpretabilnosti moguće je postići pouzdaniju i domenski korisniju predikciju obrazaca ljudskog ponašanja nego oslanjanjem na jedan tip modela ili jednu metriku performanse.

1.5.3 Pojedinačne hipoteze

Pojedinačne hipoteze dodatno razrađuju opštu i specifičnu istraživačku pretpostavku kroz ključne dimenzije disertacije. Svaka hipoteza formulisana je tako da se može proveriti kroz empirijske rezultate, ali i odbaciti ukoliko se očekivani odnos ne potvrdi.

H1: Modeli dubokog učenja, posebno sekvencijalne i transformer arhitekture, ostvaruju merljivu prednost u zadacima koji uključuju složene tekstualne i sekvencijalne podatke u odnosu na odgovarajuće referentne tradicionalne modele. Hipoteza se ne prihvata ukoliko tradicionalni ili ansambl modeli postižu jednake ili bolje rezultate bez gubitka interpretabilnosti i praktične upotrebljivosti.

H2: Kvalitet reprezentacije podataka, uključujući tekstualna, numerička, kategorijalna, sekvencijalna, fuzzy i multimodalna obeležja, značajno utiče na performanse prediktivnih modela. Hipoteza se ne prihvata ukoliko proširenje ili promena reprezentacije ne donosi merljivo poboljšanje u odnosu na jednostavnije reprezentacije.

- H3:** Kvalitet podataka, anomalije, nekonzistentnost, pristrasnost i neravnoteža klasa značajno utiču na pouzdanost prediktivnih modela, dok odgovarajuća obrada podataka može smanjiti negativan efekat tih faktora. Hipoteza se ne prihvata ukoliko se pokaže da modeli zadržavaju uporedive rezultate nezavisno od navedenih karakteristika podataka.
- H4:** Interpretabilnost, analiza grešaka i segmentna evaluacija omogućavaju potpunije razumevanje rezultata modela nego zbirne metrike performanse. Hipoteza se ne prihvata ukoliko ove metode ne otkriju dodatne domenski relevantne uvide, skrivene obrasce grešaka ili razlike između segmenata.
- H5:** Praktično najopravdaniji model nije nužno najsloženiji, već onaj koji ostvaruje najbolji odnos između performanse, stabilnosti, interpretabilnosti, potrošnje računarskih resursa i domenske korisnosti. Hipoteza se ne prihvata ukoliko se u analiziranim domenima pokaže da najsloženiji modeli dosledno dominiraju prema svim navedenim kriterijumima.

Tabela 1.1 prikazuje vezu između istraživačkih pitanja, hipoteza i očekivanog načina njihove empirijske provere. Njena uloga je da na nivou uvoda pokaže kako se istraživačka pitanja operacionalizuju kroz proverljive pretpostavke.

Tabela 1.1: Veza između istraživačkih pitanja, hipoteza i očekivanih rezultata.

Istraživačko pitanje	Hipoteze	Očekivani oblik provere
IP1	H1, H5	Poređenje tradicionalnih modela, ansambl metoda, rekurentnih mreža i transformer arhitektura u zadacima klasifikacije i regresije.
IP2	H2	Analiza doprinosa tekstualnih, numeričkih, kategorijalnih, vremenskih, fuzzy i multimodalnih reprezentacija u različitim domenima.
IP3	H3	Evaluacija uticaja anomalija, šuma, nekonzistentnosti, neravnoteže klasa i pristrasnosti na performanse modela.
IP4	H4	Primena metoda interpretabilnosti, segmentne evaluacije i analize grešaka radi domenski razumljivog tumačenja rezultata.
IP5	H1, H5	Identifikovanje domena i zadataka u kojima duboko učenje daje merljivu prednost, odnosno u kojima jednostavniji modeli ostaju praktičniji.
IP6	OH, SH	Integrativna sinteza rezultata i formiranje opšteg okvira za prediktivnu analizu ponašanja korisnika.

1.6 Naučni doprinos disertacije

Naučni doprinos disertacije ogleda se u razvoju, evaluaciji i integraciji prediktivnih modela za analizu obrazaca ljudskog ponašanja u više empirijskih domena savremenog poslovnog okruženja. Doprinos se zasniva na povezivanju tipova podataka, klasa modela, evaluacionih pristupa i interpretabilnosti rezultata u jedinstven istraživački okvir.

1.6.1 Metodološki doprinos

Metodološki doprinos odnosi se na oblikovanje okvira koji omogućava da se različiti oblici ponašanja analiziraju kroz uporediv postupak: definisanje problema, izbor i pripremu podataka, konstrukciju reprezentacija, razvoj referentnih i naprednih modela, evaluaciju, analizu grešaka, interpretabilnost i procenu primenljivosti. Takav okvir ne daje prednost unapred jednoj arhitekturi, već proverava kada duboko učenje donosi opravdanu prednost, a kada su tradicionalni ili ansambl modeli stabilnije, jednostavnije i praktičnije rešenje.

1.6.2 Empirijski doprinos

Empirijski doprinos proizilazi iz primene istog metodološkog okvira na više realnih domena: turizam i hotelijerstvo, transportne sisteme, internet trgovinu i parfemsku industriju, poslovnu komunikaciju, održivi razvoj i obrazovanje. Svaki domen uvodi drugačiji tip podataka, drugačiji prediktivni zadatak i drugačiji oblik domenskog tumačenja, čime se omogućava da se rezultati porede po strukturi podataka, vrsti modela, tipu ishoda i nivou interpretabilnosti.

1.6.3 Doprinos interpretabilnosti i odgovornoj primeni

Poseban doprinos disertacije odnosi se na povezivanje prediktivne tačnosti sa interpretabilnošću, analizom grešaka i odgovornom primenom. U zadacima koji uključuju korisnike, potrošače, putnike, studente ili digitalnu komunikaciju, nije dovoljno utvrditi šta model predviđa; potrebno je objasniti zašto model daje određenu predikciju i kakve posledice mogu imati lažno pozitivni i lažno negativni ishodi.

1.6.4 Aplikativni doprinos

Aplikativni doprinos ogleda se u mogućnosti da razvijeni modeli i analitički postupci podrže odlučivanje u realnim sistemima: razumevanje zadovoljstva gostiju, prepoznavanje rizičnih obrazaca u transportu, analizu potrošačkih preferencija, podršku inkluzivnijoj poslovnoj komunikaciji, održivo izveštavanje i odgovornu obrazovnu analitiku. Time se rezultati disertacije povezuju sa konkretnim poslovnim, organizacionim i društvenim potrebama.

Tabela 1.2 prikazuje objedinjeni pregled doprinosa disertacije, sa akcentom na metodološku, empirijsku, interpretativnu, aplikativnu, etičku i integrativnu dimenziju istraživanja.

Tabela 1.2: Pregled ključnih doprinosa disertacije.

Vrsta doprinosa	Opis doprinosa
Metodološki doprinos	Razvoj integrativnog okvira za poređenje tradicionalnih, ansambl, sekvencijalnih, transformer i multimodalnih modela u analizi obrazaca ponašanja.
Empirijski doprinos	Primena okvira na više domena u kojima se ponašanje korisnika manifestuje kroz različite tipove digitalnih tragova.
Interpretativni doprinos	Povezivanje performansi modela sa metodama objašnjive veštačke inteligencije, analizom grešaka i domenski razumljivim tumačenjem rezultata.
Aplikativni doprinos	Formulisanje mogućnosti primene rezultata u hotelijerstvu, transportu, internet trgovini, poslovnoj komunikaciji, održivom razvoju i obrazovanju.
Etički doprinos	Razmatranje pristrasnosti, neravnoteže podataka, društveno osetljivih grešaka i potrebe za stručnom kontrolom u primeni modela.
Originalni integrativni doprinos	Povezivanje rezultata iz više empirijskih domena u jedinstven okvir za prediktivnu analizu ponašanja korisnika, sa jasnim kriterijumima kada su duboko učenje, tradicionalni modeli, multimodalnost i interpretabilnost najopravdaniji.

1.7 Empirijski domeni kao prostori evaluacije modela

Svaki domen ima određenu metodološku funkciju u proveru istraživačkog okvira. Turizam i hotelijerstvo koriste se za evaluaciju modela nad tekstualnim i multimodalnim podacima o zadovoljstvu korisnika. Transportni sistemi služe za proveru sekvencijalnih modela i ansambl regresije. Internet trgovina i parfemska industrija uvode analizu preferencija i subjektivnog doživljaja proizvoda. Poslovna komunikacija obuhvata društveno osetljivu klasifikaciju, održivi razvoj uvodi analitičko izveštavanje i projektne podatke, a obrazovanje studentske ishode i ponašanje u uslovima upotrebe generativnih modela.

Tabela 1.3 prikazuje kako se svaki empirijski domen povezuje sa odgovarajućim obrascem ponašanja, tipom podataka i prediktivnim zadatkom, čime se jasno definiše njegova uloga u evaluaciji istraživačkog okvira disertacije.

Ovakvo mapiranje domena povezuje svaki deo disertacije sa osnovnim istraživačkim pitanjem. Dodatno, pruža osnovu da se u završnoj sintezi porede modeli, tipovi podataka i uslovi njihove najbolje primene.

Tabela 1.3: Empirijski domeni kao prostori za razvoj i evaluaciju prediktivnih modela.

Domen	Obrazac ponašanja	Dominantni podaci	Prediktivni zadatak
Turizam i hotelijerstvo	Zadovoljstvo gostiju, pritužbe, lojalnost	Recenzije, ocene, metapodaci	Regresija, klasifikacija, multimodalna predikcija
Transportni sistemi	Rizična vožnja, ponašanje putnika, izbor prevoznika	Senzorski, vremenski, cenovni i rasporedni podaci	Sekvencijalna klasifikacija, regresija, analiza obrazaca
Internet trgovina i parfemi	Preferencije, emocije, popularnost proizvoda	Recenzije, mirisne note, tržišni atributi	Klasifikacija, klasterovanje, predikcija vrednosti
Poslovna komunikacija	Mizogini i diskriminatorni obrasci	Tekstualni komentari i poslovni diskurs	Detekcija društveno štetnog jezika
Održivi razvoj	Analitičko odlučivanje, projektni portfolio	Narativi, indikatori, projektni opisi	NLP klasifikacija, evaluacija narativa, mapiranje tema
Obrazovanje	Studentski ishodi i oslanjanje na generativne alate	Studentski radovi, ocene, institucionalni podaci	Predikcija uspeha, analiza radova, detekcija obrazaca

1.8 Metodološki pristup

Metodološki pristup disertacije zasniva se na eksperimentalnom i komparativnom istraživačkom dizajnu. U svakom empirijskom domenu polazi se od definisanja problema i ciljne promenljive, zatim se analiziraju dostupni podaci, sprovodi pretprocesiranje, razvijaju referentni modeli, primenjuju napredniji modeli, evaluiraju rezultati i interpretiraju greške.

Formalni zapis skupa podataka, ulaznih modaliteta, podela na trening, validacioni i test skup, kao i osnovne metrike evaluacije, sistematski su dati u metodološkom poglavlju. U uvodu je važno naglasiti da se metodologija ne svodi na jednu arhitekturu, već na protokol koji omogućava kontrolisano poređenje modela kroz više domena.

Evaluacija se vrši pomoću metrika prilagođenih tipu zadatka. Izbor metrika u ovoj disertaciji nema samo tehničku funkciju, već omogućava da se kvalitet modela proceni kroz odnos između tačnosti, grešaka, stabilnosti i posledica koje predikcija može imati u konkretnom domenu. Za klasifikaciju se koriste tačnost, preciznost, odziv, F1 mera, makro F1, AUC i matrica konfuzije, koje mere uspešnost, pouzdanost pozitivnih predikcija, prepoznavanje relevantnih primera, balans preciznosti i odziva, uspešnost po klasama i raspored grešaka. Za regresiju se koriste MAE, RMSE i koeficijent determinacije, koji mere prosečnu grešku, odstupanja i objašnjenu varijansu. U domenskim poglavljima koriste se i segmentna evaluacija, analiza grešaka, poređenje po klasama, analiza pragova odlučivanja, provera stabilnosti rezultata, interpretacija karakteristika i procena poslovnog značaja rezultata.

1.9 Interpretabilnost, pristrasnost i odgovorna primena modela

Jedno od ključnih polazišta disertacije jeste da prediktivni modeli za analizu ljudskog ponašanja ne mogu biti evaluirani samo kroz numeričke performanse. Kada se modeli koriste u poslovnim, obrazovnim, transportnim ili društveno osetljivim okruženjima, potrebno je razumeti kako se donose predikcije, da li model sistematski favorizuje određene obrasce i da li njegove greške imaju nejednake posledice po različite grupe.

Pristrasnost u modelima mašinskog učenja može nastati iz više izvora: iz istorijskih podataka, procesa prikupljanja podataka, načina anotacije, neravnomerne zastupljenosti klasa, izbora karakteristika ili same formulacije ciljne promenljive. Zbog toga se pravičnost modela u ovoj disertaciji ne posmatra kao izolovan etički dodatak, već kao metodološki zahtev u zadacima u kojima greške mogu različito uticati na korisničke ili društvene grupe.

Interpretabilnost je posebno važna u situacijama u kojima korisnici, menadžeri, nastavnici ili stručnjaci moraju razumeti zbog čega je model dao određeni rezultat. Na primer, u hotelijerstvu je važno znati koji aspekti recenzije najviše utiču na predviđenu ocenu. U transportu je važno razumeti koji obrasci ponašanja prethode rizičnoj vožnji. U poslovnoj komunikaciji je važno razlikovati zaista problematičan sadržaj od pogrešno klasifikovanog izraza. U obrazovanju je važno da se model ne koristi za automatsko kažnjavanje studenata, već za identifikaciju potreba za dodatnom podrškom.

Odgovorna primena modela posebno je značajna u kontekstu generativnih i velikih jezičkih modela. U ovoj disertaciji modeli se posmatraju kao alati za podršku analizi i odlučivanju, a ne kao autonomni sistemi koji zamenjuju stručnu procenu. Takav pristup je naročito važan u društveno osetljivim domenima, kao što su detekcija diskriminatornog jezika i analiza studentskih radova, gde lažno pozitivni i lažno negativni ishodi mogu imati ozbiljne posledice.

1.10 Publikaciona i empirijska osnova disertacije

Disertacija se oslanja na više prethodno sprovedenih i tematski povezanih istraživanja kandidatkinje i koautora, koja predstavljaju empirijsku osnovu za razvoj integrativnog okvira prediktivnog modelovanja ponašanja korisnika.

Najrazvijenija empirijska osnova nalazi se u oblasti turizma i hotelijerstva, gde su istraživani detekcija anomalija u hotelskim recenzijama, prepoznavanje negativnih recenzija, predikcija hotelskih ocena, transformer modeli za detekciju pritužbi, multimodalno modelovanje zadovoljstva i procena dugoročne vrednosti korisnika. U oblasti transporta razmatrani su agresivna vožnja, sekvencijalna analiza ponašanja vozača, predikcija cena avionskih karata, zadovoljstvo putnika i struktura avio-saobraćaja. U oblasti internet trgovine i parfemske industrije analizirani su mirisne note, emocionalne reakcije korisnika, popularnost proizvoda, tržišna vrednost i fuzzy kategorizacija recenzija. U oblasti društveno odgovorne komunikacije razmatrani su mizogini i diskriminatorni obrasci jezika. U oblasti održivog razvoja razma-

traju se poslovna inteligencija, generativni modeli i projektna analitika, dok se u obrazovanju analiziraju generativni modeli, studentski radovi i analitika studentskih ishoda.

U disertaciji se ovi istraživački pravci dodatno povezuju kroz zajednički metodološki okvir, uporedive kriterijume evaluacije i završnu sintezu nalaza. Publikaciona osnova zato služi kao oslonac za šire istraživačko pitanje o tome kako se različiti oblici ljudskog ponašanja mogu modelovati, objasniti i primeniti u savremenom poslovnom okruženju.

1.11 Ograničenja i granice istraživanja

Kao i svako istraživanje zasnovano na realnim podacima, ova disertacija ima određena ograničenja. Prvo ograničenje odnosi se na dostupnost i kvalitet podataka. Pojedini skupovi podataka mogu biti javno dostupni, dok su drugi ograničeni, agregirani ili anonimizovani. U nekim domenima postoji mogućnost da podaci ne obuhvataju sve relevantne faktore ponašanja korisnika, što utiče na interpretaciju rezultata.

Drugo ograničenje odnosi se na domensku raznolikost. Iako različiti domeni omogućavaju širu proveru metodološkog okvira, oni se međusobno razlikuju prema tipu podataka, ciljnim promenljivama i poslovnim značenjima rezultata. Zbog toga se rezultati ne smeju tumačiti kao direktno prenosivi iz jednog domena u drugi bez dodatne validacije.

Treće ograničenje odnosi se na promenu distribucije podataka tokom vremena. Model koji dobro funkcioniše na istorijskim podacima ne mora nužno zadržati iste performanse u budućnosti. Ovo je posebno važno u domenima kao što su turizam, transport, internet trgovina i obrazovanje, gde se ponašanje korisnika menja pod uticajem tržišnih, tehnoloških i društvenih faktora.

Četvrto ograničenje odnosi se na interpretabilnost. Metode objašnjive veštačke inteligencije mogu pomoći u razumevanju modela, ali ne daju uvek potpuno objašnjenje unutrašnje logike složenih arhitektura. Zbog toga se interpretabilnost u ovoj disertaciji tretira kao podrška analizi, a ne kao apsolutno objašnjenje svih odluka modela.

Peto ograničenje odnosi se na etičku primenu rezultata. U društveno osetljivim domenima, kao što su poslovna komunikacija i obrazovanje, modeli se ne smeju koristiti za automatsko donošenje sankcija ili konačnih odluka bez stručne kontrole. Rezultati modela treba da služe kao podrška ljudskom odlučivanju i kao signal za dodatnu analizu.

Šesto ograničenje odnosi se na činjenicu da se disertacija zasniva na više empirijskih domena. Takva širina omogućava jaču proveru integrativnog okvira, ali zahteva pažljivo tumačenje rezultata i oprez pri generalizaciji. Zbog toga se doprinos disertacije ne zasniva na tvrdnji da jedan model jednako uspešno rešava sve zadatke, već na preciznom utvrđivanju uslova pod kojima određene klase modela daju najbolji odnos između performanse, interpretabilnosti i praktične primenljivosti.

1.12 Struktura disertacije

Disertacija je organizovana u dvanaest poglavlja, dok je literatura data na kraju rada. Nakon uvodnog poglavlja, drugo poglavlje daje pregled literature i razvija utemeljen istraživački okvir. U njemu se razmatraju savremeni pravci istraživanja u oblasti mašinskog učenja, dubokog učenja, obrade prirodnog jezika, transformer modela, sekvencijalnog modelovanja, multimodalne analize, interpretabilnosti, pristrasnosti i odgovornog razvoja i primene prediktivnih modela.

Treće poglavlje definiše metodološki okvir istraživanja kao osnovu analize. U njemu se opisuju istraživački dizajn, tipovi podataka, pretprocesiranje, konstrukcija karakteristika, modeli, evaluacione metrike, interpretabilnost, analiza grešaka i etički aspekti istraživanja.

Četvrto poglavlje posvećeno je turizmu i hotelijerstvu kao ključnom domenu. U ovom poglavlju analiziraju se online recenzije, detekcija anomalija, negativne recenzije, predikcija hotelskih ocena, transformer modeli za pritužbe, multimodalno zadovoljstvo korisnika, procena dugoročne vrednosti korisnika i primena rezultata u hotelskom menadžmentu.

Peto poglavlje obrađuje transportne sisteme kao važan aplikativni domen. U njemu se razmatraju obrasci rizičnog ponašanja u kopnenom saobraćaju, detekcija agresivne vožnje, LSTM analiza, predikcija cena avionskih karata, objašnjivost cenovnih faktora, zadovoljstvo putnika i struktura avionskog saobraćaja.

Šesto poglavlje posvećeno je internet trgovini i parfemskoj industriji kao tržišnom domenu. U njemu se analiziraju potrošačko ponašanje, subjektivni doživljaj parfema, mirisne note, popularnost proizvoda, emocionalne recenzije, reprezentaciono učenje i fuzzy kategorizacija potrošačkih komentara.

Sedmo poglavlje razmatra društveno odgovornu poslovnu komunikaciju kao osetljiv domen. Fokus je na detekciji rodno pristrasnog jezika, mizoginije i diskriminatornih obrazaca, uz poseban akcenat na odgovornu evaluaciju, lažno pozitivne i lažno negativne ishode, stručnu kontrolu i inkluzivno radno okruženje.

Osmo poglavlje obrađuje održivi razvoj, projektno odlučivanje i analitičko izveštavanje. U njemu se razmatraju poslovna inteligencija, generativni modeli u održivom turizmu, indikatori održivosti, automatski generisani narativi, Horizon Europe projekti, klasifikacija zelenih tehnologija i održivost softverske implementacije.


Deveto poglavlje posvećeno je obrazovanju i ishodima studenata u eri generativnih modela. U njemu se razmatraju promene ponašanja studenata, analiza studentskih radova, detekcija prekomernog oslanjanja na generativne alate, LLM pristupi u analizi grešaka, podaci studentske službe i pedagoške implikacije.

Deseto poglavlje daje integrativnu sintezu rezultata i naučnih doprinosa. U njemu se povezuju empirijski domen, porede modeli, tipovi podataka, uslovi primene, interpretabilnost, pouzdanost i pravičnost rezultata, a zatim se rezultati povezuju sa postavljenim hipotezama.

Jedanaesto poglavlje razmatra industrijsku primenu i poslovni uticaj rezultata. U njemu se objašnjava kako se razvijeni modeli mogu primeniti u realnim sistemima i koje su mogućnosti za razvoj softverskih rešenja.

Dvanaesto poglavlje sadrži zaključna razmatranja, sumu ključnih nalaza, ograničenja istraživanja i smernice za budući rad.

Slika 1.1 vizuelno prikazuje da poglavlja od četvrtog do devetog ne predstavljaju nepovezane tematske celine, već empirijske domene koji se povezuju u desetom poglavlju kroz integrativnu sintezu rezultata.



Slika 1.1: Logička struktura disertacije i povezanost poglavlja.

1.13 Zaključna razmatranja uvodnog poglavlja

Uvodno poglavlje postavlja osnovu za razumevanje disertacije kao fokusiranog istraživanja razvoja i evaluacije prediktivnih modela za analizu obrazaca ljudskog ponašanja. U radu se polazi od pretpostavke da savremeno poslovno okruženje generiše velike količine heterogenih podataka koji mogu poslužiti za analizu korisničkog ponašanja, ali samo ukoliko se modeli razvijaju uz pažljivo definisanje ciljeva, kontrolu kvaliteta podataka, odgovarajuću evaluaciju i interpretabilno tumačenje rezultata.

Ključna ideja disertacije jeste da se različiti domeni ne posmatraju kao odvojene oblasti, već kao empirijski prostori za proveru istog istraživačkog okvira. Time se omogućava da se rezultati iz turizma, transporta, internet trgovine, poslovne komunikacije, održivog razvoja i obrazovanja povežu kroz zajedničke metodološke principe. U nastavku disertacije najpre se razmatra relevantna literatura i razvija teorijski okvir istraživanja, zatim se definiše metodologija, a potom se kroz domenska poglavlja empirijski proveravaju postavljene hipoteze.

Uvodno poglavlje istovremeno naglašava centralnu ideju rada: kroz više empirijskih okruženja razvija se i proverava integrativni model istraživanja koji povezuje digitalne tragove ljudskog ponašanja, prediktivno modelovanje, interpretabilnost, analizu grešaka i praktičnu primenu. Na taj način se postavlja osnova za završnu sintezu u kojoj će biti pokazano pod kojim uslovima različite klase modela daju najveći naučni i aplikativni doprinos.

2. PREGLED LITERATURE I RAZVOJ ISTRAŽIVAČKOG OKVIRA

2.1 Uloga pregleda literature u strukturi disertacije

Pregled literature u ovoj disertaciji postavlja teorijsku i metodološku osnovu za razvoj istraživačkog okvira. U teorijskom smislu, potrebno je objasniti razvoj prediktivnog modelovanja, dubokog učenja, obrade prirodnog jezika, sekvencijalne analize, interpretabilnosti i odgovorne primene modela u savremenom poslovnom okruženju. U metodološkom smislu, pregled literature pokazuje kako se postojeća saznanja mogu povezati sa istraživačkim dizajnom koji se kasnije proverava kroz empirijska poglavlja disertacije.

Zbog toga ovo poglavlje nije organizovano kao opšti pregled svih oblasti u kojima se mašinsko učenje primenjuje. Umesto toga, literatura se razmatra selektivno i u odnosu na osnovni problem disertacije: razvoj i evaluaciju prediktivnih modela za analizu obrazaca ljudskog ponašanja korišćenjem dubokog učenja u savremenom poslovnom okruženju. U skladu sa tim, pregled literature povezuje tri nivoa: tipove podataka, klase modela i uslove odgovorne primene. Takav pristup omogućava da se teorijski nalazi ne zadrže na nivou opšteg pregleda, već da neposredno usmere izbor metoda, modela i kriterijuma evaluacije u nastavku rada.

Prvi nivo odnosi se na podatke. Ljudsko ponašanje u digitalnom poslovnom okruženju može biti izraženo kroz tekstualne podatke, numeričke podatke, vremenske serije, sekvencijalne zapise, kategorijalne promenljive, mrežne odnose i multimodalne kombinacije više izvora. Drugi nivo odnosi se na modele. U disertaciji se razmatraju tradicionalni modeli mašinskog učenja, ansambl metode, rekurentne neuronske mreže, LSTM modeli, konvolucione mreže, transformer arhitekture i multimodalni modeli. Treći nivo odnosi se na evaluaciju i primenu. Modeli se ne posmatraju samo prema tačnosti, već i prema interpretabilnosti, stabilnosti, pravičnosti, mogućnosti primene i posledicama grešaka.

Važnost ovog poglavlja nalazi se u tome što ono obezbeđuje teorijsko i metodološko opravdanje za izbor empirijskih domena u disertaciji. Turizam, transport, internet trgovina, poslovna komunikacija, održivi razvoj i obrazovanje predstavljaju različite prostore u kojima se proverava isti istraživački problem: pod kojim uslovima prediktivni modeli mogu pouzdano i objašnjivo analizirati obrasce ljudskog ponašanja na osnovu digitalnih tragova.

2.2 Prediktivno modelovanje ljudskog ponašanja

Prediktivno modelovanje ljudskog ponašanja obuhvata metode kojima se na osnovu prethodno prikupljenih podataka procenjuju budući ishodi, obrasci ili verovatnoće ponašanja pojedina i grupa. U savremenom poslovnom okruženju ovakvo modelovanje obuhvata širok spektar zadataka: predikciju zadovoljstva korisnika, klasifikaciju pritužbi, procenu rizika, detekciju anomalija, predikciju tržišne popularnosti, procenu dugoročne vrednosti korisnika, klasifikaciju komunikacionih obrazaca i predikciju studentskih ishoda.

Za razliku od klasičnih statističkih analiza koje često imaju cilj da objasne odnos između manjeg broja promenljivih, prediktivno modelovanje je usmereno na procenu ishoda na novim podacima. U tom smislu, centralno pitanje nije samo da li određena promenljiva ima statistički značajan efekat, već da li model može pouzdano da generalizuje na instance koje nisu korišćene u treningu. Pregled savremenih pristupa mašinskom učenju ukazuje da se uspešnost modela u realnim primenama zasniva na usklađivanju problema, podataka, algoritma, validacije i interpretacije rezultata [6].

U ovoj disertaciji formalni zapis skupa podataka, funkcije predikcije i podela na trening, validacioni i test skup dat je u metodološkom poglavlju. U pregledu literature naglasak je na tome zašto je ljudsko ponašanje složen prediktivni zadatak i kako se modeli povezuju sa različitim tipovima podataka i ishodima.

2.2.1 Specifičnost ljudskog ponašanja kao prediktivnog zadatka

Modelovanje ljudskog ponašanja razlikuje se od mnogih tehničkih prediktivnih zadataka zato što ljudske odluke i reakcije nisu potpuno stabilne, determinističke ili jednoznačne. Korisnici mogu davati kontradiktorne signale, isti tekst može imati različito značenje u različitim kontekstima, vremenski obrasci mogu zavisiti od spoljašnjih događaja, dok ciljna promenljiva često predstavlja rezultat subjektivne procene. Na primer, ocena hotela ne zavisi samo od objektivnog kvaliteta usluge, već i od očekivanja gosta, cene, svrhe putovanja, prethodnog iskustva i trenutnog emocionalnog stanja. Slično tome, studentski uspeh ne zavisi samo od znanja, već i od motivacije, dostupnosti resursa, nastavne podrške i načina procene.

Zbog toga se u disertaciji prediktivno modelovanje ljudskog ponašanja posmatra kao kombinacija tehničkog i interpretativnog problema. Tehnički problem odnosi se na izbor modela i optimizaciju performansi. Interpretativni problem odnosi se na razumevanje značenja podataka i posledica predikcije. Ova razlika je važna jer numerički dobar model nije nužno najprimereniji za domene u kojima greške imaju društvene, pedagoške ili poslovne posledice.

Ako se modeli razvijaju samo za jedan domen, postoji rizik da se zaključci vežu za specifičnost tog skupa podataka. Ako se, međutim, isti metodološki principi proveravaju u više različitih domena, moguće je preciznije utvrditi koji zaključci važe šire, a koji zavise od tipa podataka, ciljne promenljive ili domenskog konteksta.

2.2.2 Taksonomija prema tipu podataka

U literaturi i praksi prediktivne analitike podaci o ljudskom ponašanju najčešće se razlikuju prema modalitetu, strukturi i vremenskoj zavisnosti. U ovoj disertaciji ta podela se koristi kao osnova za sistematizaciju tipova podataka:

- **tekstualni podaci**, kao što su recenzije, komentari, pritužbe, studentski odgovori i poslovni diskurs; ovi podaci su posebno značajni jer sadrže semantičke, emocionalne i kontekstualne signale ponašanja;
- **numerički podaci**, kao što su ocene, cene, bodovi, indeksi, frekvencije i merene vrednosti; oni omogućavaju kvantitativno modelovanje intenziteta, vrednosti, učestalosti i ishoda posmatranih aktivnosti;
- **kategorijalni podaci**, kao što su tip korisnika, kategorija proizvoda, tip prevoznika, segment putnika ili status studenta; njihova uloga je da opišu pripadnost instanci određenoj grupi, klasi ili domenskom segmentu;
- **sekvencijalni podaci**, kao što su zapisi vožnje, promena ponašanja kroz vreme, istorija kupovine ili niz aktivnosti; oni su važni kada redosled događaja utiče na predikciju i kada ponašanje treba posmatrati kao proces, a ne kao izolovanu instancu;
- **multimodalni podaci**, koji kombinuju tekst, brojeve, kategorije, vreme, slike, senzore ili mrežne odnose; njihova vrednost je u tome što omogućavaju objedinjavanje više različitih signala u jedinstvenu reprezentaciju ponašanja.

Tabela 2.1 ističe da se različiti tipovi podataka ne mogu tretirati istom metodologijom. Tekstualni podaci zahtevaju semantičku reprezentaciju, sekvencijalni podaci zahtevaju očuvanje redosleda, a multimodalni podaci zahtevaju integraciju više izvora informacija.

2.2.3 Taksonomija prema istraživačkom zadatku

Pored tipa podataka, važna je i taksonomija prema istraživačkom zadatku. Ključni zadaci su klasifikacija, regresija, detekcija anomalija, sentiment analiza, predikcija vremenskih obrazaca i procena vrednosti korisnika. Ova podela je važna zato što isti skup podataka može imati različitu istraživačku funkciju u zavisnosti od toga da li se koristi za predviđanje klase, procenu numeričke vrednosti, otkrivanje odstupanja ili tumačenje emocionalnog i poslovnog značenja ponašanja.

Klasifikacija se koristi kada je cilj da se instanca svrsta u jednu ili više kategorija. Primeri su detekcija negativne recenzije, klasifikacija pritužbe, detekcija mizoginog jezika ili klasifikacija agresivne vožnje. Regresija se koristi kada je cilj predviđanje numeričke vrednosti, kao što su hotelska ocena, cena avionske karte ili tržišna vrednost proizvoda. Detekcija

anomalija koristi se za identifikaciju neuobičajenih obrazaca koji mogu ukazivati na nekonzistentnost, nepravilnost ili rizik. Sentiment analiza povezuje tekstualni sadržaj sa emocionalnim ili evaluativnim značenjem. Procena dugoročne vrednosti korisnika proširuje analizu od pojedinačne transakcije ka dugoročnom odnosu korisnika i organizacije.

Tabela 2.1: Taksonomija podataka o ljudskom ponašanju u kontekstu disertacije.

Tip podataka	Primeri u disertaciji	Tipični zadaci	Pogodni modeli
Tekstualni podaci	• hotelske recenzije • recenzije parfema • poslovni komentari • studentski radovi	• sentiment analiza • klasifikacija • regresija ocena	• TF-IDF • SVM • LSTM • transformer modeli
Numerički podaci	• ocene • cene • popularnost • bodovi i indikatori	• regresija • segmentacija • predikcija vrednosti	• linearni modeli • Random Forest • XGBoost
Kategorijalni podaci	• tip korisnika • tip prevoznika • kategorija pritužbe	• klasifikacija • segmentna analiza	• logistička regresija • ansambli • slojevi vektora
Sekvencijalni podaci	• vremenski zapisi vožnje • dinamika cena • aktivnost kroz vreme	• sekvencijalna klasifikacija • prognoza • rana detekcija	• RNN • LSTM • GRU • transformer modeli
Multimodalni podaci	• tekst, ocene i metapodaci • senzori i kontekst • recenzije i atributi proizvoda	• integrisana predikcija • objašnjiva analitika	• hibridna fuzija • međumodalna pažnja • ansambli

2.3 Duboko učenje za sekvencijalne i tekstualne podatke

Duboko učenje predstavlja skup metoda koje omogućavaju automatsko učenje višeslojnih reprezentacija podataka. U analizi ljudskog ponašanja posebno su značajne arhitekture koje mogu da obrađuju tekstualne, sekvencijalne i multimodalne podatke. Tekstualni podaci zahtevaju modelovanje značenja, konteksta i implicitnih signala, dok sekvencijalni podaci zahtevaju očuvanje redosleda i zavisnosti između vremenskih koraka. Pregledi dubokog učenja u tekstualnoj klasifikaciji pokazuju da neuronske arhitekture mogu nadmašiti tradicionalne pristupe kada postoji dovoljno podataka i kada zadatak zahteva semantičko razumevanje složenog teksta [7]. Ipak, ta prednost nije univerzalna, jer zavisi od veličine skupa podataka, kvaliteta oznaka, računarskih resursa i potrebe za tumačenjem rezultata.

2.3.1 Rekurentne neuronske mreže

Rekurentne neuronske mreže razvijene su za obradu sekvencijalnih podataka, kod kojih redosled elemenata nosi važno značenje. Za razliku od klasičnih feed-forward mreža, RNN modeli imaju unutrašnje stanje koje se ažurira kroz vremenske korake i omogućava da se trenutni ulaz tumači u odnosu na prethodno obrađene informacije. U opštem obliku, skriveno stanje u trenutku t može se zapisati kao:

$$h_t = \sigma(W_x x_t + W_h h_{t-1} + b), \quad (2.1)$$

gde je x_t ulaz u trenutku t , h_t novo skriveno stanje, h_{t-1} skriveno stanje iz prethodnog koraka, W_x i W_h matrice težina, b bias član, a σ nelinearna aktivaciona funkcija. Ova formulacija je dovoljna da pokaže osnovnu ideju rekurentnog modelovanja: svaka nova informacija obrađuje se zajedno sa prethodno formiranim kontekstom.

Osnovni RNN modeli imaju ograničenja u učenju dugoročnih zavisnosti, zbog čega se u praksi često koriste LSTM i GRU arhitekture. LSTM modeli uvode memorijsko stanje čelije i gate mehanizme za kontrolu toka informacija, dok GRU modeli koriste jednostavniju strukturu sa manjim brojem parametara. Za disertaciju je najvažnije metodološko razlikovanje: LSTM i GRU su opravdani kada redosled i trajanje prethodnih događaja utiču na ishod, na primer u analizi vožnje, dinamici cena ili promenama ponašanja kroz vreme.

2.3.2 Transformer arhitekture

Transformer arhitekture predstavljaju jedan od najvažnijih pravaca razvoja dubokog učenja za tekstualne i sekvencijalne podatke. Njihova glavna prednost je mehanizam pažnje, koji omogućava istovremeno modelovanje odnosa između elemenata ulazne sekvence, umesto stroge obrade redom kao kod rekurentnih mreža. Savremeni pregledi transformer arhitektura ističu da su transformer modeli postali dominantna osnova za obradu prirodnog jezika, ali da njihova primena zahteva pažljivo upravljanje memorijom i računarskim troškovima [8]. Mehanizam pažnje zasnovane na skalarnom proizvodu može se zapisati kao:

$$Attention(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V, \quad (2.2)$$

gde su Q , K i V matrice upita, ključeva i vrednosti, a d_k dimenzija vektora ključeva. U kontekstu disertacije, ovaj princip je posebno relevantan za analizu hotelskih recenzija, potrošačkih komentara, poslovne komunikacije i studentskih tekstova, jer omogućava da se značenje reči tumači u zavisnosti od rečenice i šireg konteksta. Sa druge strane, transformer modeli ne treba da budu podrazumevani izbor u svakom zadatku, jer njihova prednost mora biti potvrđena poređenjem sa jednostavnijim i interpretabilnijim modelima.

2.3.3 Konvolucione neuronske mreže za tekst i bihevioralnu analizu

Konvolucione neuronske mreže najčešće se povezuju sa obradom slika, ali se mogu koristiti i za tekstualne i bihevioralne podatke. Njihova osnovna ideja nije vezana samo za sliku, već za izdvajanje obrazaca iz strukturisanog ulaza. U tekstualnoj klasifikaciji, konvolucionni filteri mogu prepoznati lokalne obrasce reči ili karaktera, dok se u bihevioralnoj analizi mogu koristiti za izdvajanje kratkih vremenskih segmenata koji prethode određenom ishodu.

U ovoj disertaciji CNN arhitekture se posmatraju kao komplementaran pristup u odnosu na rekurentne i transformer modele. Njihova vrednost je posebno izražena kada su važni kratki signali, fraze, lokalne promene ili obrasci koji se javljaju u ograničenim segmentima teksta ili sekvence. Ako je, međutim, ishod snažno zavisn od dugoročnog konteksta, prednost obično imaju rekurentne ili transformer arhitekture.

2.3.4 Vektorske reprezentacije i kontekstualni modeli

Da bi tekstualni podaci mogli biti obrađeni modelima mašinskog i dubokog učenja, potrebno ih je predstaviti numerički. Tradicionalni pristupi, kao što su bag-of-words i TF-IDF, predstavljaju tekst kroz prisustvo i učestalost termina. TF-IDF vrednost termina t u dokumentu d može se zapisati kao:

$$TFIDF(t, d) = TF(t, d) \cdot \log \left(\frac{N}{DF(t)} \right), \quad (2.3)$$

gde $TF(t, d)$ označava učestalost termina t u dokumentu d , N ukupan broj dokumenata, a $DF(t)$ broj dokumenata u kojima se termin pojavljuje. TF-IDF je jednostavan, interpretabilan i često veoma jak referentni pristup, posebno u zadacima klasifikacije teksta sa jasno izraženim ključnim rečima.

Nasuprot tome, neuronski pristupi vektorskih reprezentacija (embedding) predstavljaju reči, rečenice ili dokumente kao guste vektore u višedimenzionalnom prostoru. Statički modeli vektorskih reprezentacija dodeljuju jednoj reči jednu reprezentaciju, dok kontekstualni modeli vektorskih reprezentacija omogućavaju da ista reč dobije različitu reprezentaciju u zavisnosti od rečenice u kojoj se pojavljuje. Ovo je važno u analizi recenzija i poslovne komunikacije, gde značenje izraza zavisi od tona, konteksta i kombinacije sa drugim rečima.

Pretprocesiranje teksta mora biti usklađeno sa tipom modela i načinom na koji model koristi jezičke informacije. Postupci kao što su uklanjanje stop-reči, lematizacija (svođenje reči na osnovni rečnički oblik), pretvaranje svih slova u mala slova (*lowercasing*) ili uklanjanje interpunkcije mogu poboljšati tradicionalne klasifikatore, ali kod transformer modela mogu dovesti do gubitka kontekstualnih, morfoloških ili stilskih signala. Zbog toga se pretprocesiranje ne može posmatrati kao univerzalni skup pravila, već kao eksperimentalna odluka koja zavisi od modela, jezika, domena i konkretnog prediktivnog zadatka [9].

2.3.5 Prednosti i ograničenja dubokog učenja

Duboko učenje ima značajne prednosti u zadacima koji uključuju tekst, sekvence i složene nelinearne obrasce. Modeli mogu automatski učiti reprezentacije iz podataka, smanjiti potrebu za ručnim oblikovanjem karakteristika i obuhvatiti odnose koje jednostavniji modeli teško prepoznaju. Međutim, takva prednost podrazumeva i veće zahteve u pogledu obima podataka, računarskih resursa, vremena treniranja i složenosti tumačenja rezultata.

Zbog toga se u ovoj disertaciji duboko učenje ne posmatra kao automatski superiorno rešenje. Njegova vrednost potvrđuje se samo onda kada složenija reprezentacija donosi bolju generalizaciju, pouzdanije rezultate ili dublje razumevanje posmatranog ponašanja.

2.4 Tradicionalni modeli mašinskog učenja

Tradicionalni modeli mašinskog učenja imaju važnu ulogu u disertaciji jer predstavljaju referentnu osnovu za procenu stvarne koristi dubokog učenja, posebno u zadacima nad strukturalnim, tabularnim i tekstualno vektorizovanim podacima. U mnogim takvim zadacima jednostavniji modeli ostaju veoma konkurentni, uz bolji odnos između tačnosti, interpretabilnosti i računarske efikasnosti. Na primer, u ranijim analizama hotelskih recenzija TF-IDF reprezentacije u kombinaciji sa linearnim modelima pokazale su se kao jaka referentna osnova za predikciju ocena i klasifikaciju korisničkih stavova.

Njihova metodološka snaga posebno dolazi do izražaja kada omogućavaju jasnije razumevanje odnosa između ulaznih karakteristika i ciljnog ishoda, bez nepotrebnog povećanja složenosti modela. Zbog toga poređenje sa tradicionalnim modelima predstavlja važan kriterijum za proveru da li složeniji modeli zaista donose dodatnu empirijsku i domensku vrednost.

U kontekstu disertacije, tradicionalni modeli nisu predstavljeni kao prevaziđeni pristupi, već kao nužan deo metodološke kontrole. Ako napredna arhitektura ne nadmašuje jednostavniji model ili ne donosi jasnu interpretativnu ili domensku vrednost, njena upotreba mora biti kritički preispitana. Ovakav pristup direktno doprinosi originalnosti disertacije, jer se vrednost modela ne meri samo nivoom tehničke složenosti, već odnosom između zadatka, podataka, performansi, interpretabilnosti i primenljivosti.

2.4.1 Linearni i logistički modeli

Linearni modeli predstavljaju osnovu mnogih prediktivnih zadataka. Njihova osnovna pretpostavka jeste da se ciljni ishod može opisati kao zbir pojedinačnih doprinosa ulaznih promenljivih. Dakle, svaka karakteristika dobija svoj koeficijent, a predikcija se formira tako što se vrednosti karakteristika pomnože odgovarajućim koeficijentima i zatim sabere sa slobodnim članom modela. Zbog transparentnosti i stabilnosti rezultata, linearni modeli često služe kao referentna osnova za procenu složenijih prediktivnih pristupa. U regresiji se takav

odnos izražava kao linearna veza između ulaznih promenljivih i ciljnog ishoda:

$$\hat{y}_i = \beta_0 + \sum_{j=1}^p \beta_j x_{ij}, \quad (2.4)$$

gde je p broj karakteristika, β_j koeficijent za karakteristiku j , a β_0 slobodni član. Koeficijent β_j pokazuje očekivanu promenu predikcije kada se odgovarajuća karakteristika promeni za jednu jedinicu, uz pretpostavku da ostale karakteristike ostaju nepromenjene, što linearne modele čini interpretabilnim. Prednost linearnih modela ogleda se u jednostavnoj interpretaciji koeficijenata, ali je njihova slabost ograničena sposobnost modelovanja nelinearnih odnosa. Logistička regresija koristi se za binarnu ili višeklasnu klasifikaciju. U binarnom slučaju procenjuje se verovatnoća pripadnosti pozitivnoj klasi:

$$P(y_i = 1 \mid x_i) = \frac{1}{1 + e^{-(\beta_0 + \sum_{j=1}^p \beta_j x_{ij})}}. \quad (2.5)$$

U ovoj formulaciji linearna kombinacija ulaznih karakteristika transformiše se sigmoidnom funkcijom u vrednost između 0 i 1, pa se izlaz modela može tumačiti kao procenjena verovatnoća pripadnosti klasi. U disertaciji logistička regresija ima važnu ulogu kao referentni model u zadacima klasifikacije tekstualnih i strukturisanih podataka. Kada se kombinuje sa TF-IDF reprezentacijama, ona pruža jaku osnovu za poređenje sa neuralnim modelima.

2.4.2 SVM i Naive Bayes modeli

Support Vector Machine modeli se primenjuju u tekstualnoj klasifikaciji i višedimenzionalnim problemima. Njihova osnovna ideja je pronalaženje hiperravni koja maksimalno razdvaja klase. Za linearno separabilan slučaj, odluka modela može se predstaviti kao:

$$\hat{y}_i = \text{sign}(w^T x_i + b), \quad (2.6)$$

gde su w vektor težina, x_i ulazna instanca, a b slobodni član. Izraz $w^T x_i + b$ određuje položaj instance u odnosu na razdvajajuću hiperravan, dok funkcija sign prevodi taj položaj u klasnu odluku. Što je instanca udaljenija od hiperravni, to je odluka modela sigurnija, dok se granica odlučivanja određuje pre svega primerima koji se nalaze najbliže toj hiperravni, odnosno potpornim vektorima. Zbog toga su SVM modeli posebno korisni u problemima sa velikim brojem karakteristika, jer nastoje da pronađu granicu odlučivanja koja ne razdvaja samo trening primere, već obezbeđuje što veću marginu između klasa.

Naive Bayes modeli zasnivaju se na pretpostavci uslovne nezavisnosti karakteristika. Iako je ta pretpostavka često pojednostavljena, ovi modeli mogu biti efikasni u tekstualnoj klasifikaciji i kao početni referentni model. Njihova prednost je brzina i jednostavnost, dok je ograničenje slabija sposobnost modelovanja složenih interakcija između karakteristika.

2.4.3 Slučajne šume i gradijentno pojačavanje

Slučajne šume i gradijentno pojačavanje predstavljaju ansambl pristupe zasnovane na kombinovanju više slabijih modela u jači prediktivni sistem. Slučajna šuma gradi više stabala odlučivanja nad različitim poduzorcima podataka i karakteristika, čime se smanjuje zavisnost modela od jednog uzorka ili jedne kombinacije obeležja. Konačna predikcija se dobija agregacijom predikcija stabala. Kod regresije, agregacija se najčešće vrši prosekom:

$$\hat{y}_i = \frac{1}{T} \sum_{t=1}^T f_t(x_i), \quad (2.7)$$

gde je T broj stabala, a $f_t(x_i)$ predikcija pojedinačnog stabla za instancu x_i . Ova formula pokazuje da konačna vrednost nije rezultat jednog stabla odlučivanja, već prosečna procena celog ansambla. Time se ublažava uticaj pojedinačnih grešaka i smanjuje varijansa modela, što slučajne šume čini pogodnim za zadatke u kojima postoje šum, nelinearni odnosi i veliki broj ulaznih karakteristika. Slučajne šume prvenstveno smanjuju varijansu paralelnim učenjem većeg broja stabala, dok gradijentno pojačavanje gradi modele sekvencijalno, tako da svaki novi model koriguje greške prethodnih. Zbog toga se gradijentno pojačavanje može posmatrati kao aditivni ansambl u kojem se konačna predikcija formira postepenim dodavanjem slabijih modela, a njegov opšti oblik može se zapisati kao:

$$F_m(x) = F_{m-1}(x) + \eta h_m(x), \quad (2.8)$$

gde je F_m model u iteraciji m , F_{m-1} model iz prethodne iteracije, h_m novi slabiji model, a η stopa učenja. Ovaj izraz pokazuje da se konačni model gradi postepeno, dodavanjem novih komponenti koje koriguju prethodne greške. Parametar η kontroliše koliko snažno novi model utiče na postojeći ansambl, pa ima važnu ulogu u sprečavanju prekomernog prilagođavanja podacima. U disertaciji su ovakvi modeli posebno relevantni za strukturisane podatke, predikciju cena, procenu vrednosti korisnika, popularnost proizvoda i studentske ishode.

2.4.4 Uloga tradicionalnih modela kao referentnih pristupa

Tradicionalni modeli obezbeđuju referentnu tačku za procenu da li složenije arhitekture donose dodatnu prediktivnu, interpretativnu ili domensku vrednost. Kod tabularnih i strukturisanih podataka često ostaju važni jer omogućavaju jasnije poređenje obeležja i proveru doprinosa složenije arhitekture kvalitetu predikcije. Ako napredni model ne pokazuje jasnu prednost u odnosu na jednostavniji referentni pristup, njegov izbor treba obrazložiti kroz usklađenost sa tipom podataka, zahtevima zadatka i tumačenjem rezultata. Nasuprot tome, ako duboki model značajno nadmašuje tradicionalni model u tekstualnom ili sekvencijalnom zadatku, može se govoriti o stvarnoj dodatoj vrednosti arhitekture.

Radi jasnijeg poređenja, Tabela 2.2 prikazuje osnovne prednosti, ograničenja i uloge tradicionalnih i dubokih modela u kontekstu istraživačkih zadataka analiziranih u disertaciji.

Tabela 2.2: Poređenje tradicionalnih i dubokih modela u kontekstu disertacije.

Klasa modela	Prednosti	Ograničenja	Tipična uloga
Linearni modeli	Jednostavni, brzi, interpretabilni	Ograničeni za nelinearne odnose	Referentni pristup, objašnjiva regresija
SVM	Dobri za visoko dimenzionalne tekstualne podatke	Mogu biti zahtevni za velike skupove	Tekstualni referentni model
Random Forest	Otporan na šum, dobar za tabularne podatke	Manje efikasan za veoma visoke dimenzije teksta	Strukturisani podaci
Gradient Boosting	Visoka tačnost na tabularnim podacima	Potrebno podešavanje hiperparametara	Regresija i klasifikacija
LSTM/GRU	Modelovanje sekvenci i vremenskih zavisnosti	Zahtevniji trening, slabija interpretabilnost	Sekvencijalno ponašanje
Transformer modeli	Kontekstualno razumevanje teksta	Visoki resursi, potreba za pažljivom validacijom	NLP zadaci, pritužbe, recenzije

2.5 Pristrasnost i pravičnost u prediktivnim modelima

Pristrasnost predstavlja jedan od centralnih problema u razvoju prediktivnih modela za analizu ljudskog ponašanja. Pošto se modeli treniraju na podacima nastalim u realnim društvenim, poslovnim i institucionalnim kontekstima, postoji rizik da preuzmu i reprodukuju postojeće neravnoteže, stereotipe, nejednakosti ili sistematske greške. Pregledi pravičnosti u mašinskom učenju naglašavaju da se pristrasnost može pojaviti u različitim fazama životnog ciklusa modela: prikupljanju podataka, definisanju ciljne promenljive, anotaciji, preprocesiranju, izboru algoritma, evaluaciji i implementaciji [10].

U hotelijerstvu se pristrasnost može javiti kroz neravnomernu zastupljenost hotela, ocena ili tipova gostiju. U transportu se može javiti kroz različite uslove vožnje, tipove uređaja ili segmente putnika. U internet trgovini može biti povezana sa popularnošću brendova i vidljivošću proizvoda. U poslovnoj komunikaciji pristrasnost je posebno osetljiva jer modeli mogu pogrešno označiti izraze koji zavise od konteksta, ironije ili identiteta govornika. U obrazovanju se pristrasnost može javiti kroz institucionalne podatke, ocenjivanje, dostupnost resursa i razlike u načinu rada studenata.

2.5.1 Izvori pristrasnosti

Pristrasnost u prediktivnom modelovanju može nastati u različitim fazama istraživačkog procesa, od nastanka i merenja podataka do anotacije i primene modela. Zato se pristrasnost ne može posmatrati samo kao tehnički problem algoritma, već kao posledica odnosa između podataka, društvenog konteksta, domenskog značenja i odluka donetih tokom modelovanja.

U literaturi se najčešće razlikuje nekoliko izvora pristrasnosti. Istorijska pristrasnost (*historical bias*) nastaje kada podaci odražavaju već postojeće društvene, poslovne ili organizacione nejednakosti. Pristrasnost zastupljenosti (*representation bias*) javlja se kada određene grupe, klase ili situacije nisu dovoljno prisutne u skupu podataka. Pristrasnost merenja (*measurement bias*) nastaje kada dostupne promenljive samo posredno ili nepotpuno mere koncept koji se želi modelovati. Pristrasnost agregacije (*aggregation bias*) javlja se kada se različite grupe posmatraju kroz jedan zajednički model, iako za njih mogu važiti različiti obrasci ponašanja. Poseban značaj ima i pristrasnost anotacije (*annotation bias*), koja nastaje kada oznake u skupu podataka zavise od subjektivnih procena, iskustva ili pretpostavki anotatora. Tabela 2.3 prikazuje najvažnije izvore pristrasnosti i njihove primere u domenima disertacije.

Tabela 2.3: Izvori pristrasnosti i primeri u empirijskim domenima disertacije.

Tip pristrasnosti	Opis	Primer u disertaciji
Historical bias	Podaci odražavaju postojeće društvene ili poslovne nejednakosti	Diskriminatorni obrasci u digitalnoj komunikaciji
Representation bias	Neke klase ili grupe su nedovoljno zastupljene	Manji broj negativnih recenzija ili retkih pritužbi
Measurement bias	Promenljive ne mere direktno posmatrani koncept	Ocena hotela kao nepotpuna mera zadovoljstva gosta
Aggregation bias	Jedan model se koristi za grupe sa različitim obrascima	Jedinstveni model za različite segmente putnika ili studenata
Annotation bias	Oznake zavise od subjektivnosti anotatora	Obeležavanje mizoginog ili uvredljivog sadržaja

2.5.2 Neravnoteža klasa i posledice na evaluaciju

Neravnoteža klasa javlja se kada su neke klase znatno zastupljenije od drugih. U takvim situacijama ukupna tačnost može biti pogrešna mera kvaliteta modela. Na primer, ako je 90% instanci u dominantnoj klasi, model koji uvek predviđa dominantnu klasu može ostvariti visoku tačnost, ali neće imati stvarnu vrednost za prepoznavanje manjinske klase. Ovo je posebno važno u detekciji negativnih recenzija, mizoginog sadržaja, retkih pritužbi, rizične vožnje ili

neuspeha studenata. Zbog toga se kod neravnoteže klasa model ne procenjuje samo prema ukupnoj tačnosti, već prema sposobnosti da prepozna retke, ali domenski važne obrasce čije propuštanje može imati veće posledice od greške na dominantnoj klasi. Distribucija klasa može se izraziti kao:

$$p_c = \frac{n_c}{n}, \quad (2.9)$$

gde je n_c broj instanci klase c , a n ukupan broj instanci. Ovaj odnos pokazuje koliki udeo ukupnog skupa podataka pripada određenoj klasi, pa omogućava da se neravnoteža ne procenjuje samo opisno, već i kvantitativno. Visoka neravnoteža postoji kada je razlika između najveće i najmanje vrednosti p_c značajna. Zato odnos dominantne i manjinske klase dodatno pokazuje koliko ukupna tačnost može biti varljiva u neuravnoteženom skupu podataka. Za skupove podataka sa neravnotežom klasa značajne su metrike poput makro F1, ponderisani F1, odziv manjinske klase i AUC. Makro F1 računa prosečnu F1 meru po klasama:

$$Macro\ F1 = \frac{1}{C} \sum_{c=1}^C F1_c, \quad (2.10)$$

gde je C broj klasa, a $F1_c$ F1 mera za klasu c . Ova metrika je korisna zato što svim klasama daje jednaku težinu, bez obzira na njihovu zastupljenost. Zbog toga makro F1 jasnije pokazuje da li model zaista prepoznaje i manjinske klase, umesto da visoku ukupnu performansu ostvaruje uglavnom na dominantnoj klasi.

2.5.3 Metrike pravičnosti

Pravičnost modela može se posmatrati kroz različite metrike. Jedna od osnovnih metrika je demografska paritetnost, koja zahteva da verovatnoća pozitivne predikcije bude približno jednaka za različite grupe:

$$P(\hat{Y} = 1 \mid A = a) \approx P(\hat{Y} = 1 \mid A = b), \quad (2.11)$$

gde je A osetljivo obeležje ili grupa, a a i b dve grupe koje se porede. Znak $\approx$ ne označava potpunu jednakost, već prihvatljivo malo odstupanje između grupa, koje se u empirijskoj analizi procenjuje u odnosu na domen, posledice odluke i istraživački cilj. Druga metrika je jednakost mogućnosti, koja zahteva da stopa tačno pozitivnih predikcija bude približno jednaka po grupama:

$$P(\hat{Y} = 1 \mid Y = 1, A = a) \approx P(\hat{Y} = 1 \mid Y = 1, A = b). \quad (2.12)$$

Ova metrika proverava da li model uspešno prepoznaje pozitivne slučajeve u različitim grupama, odnosno da li neka grupa ima veći rizik da stvarno pozitivan slučaj bude propušten.

Treća relevantna metrika je prediktivna jednakost, koja se odnosi na sličnu stopu lažno pozitivnih odluka po grupama:

$$P(\hat{Y} = 1 \mid Y = 0, A = a) \approx P(\hat{Y} = 1 \mid Y = 0, A = b). \quad (2.13)$$

Ova metrika je posebno značajna u situacijama u kojima pogrešna pozitivna odluka može dovesti do neopravdanog favorizovanja ili opterećivanja određene grupe.

2.5.4 Pristrasnost u jeziku i tekstualnim modelima

Tekstualni modeli posebno su osetljivi na pristrasnost jer jezik odražava društvene norme, stereotipe, moć i kontekst. Modeli trenirani na velikim tekstualnim korpusima mogu naučiti asocijacije koje nisu neutralne, već reprodukuju obrasce iz podataka. U analizi uvredljivog, agresivnog ili diskriminatornog jezika potrebno je voditi računa o tome da model ne poistoveti identitetske termine sa toksičnošću i da ne kažnjava legitimni govor o diskriminaciji. Krićka literatura o jezićkim tehnologijama naglašava da se modeli moraju posmatrati kroz odnos između podataka, društvenog konteksta i posledica automatizovane klasifikacije [11].

Ovaj problem je direktno relevantan za poglavlje o društveno odgovornoj poslovnoj komunikaciji. Detekcija mizoginog ili rodno pristrasnog jezika ne sme biti posmatrana kao neutralna tehnića klasifikacija. Ona zahteva razumevanje konteksta, jasnu definiciju kategorija, analizu grešaka i ukljućenost stručne kontrole.

2.5.5 Strategije smanjenja pristrasnosti

Strategije smanjenja pristrasnosti mogu se grupisati prema trenutku u kojem se primenjuju u životnom ciklusu modela: pre obuke modela (*pre-processing*), tokom obuke (*in-processing*) i nakon obuke (*post-processing*). Metode pre obuke odnose se na intervencije nad podacima pre nego što model počne da ući, kao što su balansiranje podataka, uklanjanje ili korekcija problematićnih instanci, promena težina primera (*reweighting*) i dizajn uzorka. Cilj je da model ne ući iz podataka koji sadrže izraženu neravnotežu ili favorizovanje odrećdenih grupa. Metode tokom obuke menjaju proces ućenja modela, na primer kroz funkcije gubitka prilagoćdene neravnoteži, regularizaciju ili suparnićko smanjenje pristrasnosti (*adversarial debiasing*), pri ćemu se model usmerava da zadrži prediktivnu taćnost i smanji oslanjanje na neželjene obrasce. Metode nakon obuke primenjuju se na već treniran model i obuhvataju kalibraciju (usklaćdivanje procenjenih verovatnoća), promenu praga odlućivanja (*threshold adjustment*), segmentnu evaluaciju i naknadne korekcije rezultata (*post-hoc correction*).

Tabela 2.4 povezuje strategije smanjenja pristrasnosti sa fazama razvoja prediktivnog modela i empirijskim zadacima analiziranim u disertaciji. Pristrasnost se pritom ne posmatra kao problem koji se moće potpuno ukloniti jednim tehnićkim postupkom, već kao stalni rizik koji zahteva paćljiv dizajn podataka, odgovarajuće metrike i stručnu kontrolu.

Tabela 2.4: Strategije za smanjenje pristrasnosti u prediktivnim modelima.

Faza	Primeri metoda	Primena u disertaciji
Pre obuke	Balansiranje, undersampling, oversampling, reweighting, čišćenje podataka	Negativne recenzije, manjinske klase pritužbi, osetljivi komunikacioni obrasci
Tokom obuke	Class weights, focal loss, regularizacija, adversarial pristupi	Klasifikacija neuravnoteženih tekstualnih i sekvencijalnih podataka
Nakon obuke	Kalibracija, pragovi odlučivanja, segmentna evaluacija, analiza grešaka	Procena lažno pozitivnih i lažno negativnih ishoda

2.6 Interpretabilnost modela i objašnjiva veštačka inteligencija

Interpretabilnost predstavlja sposobnost da se rezultat modela razume, objasni i poveže sa relevantnim faktorima u domenu primene. U kontekstu ove disertacije, interpretabilnost je ključna zato što se modeli razvijaju radi tehničkog predviđanja kao i podrške odlučivanju u hotelijerstvu, transportu, trgovini, poslovnoj komunikaciji, održivom razvoju i obrazovanju. Posebno je važna kod procene iskustva, rizika, osetljivog sadržaja i podrške odlučivanju.

Objašnjiva veštačka inteligencija obuhvata metode koje omogućavaju uvid u to kako model koristi ulazne karakteristike i zašto proizvodi određenu predikciju. SHAP pristup, zasnovan na Šeplijevim vrednostima, postao je jedan od najčešće korišćenih okvira za objašnjavanje modela jer omogućava lokalnu i globalnu interpretaciju doprinosa karakteristika [12]. Interpretabilnost u ovoj disertaciji ne predstavlja samo dodatak nakon evaluacije, već metodološku vezu između prediktivne tačnosti, domenskog tumačenja i odgovorne primene modela. Na taj način se rezultati modela ne posmatraju samo kroz metrike performansi, već i kroz pitanje da li se mogu pretvoriti u razumljive, proverljive i domenski korisne zaključke.

2.6.1 Strukturno interpretabilni i post-hoc objašnjivi modeli

Modeli se prema interpretabilnosti mogu podeliti na strukturno interpretabilne i post-hoc objašnjive. Strukturno interpretabilni modeli, kao što su linearni modeli, stabla odlučivanja i pravila, imaju unutrašnju formu koju korisnik može relativno lako razumeti. Kod takvih modela način donošenja odluke neposredno je povezan sa koeficijentima, grananjem stabla ili skupom pravila. Njihova prednost je u tome što se objašnjenje dobija iz same strukture modela, bez potrebe za dodatnim metodama naknadnog tumačenja. Post-hoc metode koriste se za objašnjavanje složenijih modela nakon obuke, uključujući ansambl modele i duboke neuronske mreže. Tada objašnjenje ne zamenjuje model, već služi kao dodatni analitički sloj koji pomaže da se predikcija poveže sa ulaznim karakteristikama i domenskim značenjem.

Tabela 2.5 prikazuje pregled metoda interpretabilnosti koje su relevantne za disertaciju, sa naglaskom na tip objašnjenja koji pružaju i njihovu moguću primenu u analiziranim empirijskim domenima.

Tabela 2.5: Pregled metoda interpretabilnosti relevantnih za disertaciju.

Metoda	Tip objašnjenja	Relevantnost za disertaciju
Koeficijenti linearnih modela	Globalno objašnjenje	Tumačenje uticaja karakteristika u referentnim modelima
Važnost karakteristika	Globalno objašnjenje	Random Forest, XGBoost, tabularni zadaci
SHAP	Lokalno i globalno objašnjenje	Hoteli, CLV, cene, popularnost proizvoda, studentski ishodi
LIME	Lokalno objašnjenje	Tekstualni modeli, pojedinačne recenzije i komentari
Attention vizuelizacija	Analiza fokusa modela	Transformer i sekvencijalni modeli
Analiza grešaka	Kvalitativno i kvantitativno objašnjenje	Svi društveno i poslovno osetljivi zadaci

2.6.2 Lokalna i globalna objašnjenja

Globalna objašnjenja pokušavaju da objasne opšte ponašanje modela. Ona odgovaraju na pitanje koje karakteristike model najčešće koristi i kako one utiču na predikcije. Lokalna objašnjenja odnose se na pojedinačnu instancu i odgovaraju na pitanje zašto je model za konkretan primer dao određeni rezultat.

Kod modela za analizu ljudskog ponašanja potrebna su oba nivoa. Globalno objašnjenje može pokazati da su određeni aspekti recenzija, ponašanja vozača ili studentskih aktivnosti najvažniji za model. Lokalno objašnjenje može pomoći da se razume pojedinačna greška ili pojedinačna odluka modela. Ovo je posebno važno u zadacima gde se rezultat koristi za intervenciju, upozorenje ili menadžersku odluku. Opšti oblik aditivnog objašnjenja može se zapisati kao:

$$g(z') = \phi_0 + \sum_{j=1}^M \phi_j z'_j, \quad (2.14)$$

gde je g objašnjavajući model, ϕ_0 osnovna vrednost, ϕ_j doprinos karakteristike j , a z'_j indikator prisustva karakteristike u pojednostavljenom prostoru objašnjenja. Dakle, svaka karakteristika utiče na predikciju preko pojedinačnog člana, dok osnovna vrednost predstavlja početnu procenu modela. Ova formulacija pokazuje da se složena predikcija može aproksimirati

zbirnom strukturom u kojoj se polazna vrednost modela koriguje pojedinačnim doprinosima karakteristika, što omogućava da se predikcija razloži na razumljive komponente.

2.6.3 Interpretabilnost u tekstualnim modelima

Kod tekstualnih modela interpretabilnost ima dodatnu složenost. Nije dovoljno znati da je određena karakteristika važna, već je potrebno razumeti koji izrazi, fraze ili delovi teksta utiču na rezultat. U hotelijerstvu, to može značiti identifikaciju fraza koje ukazuju na higijenu, lokaciju, osoblje ili buku. U parfemskoj industriji to može biti prepoznavanje emocionalnih izraza povezanih sa mirisnim notama. U poslovnoj komunikaciji to može biti identifikacija izraza koji ukazuju na diskriminaciju ili omalovažavanje. U obrazovanju to može biti prepoznavanje obrazaca koji ukazuju na površno razumevanje ili generisani tekst.


Zbog toga se u disertaciji interpretabilnost tekstualnih modela ne tretira samo kroz vizualizaciju tokena, već kroz povezivanje tokena sa domenskim kategorijama. Rezultat modela postaje koristan tek kada se može prevesti u oblik koji stručnjak u datom domenu može razumeti i proveriti. Drugim rečima, objašnjenje tekstualnog modela nema punu vrednost ako pokazuje samo koje su reči bile važne, već tek kada otkrije zašto su te reči značajne u konkretnom domenu i odluci koju model podržava.

2.6.4 Dokumentovanje podataka kao deo interpretabilnosti

Interpretabilnost ne zavisi samo od modela, već i od transparentnosti podataka. Ako nije jasno kako je skup podataka nastao, koje instance sadrži, ko je označio podatke, koje su grupe zastupljene i koja su ograničenja, onda je i tumačenje modela ograničeno. Koncept datasheets for datasets naglašava potrebu da se skupovi podataka dokumentuju kroz poreklo, namenu, strukturu, procedure prikupljanja, potencijalne rizike i preporučene načine upotrebe [13]. Takva dokumentacija omogućava da se objašnjenja modela ne tumače izolovano, već u odnosu na poreklo podataka, način označavanja, sastav uzorka i ograničenja skupa podataka. Time se interpretabilnost proširuje sa nivoa pojedinačne predikcije na nivo celog istraživačkog procesa, jer postaje jasno pod kojim uslovima se rezultati modela mogu smatrati pouzdanim i domenski primenljivim.

U ovoj disertaciji dokumentovanje podataka važno je zato što se koristi više različitih domena. Svaki skup podataka mora biti opisan prema izvoru, periodu, tipu podataka, ciljnim promenljivama, postupcima čišćenja, etičkim ograničenjima i načinu podele na trening, validacioni i test skup.

Slika 2.1 naglašava da interpretabilnost nije izolovana tehnika, već proces koji počinje dokumentovanjem podataka i završava stručnom proverom rezultata. Prikazani tok naglašava da interpretabilnost ne nastaje tek u fazi objašnjenja modela, već kroz celokupan postupak izbora podataka, evaluacije rezultata i njihove stručne validacije.



Slika 2.1: Interpretabilnost kao veza između podataka, modela i stručne validacije.

2.7 Multimodalno učenje i integracija heterogenih izvora

Multimodalno učenje predstavlja pristup u kojem model koristi više izvora ili tipova podataka za donošenje predikcije. U kontekstu ljudskog ponašanja, multimodalnost je posebno važna zato što se ponašanje retko može objasniti samo jednim signalom. Hotelsko zadovoljstvo zavisi od teksta recenzije, numeričke ocene, tipa putovanja, vremena boravka i karakteristika hotela. Potrošački doživljaj parfema zavisi od mirisnih nota, brenda, tržišnih atributa i tekstualnih emocija. Ponašanje vozača zavisi od senzorskih očitavanja, okruženja i vremenskog konteksta. Studentski ishod zavisi od bodova, aktivnosti, teksta odgovora i prethodnog uspeha. Zbog toga multimodalno učenje omogućava da se različiti aspekti ponašanja ne analiziraju izolovano, već kao međusobno povezani izvori signala koji zajedno oblikuju prediktivni ishod. Multimodalni model može se opšte zapisati kao:

$$\hat{y}_i = f_{\theta}(x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)}), \quad (2.15)$$

gde $x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(m)}$ predstavljaju različite modalitete instance i . Cilj je da model nauči zajedničku reprezentaciju koja kombinuje informacije iz više izvora. Ova formulacija pokazuje da predikcija ne zavisi od jednog ulaza, već od funkcije koja istovremeno obrađuje više heterogenih reprezentacija i uči njihove međusobne odnose. Zato je multimodalno učenje posebno važno u zadacima u kojima se ponašanje korisnika formira kroz istovremeno delovanje tekstualnih, numeričkih i kontekstualnih signala.

2.7.1 Strategije fuzije podataka

U literaturi se najčešće razlikuju tri strategije fuzije: rana fuzija, kasna fuzija i hibridna fuzija. Rana fuzija podrazumeva spajanje karakteristika pre modelovanja. Kasna fuzija podrazumeva da se za svaki modalitet trenira poseban model, a zatim se kombinuju njihove predikcije. Hibridna fuzija kombinuje ova dva pristupa i može uključiti neuronske mehanizme pažnje ili adaptivnog ponderisanja modaliteta.

Kod rane fuzije, zajednički vektor može se zapisati kao:

$$z_i = [\phi_1(x_i^{(1)}), \phi_2(x_i^{(2)}), \dots, \phi_m(x_i^{(m)})], \quad (2.16)$$

gde ϕ_j označava funkciju reprezentacije modaliteta j , a $[\cdot]$ označava konkatenciju. Svaki modalitet se najpre transformiše u odgovarajući reprezentacioni prostor, a zatim se dobijene reprezentacije spajaju u jedan zajednički vektor z_i koji se koristi kao ulaz u model. Važno je da reprezentacije različitih modaliteta budu usklađene po skali i dimenzionalnosti, jer u suprotnom modalitet sa većim brojem karakteristika može nesrazmerno uticati na učenje modela. Kod kasne fuzije, konačna predikcija može se dobiti kombinovanjem predikcija pojedinačnih modela:

$$\hat{y}_i = \sum_{j=1}^m \alpha_j f_j(x_i^{(j)}), \quad (2.17)$$

gde je α_j težina modaliteta j , a f_j model specifičan za taj modalitet. Ova formula pokazuje da se svaki modalitet može modelovati zasebno, dok se konačna odluka formira ponderisanjem njihovih pojedinačnih doprinosa. Težine α_j mogu se posmatrati kao mera relativnog značaja ili pouzdanosti modaliteta, pri čemu veća vrednost težine znači da odgovarajući modalitet ima veći uticaj na konačnu predikciju. Takav pristup je koristan kada modaliteti imaju različitu strukturu, različit nivo pouzdanosti ili različitu prediktivnu snagu. Na taj način fuzija podataka nije samo tehničko spajanje izvora, već mehanizam za izgradnju bogatije reprezentacije ponašanja.

Tabela 2.6 prikazuje osnovne strategije multimodalne fuzije, njihove prednosti, ograničenja i značaj za integraciju heterogenih izvora podataka u prediktivnim zadacima analiziranim u disertaciji.

Tabela 2.6: Strategije multimodalne fuzije podataka.

Strategija	Opis	Prednosti i ograničenja
Rana fuzija	Spajanje karakteristika pre obuke modela	Jednostavna implementacija; može zanemariti specifičnost modaliteta
Kasna fuzija	Kombinovanje predikcija odvojenih modela	Fleksibilna za različite modalitete; teže hvata interakcije na nivou karakteristika
Hibridna fuzija	Kombinovanje reprezentacija i predikcija kroz složenije arhitekture	Omogućava modelovanje interakcija; zahteva više podataka i pažljivu validaciju
Attention fuzija	Dinamičko ponderisanje modaliteta po instanci	Može povećati interpretabilnost; složenija implementacija

2.7.2 Multimodalnost u empirijskim domenima disertacije

U hotelijerstvu, multimodalnost se javlja kroz kombinaciju tekstualnih recenzija, numeričkih ocena, metapodataka o gostu i karakteristika hotela. U transportu se javlja kroz kombinaciju senzorskih podataka, vremenskih karakteristika i konteksta puta ili leta. U internet trgovini i parfemskoj industriji javlja se kroz kombinaciju tekstualnih recenzija, mirisnih nota, brenda, cene i popularnosti. U obrazovanju se javlja kroz kombinaciju studentskih radova, ocena, aktivnosti i administrativnih podataka. U svim ovim domenima multimodalnost omogućava da se ponašanje korisnika posmatra kao rezultat više istovremenih signala, pri čemu svaki modalitet može otkriti drugačiji sloj informacije: tekstualni, numerički, vremenski, kontekstualni ili tržišni. Zbog toga se vrednost multimodalnog pristupa ne ogleda samo u spajanju različitih izvora podataka, već u proveru da li se između modaliteta javlja komplementarnost koja modelu omogućava potpunije razumevanje ponašanja.

Ovakav pristup povezuje multimodalnost sa osnovnom metodološkom idejom disertacije: procenom dodatne vrednosti modela u odnosu na složenost podataka, interpretaciju rezultata, opravdanost primene i mogućnost da se iz heterogenih izvora izvedu pouzdaniji uvidi o ponašanju korisnika.

Najvažnije pitanje nije samo da li multimodalni model daje bolju tačnost, već da li dodatni modaliteti daju novo značenje. Ako tekstualni podaci već objašnjavaju većinu varijanse, dodavanje numeričkih karakteristika može imati ograničen efekat. Ako, međutim, različiti modaliteti obuhvataju različite aspekte ponašanja, njihova integracija može značajno poboljšati predikciju i interpretaciju.

2.8 Održivo mašinsko učenje i green AI

Razvoj velikih modela veštačke inteligencije otvorio je pitanje računarskih, energetskih i ekoloških troškova treniranja i primene modela. U kontekstu ove disertacije, održivost nije centralni metodološki kriterijum za sve eksperimente, ali predstavlja važan deo odgovorne primene prediktivnih modela. Ako se složeni modeli koriste bez jasne potrebe, oni mogu povećati troškove i potrošnju resursa bez proporcionalnog poboljšanja rezultata.

Koncept *Green AI* naglašava potrebu da se u istraživanjima mašinskog učenja, pored tačnosti, razmatraju i efikasnost, potrošnja računarskih resursa i odnos između performansi i resursa [14]. Autori ovaj pristup suprotstavljaju logici takozvanog *Red AI*, u kojoj se napredak modela često meri malim povećanjem tačnosti, bez dovoljnog uvida u cenu tog poboljšanja u pogledu računarskog vremena, hardvera i energije. Zbog toga održivo mašinsko učenje ne podrazumeva odustajanje od složenih modela, već pažljivo procenjivanje da li dodatna performansa opravdava veću složenost i potrošnju resursa. Ovaj princip je posebno važan kada se tradicionalni modeli porede sa dubokim arhitekturama, jer model koji ostvaruje sličan rezultat uz manju računarsku zahtevnost može biti primereniji izbor u praktičnoj primeni.

2.8.1 Računarska zahtevnost modelovanja

Potrošnja računarskih resursa zavisi od veličine skupa podataka, broja parametara, broja epoha, složenosti arhitekture, dimenzije ulaza i dostupnog hardvera. U pojednostavljenom obliku, ukupni trošak treninga može se posmatrati kroz broj operacija i vreme izvršavanja:

$$Cost(M) = T_{train}(M) \cdot R(M), \quad (2.18)$$

gde je $T_{train}(M)$ vreme treninga modela M , a $R(M)$ prosečna potrošnja resursa po jedinici vremena. Ova jednačina je konceptualna i ne predstavlja jedinstvenu meru za sve eksperimente, ali pokazuje da se efikasnost modela mora posmatrati zajedno sa performansama.

Ovakav pristup omogućava da se modeli ne porede samo prema krajnjoj performansu, već i prema odnosu između postignutog poboljšanja, vremena treniranja, potrošnje resursa i mogućnosti ponovne primene u realnom sistemu.

2.8.2 Održivost kao kriterijum izbora modela

U disertaciji se održivost povezuje sa principom proporcionalnosti. Složeniji model ima smisla ako donosi jasno poboljšanje performansi, interpretabilnosti ili domenske koristi. Ako takvo poboljšanje ne postoji, jednostavniji model može biti odgovorniji izbor. Drugim rečima, izbor modela treba da bude zasnovan na ravnoteži između prediktivne koristi, objašnjivosti, troškova implementacije i dugoročne održivosti sistema. Ovaj princip posebno je važan u industrijskoj primeni, gde se modeli ne treniraju samo jednom, već se periodično ažuriraju, prate i koriste u realnom vremenu.

Tabela 2.7 prikazuje kako se održivost može uključiti u evaluaciju modela kroz povezivanje tačnosti, interpretabilnosti, potrošnje računarskih resursa, skalabilnosti i složenosti.

Tabela 2.7: Održivost kao dodatni kriterijum evaluacije modela.

Kriterijum	Pitanje	Primer u disertaciji
Tačnost	Da li model daje bolje predikcije?	Transformer naspram TF-IDF referentnog modela
Interpretabilnost	Da li se rezultat može objasniti?	SHAP analiza ansambl modela
Računarska zahtevnost	Koliko resursa zahteva trening i primena?	Poređenje XGBoost i dubokih arhitektura
Skalabilnost	Može li se model koristiti u realnom sistemu?	Analiza recenzija u hotelskom menadžmentu
Održiva opravdanost	Da li dodatna složenost donosi dovoljnu korist?	Izbor modela za poslovnu implementaciju

2.8.3 Veza sa održivim razvojem i softverskom implementacijom

Održivo mašinsko učenje povezano je i sa kvalitetom softverske implementacije, jer se računarska zahtevnost modela ne određuje samo izborom algoritma, već i načinom na koji je ceo eksperimentalni proces projektovan i sproveden. Efikasno pretprocesiranje, izbegavanje nepotrebnog ponavljanja eksperimenata, dokumentovanje hiperparametara, korišćenje odgovarajućih veličina modela i optimizacija koda mogu smanjiti troškove, povećati reproducibilnost i olakšati kasniju primenu modela u realnom sistemu.

U tom smislu, održivost se ne odnosi samo na energetske potrošnje, već i na istraživačku disciplinu, transparentnost postupka i sposobnost da se eksperiment ponovi, proveriti i unapredi bez nepotrebnog trošenja resursa. U poglavlju o održivom razvoju i projektnom odlučivanju ova tema se dodatno proširuje kroz green coding principe, analitičko izveštavanje i vezu između softverskih odluka, resursne efikasnosti i poslovne primenljivosti.

2.9 Pregled domenski relevantne literature

Nakon razmatranja opštih metodoloških osnova prediktivnog modelovanja, dubokog učenja, interpretabilnosti, multimodalnosti i odgovorne primene modela, potrebno je pozicionirati empirijske domene disertacije u odnosu na relevantnu literaturu. Izabrani domeni nisu posmatrani kao odvojene istraživačke celine, već kao različiti prostori u kojima se proverava ista metodološka logika: kako se iz složenih digitalnih tragova ponašanja mogu razviti tačni, objašnjivi i primenljivi prediktivni modeli.

Cilj ovog odeljka jeste da pokaže zašto su hotelijerstvo, transport, internet trgovina, poslovna komunikacija, održivi razvoj i obrazovanje metodološki relevantni za istraživanje obrazaca ljudskog ponašanja. Svaki od ovih domena uvodi drugačiji tip podataka, drugačiji prediktivni zadatak i drugačiji oblik interpretacije rezultata, čime se omogućava šira evaluacija modela u realnim poslovnim i društvenim kontekstima.

2.9.1 Turizam i hotelijerstvo

Turizam i hotelijerstvo predstavljaju jedan od najvažnijih domena za analizu korisničkog ponašanja jer digitalne platforme generišu velike količine podataka o zadovoljstvu, iskustvu, pritužbama i lojalnosti gostiju. Sistematski pregledi primene veštačke inteligencije u hotelijerstvu i turizmu pokazuju da se AI metode koriste za predikciju potražnje, analizu zadovoljstva, segmentaciju korisnika, preporučivanje, modelovanje ponašanja turista i upravljanje iskustvom gostiju [15]. Poseban značaj ovih pregleda ogleda se u tome što AI ne posmatraju samo kao skup izolovanih algoritama, već kao deo šireg sistema prikupljanja, obrade i modelovanja podataka koji može podržati operativne, marketinške i menadžerske odluke u turizmu. Novija istraživanja dodatno ukazuju da se pravci razvoja pomeraju ka ob-

jašnjivim, strateški primenljivim i održivim AI sistemima u turizmu i hotelijerstvu [16]. Time se otvara prostor za istraživanja koja ne mere samo prediktivnu tačnost modela, već i njihovu upotrebljivost, transparentnost i opravdanost u realnim uslužnim sistemima.

Tekstualna klasifikacija u turizmu i hotelijerstvu posebno je relevantna za ovu disertaciju zato što online recenzije sadrže kontekstualne, emocionalne i aspektne signale korisničkog iskustva. Savremena literatura pokazuje da se duboko učenje i transformer arhitekture sve intenzivnije koriste za klasifikaciju turističkih tekstova, analizu sentimenta i razumevanje pritužbi korisnika [17]. U tom kontekstu, tekstualna klasifikacija nije samo tehnički zadatak dodeljivanja oznake tekstu, već način da se iz nestrukturisanog korisničkog sadržaja izdvoje obrasci zadovoljstva, nezadovoljstva, očekivanja i percipiranog kvaliteta usluge. Pregledi ove oblasti zato ukazuju na značaj pažljivog izbora modela, kvalitetnih podataka, jasne evaluacije i poređenja arhitektura u skladu sa specifičnostima turističkog teksta.

Pored toga, novija poređenja BERT, GPT i drugih NLP pristupa u analizi turističkih recenzija potvrđuju potrebu za kontrolisanim empirijskim poređenjem modela, umesto oslanjanja na pretpostavku da je najnoviji model uvek i metodološki najopravdaniji [18]. U radu Roumeliotis i saradnika posebno je značajno to što se hotelske recenzije koriste za predikciju zvezdica na osnovu tekstualnog sadržaja, pri čemu se prednost GPT-4 Omni modela nad BERT pristupom razmatra zajedno sa pitanjem kontekstualnog razumevanja, fine-tuninga, few-shot učenja, vremena treniranja i troškova obrade.

U disertaciji hotelijerstvo ima centralnu ulogu zato što omogućava razvoj kompletnog lanca analize: od kvaliteta i pouzdanosti recenzija, preko sentimenta i pritužbi, do predikcije ocena, multimodalnog zadovoljstva i procene dugoročne vrednosti korisnika.

2.9.2 Transportni sistemi

Transportni sistemi predstavljaju domen u kojem se ljudsko ponašanje može analizirati kroz sigurnosne, vremenske, tržišne i organizacione obrasce. Za razliku od hotelijerstva, gde se ponašanje korisnika najčešće izražava kroz tekstualne recenzije i ocene, transportni domen uvodi podatke koji nastaju kroz kretanje, senzore, cene, rasporede i uslove putovanja.

U kopnenom saobraćaju posebno je razvijena literatura o detekciji ponašanja vozača na osnovu senzorskih i vremenskih podataka. Istraživanja pokazuju da se agresivno ili rizično ponašanje može modelovati pomoću podataka o brzini, ubrzanju, kočenju, promenama pravca, GPS signalu, uslovima puta i vremenskom kontekstu. Ben Brahim i saradnici razmatraju klasifikaciju ponašanja vozača pomoću smartphone senzora, kao što su akcelerometar, žiroskop i GPS, pri čemu se podaci tretiraju kao vremenske serije i porede različiti algoritmi za klasifikaciju ponašanja [19]. Slično tome, Talebloo i saradnici koriste RNN, GRU i LSTM arhitekture za detekciju agresivne vožnje, naglašavajući značaj sekvencijalnog modelovanja i činjenicu da se obrazac vožnje ne može pouzdano proceniti iz jedne izolovane tačke, već iz niza vremenski povezanih signala [20].

U avio-saobraćaju literatura se razvija u pravcu predikcije potražnje, cena karata, zadovoljstva putnika, povezanosti letova i optimizacije operativnih odluka. Sistematski pregled Zachariah i saradnika pokazuje da je predikcija putničke potražnje u avio-industriji složen zadatak, jer na nju utiču sezonalnost, ekonomski faktori, mrežna povezanost, cene, kvalitet usluge i spoljašnji poremećaji [21]. U oblasti cena karata, Korkmaz analizira primenu mašinskog učenja za predikciju cena avionskih karata i poredi više algoritama kroz standardne regresione metrike, naglašavajući da se cene formiraju pod uticajem potražnje, sezonskih varijacija i konkurentskih strategija [22]. Dodatno, Wong i saradnici koriste veliki skup podataka o cenama letova i Spark ML modele, čime se pitanje predikcije cena povezuje sa skalabilnošću, vremenom obrade i mogućnošću primene u realnim sistemima [23].

Posebno važan pravac za ovu disertaciju jeste objašnjivo modelovanje u avio-saobraćaju. Guimaraes i saradnici razvijaju modele za predikciju propuštenih konekcija putnika na aerodromskom čvorištu, koristeći heterogene, neuravnotežene i šumovite podatke, a rezultate objašnjavaju pomoću SHAP vrednosti [24]. Ovakav pristup je relevantan zato što pokazuje da u transportu nije dovoljno samo predvideti ishod, već je potrebno razumeti koji faktori doprinose riziku, kao što su vreme konekcije, karakteristike putnika i operativni uslovi.

U kontekstu ove disertacije, transport ima posebnu vrednost jer povezuje dva tipa problema. Prvi je sigurnosni problem, gde pogrešna klasifikacija agresivne ili rizične vožnje može imati ozbiljne posledice. Drugi je poslovni problem, gde se cene karata, raspored letova, potražnja, povezanost ruta i zadovoljstvo putnika analiziraju kao obrasci ponašanja sistema. Zbog toga transportni domen doprinosi proveriti hipoteza o sekvencijalnom modelovanju, radu sa vremenskim i tržišnim podacima, segmentnoj pouzdanosti i interpretabilnosti rezultata.

2.9.3 Internet trgovina i parfemska industrija

Internet trgovina predstavlja domen u kojem potrošačko ponašanje ostavlja bogate digitalne tragove kroz ocene, recenzije, pretrage, rangiranja, komentare, liste želja i reakcije na proizvode. Zbog toga e-commerce podaci omogućavaju analizu preferencija, percepcije kvaliteta, zadovoljstva, popularnosti proizvoda i emocionalnih reakcija potrošača.

Parfemska industrija je posebno pogodna za ovu disertaciju zato što parfemi predstavljaju proizvode čija se vrednost ne formira samo na osnovu funkcionalnih karakteristika, već kroz lični doživljaj, emocije, identitet, mirisne note, brend i društveni kontekst. Za razliku od proizvoda kod kojih se kvalitet može lakše povezati sa objektivnim tehničkim karakteristikama, kod parfema važnu ulogu imaju subjektivna percepcija, sećanje, asocijacije i način na koji korisnici jezički opisuju mirisno iskustvo.

U literaturi o e-commerce recenzijama posebno su zastupljeni modeli za sentiment analizu, predikciju ocena i razumevanje odnosa između korisničkog teksta i tržišne vrednosti proizvoda. Liu i saradnici pokazuju da se kombinovanjem BERT reprezentacija i BiGRU arhitekture može modelovati sentiment u recenzijama proizvoda, čime se naglašava značaj

kontekstualnog razumevanja teksta u digitalnoj trgovini [25]. Balakrishnan i saradnici analiziraju predikciju sentimenta i ocena proizvoda pomoću dubokog učenja, čime potvrđuju da recenzije mogu služiti i za klasifikaciju stava i za procenu potrošačkog iskustva [26]. Dodatno, Amirifar i saradnici povezuju online recenzije i karakteristike proizvoda u NLP pristup zasnovan na dubokom učenju za predikciju ocena, čime se potvrđuje značaj integracije tekstualnih i atributskih podataka u modelovanju potrošačkog ponašanja [27].

Klasterizacija omogućava da se proizvodi organizuju prema sličnosti mirisnih nota, tekstualnih opisa ili tržišnih karakteristika. Savremeni pregledi algoritama za klasterovanje pokazuju da grupisanje ostaje važan alat za otkrivanje strukture u visokodimenzionalnim podacima. K-means i njegove varijante posebno su korisni kao osnova za segmentaciju proizvoda kada su parfemi predstavljeni numeričkim vektorima nota, recenzija ili tržišnih atributa [28].

Specifičnost parfemske industrije dodatno se ogleda u tome što se mirisni proizvodi mogu analizirati i kroz odnos između sastava, perceptivnih oznaka i korisničkog doživljaja. Novija istraživanja mašinskog učenja u oblasti mirisa pokazuju da se olfaktorne osobine mogu modelovati pomoću reprezentacija molekularne strukture i deskriptora mirisa, što potvrđuje da parfemski domen ima i hemijski, senzorski i tržišni sloj podataka [29].

Za disertaciju, parfemska industrija ima metodološku vrednost jer uvodi emocionalno bogatije podatke od prethodnih domena. Time se proverava da li prediktivni modeli mogu objasniti ponašanje korisnika kada su kategorije semantički fleksibilnije, značenja složenija, a granice između klasa manje jasne. Ovaj domen je zato važan za proveru modela koji kombinuju tekstualne i tržišne signale i koriste latentne reprezentacije za objašnjivu analizu proizvoda, preferencija i popularnosti.

2.9.4 Društveno odgovorna poslovna komunikacija

Društveno odgovorna poslovna komunikacija uvodi u disertaciju društveno osetljiv domen u kojem pogrešne predikcije mogu imati organizacione, etičke i reputacione posledice. Za razliku od domena u kojima se predviđaju ocene, cene ili tržišni ishodi, ovde se model primenjuje na jezičke obrasce koji mogu biti povezani sa diskriminacijom, isključivanjem, stereotipima i narušavanjem profesionalne kulture. Detekcija rodno pristrasnog, seksističkog ili mizoginog jezika zato nije neutralan tehnički zadatak, jer isti tekst može imati različito značenje u zavisnosti od konteksta, ironije, citiranja, namere ili komunikacione situacije.

Savremena istraživanja digitalne mizoginije pokazuju da se štetni obrasci ne javljaju samo kao eksplicitne uvrede, već i kroz implicitne, kulturno i kontekstualno oblikovane strategije [30]. Fontanella i saradnici posebno ukazuju na interdisciplinarnu prirodu istraživanja digitalne mizoginije, jer se ovaj fenomen ne može razumeti samo kroz računarstvo, već zahteva povezivanje društvenih, jezičkih, psiholoških i komunikoloških perspektiva.

U oblasti automatske detekcije online seksizma posebno je značajan EDOS okvir, razvijen u okviru SemEval-2023 Task 10, jer uvodi hijerarhijsku taksonomiju seksističkog sa-

držaja i detaljno razrađene kategorijske oznake koje omogućavaju preciznije i objašnjivije tumačenje klasifikacije [31]. Umesto da se tekst posmatra samo kroz binarnu odluku da li je seksistički ili nije, ovaj pristup naglašava potrebu da se razume tip štetnog sadržaja, njegova forma i razlog zbog kojeg je problematičan.

Sličan značaj ima i EXIST 2023, koji se bavi identifikacijom seksizma u društvenim mrežama, kategorizacijom seksističkog sadržaja i analizom namere izvora [32]. Posebno je važno to što EXIST uvodi pitanja pristrasnosti, pravičnosti i neslaganja anotatora, čime pokazuje da oznake u ovakvim zadacima ne predstavljaju uvek jednoznačnu istinu, već mogu zavisi od perspektive, društvenog iskustva i konteksta tumačenja.

Za ovu disertaciju, poslovna komunikacija je važna zato što testira odgovornu dimenziju prediktivnog modelovanja. Model ne sme biti procenjen samo prema ukupnoj tačnosti, već i prema lažno pozitivnim i lažno negativnim ishodima, mogućnosti objašnjenja i potrebi za stručnom kontrolom. Lažno negativna odluka može omogućiti da štetan sadržaj ostane neprepoznat, dok lažno pozitivna odluka može neopravdano označiti komunikaciju kao problematičnu. Zbog toga ovaj domen direktno povezuje interpretabilnost, pravičnost, segmentnu evaluaciju, ljudsku proveru i etičku primenu modela u organizacionom kontekstu.

2.9.5 Obrazovanje i generativni modeli

Visokoškolsko obrazovanje u eri generativnih modela predstavlja jedan od najdinamičnijih domena za analizu promena ljudskog ponašanja. Veliki jezički modeli menjaju način na koji studenti pišu, programiraju, traže pomoć, objašnjavaju rešenja i pristupaju učenju. U računarstvu i programerskom obrazovanju generativna AI istovremeno otvara mogućnosti za personalizovanu podršku, generisanje primera, objašnjavanje koda i bržu povratnu informaciju, ali uvodi i ozbiljne izazove za procenu znanja, akademski integritet i dizajn zadataka [33]. Zbog toga se obrazovni domen ne može posmatrati samo kroz pitanje da li AI alati poboljšavaju performanse studenata, već i kroz pitanje kako menjaju obrasce učenja, samostalnog rada i dokazivanja razumevanja.

Radovi u oblasti computing education ukazuju da generativni modeli zahtevaju preispitivanje nastavnih strategija, jer tradicionalni zadaci i oblici ocenjivanja više ne proveravaju uvek samostalno razumevanje studenta [34]. Prather i saradnici posebno naglašavaju da pojava LLM alata utiče na kurikulum, politiku korišćenja AI alata, etička pitanja i način na koji nastavnici oblikuju aktivnosti u programerskim predmetima. To znači da se studentski rad mora analizirati ne samo kao konačan proizvod, već i kao trag procesa učenja, pomoći, razumevanja i donošenja odluka. Ovaj pravac literature važan je za disertaciju jer pokazuje da generativni modeli ne menjaju samo tehnički proces izrade zadataka, već i pedagoški odnos između studenta, nastavnika, alata i ishoda učenja.

Pored toga, istraživanja o primeni generativnih modela u obrazovanju pokazuju da se AI alati mogu koristiti kao podrška učenju, ali da njihovi odgovori moraju biti provereni u odnosu

na pedagoški cilj i pouzdanost generisanog sadržaja. Phung i saradnici porede ChatGPT, GPT-4 i ljudske tutore u scenarijima programerskog obrazovanja, uključujući rešavanje zadataka, objašnjavanje koncepata i rad sa greškama u kodu [35]. Walters i Wilder pokazuju da se rizik generativnih modela ne odnosi samo na tačnost odgovora, već i na bibliografske halucinacije, odnosno formalno uverljive, ali nepostojeće ili neproverljive ChatGPT izvore [36].

Za ovu disertaciju, obrazovni domen ima važnu funkciju jer uvodi podatke koji nisu samo poslovni, već i pedagoški osetljivi. Studentski radovi, greške, objašnjenja, obrasci sličnosti i ishodi mogu se analizirati pomoću NLP i ML metoda, ali rezultati modela ne smeju se koristiti za automatsko optuživanje ili sankcionisanje studenata. Posebna vrednost ovog domena ogleda se u tome što omogućava analizu novih oblika ponašanja nastalih u interakciji studenata sa generativnim alatima, kao što su promena stila pisanja, strukture koda, načina objašnjavanja i oslanjanja na spoljašnju pomoć. U tom smislu, obrazovni domen omogućava da se generativna AI ne posmatra samo kao tehnološki alat, već kao faktor koji menja obrasce studentskog ponašanja i zahteva nove kriterijume za tumačenje znanja, samostalnosti i kvaliteta akademskog rada.

2.9.6 Održivi razvoj i analitičko izveštavanje

Održivi razvoj i analitičko izveštavanje predstavljaju domen u kojem se prediktivni modeli povezuju sa organizacionim odlučivanjem, indikatorima održivosti, projektima, narativima i softverskom implementacijom. Za razliku od domena u kojima je cilj predvideti ponašanje pojedinačnog korisnika, ovde je naglasak na tome kako se rezultati modela mogu pretvoriti u analitički razumljive, proverljive i odgovorne odluke. Zbog toga ovaj domen uvodi širi nivo primene veštačke inteligencije, u kojem model ne služi samo za predikciju, već i za podršku planiranju, praćenju, izveštavanju i strateškoj interpretaciji podataka.

Inteligentna automatizacija u održivom turizmu može podržati planiranje, praćenje i optimizaciju turističkih tokova, ali njena vrednost zavisi od povezanosti modela sa merljivim indikatorima, realnim odlukama i širim ciljevima razvoja [37]. Majid i saradnici pokazuju da se AI rešenja u turizmu ne mogu posmatrati samo kao tehnološka inovacija, već kroz doprinos turističkom iskustvu, očuvanju resursa, kvalitetu života lokalne zajednice i održivim praksama. Ovaj pristup pokazuje da prediktivna analitika ima veću vrednost kada je povezana sa konkretnim indikatorima, organizacionim ciljevima i mogućnošću praktične intervencije.

Generativni modeli i automatska obrada teksta mogu doprineti održivom izveštavanju, ali zahtevaju kritičku procenu tačnosti, odgovornosti i načina na koji se generisani narativi oslanjaju na podatke [38]. De Villiers i saradnici ukazuju da AI može uticati na različite faze izveštavanja o održivosti, uključujući prikupljanje informacija, obradu teksta, oblikovanje izveštaja, proveru i korišćenje izveštajnih sadržaja. Posebno je značajno pitanje da li automatizovani narativi zaista povećavaju transparentnost ili mogu doprineti formalno uverljivom, ali sadržajno nedovoljno proverljivom prikazivanju održivosti.

Zajednički značaj ovih pristupa je u tome što AI u održivom izveštavanju ne treba da služi samo za automatizovano generisanje teksta, već za uspostavljanje proverljive veze između izvornog dokumenta, indikatora, standarda i zaključka koji se predstavlja korisniku.

Za disertaciju, ovaj domen ima ulogu povezivanja prediktivne analitike sa strateškim i organizacionim nivoom odlučivanja. Time se pokazuje da modeli nisu značajni samo kada direktno klasifikuju korisničko ponašanje, već i kada podržavaju interpretaciju indikatora, projektno mapiranje, analitičko izveštavanje i održivu implementaciju softverskih sistema.

2.10 Naučni izazovi i motivacija istraživanja

Na osnovu pregleda literature mogu se izdvojiti ključni naučni izazovi koji motivišu ovu disertaciju. Prvi izazov odnosi se na sintezu postojećih istraživanja. Većina radova fokusira se na jedan domen, jedan skup podataka ili jedan tip modela. Takav pristup omogućava detaljnu analizu pojedinačnog problema, ali otežava zaključivanje o tome kada je određena klasa modela zaista najbolji izbor i u kojoj meri se zaključci mogu preneti na druge domene.

Drugi izazov odnosi se na nedovoljno sistematsko poređenje tradicionalnih i dubokih modela. U mnogim istraživanjima duboko učenje se predstavlja kao naprednije rešenje, ali se ne upoređuje uvek sa snažnim referentnim modelima. Ova disertacija polazi od principa da duboko učenje mora pokazati dodatnu vrednost u odnosu na jednostavnije modele, bilo kroz bolju tačnost, obradu složenih modaliteta, generalizaciju ili veću domensku korisnost.

Treći izazov odnosi se na interpretabilnost. Postojeća istraživanja često prikazuju performanse modela, ali ne objašnjavaju dovoljno zašto model daje određene predikcije, koji ulazni faktori najviše utiču na rezultat i kako se takvo objašnjenje može proveriti i koristiti u realnom poslovnom ili društvenom okruženju.

Četvrti izazov odnosi se na kvalitet podataka. Realni podaci o ljudskom ponašanju često su nepotpuni, neuravnoteženi, pristrasni, ili zavisni od konteksta. Zato se kvalitet podataka mora povezati sa evaluacijom, interpretacijom i procenom pouzdanosti izvedenih zaključaka.

Peti izazov odnosi se na odgovornu primenu modela. U domenima kao što su poslovna komunikacija, obrazovanje, transport i korisničko iskustvo, pogrešne predikcije mogu imati konkretne posledice. Zato se modeli moraju procenjivati ne samo prema prosečnoj tačnosti, već i prema greškama, segmentima, pragovima odlučivanja, interpretabilnosti i potrebi za ljudskom proverom.

Šesti izazov odnosi se na primenljivost i održivu opravdanost modela. U literaturi se često naglašava poboljšanje performansi, ali se ređe jednako sistematski razmatra da li je složeniji model opravdan u odnosu na računarsku zahtevnost, dostupnost podataka, mogućnost održavanja i primenu u realnom sistemu. Zbog toga se u ovoj disertaciji izbor modela posmatra i kroz odnos između kvaliteta predikcije, objašnjivosti modelskih odluka, vremena obrade, računarske zahtevnosti i mogućnosti praktične primene.

Navedeni izazovi oblikuju istraživačku motivaciju disertacije i usmeravaju razvoj integrativnog okvira u kojem se različiti modeli, tipovi podataka i empirijski domeni ne posmatraju odvojeno, već kroz zajedničko pitanje kako obezbediti tačnu, objašnjivu i odgovornu predikciju obrazaca ljudskog ponašanja u različitim poslovnim i društvenim kontekstima.

2.11 Razvoj istraživačkog okvira disertacije

Na osnovu prethodno razmotrene literature i identifikovanih naučnih izazova, u disertaciji se razvija integrativni istraživački okvir za prediktivnu analizu obrazaca ljudskog ponašanja. Okvir je zasnovan na pretpostavci da se različiti oblici ponašanja mogu analizirati kroz zajedničke faze, čak i kada se razlikuju prema domenu, tipu podataka i ciljnoj promenljivoj.

Prva faza okvira je definisanje ponašanja koje se modeluje. U hotelijerstvu to može biti zadovoljstvo gosta, u transportu rizična vožnja ili zadovoljstvo putnika, u internet trgovini potrošačka preferencija, u poslovnoj komunikaciji diskriminatorni jezik, a u obrazovanju studentski ishod ili oslanjanje na generativni alat.

Druga faza je identifikacija digitalnog traga ponašanja. Digitalni trag može biti tekstualna recenzija, ocena, signal senzora, cena, komentar, studentski rad, projektni opis ili narativ.

Treća faza je konstrukcija reprezentacije. Tekst se može predstaviti pomoću TF-IDF ili transformerskih vektorskih reprezentacija, numerički podaci kroz skalirane karakteristike, kategorijalni podaci kroz kodiranje ili prostor vektorskih reprezentacija, sekvencijalni podaci kroz vremenske prozore, a multimodalni podaci kroz strategije fuzije.

Četvrta faza je izbor modela. U ovoj fazi porede se tradicionalni modeli, ansambli, sekvencijalne arhitekture, transformer modeli i multimodalni pristupi. Izbor modela ne zavisi samo od teorijske sofisticiranosti, već od odnosa između tipa podataka, cilja, performansi, interpretabilnosti i praktične opravdanosti.


Peta faza je evaluacija. Evaluacija obuhvata standardne metrike, domenski relevantne metrike, analizu grešaka, segmentnu procenu i proveru stabilnosti rezultata. U društveno osetljivim domenima posebno su važni lažno pozitivni i lažno negativni ishodi.

Šesta faza je interpretacija i primena. Rezultati modela se prevode oblik koji je koristan za menadžere, nastavnike, analitičare, stručnjake za komunikaciju ili donosiocima odluka.

Grafički prikaz integrativnog okvira dat je na Slici 2.2, gde su objedinjene ključne faze prelaska od domenskog ponašanja i digitalnih tragova ka reprezentaciji, modelovanju, evaluaciji, interpretaciji i praktičnoj primeni rezultata.

2.11.1 Veza između okvira i hipoteza

Integrativni okvir direktno je povezan sa hipotezama disertacije. Ova tabela nema istu ulogu kao tabela u uvodu: dok uvodno poglavlje povezuje istraživačka pitanja sa hipotezama, ovde se prikazuje kako se hipoteze ugrađuju u elemente istraživačkog okvira. Hipoteza H1



Slika 2.2: Integrativni istraživački okvir za prediktivnu analizu obrazaca ljudskog ponašanja.

odnosi se na poređenje klasa modela. Hipoteza H2 odnosi se na reprezentaciju podataka. Hipoteza H3 odnosi se na kvalitet, šum, pristrasnost i neravnotežu podataka. Hipoteza H4 odnosi se na interpretabilnost, analizu grešaka i segmentnu evaluaciju. Hipoteza H5 odnosi se na praktičnu opravdanost modela.

Tabela 2.8 prikazuje kako se pojedinačne hipoteze disertacije povezuju sa elementima istraživačkog okvira i metodama empirijske provere u različitim domenima. Na taj način tabela spaja hipoteze sa konkretnim elementima istraživačkog okvira i pokazuje kako se svaka od njih proverava kroz podatke, modele, evaluaciju i domensko tumačenje rezultata.

Tabela 2.8: Veza između istraživačkog okvira i hipoteza disertacije.

Hipoteza	Element okvira	Način provere
H1	Poređenje klasa modela	Upoređivanje tradicionalnih, ansambl, sekvencijalnih i transformer modela u tekstualnim i sekvencijalnim zadacima
H2	Reprezentacija podataka	Analiza doprinosa tekstualnih, numeričkih, sekvencijalnih, fuzzy i multimodalnih obeležja
H3	Kvalitet i struktura podataka	Analiza anomalija, nekonzistentnosti, šuma, pristrasnosti, neravnoteže klasa i segmentnih razlika
H4	Interpretabilnost i analiza grešaka	SHAP, lokalna objašnjenja, matrica konfuzije, segmentna evaluacija i domenska validacija
H5	Praktična opravdanost modela	Procena odnosa performanse, stabilnosti, složenosti, interpretabilnosti, troška i domenske koristi

2.11.2 Veza između okvira i domenskih poglavlja

Svako domensko poglavlje disertacije proverava drugi deo integrativnog okvira. Poglavlje o hotelijerstvu proverava tekstualno, multimodalno i CLV modelovanje. Poglavlje o transportu proverava sekvencijalne, regresione i segmentne pristupe. Poglavlje o internet trgovini i parfemima proverava emocionalne, subjektivne i fuzzy obrasce potrošačkog ponašanja. Poglavlje o društveno odgovornoj komunikaciji proverava odgovornu klasifikaciju osetljivog jezika. Poglavlje o održivom razvoju proverava analitičko izveštavanje i projekt-no odlučivanje. Poglavlje o obrazovanju proverava promene studentskog ponašanja, LLM podršku i obrazovnu analitiku.

2.12 Zaključna razmatranja poglavlja

Pregled literature pokazuje da se analiza ljudskog ponašanja u savremenom poslovnom i društvenom okruženju nalazi na preseku mašinskog učenja, obrade prirodnog jezika, interpretabilnosti, odgovorne AI i poslovne analitike. Različiti tipovi podataka, zadaci i modeli se moraju posmatrati kroz koherentan istraživački okvir, a ne kao odvojene tehničke celine.

U poglavlju su razmotreni osnovni elementi tog okvira: duboko učenje za tekstualne i sekvencijalne podatke, tradicionalni modeli kao referentna osnova, interpretabilnost, pristranost, multimodalno učenje i održiva primena modela. Posebno je naglašeno da vrednost modela ne zavisi samo od performansi, već i od mogućnosti objašnjenja, kvaliteta podataka, domenske korisnosti i odgovorne primene.

Empirijski domeni disertacije, turizam, transport, internet trgovina, poslovna komunikacija, održivi razvoj i obrazovanje, predstavljeni su kao različiti prostori za proveru istih metodoloških principa. Time se obezbeđuje da disertacija ostane usmerena na razvoj i evaluaciju prediktivnih modela ponašanja, a ne na opis pojedinačnih industrija.

Na osnovu ovog pregleda, naredno poglavlje definiše metodološki okvir istraživanja, uključujući opis podataka, pretprocesiranje, izbor modela, evaluacione metrike, interpretaciju rezultata, analizu grešaka, reproducibilnost i etičke smernice.

3. METODOLOŠKI OKVIR ISTRAŽIVANJA


Metodološko poglavlje definiše istraživački okvir koji povezuje teorijske osnove disertacije sa empirijskim analizama u narednim poglavljima. Pošto se istraživanje odnosi na prediktivno modelovanje obrazaca ljudskog ponašanja u više savremenih poslovnih i društvenih okruženja, metodologija mora da obezbedi dosledan, uporediv i proverljiv postupak rada kroz različite tipove podataka, zadatke i modele.

Osnovna ideja ovog poglavlja jeste da se domenska raznovrsnost prevede u zajednički istraživački protokol. Turizam i hotelijerstvo, transportni sistemi, internet trgovina, društveno odgovorna poslovna komunikacija, održivi razvoj i obrazovanje razlikuju se po prirodi podataka i značenju rezultata, ali ih povezuje isti analitički tok: definisanje problema, izbor i priprema podataka, konstrukcija obeležja, izbor modela, evaluacija, analiza grešaka, interpretacija i sinteza nalaza.

Za razliku od prethodnog poglavlja, u kojem su razmatrane teorijske i istraživačke osnove modelovanja, ovo poglavlje ima operativnu funkciju. Ono ne ponavlja pregled literature, već definiše postupak kojim se u domenskim poglavljima podaci pretvaraju u prediktivne modele, rezultati u objašnjenja, a pojedinačni nalazi u integrativnu proveru hipoteza disertacije.

Metodologija se zasniva na eksperimentalnom i komparativnom okviru koji se prilagođava strukturi podataka i cilju analize. U zavisnosti od zadatka koriste se tradicionalni modeli mašinskog učenja, ansambl metode, sekvencijalne neuronske mreže, transformer arhitekture i multimodalni pristupi. Takav okvir omogućava da se u svakom domenu proceni ne samo performansa modela, već i njegova stabilnost, objašnjivost i praktična upotrebljivost.

Slika 3.1 prikazuje da se svaki empirijski domen obrađuje kroz isti istraživački tok, iako se konkretni podaci, modeli i ciljni ishodi razlikuju. Na taj način se uspostavlja osnova za poređenje rezultata i njihovu završnu integrativnu sintezu.



Slika 3.1: Opšti metodološki tok istraživanja u disertaciji.

3.1 Istraživački dizajn i zajednički protokol

Istraživački dizajn disertacije zasniva se na kombinaciji teorijskog, eksperimentalnog, komparativnog i integrativnog pristupa. Teorijski pristup koristi se za definisanje istraživačkog problema i utemeljenje modelovanja u relevantnoj literaturi. Eksperimentalni pristup koristi se za razvoj i evaluaciju modela u pojedinačnim empirijskim domenima. Komparativni pristup omogućava poređenje modela, reprezentacija i metrika, dok integrativni pristup povezuje nalaze iz različitih domena u završnu sintezu naučnih doprinosa.

3.1.1 Zajednički istraživački protokol

U svakom empirijskom domenu primenjuje se zajednički istraživački protokol koji obuhvata: definisanje domenskog problema, izbor izvora podataka, određivanje ciljne promerljive, proveru kvaliteta podataka, pripremu i transformaciju podataka, konstrukciju obeležja, izbor modela, trening, evaluaciju, analizu grešaka, interpretaciju i povezivanje nalaza sa hipotezama disertacije.

Različiti izvori podataka, kao što su hotelske recenzije, zapisi o vožnji, potrošačke recenzije, poslovni komentari, projektni opisi i studentski radovi, ne obrađuju se istim tehničkim postupkom. Ipak, u svakom domenu postavljaju se ista metodološka pitanja: koji digitalni trag opisuje ponašanje, koji ishod se predviđa, koji model je primenjen, kako je rezultat evaluiran i kako se predikcija može objasniti u konkretnom kontekstu.

Tabela 3.1 prikazuje sažet metodološki tok istraživanja. Njena uloga je da prikaže zajedničku logiku postupka, dok se specifični protokoli, skupovi podataka, arhitekture i rezultati detaljno razrađuju u empirijskim poglavljima. Time se obezbeđuje da se svaki empirijski domen analizira kroz isti istraživački tok, uz dovoljno prostora za prilagođavanje specifičnostima podata

3.1.2 Eksperimentalna i komparativna logika

Eksperimentalna logika disertacije zasniva se na poređenju više klasa modela. Kada je metodološki opravdano, prvo se definiše jednostavniji referentni model, a zatim se uvode složeniji pristupi, uključujući ansamble, sekvencijalne mreže, transformer arhitekture ili multimodalne modele. Na taj način se proverava da li složeniji model zaista donosi dodatnu vrednost ili samo povećava potrošnju resursa.

Komparativna evaluacija ne svodi se na rangiranje modela prema jednoj metrici. Model se procenjuje prema odnosu između kvaliteta predikcije, stabilnosti, složenosti, interpretabilnosti i domenske opravdanosti primene. Takav pristup je važan zato što sprečava nekritičku primenu dubokog učenja. U tekstualnim i sekvencijalnim zadacima duboki modeli mogu imati jasnu prednost, dok u strukturisanim tabularnim podacima ansambl modeli ili jednostavniji pristupi mogu ostati stabilniji, efikasniji i lakši za tumačenje.

Tabela 3.1: Opšti metodološki tok istraživanja u disertaciji.

Faza	Sadržaj faze	Metodološka uloga
Definisanje problema	Određivanje ponašanja i ciljnog ishoda	Povezuje domen sa istraživačkim pitanjem
Priprema podataka	Čišćenje, filtriranje, transformacije i podela skupova	Obezbeđuje validnu osnovu za modelovanje
Konstrukcija obeležja	Tekstualne, numeričke, sekvencijalne i multimodalne reprezentacije	Pretvara sirove podatke u oblik pogodan za učenje
Modelovanje	Referentni pristup, tradicionalni ML, ansambli, sekvencijalni i transformer modeli	Omogućava poređenje različitih pristupa
Evaluacija i interpretacija	Metrike, analiza grešaka, segmentna evaluacija i XAI	Povezuje performanse sa značenjem rezultata
Sinteza nalaza	Povezivanje rezultata sa hipotezama i domenima	Omogućava integrativni zaključak disertacije

3.2 Podaci, priprema i podela skupova

Podaci korišćeni u disertaciji razlikuju se prema izvoru, strukturi, obimu i načinu nastanka. U metodološkom smislu, najvažnije grupe čine tekstualni, numerički, kategorijalni, vremenski, sekvencijalni, mrežni i multimodalni podaci. Zbog toga priprema podataka nije samo tehnički korak, već deo istraživačkog dizajna koji neposredno utiče na validnost modela, pouzdanost evaluacije i tumačenje dobijenih rezultata. U formalnom obliku, skup podataka može se zapisati kao:

$$D = \{(x_i, y_i)\}_{i=1}^n, \quad (3.1)$$

gde je x_i ulazni opis instance, y_i ciljna vrednost, a n ukupan broj instanci. U zavisnosti od zadatka, y_i može biti numerička vrednost, binarna oznaka, višeklasna oznaka, višelabelna oznaka, fuzzy stepen pripadnosti ili indikator anomalije. Pošto se u disertaciji često kombinuje više tipova podataka, ulazna instanca može se predstaviti kao skup modaliteta:

$$x_i = \{x_i^{text}, x_i^{num}, x_i^{cat}, x_i^{time}, x_i^{meta}\}, \quad (3.2)$$

gde x_i^{text} označava tekstualni sadržaj, x_i^{num} numeričke karakteristike, x_i^{cat} kategorijalne promenljive, x_i^{time} vremenske ili sekvencijalne podatke, a x_i^{meta} metapodatke. Metapodaci mogu obuhvatati informacije kao što su datum nastanka zapisa, izvor podataka, identifikator korisnika ili proizvoda, kanal interakcije, tip uređaja ili drugi atributi koji prate sadržaj instance.

3.2.1 Priprema i kontrola kvaliteta podataka

Priprema podataka obuhvata proveru nedostajućih vrednosti, duplikata, tehničkih grešaka, ekstremnih vrednosti, neravnoteže klasa i mogućeg curenja informacija. Kod tekstualnih podataka primenjuju se čišćenje, normalizacija, tokenizacija i filtriranje neinformativnih zapisa, uz oprez da se ne uklone signali važni za sentiment, pritužbe ili društveno osetljiv sadržaj. Kod numeričkih podataka primenjuju se skaliranje, normalizacija, imputacija ili logaritamske transformacije, dok se kategorijalne promenljive predstavljaju kroz one-hot kodiranje, ordinalno kodiranje, target encoding ili vektorske reprezentacije. Standardizacija numeričke promenljive može se zapisati kao:

$$z_i = \frac{x_i - \mu}{\sigma}, \quad (3.3)$$

gde je x_i originalna vrednost, μ srednja vrednost, a σ standardna devijacija. Kod sekvencijalnih podataka posebna pažnja posvećuje se redosledu događaja. Ako se koriste vremenski prozori, sekvenca može biti definisana kao:

$$S_i = (x_{i-t+1}, x_{i-t+2}, \dots, x_i), \quad (3.4)$$

gde je t dužina prozora.

Tabela 3.2 prikazuje najčešće probleme kvaliteta podataka, moguće postupke obrade i metodološke napomene koje usmeravaju donošenje odluka u pripremi skupova podataka.

Tabela 3.2: Kontrola kvaliteta podataka u metodološkom okviru.

Problem	Moguća obrada	Metodološka napomena
Nedostajuće vrednosti	Imputacija, uklanjanje ili posebna kategorija	Izbor zavisi od značenja promenljive
Duplikati	Uklanjanje ili označavanje	Proverava se da li ponavljanje ima domensko značenje
Ekstremne vrednosti	Provera, winsorization ili modeli otporni na odstupanja	Ne uklanjaju se bez domenske provere
Kratki tekstovi	Filtriranje ili posebna oznaka	Kratak iskaz može biti informativan u nekim domenima
Neravnoteža klasa	Ponderisanje, balansiranje, makro metrike	Važno za manjinske i osetljive obrasce
Vremensko curenje	Hronološka podela podataka	Obavezno kod predikcije kroz vreme

3.2.2 Podela skupova i sprečavanje curenja informacija

Podela podataka na trening, validacioni i test skup predstavlja osnovu validne evaluacije:

$$D = D_{train} \cup D_{val} \cup D_{test}, \quad (3.5)$$

pri čemu su skupovi međusobno disjunktne. Kod klasifikacionih zadataka koristi se stratifikovana podela kada je potrebno očuvati odnos klasa. Kod vremenski zavisnih podataka primenjuje se hronološka podela:

$$t(D_{train}) < t(D_{val}) < t(D_{test}), \quad (3.6)$$

gde $t(D)$ označava vremenski period odgovarajućeg skupa. Kada postoji grupisanje instanci po hotelima, studentima, proizvodima, korisnicima ili rutama, koristi se podela po grupama kako bi se umanjio rizik od prelivanja informacija između trening i test skupa.

3.3 Reprezentacija podataka i konstrukcija obeležja

Reprezentacija podataka predstavlja postupak pretvaranja sirovih zapisa u oblik pogodan za modelovanje. U disertaciji se koriste tekstualne reprezentacije, numerička i statistička obeležja, fuzzy stepeni pripadnosti, vremenski prozori i multimodalne kombinacije. Izbor reprezentacije zavisi od prirode podataka, ciljnog ishoda i modela koji se primenjuje. Tekstualni podaci mogu se predstaviti pomoću TF-IDF reprezentacije, vektorskih reprezentacija ili kontekstualnih reprezentacija dobijenih pomoću transformer modela. Ako je tekst instance i označen kao d_i , njegova vektorska reprezentacija može se zapisati kao:

$$h_i = \text{Encoder}_\theta(d_i), \quad (3.7)$$

gde je Encoder_θ model za kodiranje teksta, a h_i dobijeni vektor reprezentacije. TF-IDF se koristi kao jednostavna i razumljiva osnova, dok se transformer reprezentacije koriste kada zadatak zahteva razumevanje složenijih jezičkih obrazaca. Numerička i statistička obeležja obuhvataju ocene, cene, frekvencije, proseke, standardne devijacije i promene kroz vreme. Na primer, prosečna ocena hotela može se izračunati kao:

$$\bar{r}_h = \frac{1}{n_h} \sum_{i=1}^{n_h} r_i, \quad (3.8)$$

gde je r_i ocena pojedinačne recenzije, a n_h broj recenzija hotela h . Ova obeležja su korisna kod regresionih i segmentacionih zadataka, ali i kao dopuna tekstualnim reprezentacijama. U zadacima u kojima se granice između kategorija ne mogu jasno odrediti koriste se fuzzy

reprezentacije. Fuzzy stepen pripadnosti instance i kategoriji k označava se kao:

$$\mu_{ik} \in [0, 1]. \quad (3.9)$$

Za razliku od binarne klasifikacije, fuzzy zapis omogućava izražavanje delimične pripadnosti, što je posebno korisno kada tekst istovremeno sadrži obeležja više semantički bliskih kategorija. Ako se koristi semantička sličnost između reprezentacije teksta i prototipa kategorije, kosinusna sličnost može se zapisati kao:


$$s_{ik} = \frac{x_i \cdot p_k}{\|x_i\| \|p_k\|}, \quad (3.10)$$

gde je x_i reprezentacija teksta, a p_k prototip kategorije. Kod multimodalnih podataka zajednička reprezentacija može se zapisati kao:

$$z_i = [\phi_{text}(x_i^{text}), \phi_{num}(x_i^{num}), \phi_{cat}(x_i^{cat})], \quad (3.11)$$

gde funkcije ϕ predstavljaju transformacije pojedinačnih modaliteta, a $[\cdot]$ označava njihovo spajanje. Multimodalni pristup je važan u domenima gde tekst sam po sebi nije dovoljan, već ga treba povezati sa ocenama, atributima korisnika ili vremenskim informacijama.

Slika 3.2 prikazuje prelazak od sirovih podataka ka zajedničkom vektoru obeležja. Ova faza je ključna jer direktno određuje koje informacije model može da koristi tokom učenja.



Slika 3.2: Proces konstrukcije obeležja za heterogene podatke.

3.4 Modeli i logika poređenja

Modeli korišćeni u disertaciji grupišu se prema tipu podataka, cilju predikcije i potrebi za interpretabilnošću. Izbor modela određen je odnosom između performansi, stabilnosti, razumljivosti, potrošnje računarskih resursa i domenske korisnosti. Zato se u svakom empirijskom

domenu polazi od pitanja da li model odgovara strukturi podataka, prirodi ciljnog ishoda i nivou objašnjivosti potrebnom za tumačenje rezultata. Jednostavniji modeli daju referentnu osnovu, dok su složeniji opravdani kada mogu da obuhvate nelinearne, sekvencijalne, tekstualne ili multimodalne odnose koje jednostavniji pristupi ne prepoznaju dovoljno dobro. U klasifikacionim zadacima model najčešće procenjuje verovatnoću pripadnosti klase:

$$\hat{p}_{ic} = P(y_i = c \mid x_i), \quad (3.12)$$

gde $\hat{p}_{ic}$ označava procenjenu verovatnoću da instanca i pripada klasi c . Konačna klasa može se odrediti kao:

$$\hat{y}_i = \arg \max_{c \in C} \hat{p}_{ic}, \quad (3.13)$$

gde je C skup mogućih klasa.

3.4.1 Grupe modela

Referentni modeli služe kao osnova za proveru dodatne vrednosti složenijih pristupa. U klasifikacionim zadacima referentni pristup može biti većinska klasa, logistička regresija ili TF-IDF model sa linearnim klasifikatorom, dok u regresionim zadacima može biti prosečna vrednost, medijana ili jednostavan linearni model. Tradicionalni modeli, kao što su logistička regresija, Ridge regresija, SVM i Naive Bayes, koriste se kada su važni jednostavnost, brzina, stabilnost i razumljivost rezultata. Ansambl modeli, kao što su Random Forest, Gradient Boosting, XGBoost, LightGBM i CatBoost, posebno su korisni kod tabularnih i kombinovanih podataka. Opšti oblik ansambl predikcije može se zapisati kao:

$$\hat{y}_i = \sum_{m=1}^M \alpha_m f_m(x_i), \quad (3.14)$$

gde je f_m pojedinačni model, α_m njegova težina, a M broj modela u ansamblu.

Sekvencijalni modeli, kao što su LSTM i GRU, koriste se kada je redosled događaja važan i kada se ishod ne može pouzdano proceniti samo iz statičkog opisa instance. Transformer modeli koriste se za složene tekstualne zadatke, naročito kada je potrebno modelovati kontekst, semantičke odnose i implicitne signale u tekstu. Multimodalni modeli primenjuju se kada je potrebno objediniti više izvora podataka u jednu prediktivnu strukturu.

3.4.2 Optimizacija hiperparametara

Optimizacija hiperparametara sprovodi se na validacionom skupu ili kroz ograničenu pretragu prostora parametara. Hiperparametri uključuju broj stabala, dubinu stabla, stopu učenja, broj epoha, veličinu serije podataka za obuku (*batch size*), stopu isključivanja neurona (*dropout*), dužinu sekvence, dimenziju prostora vektorskih reprezentacija i prag odlučivanja.

U opštem obliku, izbor hiperparametara može se zapisati kao:

$$\lambda^* = \arg \max_{\lambda \in \Lambda} \text{Score}(M_\lambda, D_{val}), \quad (3.15)$$

gde je λ skup hiperparametara, Λ prostor pretrage, M_λ model sa zadatim hiperparametrima, a D_{val} validacioni skup. Test skup se ne koristi za izbor hiperparametara, već isključivo za završnu proveru performansi.

3.5 Evaluacija, analiza grešaka i interpretabilnost

Modeli se procenjuju prema tačnosti ili grešci predikcije, stabilnosti rezultata na novim podacima, ponašanju po segmentima, prirodi grešaka, interpretabilnosti i mogućnosti primene u realnom sistemu. Ovaj pristup je važan jer se analiziraju domeni u kojima predikcije mogu imati poslovne, društvene, pedagoške ili bezbednosne posledice.

3.5.1 Evaluacione metrike

Za klasifikaciju se koriste tačnost, preciznost, odziv, F1 mera, makro F1, AUC i matrica konfuzije:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}, \quad (3.16)$$

$$\text{Precision} = \frac{TP}{TP + FP}, \quad \text{Recall} = \frac{TP}{TP + FN}, \quad (3.17)$$

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (3.18)$$

Kod neuravnoteženih klasa važno je posmatrati preciznost i odziv zajedno, jer model može imati visoku tačnost, a ipak slabo prepoznavati manjinske ili kritične klase. Za regresione zadatke koriste se MAE, RMSE i koeficijent determinacije:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (3.19)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (3.20)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (3.21)$$

Kod fuzzy i višelabelnih zadataka procenjuje se ne samo dominantna kategorija, već i preklapanje između kategorija. Ako je μ_{ik} fuzzy stepen pripadnosti instance i kategoriji k ,

broj aktivnih kategorija može se definisati kao:

$$A_i = \sum_{k=1}^K I(\mu_{ik} \geq \tau), \quad (3.22)$$

gde je τ prag aktivacije.

3.5.2 Analiza grešaka i segmentna evaluacija

Matrica konfuzije koristi se za razumevanje grešaka po klasama. Za višeklasni zadatak element matrice C_{ij} označava broj instanci stvarne klase i koje su predviđene kao klasa j :

$$C_{ij} = |\{x : y(x) = i, \hat{y}(x) = j\}|. \quad (3.23)$$

Analiza grešaka je posebno važna u zadacima koji uključuju ljudsko ponašanje. Lažno negativan ishod u hotelijerstvu može značiti da pritužba gosta ostaje neprepoznata, u transportu da rizično ponašanje nije otkriveno, u poslovnoj komunikaciji da štetan sadržaj ostaje neoznačen, a u obrazovanju da student kome je potrebna podrška nije prepoznat. Lažno pozitivan ishod može dovesti do nepotrebnog upozorenja, pogrešne intervencije ili neadekvatnog tumačenja sadržaja. Segmentna evaluacija proverava da li model jednako dobro funkcioniše u različitim grupama podataka. Ako je G skup segmenata, performansa po segmentu može se zapisati kao:

$$Score_g = Score(M, D_g), \quad g \in G, \quad (3.24)$$

gde je D_g podskup podataka za segment g , a $Score$ izabrana metrika evaluacije.

3.5.3 Interpretabilnost modela

Interpretabilnost podrazumeva sposobnost da se predikcije objasne na način razumljiv istraživačima i korisnicima rezultata. Globalna interpretabilnost pokazuje koje karakteristike najviše utiču na model u celini, dok lokalna interpretabilnost objašnjava pojedinačnu predikciju. Kod ansambl i tabularnih modela mogu se koristiti SHAP vrednosti, dok se kod tekstualnih modela analiziraju reči, fraze, tokeni, pažnja ili semantičke dimenzije. SHAP zapis predikcije može se predstaviti kao:

$$\hat{y}_i = \phi_0 + \sum_{j=1}^p \phi_{ij}, \quad (3.25)$$

gde je ϕ_0 osnovna vrednost, a ϕ_{ij} doprinos obeležja j za instancu i . U disertaciji se objašnjenja ne tumače izolovano, već se povezuju sa domenskim kategorijama, kao što su higijena, usluga, cena, isporuka, poverenje, diskriminatorni obrazac ili pedagoški signal.

Tabela 3.3 sažima kriterijume evaluacije koji povezuju numeričke performanse, analizu grešaka, interpretabilnost i praktičnu primenu modela.

Tabela 3.3: Kriterijumi evaluacije modela u disertaciji.

Kriterijum	Šta se proverava	Primer primene
Prediktivna performansa	Tačnost ili greška modela	F1 za pritužbe, MAE za ocene, RMSE za cene
Stabilnost	Ponašanje na validacionom, test i segmentnim skupovima	Hoteli, studenti, rute, proizvodi
Analiza grešaka	Lažno pozitivni i lažno negativni ishodi	Pritužbe, rizična vožnja, društveno osetljiv jezik
Interpretabilnost	Objašnjenje faktora koji utiču na predikciju	SHAP, lokalna objašnjenja, analiza tokena
Praktična primenljivost	Računarska zahtevnost, jednostavnost i domenska korisnost	Izbor modela za realni sistem podrške odlučivanju

3.6 Odgovornost, reproducibilnost i granice tumačenja

Metodološki okvir mora da obuhvati i odgovornu primenu modela, jer se disertacija bavi podacima koji opisuju korisnike, putnike, studente i učesnike digitalne komunikacije. Zbog toga se rezultati modela ne tumače samo kroz tehničku performansu, već i kroz ograničenja podataka, posledice grešaka i mogućnost stručne kontrole.

Modeli razvijeni u disertaciji namenjeni su podršci analizi i odlučivanju, a ne automatskom donošenju konačnih odluka. U obrazovnom domenu koriste se anonimizovani ili agregirani podaci, dok se u društveno osetljivim zadacima rezultati tumače na nivou klasa, modela i obrazaca, a ne kao konačna ocena pojedinca. Odgovorna primena zato podrazumeva da se svaka predikcija posmatra kao analitički signal koji zahteva kontekstualno tumačenje, proveru ograničenja i mogućnost ljudske intervencije pre praktične odluke.

Reproducibilnost se obezbeđuje dokumentovanjem izvora podataka, postupaka preprocesiranja, podele skupova, hiperparametara, evaluacionih metrika i načina interpretacije rezultata. Kod modela koji uključuju slučajnost potrebno je postaviti slučajna semena kada je to moguće, uz napomenu da potpuna deterministička ponovljivost kod dubokog učenja nije uvek ostvariva zbog hardvera i paralelizacije.

Metodološka ograničenja odnose se na heterogenost domena, dostupnost i kvalitet podataka, subjektivnost oznaka, neravnotežu klasa, promene distribucije kroz vreme i ograničenja

interpretabilnih metoda. Ova ograničenja ne umanjuju doprinos disertacije, već preciziraju granice u kojima se rezultati mogu tumačiti.

U odnosu na hipoteze disertacije, metodološki okvir definiše način njihove operativne provere. H1 se proverava poređenjem tradicionalnih, ansambl, sekvencijalnih i transformer modela. H2 se proverava kroz promenu i proširenje reprezentacije podataka. H3 se povezuje sa kvalitetom podataka, šumom, pristrasnošću i neravnotežom klasa. H4 se proverava kroz interpretabilnost, analizu grešaka i segmentnu evaluaciju, dok H5 objedinjuje pitanje praktične primenljivosti i odnosa između performanse, stabilnosti, složenosti i domenske koristi.

3.7 Zaključna razmatranja metodološkog poglavlja

Metodološki okvir definisan u ovom poglavlju uspostavlja zajedničku osnovu za sva empirijska poglavlja disertacije. Njegova uloga nije da izjednači različite domene, već da omogućiti njihovo poređenje kroz iste istraživačke kriterijume: podatke, reprezentaciju, model, evaluaciju, interpretaciju i primenu.

U skraćenoj formi, ovo poglavlje ima funkciju metodološke kičme disertacije. Ono ne zamenjuje domenske eksperimente, niti ponavlja teorijski pregled iz prethodnog poglavlja, već precizira postupak kojim se u svakom empirijskom domenu proverava odnos između tipa podataka, izbora modela, evaluacionog protokola i značenja rezultata.

Posebna vrednost okvira ogleda se u tome što omogućava da se svaka hipoteza proverava kroz više domena, ali uz očuvanje iste logike poređenja, evaluacije i tumačenja rezultata. U narednim empirijskim poglavljima ovaj okvir služi kao osnova procene, pri čemu se vrednost primenjenih modela ne meri samo numeričkim rezultatom, već i njihovom sposobnošću da podatke o ponašanju prevedu u pouzdane, objašnjive i odgovorno primenljive nalaze u konkretnom domenu.

4. TURIZAM I HOTELIJERSTVO

4.1 Digitalni podaci o korisnicima u turizmu i hotelijerstvu

Turizam i hotelijerstvo predstavljaju jedan od najznačajnijih empirijskih domena za razvoj i evaluaciju prediktivnih modela ponašanja korisnika. Razlog za to nalazi se u činjenici da se iskustvo gosta danas u velikoj meri dokumentuje kroz digitalne tragove: online recenzije, numeričke ocene, komentare, pritužbe, podatke o rezervacijama, metapodatke o boravku, informacije o tipu putovanja, istoriju interakcije sa hotelom i signale koji ukazuju na buduću lojalnost ili rizik nezadovoljstva. Ovi tragovi omogućavaju da se zadovoljstvo, nezadovoljstvo, lojalnost, rizik od odlaska, verovatnoća otkazivanja rezervacije i dugoročna vrednost korisnika analiziraju pomoću metoda mašinskog učenja, dubokog učenja, obrade prirodnog jezika i interpretabilne veštačke inteligencije. U ovom poglavlju hotelijerstvo ima funkciju centralnog domena za proveru istraživačkog okvira, jer povezuje tekstualne recenzije, strukturisane rezervacione podatke, procenu zadovoljstva, lojalnost i rizik otkazivanja u jedinstven tok prediktivne analitike ponašanja gostiju.

U savremenoj literaturi turizam i hotelijerstvo prepoznati su kao jedan od ključnih domena primene veštačke inteligencije, jer hotelske i turističke platforme istovremeno generišu strukturisane, tekstualne, vremenske i ponašajne podatke. Sistematski pregledi pokazuju da se AI metode u ovom domenu koriste za analizu korisničkog iskustva, predikciju potražnje, segmentaciju gostiju, upravljanje reputacijom i podršku menadžerskom odlučivanju [15]. Noviji pregledni radovi dodatno naglašavaju pomeranje istraživanja ka objašnjivim, odgovornim i strateški primenljivim AI rešenjima u turizmu i hotelijerstvu [16].

U kontekstu ove disertacije, hotelijerstvo nije izabrano samo kao poslovni sektor u kojem postoje dostupni podaci, već kao metodološki bogat domen u kojem se mogu ispitati gotovo svi ključni elementi istraživačkog okvira. Hotelske recenzije omogućavaju analizu prirodnog jezika, sentimenta, pritužbi, semantičkih obrazaca i nekonzistentnosti između numeričkih i tekstualnih signala. Numeričke ocene omogućavaju regresiono modelovanje i predikciju zadovoljstva. Rezervacioni zapisi omogućavaju analizu ponašanja pre dolaska gosta, procenu rizika otkazivanja i modelovanje vrednosti korisnika. Metapodaci, kao što su identifikator hotela, datum recenzije, kanal rezervacije, segment gosta, oznake boravka, prethodna aktivnost korisnika i podaci o ponovljenim interakcijama, omogućavaju multimodalno povezivanje tekstualnih i strukturisanih izvora. Podaci o datumima i vremenima rezervacija omogu-

ćavaju proveru hronoloških podela i smanjenje rizika od curenja informacija. Ponavljanje korisničkih interakcija omogućava procenu dugoročne vrednosti i odnosa između iskustva, lojalnosti i poslovnog ishoda.

Zbog toga se ovaj domen u disertaciji posmatra kao centralni empirijski prostor za proveru sledećih pitanja: da li tekstualni podaci mogu pouzdano predvideti numeričku ocenu, da li duboki modeli daju prednost u odnosu na tradicionalne pristupe, kako se mogu otkriti anomalije i nekonzistentnosti u recenzijama, kako se negativne recenzije mogu prepoznati, da li transformer modeli mogu detektovati kategorije pritužbi, kako se strukturisani i tekstualni podaci mogu objediniti u multimodalni model zadovoljstva i kako se rezultati mogu objasniti hotelijerskom menadžmentu. U najopštijem obliku, digitalni zapis o hotelskom korisniku može se predstaviti kao:

$$x_i = \{r_i, t_i, m_i, h_i, u_i, b_i\}, \quad (4.1)$$

gde je r_i numerička ocena, t_i tekstualna recenzija, m_i skup metapodataka, h_i identifikator hotela ili karakteristika hotela, u_i skup podataka koji opisuje korisnika ili njegovo prethodno ponašanje, a b_i rezervacioni ili bihejvioralni zapis, ukoliko je dostupan. Ciljna promenljiva u zavisnosti od zadatka može biti ocena, sentiment, kategorija pritužbe, indikator anomalije, procena zadovoljstva, rizik otkazivanja rezervacije ili dugoročna vrednost korisnika.

Tabela 4.1 pokazuje da hotelski podaci imaju multimodalnu strukturu. To znači da se ponašanje gostiju ne može potpuno razumeti samo iz jedne promenljive. Numerička ocena daje sažetu procenu iskustva, ali tekstualna recenzija objašnjava razloge te procene. Rezervacioni zapisi pružaju uvid u ponašanje pre ostvarenog boravka, dok metapodaci i vremenski podaci omogućavaju analizu konteksta, pouzdanosti i promena kroz vreme.

Tabela 4.2 jasno pokazuje da se doprinos hotelskog domena ne svodi na primenu jedne arhitekture nad jednim skupom recenzija. Naprotiv, ovaj domen omogućava proveru celog istraživačkog lanca: od provere kvaliteta podataka, preko tekstualne i multimodalne reprezentacije, do interpretacije rezultata u menadžerskom i reputacionom kontekstu.

4.2 Online recenzije kao izvor podataka o zadovoljstvu gostiju

Online recenzije predstavljaju jedan od najbogatijih izvora podataka o zadovoljstvu hotelskih gostiju. Za razliku od numeričkih ocena, koje iskustvo svode na jednu vrednost, tekstualne recenzije sadrže obrazloženje, emocionalni ton, pritužbe, pohvale, poređenja, očekivanja i implicitne signale budućeg ponašanja. U hotelijerstvu imaju dvostruku ulogu: utiču na odluke budućih gostiju, ali istovremeno pružaju hotelima povratnu informaciju o kvalitetu usluge.

Predikcija sentimenta i ocena turističkih recenzija predstavlja važan istraživački zadatak jer povezuje tekstualni narativ korisnika sa numeričkom merom zadovoljstva [39]. Upravo ta veza čini hotelske recenzije pogodnim domenom za proveru hipoteza disertacije: tekstualni signal može se uporediti sa numeričkim ishodom, dok se razlike između ta dva signala mogu

Tabela 4.1: Tipovi digitalnih podataka u hotelijerstvu i njihova analitička uloga.

Tip podataka	Primeri	Analitička uloga
Tekstualni podaci	Online recenzije, naslovi recenzija, pritužbe	Sentiment analiza, detekcija pritužbi, predikcija ocena, identifikacija tema
Numerički podaci	Ocene, prosečne ocene, broj recenzija, cene	Regresija, merenje zadovoljstva, segmentna analiza, procena vrednosti
Kategorijalni podaci	Tip putovanja, kategorija hotela, kanal rezervacije, tip gosta	Segmentacija, poređenje grupa, kontrola varijabilnosti
Vremenski podaci	Datum recenzije, period boravka, period između rezervacije i planiranog dolaska, sezona	Hronološka validacija, analiza promena kroz vreme, procena rizika otkazivanja
Metapodaci i ponašajni podaci	Hotel, korisnik, lokacija, istorija recenzija, zahtevi gosta	Multimodalno modelovanje, procena pouzdanosti, CLV analiza, menadžerska interpretacija

koristiti za analizu nekonzistentnosti, pouzdanosti, značenja greške modela i granica automatizovanog tumačenja korisničkog iskustva. Recenzija se može posmatrati kao tekstualni izraz latentnog zadovoljstva gosta. Ako se latentno zadovoljstvo označi kao z_i , a tekst recenzije kao t_i , tada se može pretpostaviti da tekst predstavlja posredni signal tog zadovoljstva:

$$t_i = g(z_i, c_i, \epsilon_i), \quad (4.2)$$

gde je c_i kontekst iskustva, a ϵ_i šum koji može poticati od subjektivnosti korisnika, stila pisanja, trenutnog raspoloženja, očekivanja ili drugih nemeranih faktora. Cilj modela nije da potpuno rekonstruiše latentno zadovoljstvo, već da izdvoji one obrasce u tekstu koji su dovoljno stabilni da podrže predikciju, klasifikaciju ili menadžersku interpretaciju.

Tekstualna recenzija može sadržati više dimenzija zadovoljstva i više suprotstavljenih signala. Recenzija u kojoj gost hvali lokaciju i ljubaznost osoblja, ali istovremeno navodi buku ili nečistoću sobe, pokazuje da se hotelsko iskustvo ne može tumačiti samo kroz ukupnu ocenu ili jednostavnu podelu na pozitivne i negativne komentare. Takva podela može biti korisna kao početni zadatak, ali nije dovoljna za potpunu hotelsku analitiku i donošenje konkretnih menadžerskih odluka. U ovoj disertaciji recenzije se zato analiziraju kroz više povezanih zadataka, uključujući detekciju anomalija na platformama za rezervaciju smeštaja, identifikaciju negativnih recenzija, predikciju ocene, detekciju kategorija pritužbi, multimodalnu procenu zadovoljstva i procenu dugoročne vrednosti korisnika.

Tabela 4.2: Istraživački zadaci u hotelskom domenu i konkretan doprinos disertacije.

Zadatak	Dominantni podaci	Modeli	Konkretan doprinos
Detekcija anomalija	Recenzije, ocene, vreme, korisnik	EDA, TF-IDF, sentiment, topic modeling	Uvođenje kvaliteta i integriteta recenzija kao posebnog sloja pre prediktivnog modelovanja.
Detekcija negativnih recenzija	Tekst, ocena, numerički atributi	FCNN, vektorske reprezentacije, optimizacija	Razvoj skalabilnog sistema za rano prepoznavanje nezadovoljstva i pritužbi.
Predikcija ocena	Tekst recenzije, naslov, metapodaci	TF-IDF, LSTM, BiLSTM, DistilBERT	Regresiona provera odnosa između narativnog i numeričkog izraza zadovoljstva uz kontrolu curenja informacija.
Detekcija pritužbi	Tekstualne povratne informacije	BERT, RoBERTa, višelabelna klasifikacija	Prelazak sa opšteg sentimenta na operativno korisne kategorije problema.
Multimodalno zadovoljstvo i CLV	Rezervacije, recenzije, ponašajni i emocionalni signali	RoBERTa, XGBoost, MLP, SHAP, LIME	Povezivanje korisničkog iskustva sa poslovnim ishodima, segmentacijom i dugoročnom vrednošću korisnika.

4.2.1 Struktura hotelske recenzije

Hotelska recenzija najčešće sadrži numeričku ocenu i tekstualni komentar. U zavisnosti od platforme, komentar može biti podeljen na pozitivni i negativni deo, naslov i telo recenzije, ili slobodni tekst. Numerička ocena može biti izražena na skali od 1 do 5, od 1 do 10 ili nekoj drugoj skali. U analitičkom smislu, recenzija se može predstaviti kao uređeni skup:

$$review_i = (rating_i, text_i, date_i, hotel_i, user_i, meta_i). \quad (4.3)$$

Ovakva struktura omogućava više nivoa analize. Na nivou pojedinačne recenzije može se predviđati ocena ili sentiment. Na nivou hotela može se pratiti reputacija i dinamika zadovoljstva. Na nivou korisnika može se analizirati istorija ponašanja i potencijalna vrednost. Na nivou vremena može se pratiti promena u percepciji usluge, sezonalnost, pojava reputacionih rizika i stabilnost modela kroz buduće periode.

4.2.2 Izazovi u korišćenju recenzija

Korišćenje online recenzija kao izvora podataka nosi više metodoloških izazova. Prvi izazov je subjektivnost. Gosti ne vrednuju uslugu samo prema objektivnim kriterijumima, već i prema očekivanjima, prethodnim iskustvima i svrsi putovanja. Drugi izazov je neravnoteža, jer su pozitivne recenzije često brojnije od negativnih. Treći izazov su kratke ili generičke recenzije, koje sadrže malo informacija. Četvrti izazov je nekonzistentnost između teksta i ocene. Peti izazov je mogućnost anomalija, uključujući ponavljanja, ekstremne ocene, neuobičajene obrasce i potencijalno nepouzdanе zapise.

Ovi izazovi opravdavaju primenu naprednijeg metodološkog okvira. Umesto da se recenzije koriste direktno, potrebno je analizirati njihov kvalitet, pouzdanost i informativnost. Upravo zbog toga se u ovom poglavlju najpre razmatra detekcija anomalija i nekonzistentnosti, zatim sentiment analiza, a tek potom složeniji zadaci predikcije ocena, pritužbi, multimodalnog zadovoljstva, dugoročne vrednosti korisnika i rezervacionog rizika.

4.3 Detekcija anomalija i nekonzistentnosti u hotelskim recenzijama

Pre razvoja prediktivnih modela potrebno je analizirati kvalitet podataka. U hotelijerstvu je ovo posebno važno zato što online recenzije mogu sadržati šum, duplikate, ekstremne vrednosti, vrlo kratke komentare, kontradiktorne signale i potencijalno nepouzdanе obrasce. Detekcija anomalija i nekonzistentnosti zato predstavlja početnu fazu metodološkog lanca u hotelskom domenu.

Anomalija u hotelskim recenzijama ne mora nužno značiti netačan ili zlonameran zapis. Ona može označavati instancu koja odstupa od očekivanog obrasca i zahteva dodatnu pažnju. Na primer, recenzija sa vrlo visokom ocenom i izrazito negativnim tekstom može biti nekonzistentna. Recenzija sa vrlo niskom ocenom i generičkim pozitivnim tekstom takođe može biti nekonzistentna. Veliki broj sličnih recenzija u kratkom periodu može ukazivati na neuobičajeno ponašanje. Istraživanje anomalija u hotelskim recenzijama predstavlja jednu od ranih publikacionih osnova ovog dela disertacije, u kojoj su korišćeni sentiment, sličnost recenzija, vremenski obrasci i topic modeling za identifikaciju neuobičajenih zapisa [40].

4.3.1 Tipovi anomalija

U hotelskim recenzijama mogu se razlikovati sledeći tipovi anomalija:

- **tekstualne anomalije**, kao što su ekstremno kratke, duplirane ili generičke recenzije;
- **ocenske anomalije**, kao što su ekstremne ocene koje ne odgovaraju tekstualnom tonu;
- **vremenske anomalije**, kao što je neuobičajeno velika koncentracija recenzija u kratkom periodu;

- **korisničke anomalije**, kao što su neuobičajeni obrasci aktivnosti korisnika;
- **semantičke nekonzistentnosti**, kao što je neslaganje između pozitivnog i negativnog dela komentara ili između teksta i ocene.

U ranom istraživačkom toku anomalije su analizirane kombinovanjem sentimenta, TF-IDF sličnosti, korelacije između naslova, teksta, oznaka i ocene, kao i vremenske aktivnosti korisnika. Primena normalizovanih skorova i praga od 0.4 omogućila je izdvajanje 132 anomalne recenzije u posmatranom skupu, dok je većina zapisa zadržana kao legitimna. Ovaj rezultat je važan kao broj detektovanih anomalija, ali i kao potvrda da se pouzdanost recenzija može tretirati kao merljiv sloj podataka, a ne kao neformalna procena pre modelovanja. Opšti indikator nekonzistentnosti između ocene i sentimenta može se definisati kao:

$$gap_i = |norm(r_i) - sent(t_i)|, \quad (4.4)$$

gde je $norm(r_i)$ normalizovana ocena recenzije, a $sent(t_i)$ procenjeni sentiment teksta. Veća vrednost gap_i ukazuje na jače neslaganje između numeričke i tekstualne komponente recenzije. Ovaj indikator je koristan za dijagnostiku nekonzistentnosti, ali se mora pažljivo tumačiti u odnosu na zadatak predikcije ocene.

4.3.2 Dijagnostika nekonzistentnosti i pouzdanosti za modelovanje

Ovde je važno razlikovati dva pojma: dijagnostičku nekonzistentnost i pouzdanost koja se koristi u prediktivnom modelovanju. Dijagnostička nekonzistentnost može koristiti odnos između ocene i teksta, jer joj je cilj da otkrije slučajeve u kojima različiti delovi recenzije šalju suprotne signale. Međutim, kada je cilj modela predikcija same ocene, direktno korišćenje ocene u konstrukciji ulaznih obeležja ili filtriranju test skupa može dovesti do curenja informacija. Zbog toga se u najstrožem regresionom protokolu pouzdanost mora konstruisati pomoću signala koji ne zavise direktno od ciljne ocene. Jedan mogući oblik kompozitnog indikatora pouzdanosti, kada se koristi za analizu kvaliteta recenzije, može se zapisati kao:

$$Rel_i = 1 - (w_1 A_i + w_2 G_i + w_3 S_i + w_4 R_i), \quad (4.5)$$

gde je A_i indikator anomalije, G_i indikator neslaganja između različitih tekstualnih komponenti ili kontrolisani signal nekonzistentnosti, S_i indikator ekstremne kratkoće ili neinformativnosti teksta, R_i indikator ponavljanja ili sličnosti sa drugim recenzijama, a w_1, w_2, w_3, w_4 težinski koeficijenti. U zadacima u kojima se predviđa ocena, komponenta G_i mora biti definisana bez direktnog korišćenja ciljne ocene, na primer kroz neslaganje sentimenta naslova i tela recenzije, ponavljanje teksta, kratkoću, prethodnu aktivnost korisnika ili druge signale dostupne nezavisno od ciljne promenljive.

Razlika između ova dva pristupa prikazana je u Tabeli 4.3. Tabela naglašava da isti tip signala ne mora imati istu metodološku ulogu u svim zadacima: u dijagnostičkoj analizi ocena može pomoći da se uoči neslaganje između numeričke i tekstualne poruke recenzije, dok u regresionom modelovanju ona ne sme postati deo ulazne konstrukcije ako predstavlja ciljnu promenljivu. Na taj način se pouzdanost recenzije ne tretira samo kao pitanje kvaliteta podataka, već i kao pitanje validnosti eksperimentalnog protokola.

Tabela 4.3: Razlika između dijagnostike nekonzistentnosti i pouzdanosti za prediktivno modelovanje.

Element	Dijagnostika nekonzistentnosti	Pouzdanost za prediktivno modelovanje
Cilj	Otkriti neslaganje između delova recenzije	Procena informativnosti zapisa bez narušavanja validacije
Upotreba ocene	Može koristiti ocenu radi post-hoc analize	Ne sme koristiti ciljnu ocenu ako se ta ocena predviđa
Primer signala	Neslaganje ocene i sentimenta teksta	Ponavljanje teksta, kratkoća, title–text sentiment gap, aktivnost korisnika
Uloga u disertaciji	Razumevanje kvaliteta i integriteta recenzija	Kontrolisana evaluacija modela bez curenja informacija

Ovo razdvajanje predstavlja jedan od ključnih metodoloških doprinosa hotelskog dela disertacije. Kvalitet podataka se ne posmatra kao mehaničko čišćenje, već kao istraživački problem koji direktno utiče na validnost modela i tumačenje rezultata.

4.3.3 Nekonzistentne recenzije

Nekonzistentne recenzije predstavljaju poseban oblik anomalije u kojem različiti delovi recenzije šalju suprotne signale. Na primer, gost može dati ocenu 10, ali u tekstu navesti niz ozbiljnih problema. Suprotno tome, može dati nisku ocenu, ali tekstualno izraziti zadovoljstvo. Ovakvi slučajevi ne moraju biti greška, ali mogu značajno uticati na trening modela i interpretaciju rezultata i onemogućiti pravilnu predikciju.

Ranije istraživanje o detekciji nekonzistentnih hotelskih recenzija pokazuje da se kombinovanjem VADER sentimenta [41], korelacionih pragova, tekstualnih signala i XGBoost modela mogu identifikovati obrasci koji zahtevaju dodatnu proveru [42]. U toj analizi model je ostvario tačnost od 88%, pri čemu je za klasu nekonzistentnih recenzija postignut odziv od 0.92 i F1 mera od 0.90. Ovakav rezultat je važan zato što pokazuje da se integritet recenzija može kvantifikovati pomoću modela koji ne služe samo za uklanjanje šuma, već i za razumevanje odnosa između korisničkog teksta, ocene i poverenja u platformu.

Tabela 4.4 sistematizuje ključne signale koji pokazuju da problematična recenzija nije samo negativna recenzija, već i zapis u kojem su informativnost, autentičnost ili odnos između ocene i teksta dovoljno narušeni da mogu promeniti ponašanje prediktivnog modela.

Tabela 4.4: Primeri indikatora anomalija i nekonzistentnosti u hotelskim recenzijama.

Indikator	Opis	Moguće značenje
Ekstremno kratak tekst	Recenzija sadrži veoma mali broj reči	Niska informativnost ili brz odgovor korisnika
Duplirani tekst	Isti ili gotovo isti tekst se ponavlja	Tehnički duplikat ili sumnjiv obrazac
Ocena–sentiment nepoklapanje	Velika razlika između ocene i sentimenta teksta	Nekonzistentnost ili složeno iskustvo
Vremenski pik	Veliki broj recenzija u kratkom periodu	Kampanja, događaj ili neuobičajena aktivnost
Ekstremna ocena bez objašnjenja	Najviša ili najniža ocena uz generički tekst	Moguća niska analitička vrednost

4.4 Sentiment analiza i prepoznavanje negativnih recenzija

Negativne recenzije imaju značajnu ulogu u hotelijerstvu. One ukazuju na probleme koji mogu uticati na reputaciju hotela, zadovoljstvo budućih gostiju, ponovljene rezervacije i prihod. Za menadžment hotela, prepoznavanje negativnih recenzija nije samo zadatak klasifikacije teksta, već instrument ranog upozorenja koji omogućava brzu reakciju na probleme. Sentiment analiza predstavlja proces automatske procene evaluativnog tona teksta. U najjednostavnijem obliku, recenzije se mogu klasifikovati kao pozitivne, negativne ili neutralne. U složenijem obliku, sentiment se može posmatrati kao kontinuirana vrednost:

$$sent(t_i) \in [-1, 1], \quad (4.6)$$

gde vrednosti bliže -1 označavaju negativan sentiment, vrednosti bliže 1 pozitivan sentiment, a vrednosti oko nule neutralan ili mešoviti ton.

U okviru disertacije, detekcija negativnih hotelskih recenzija posmatra se kao klasifikacioni problem. Cilj je da se na osnovu tekstualnog sadržaja recenzije i pratećih numeričkih signala proceni da li recenzija sadrži negativno iskustvo ili pritužbu. Prethodno istraživanje o automatskoj detekciji negativnih hotelskih recenzija pomoću dubokog učenja predstavlja važnu empirijsku osnovu ove sekcije [43]. U tom istraživanju početni model ostvario je tačnost od 86.2%, preciznost od 82.4%, odziv od 74.1% i F1 meru od 78.1%, dok je optimizovani

model, nakon podešavanja hiperparametara, balansiranja klase i poboljšanog pretprocesiranja, dostigao tačnost od 90.1%, preciznost od 88.6%, odziv od 85.2% i F1 meru od 86.9%.

4.4.1 Definisanje negativne recenzije

Negativna recenzija ne mora uvek imati nisku numeričku ocenu. Gost može dati srednju ili čak relativno visoku ocenu, ali u tekstu navesti konkretne probleme. Zbog toga se negativnost ne može definisati isključivo na osnovu ocene. Potrebno je kombinovati numeričku ocenu, tekstualne signale, kontekst i eventualno domenski definisane pragove. Binarna oznaka negativne recenzije može se definisati kao:

$$y_i = \begin{cases} 1, & \text{ako recenzija sadrži negativan obrazac ili pritužbu,} \\ 0, & \text{u suprotnom.} \end{cases} \quad (4.7)$$

U zavisnosti od dostupnih oznaka, negativna klasa može biti izvedena iz ocene, ručne anotacije, sentiment modela ili kombinovanog pravila. Ipak, metodološki je poželjno da se tekstualni signal ne svodi na numeričku ocenu, jer se time mogu izgubiti važne informacije.

4.4.2 Modeli za sentiment analizu

Za sentiment analizu mogu se koristiti tradicionalni i duboki modeli. Tradicionalni pristupi obično kombinuju TF-IDF reprezentaciju sa logističkom regresijom, SVM modelom ili Naive Bayes klasifikatorom. Duboki modeli koriste vektorske reprezentacije, rekurentne mreže ili transformer arhitekture. U istraživanju negativnih recenzija posebno je značajna kombinacija tekstualnih i numeričkih obeležja, jer omogućava da model ne uči samo na osnovu izolovanog teksta, već i na osnovu odnosa teksta, ocene i drugih atributa. U klasifikacionom zadatku model procenjuje verovatnoću negativne klase:

$$\hat{p}_i = P(y_i = 1 | t_i), \quad (4.8)$$

a konačna oznaka se dobija poređenjem sa pragom τ :

$$\hat{y}_i = \begin{cases} 1, & \hat{p}_i \geq \tau, \\ 0, & \hat{p}_i < \tau. \end{cases} \quad (4.9)$$

Izbor praga τ zavisi od domenskog cilja. Ako je cilj da se propusti što manje stvarnih negativnih recenzija, prag može biti niži kako bi se povećao odziv. Ako je cilj da se smanji broj lažnih upozorenja, prag može biti viši kako bi se povećala preciznost. U hotelskom menadžmentu je ovo posebno važno jer lažno negativni ishod može značiti propuštenu pritužbu, dok lažno pozitivni ishod može nepotrebno opteretiti tim za korisničku podršku.

4.4.3 Poslovno značenje negativnih recenzija

U hotelskom menadžmentu, negativne recenzije imaju vrednost samo ako se mogu povezati sa konkretnim dimenzijama usluge. Zato se sentiment analiza ne sme završiti binarnom klasifikacijom. Potrebno je analizirati i sadržaj negativnosti: da li se pritužba odnosi na higijenu, osoblje, lokaciju, doručak, buku, cenu, komunikaciju, rezervaciju ili tehničke probleme.

Tabela 4.5 prikazuje kako se negativne hotelske recenzije mogu prevesti iz opšteg sentimenta u konkretnije kategorije problema. Takva podela je važna zato što model detekcije negativnosti ne treba da zaustavi analizu na zaključku da je recenzija nepovoljna, već treba da omogući povezivanje tekstualnih signala sa mogućim menadžerskim reakcijama.

Rezultati iz perioda početka doktorskih studija pokazali su da analiza negativnih recenzija može prerasti iz klasifikacije sentimenta u širi oblik poslovne inteligencije, čime je motivisan dalji razvoj modela za hotelski menadžment. Sam proces prikupljanja podataka, od ličnog web scraping-a do pretrage javno dostupnih skupova za treniranje, pokazao je koliko su online recenzije vredan izvor za razumevanje i analitiku ponašanja korisnika na internetu.

Tabela 4.5: Primeri kategorija negativnih hotelskih recenzija.

Kategorija	Tipični tekstualni signali	Moguća menadžerska reakcija
Higijena	prljavo, neuredno, neprijatan miris	Kontrola kvaliteta soba i zajedničkih prostora
Osoblje	neljubazno, sporo, neprofesionalno	Trening zaposlenih i praćenje usluge
Buka	bučno, loša izolacija, čuje se svaki korak, nemoguće spavati	Promena rasporeda soba ili tehnička intervencija
Lokacija	daleko, teško dostupno, slaba konekcija sa gradskim prevozom	Jasnije informisanje gostiju pre rezervacije
Cena i vrednost	preskupo, ne vredi, loš odnos cena-kvalitet	Revizija cenovne strategije i ponude

Slika 4.1 prikazuje matricu konfuzije modela za detekciju negativnih hotelskih recenzija na testnom uzorku od 2.000 online recenzija hotela, prikupljenih iz javno dostupnog skupa podataka sa recenzijama evropskih hotela, pretežno iz Belgije i Holandije. Model je pravilno klasifikovao 1280 nenegativnih i 510 negativnih recenzija, dok je 120 nenegativnih recenzija pogrešno označeno kao negativno, a 90 negativnih recenzija ostalo neprepoznato. Posebno je važno što je broj lažno negativnih ishoda relativno nizak, jer propuštanje zaista negativnih recenzija može imati direktne posledice za praćenje kvaliteta usluge i blagovremenu reakciju hotelskog menadžmenta.

Stvarno: ne-negativna	TN 1280	FP 120
	FN 90	TP 510
	Predviđeno: ne-negativna	Predviđeno: negativna

Slika 4.1: Matrica konfuzije za model detekcije negativnih hotelskih recenzija.

4.5 Predikcija hotelskih ocena na osnovu tekstualnih karakteristika recenzija

Predikcija hotelskih ocena na osnovu tekstualnih karakteristika recenzija predstavlja centralni regresioni zadatak ovog poglavlja. Osnovna ideja je da tekst recenzije sadrži dovoljno informacija da se može proceniti numerička ocena koju je gost dodelio hotelu, čak i kada se polazi prvenstveno od samog korisničkog narativa. Ovaj zadatak je važan zato što povezuje subjektivni opis iskustva sa kvantitativnim merama zadovoljstva.

U okviru disertacije, ovaj pravac se razvija kroz konferencijski i časopisni istraživački tok. Konferencijski rad INFOTEH 2025 predstavlja prethodnu fazu ovog pravca, u kojoj su primenjene vektorske reprezentacije i rekurentne arhitekture za predikciju hotelskih ocena na osnovu naslova, teksta i oznaka recenzija [44]. Taj rad je pokazao da pojedinačne reči i kratki tekstualni signali mogu imati merljiv prediktivni značaj, dok metodološki unapređena i centralna publikaciona osnova ovog dela jeste rad objavljen u časopisu *Computers*, u kojem je razvijen okvir za predikciju hotelskih ocena iz online povratnih informacija gostiju, uz modelovanje pouzdanosti recenzija i neuralnu analizu teksta [45]. U tom pravcu se predikcija ocene ne posmatra samo kao tehničko pogađanje broja, već kao provera koliko model razume odnos između tona recenzije, sadržaja pritužbe, pouzdanosti zapisa i ukupnog iskustva gosta.

Ovaj pravac je posebno značajan za disertaciju jer jasno povezuje razvoj modela, hronološku podelu podataka, kontrolu curenja informacija, poređenje tradicionalnih i dubokih modela i interpretaciju rezultata u hotelijerskom kontekstu. Time predikcija ocena ne predstavlja samo izolovan regresioni zadatak, već centralni dokaz da se tekstualni narativi korisnika mogu prevesti u merljive i poslovno relevantne indikatore zadovoljstva.

4.5.1 Formulacija regresionog zadatka

Neka je t_i tekst recenzije, a r_i stvarna numerička ocena. Cilj je naučiti funkciju f_θ koja procenjuje ocenu na osnovu tekstualnog i eventualno dodatnog ulaza:

$$\hat{r}_i = f_\theta(t_i), \quad (4.10)$$

ili, u multimodalnom obliku:

$$\hat{r}_i = f_\theta(t_i, m_i), \quad (4.11)$$

gde m_i označava metapodatke ili dodatne karakteristike recenzije. Funkcija gubitka u regresionom zadatku može biti srednja kvadratna greška:

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (r_i - \hat{r}_i)^2. \quad (4.12)$$

Međutim, u hotelijerskom kontekstu srednja apsolutna greška često je pogodnija jer pokazuje prosečno odstupanje predviđene ocene od stvarne ocene:

$$MAE = \frac{1}{n} \sum_{i=1}^n |r_i - \hat{r}_i|. \quad (4.13)$$

4.5.2 Eksperimentalni protokol i sprečavanje curenja informacija

Kod hotelskih recenzija važno je sprečiti curenje informacija. Ako se recenzije nasumično podele na trening i test skup, može se dogoditi da model uči obrasce povezane sa istim hotelima, istim periodima ili informacijama koje u realnom scenariju ne bi bile dostupne. Zbog toga je hronološka podela jača kada se model koristi za predikciju budućih recenzija. Hronološka podela može se predstaviti kao:

$$D_{train}^{time} < D_{val}^{time} < D_{test}^{time}, \quad (4.14)$$

gde D_{train}^{time} označava vremenski najraniji skup za treniranje modela, D_{val}^{time} validacioni skup iz narednog perioda, a D_{test}^{time} vremenski najkasniji test skup. Ova podela znači da se model trenira na ranijim recenzijama, validira na kasnijim zapisima i testira na najnovijem periodu. U proširenom istraživanju korišćen je Booking.com skup sa 26.675 recenzija i 819 hotela. Nakon minimalnog čišćenja zadržane su 26.384 recenzije, a hronološka podela sprovedena je pre formiranja tekstualnih reprezentacija, računanja pouzdanosti i treniranja modela. Trening, validacioni i test skup obuhvatili su 18.468, 2.639 i 5.277 recenzija, pri čemu test skup nije filtriran na osnovu pouzdanosti. Ovaj protokol je važan jer sprečava da se rezultati modela prikažu kao bolji samo zato što su iz test skupa uklonjeni teži ili manje pouzdani primeri.

4.5.3 Referentni modeli i duboko učenje

Metodološki ispravan pristup zahteva poređenje dubokih modela sa jednostavnijim referentnim rešenjima. U ovom zadatku referentni pristup predstavljaju TF-IDF reprezentacije u kombinaciji sa Ridge regresijom i dodatnim obeležjima pouzdanosti konstruisanim bez curenja informacija. Napredniji modeli uključuju LSTM, BiLSTM, BiLSTM sa pažnjom i transformer arhitekture, među kojima su DistilBERT, BERT, RoBERTa, MobileBERT i TinyBERT. Njihovo poređenje je korisno jer obuhvata modele različite složenosti, od punih transformer arhitektura do kompaktnijih varijanti prilagođenih bržoj primeni sa manjim zahtevima za računarske resurse.


Uloga referentnog modela je da pokaže koliki deo prediktivnog signala može biti uhvaćen jednostavnim tekstualnim karakteristikama. Ako transformer model daje značajno bolju performansu, tada se može tvrditi da kontekstualna reprezentacija teksta donosi dodatnu vrednost. Ako razlika nije značajna, potrebno je razmotriti da li je složeniji model opravdan u pogledu resursa i interpretabilnosti. U ovom zadatku rezultati pokazuju da transformer modeli zaista donose prednost u prosečnoj grešci, ali i da BiLSTM modeli mogu biti osetljiviji na retke recenzije sa niskim ocenama. To znači da izbor modela zavisi od toga da li je cilj minimizacija prosečne greške ili bolje prepoznavanje negativnog iskustva.

4.5.4 Rezultati modela i doprinos zadatka predikcije ocena

Rezultati pokazuju da transformer reprezentacije mogu ostvariti bolju prediktivnu performansu u odnosu na tradicionalne i rekurentne pristupe. DistilBERT ostvaruje najnižu prosečnu grešku i najbolji koeficijent determinacije, što ukazuje na snažnu sposobnost modela da iz kratkih i pozitivno asimetričnih recenzija izdvoji relevantne semantičke signale. Istovremeno, BiLSTM modeli ostvaruju viši odziv na recenzije sa niskim ocenama, što je važno jer niske ocene često nose veću menadžersku vrednost od malih razlika među visokim ocenama.

Slika 4.2 prikazuje uporedne performanse tri modela za predikciju hotelskih ocena prema MAE metrici, odnosno srednjoj apsolutnoj grešci između stvarne i predviđene ocene. Niža MAE vrednost označava precizniju predikciju, pa se vidi da tradicionalni TF-IDF + Ridge model ostvaruje grešku od 0.5913, BiLSTM model sa pažnjom smanjuje grešku na 0.5353, dok DistilBERT postiže najbolji rezultat sa MAE vrednošću od 0.4370. Ovaj rezultat pokazuje da kontekstualne transformer reprezentacije bolje hvataju nijanse korisničkog iskustva u kratkim, subjektivnim i često asimetričnim hotelskim recenzijama, zbog čega se DistilBERT izdvaja kao najuspešniji model u ovom poređenju.

Tabela 4.6 prikazuje sažetak ključnih modela korišćenih u zadatku predikcije hotelskih ocena. Rezultati pokazuju jasnu prednost kontekstualnog transformer pristupa u odnosu na tradicionalnu TF-IDF reprezentaciju i rekurentne neuronske modele, uz napomenu da pojedini rekurentni modeli ostvaruju bolju osetljivost na niske ocene.



Slika 4.2: Poređenje performansi modela za predikciju hotelskih ocena.

Tabela 4.6: Sažetak modela za predikciju hotelskih ocena na hronološkom test skupu.

Model	Reprezentacija	MAE	RMSE	R^2	Niske ocene
TF-IDF + Ridge + pouzdanost	Klasična tekstualna i kontrolisana obeležja	0.5913	0.8778	0.7182	76.16%
LSTM	Sekvencijalna neuralna reprezentacija	0.6012	0.9019	0.7024	77.59%
BiLSTM	Dvosmerna sekvencijalna reprezentacija	0.5376	0.8728	0.7213	84.05%
BiLSTM + pažnja	Sekvencijalna reprezentacija sa pažnjom	0.5353	0.8845	0.7138	82.83%
DistilBERT	Kontekstualna transformer reprezentacija	0.4370	0.6979	0.8217	75.60%

Dodatne analize u proširenom istraživanju uključuju proveru jezičke strukture korpusa, testiranje generalizacije na prethodno neviđenim hotelima, analizu osetljivosti pragova pouzdanosti i prognozu dinamike budućih hotelskih ocena kroz horizonte od 7, 30, 60 i 90 dana. Time se hotelski domen ne iscrpljuje samo predikcijom pojedinačne ocene, već ostaje važan istraživački tok koji je još uvek aktuelan. Ove analize imaju i važnu metodološku funkciju: pokazuju da se rezultat ne zasniva samo na jednoj podeli podataka ili jednom pragu filtriranja, već na širem protokolu stabilnosti i generalizacije.

4.6 Transformer modeli za analizu sentimenta i kategorija pritužbi gostiju

Iako predikcija ocene pruža važan kvantitativni uvid, hotelskom menadžmentu je često potrebna detaljnija informacija o tome na šta se nezadovoljstvo odnosi. Gost može dati nisku ocenu zbog širokog spektra razloga, stoga je detekcija kategorija pritužbi važan nastavak sentiment analize i predikcije ocena.

Negativne hotelske recenzije posebno su korisne za razumevanje pritužbi gostiju, jer BERT-zasnovani pristupi omogućavaju prepoznavanje kontekstualnih obrazaca nezadovoljstva [46]. Transformer modeli su posebno pogodni za ovaj zadatak jer mogu obuhvatiti kontekstualno značenje recenzije. Ista reč može imati različito značenje u zavisnosti od rečenice. Na primer, izraz *cold* može označavati hladnu sobu, hladan obrok ili hladan odnos osoblja. Kontekstualni modeli omogućavaju da se ovakve razlike bolje prepoznaju.

Prethodno istraživanje o transformer arhitekturama za višelabelnu detekciju pritužbi i sentiment analizu u hotelskim sistemima za obradu povratnih informacija predstavlja publikacionu osnovu ovog dela poglavlja [47]. U tom pravcu korišćeni su hotelski tekstualni podaci i dopunski korpusi pritužbi, uključujući javno dostupne TripAdvisor recenzije i Consumer Complaint Database kao širi izvor tekstualnih narativa pritužbi [48, 49].

Hotelska recenzija može sadržati više pritužbi istovremeno. Zbog toga zadatak nije uvek višeklasna klasifikacija, gde svaka instanca pripada samo jednoj klasi, već višelabelna klasifikacija, gde jedna recenzija može pripadati više kategorija.

Ako postoji K kategorija pritužbi, ciljna oznaka za recenziju i može se zapisati kao vektor. Na primer, ako se pritužbe dele na kategorije kao što su higijena, osoblje, buka i lokacija, ista recenzija može istovremeno pripadati jednoj, nijednoj ili više kategorija.

$$y_i = (y_{i1}, y_{i2}, \dots, y_{iK}), \quad (4.15)$$

gde je $y_{ik} = 1$ ako recenzija sadrži pritužbu kategorije k , a $y_{ik} = 0$ u suprotnom. Model procenjuje verovatnoću svake kategorije:

$$\hat{p}_{ik} = P(y_{ik} = 1 | t_i). \quad (4.16)$$

Konačna oznaka dobija se poređenjem sa pragom:

$$\hat{y}_{ik} = \begin{cases} 1, & \hat{p}_{ik} \geq \tau_k, \\ 0, & \hat{p}_{ik} < \tau_k. \end{cases} \quad (4.17)$$

Prag τ_k može biti isti za sve kategorije ili prilagođen individualno u zavisnosti od učestalosti i značaja pritužbe. U hotelskom kontekstu ovo je važno jer kategorije nemaju jednaku poslovnu težinu: pritužbe na higijenu ili bezbednost traže hitniju reakciju od pritužbi na stil enterijera.

4.6.1 Kategorije pritužbi

Kategorije pritužbi mogu se definisati na osnovu hotelskog konteksta. Tabela 4.7 prikazuje kako se najučestalije kategorije mogu razraditi kroz opis problema i tipične tekstualne signale koji se javljaju u analiziranim recenzijama gostiju.

Tabela 4.7: Primer višelabelnih kategorija pritužbi u hotelskim recenzijama.

Kategorija	Opis	Primer tekstualnog signala
Higijena	Čistoća sobe, kupatila i zajedničkih prostora	dirty room, bathroom was not clean
Osoblje	Ljubaznost, profesionalnost i brzina reakcije	rude staff, helpful receptionist
Buka	Akustika, spoljna buka i smetnje tokom spavanja	noisy street, could not sleep
Doručak/hrana	Kvalitet i raznovrsnost hrane	poor breakfast, limited options
Cena/vrednost	Odnos cene i kvaliteta	not worth the price, overpriced
Rezervacija	Problemi sa booking procesom i dostupnošću sobe	reservation problem, room not available

4.6.2 Arhitektura modela za pritužbe

Transformer model za detekciju pritužbi može se predstaviti kao:

$$h_i = \text{Transformer}(t_i), \quad (4.18)$$

$$\hat{y}_i = \sigma(Wh_i + b), \quad (4.19)$$

gde je h_i kontekstualna vektorska reprezentacija recenzije dobijena iz transformer sloja, W matrica težina izlaznog sloja, b pristrasni član, a σ sigmoidna funkcija koja omogućava nezavisnu procenu verovatnoće pripadnosti svakoj kategoriji pritužbe.


U empirijskoj proveru RoBERTa je ostvarila bolje rezultate od BERT modela. Za sentiment klasifikaciju postignuta je prosečna F1 mera od 0.928, dok je BERT ostvario 0.892. U višelabelnoj detekciji pritužbi RoBERTa je postigla srednju preciznost od 87% i makro F1 meru od 0.861, naspram 0.824 kod BERT modela. Analiza krivih preciznosti i odziva (*precision-recall*) pokazuje da prednost RoBERTa modela nije jednaka u svim kategorijama: za kategorije kao što je higijena prednost je izraženija, dok se kod ambivalentnijih kategorija, kao što su problemi sa rezervacijom, krive približavaju. To potvrđuje da se višelabelni zadatak ne može svesti na jednu zbirnu metriku, već zahteva analizu po kategorijama.

4.6.3 Doprinos detekcije pritužbi

Doprinos ovog zadatka ogleda se u prelasku sa opšte procene sentimenta na operativno korisnu klasifikaciju problema. Model koji samo označi recenziju kao negativnu može biti koristan za filtriranje, ali model koji identifikuje kategoriju pritužbe može direktno podržati menadžersku akciju. Na primer, pritužbe na higijenu mogu biti prosleđene operativnom sektoru, pritužbe na rezervaciju recepciji, a pritužbe na cenu menadžmentu prihoda.

Transformer modeli ne koriste samo za opštu klasifikaciju sentimenta, već i za višelabelnu identifikaciju konkretnih aspekata korisničkog nezadovoljstva. Dodatna primena SHAP i LIME pristupa omogućila je proveru da model ne zasniva odluke isključivo na čestim ili generičkim tokenima, nego na semantički relevantnim izrazima, kao što su izrazi koji ukazuju na izostanak čišćenja, neprijatan miris kupatila ili ignorisanje zahteva gosta. Time se tekstualna analitika približava realnim operativnim potrebama hotela, a model postaje instrument za strukturisanje povratnih informacija gostiju.

Slika 4.3 prikazuje interpretabilni prikaz doprinosa pojedinačnih tekstualnih signala u detekciji hotelskih pritužbi. Ovde SHAP procenjuje doprinos pojedinačnih termina predikciji, dok LIME proverava da li isti signali ostaju važni pri lokalnim izmenama teksta. Crvenim nijansama označeni su izrazi koji model usmeravaju ka prepoznavanju konkretne pritužbe, kao što su izostanak usluge, ignorisanje gosta ili problem sa higijenom, dok zelene nijanse označavaju pozitivne signale koji smanjuju verovatnoću negativnog tumačenja recenzije. Na taj način se rezultat modela povezuje sa konkretnim jezičkim obrascima koji mogu ukazati na potrebu za poslovnom reakcijom hotela.



Slika 4.3: Doprinos tekstualnih signala u detekciji hotelskih pritužbi prema SHAP/LIME analizi.

4.7 Multimodalno modelovanje zadovoljstva korisnika hotelskih usluga

Zadovoljstvo gosta ne zavisi samo od teksta recenzije ili samo od numeričke ocene. Ono se formira kroz kombinaciju očekivanja, iskustva, usluge, cene, lokacije, tipa putovanja, rezervacionih okolnosti i prethodnih interakcija. Zbog toga multimodalno modelovanje predstavlja prirodan nastavak tekstualne analize u hotelijerstvu.

Multimodalni model integriše više izvora podataka. U hotelskom domenu to mogu biti tekst recenzije, numeričke ocene, metapodaci o hotelu, tip putovanja, istorija recenzija, rezervacioni atributi i izvedeni indikatori pouzdanosti. U okviru ove disertacije multimodalno modelovanje zadovoljstva korisnika razmatra se kao posebna empirijska analiza koja povezuje tekstualne i strukturisane signale hotelskog iskustva [50]. U toj analizi numerički podaci iz rezervacionih sistema, kao što su dužina boravka, period između rezervacije i planiranog dolaska, broj posebnih zahteva i cena noćenja, kombinovani su sa RoBERTa reprezentacijama tekstualnih recenzija. Posebno je značajno to što se tekstualne recenzije koriste tokom treniranja radi učenja latentnih obrazaca zadovoljstva, dok se u operativnoj primeni rizik nezadovoljstva može procenjivati na osnovu atributa dostupnih pre dolaska gosta.

4.7.1 Formalni prikaz multimodalnog modela

Neka su t_i tekstualni podaci za gosta ili recenziju i , n_i numeričke karakteristike, c_i kategorijalne karakteristike, a m_i metapodaci o rezervaciji, hotelu ili korisničkoj interakciji. U hotelskom kontekstu t_i može obuhvatiti tekst recenzije, n_i ocenu, cenu, dužinu boravka ili broj posebnih zahteva, c_i tip sobe, segment gosta ili kanal rezervacije, dok m_i može sadržati informacije o hotelu, datumu boravka ili prethodnoj aktivnosti korisnika. Multimodalna reprezentacija nastaje tako što se svaki izvor podataka najpre transformiše u odgovarajući vektorski oblik, a zatim se ti prikazi spajaju u zajednički vektor:

$$z_i = [\phi_t(t_i), \phi_n(n_i), \phi_c(c_i), \phi_m(m_i)], \quad (4.20)$$

gde funkcije ϕ_t , ϕ_n , ϕ_c i ϕ_m predstavljaju transformacije pojedinačnih modaliteta, odnosno postupke kojima se tekstualni, numerički, kategorijalni i metapodaci prevode u oblik pogodan za modelovanje. Konačna predikcija zadovoljstva može se zapisati kao:

$$\hat{s}_i = f_\theta(z_i), \quad (4.21)$$

gde je $\hat{s}_i$ predviđena vrednost zadovoljstva ili verovatnoća pripadnosti određenoj kategoriji zadovoljstva, a f_θ prediktivni model sa parametrima θ . Ovakav zapis pokazuje da model ne donosi odluku na osnovu jednog izvora, već na osnovu objedinjene reprezentacije više komplementarnih signala, čime se tekstualni utisak gosta povezuje sa merljivim ponašajnim i kontekstualnim podacima.

4.7.2 Strategije fuzije podataka

U hotelskom domenu mogu se koristiti tri osnovne strategije fuzije. Rana fuzija podrazumeva spajanje svih obeležja pre modelovanja. Kasna fuzija podrazumeva odvojene modele za tekst, numeričke i kategorijalne podatke, čije se predikcije zatim kombinuju. Hibridna fuzija kombinuje prednosti oba pristupa i može uključiti neuronske slojeve za spajanje reprezentacija. Tabela 4.8 prikazuje osnovne načine spajanja različitih izvora podataka u multimodalnom modelu. Ova podela je važna jer izbor strategije fuzije utiče na to da li će model ranije povezati tekstualne, numeričke i kategorijalne signale ili će svaki izvor najpre obraditi zasebno, a zatim ih spojiti u završnoj fazi predikcije.

Tabela 4.8: Strategije multimodalnog modelovanja zadovoljstva gostiju.


Strategija	Opis	Prednosti i ograničenja
Rana fuzija	Spajanje tekstualnih i strukturisanih obeležja pre modela	Jednostavna implementacija, ali može zanemariti specifičnost modaliteta
Kasna fuzija	Odvojeni modeli za različite modalitete, zatim kombinovanje predikcija	Fleksibilna, ali može propustiti duboke interakcije
Hibridna fuzija	Učenje posebnih reprezentacija i njihovo spajanje u zajednički sloj	Najbogatija, ali zahteva više podataka i pažljivu validaciju

Slika 4.4 prikazuje multimodalnu arhitekturu za predikciju zadovoljstva hotelskih gostiju. Različiti izvori podataka, uključujući tekstualne recenzije, numeričke attribute rezervacije, kategorijalne osobine i metapodatke, najpre se transformišu u odgovarajuće reprezentacije, zatim spajaju u zajednički vektor i koriste za konačnu procenu zadovoljstva. Time se naglašava da model ne posmatra iskustvo gosta samo kroz jedan signal, već kroz kombinaciju tekstualnog utiska, ocene, konteksta boravka i karakteristika rezervacije.

4.7.3 Prednosti i rezultati multimodalnog pristupa

Multimodalni pristup može doprineti modelovanju zadovoljstva na tri načina. Prvo, tekstualni podaci pružaju semantičko objašnjenje iskustva gosta. Drugo, numeričke i kategorijalne karakteristike pružaju kontekst koji tekst ne mora sadržati. Treće, kombinovanje izvora može povećati efikasnost modela, jer se model ne oslanja samo na jedan signal.

Međutim, multimodalnost ne garantuje automatski bolje rezultate. Ako dodatni modaliteti ne nose nove informacije ili uvode šum, performanse mogu ostati iste ili se pogoršati. Zato je potrebno sprovesti analizu uklanjanja pojedinačnih komponenti modela (*ablation analysis*), poredeći modele koji koriste samo tekst, samo strukturisane podatke i kombinaciju više modaliteta. Dobitak multimodalnog pristupa može se izraziti razlikom između rezultata



Slika 4.4: Multimodalna arhitektura za predikciju zadovoljstva hotelskih gostiju.

fuzionog modela i tekstualnog modela:

$$\Delta_{multi} = Score_{text+meta} - Score_{text}, \quad (4.22)$$

gde Δ_{multi} označava dobitak od dodavanja metapodataka tekstualnom modelu. Pozitivna vrednost ukazuje da multimodalnost doprinosi performansima.

U empirijskoj analizi zadovoljstva hotelskih korisnika osnovni multimodalni model ostvario je tačnost od približno 84.9%, F1 meru oko 0.82 i ROC–AUC oko 0.88. Nakon optimizacije hiperparametara model je dostigao tačnost blisku 90% i F1 meru od 0.87, nadmašujući referentne modele logističke regresije i Random Forest. Ovakav rezultat je očekivan jer zadovoljstvo gosta ne zavisi samo od tona recenzije, već i od šireg konteksta boravka, tipa usluge i prethodnog iskustva. Ovaj rezultat ima metodološki značaj jer pokazuje da semantički signal iz recenzija, kada se kombinuje sa strukturisanim podacima o boravku i korisničkom kontekstu, može poboljšati procenu zadovoljstva, ali i aplikativni značaj jer omogućava ranije prepoznavanje rizika nezadovoljstva i pravovremeniju reakciju hotela.

4.8 Procena dugoročne vrednosti korisnika u hotelijerstvu

Analiza hotelskih recenzija i ocena pruža uvid u pojedinačno iskustvo gosta, ali poslovni značaj korisnika često prevazilazi jednu recenziju ili jedan boravak. Zbog toga se u hotelijerstvu sve više razmatra dugoročna vrednost korisnika, odnosno *Customer Lifetime Value*. CLV predstavlja procenu ukupne vrednosti koju korisnik može doneti organizaciji tokom budućeg odnosa, kroz ponovljene boravke, dodatnu potrošnju, preporuke i dugoročnu lojalnost.

U kontekstu ove disertacije, CLV je važan zato što povezuje bihevioralne, emocionalne i poslovne dimenzije korisničkog ponašanja. Procena dugoročne vrednosti ne zavisi samo od potrošnje, već i od zadovoljstva, lojalnosti, emocionalne povezanosti, verovatnoće ponovlje-

ne kupovine i reputacionog uticaja korisnika. Na taj način se analiza pomera sa pojedinačne transakcije ka dugoročnom odnosu između gosta i hotelskog sistema. Literatura o CLV u hotelskom i avio-kontekstu ukazuje da se dugoročna vrednost korisnika mora posmatrati kroz međudejstvo iskustva, angažovanja i budućeg ponašanja korisnika [51]. Pored toga, predikcija budućih obrazaca odliva korisnika (*churn patterns*) kod ponovljenih hotelskih korisnika pokazuje da je za razumevanje lojalnosti potrebno povezati prethodno ponašanje, zadovoljstvo i kontekst boravka [52].

Prethodno istraživanje o primeni prediktivnih AI modela za CLV u hotelijerstvu predstavlja jednu od publikacionih osnova ove sekcije [53]. U toj analizi hibridni model koji kombinuje RoBERTa reprezentacije recenzija i XGBoost obradu strukturisanih rezervacionih atributa dostigao je približno 89% tačnosti, 87% preciznosti i 86% odziva, nadmašujući modele zasnovane samo na rezervacijama ili samo na recenzijama. U ovoj analizi relevantni su i javno dostupni skupovi podataka o hotelskim rezervacijama i recenzijama, uključujući *Hotel Booking Demand* skup podataka i njegovu verziju [54, 55] sa Kaggle platforme, kao i *515K Hotel Reviews Data in Europe* i *TripAdvisor hotel reviews* skup [56].

4.8.1 Formalni prikaz CLV

U opštem obliku, CLV se može prikazati kao sadašnja vrednost očekivanih budućih prihoda korisnika, pri čemu se u obzir uzimaju očekivani prihodi, povezani operativni troškovi i vremenska vrednost novca:

$$CLV_i = \sum_{t=1}^T \frac{E(R_{it}) - E(C_{it})}{(1 + d)^t}, \quad (4.23)$$

gde je $E(R_{it})$ očekivani prihod od korisnika i u periodu t , $E(C_{it})$ očekivani trošak servisiranja tog korisnika, d diskontna stopa, a T vremenski horizont. Prva jednačina predstavlja idealizovan finansijski prikaz CLV-a, u kojem se budući očekivani prihodi i troškovi korisnika diskontuju kroz vremenski horizont T . Međutim, u realnim javno dostupnim skupovima podataka takvi detaljni finansijski tokovi najčešće nisu dostupni, pa se CLV ne procenjuje direktno, već preko dostupnih signala koji ukazuju na verovatnu buduću vrednost korisnika. U praktičnim prediktivnim modelima, naročito kada se koriste javno dostupni skupovi podataka bez dugoročnih individualnih finansijskih istorija, CLV se često aproksimira pomoću dostupnih karakteristika:

$$\widehat{CLV}_i = f_{\theta} \left(\mathbf{x}_i^{behavior}, \mathbf{x}_i^{satisfaction}, \mathbf{x}_i^{text}, \mathbf{x}_i^{meta} \right), \quad (4.24)$$

gde $\mathbf{x}_i^{behavior}$ označava pokazatelje ponašanja, $\mathbf{x}_i^{satisfaction}$ ocene i indikatore zadovoljstva, $\mathbf{x}_i^{text}$ tekstualne signale, a $\mathbf{x}_i^{meta}$ dodatne metapodatke. Ovde se CLV ne tumači kao potpuna finansijska istorija korisnika, već kao procena vrednosti zasnovana na dostupnim podacima

o boravcima, transakcijama i interakcijama u posmatranom periodu. Takva aproksimacija je korisna za rangiranje korisnika i procenu potencijala za dugoročni odnos sa hotelom.

4.8.2 Bihevioralna i emocionalna komponenta CLV

Tradicionalni CLV modeli često se zasnivaju na transakcionim podacima: učestalosti kupovine, vrednosti transakcije i vremenu od poslednje interakcije. Međutim, u hotelijerstvu korisničko ponašanje uključuje i emocionalnu komponentu, koja se najjasnije vidi kroz ton, sadržaj i intenzitet recenzija. Gosti koji ostavljaju izrazito pozitivne recenzije mogu imati veći potencijal lojalnosti i preporuke. Gosti koji ostavljaju negativne, ali konstruktivne komentare mogu ukazati na probleme čijim rešavanjem hotel može zadržati korisnika.

Zbog toga se u ovoj disertaciji CLV posmatra kroz kombinaciju bihevioralnih i emocionalnih signala. Objavljeni rad o interpretabilnom multimodalnom deep learning okviru za procenu CLV u hospitality industriji pokazuje da povezivanje bihevioralnih i emocionalnih signala može doprineti razumevanju buduće vrednosti korisnika [57]. U toj analizi optimizovani multimodalni model ostvario je $MAE = 118.9$, $RMSE = 199.4$, $R^2 = 0.89$ i $MAPE = 14.6\%$, čime je nadmašio Random Forest, Gradient Boosting, Behavioral MLP i unimodalni transformer model. Tekstualni model je samostalno bio slabiji od ponašajnih modela, ali je u kombinaciji sa strukturisanim podacima doneo značajno poboljšanje.

4.8.3 Modeli za CLV procenu

Za CLV procenu mogu se koristiti regresioni modeli, ansambl modeli i multimodalne neuronske arhitekture. Ako je ciljna promenljiva kontinuirana vrednost, koriste se regresione metrike. Ako se korisnici dele na segmente visoke, srednje i niske vrednosti, zadatak se može formulisati kao klasifikacija. Segmentacija korisnika prema predviđenoj vrednosti može se zapisati kao:

$$segment_i = \begin{cases} visok, & \widehat{CLV}_i \geq q_{0.75}, \\ srednji, & q_{0.25} < \widehat{CLV}_i < q_{0.75}, \\ nizak, & \widehat{CLV}_i \leq q_{0.25}. \end{cases} \quad (4.25)$$

Ovakva segmentacija omogućava da se rezultati modela prevedu u menadžerske odluke. Gosti visoke CL vrednosti mogu biti cilj personalizovanih ponuda, programa lojalnosti i proaktivne komunikacije. Gosti srednje CL vrednosti mogu biti predmet strategija povećanja angažovanja, dok se za goste niske CL vrednosti mogu primeniti efikasnije i manje skupe komunikacione strategije. Najvažniji doprinos CLV dela disertacije nije samo u poboljšanju metrike, već u tome što se korisničko iskustvo, emocionalni ton recenzije i rezervaciono ponašanje povezuju sa finansijski relevantnim ishodom.

Tabela 4.9 prikazuje poređenje modela prema četiri regresione metrike: MAE, RMSE, R^2 i MAPE. MAE pokazuje prosečnu apsolutnu grešku procene, dok RMSE jače kažnjava veća odstupanja i zato ukazuje na stabilnost modela kod težih primera. Koeficijent determinacije R^2 pokazuje koliki deo varijanse ciljne vrednosti model uspeva da objasni, dok MAPE izražava prosečnu procentualnu grešku i olakšava poslovno tumačenje rezultata.

Tabela 4.9: Sažetak rezultata multimodalnog CLV modelovanja u hotelijerstvu.


Model	MAE	RMSE	R^2	MAPE
Random Forest regresija	182.4	295.7	0.71	24.8%
Gradient Boosting	175.1	284.3	0.74	23.5%
Behavioral MLP	168.7	271.5	0.76	22.1%
Unimodalni transformer	201.3	318.9	0.68	27.9%
Inicijalni multimodalni model	141.6	231.9	0.84	18.7%
Optimizovani multimodalni model	118.9	199.4	0.89	14.6%

Rezultati pokazuju da multimodalna integracija ne donosi samo marginalno poboljšanje, već sistematsko smanjenje greške i rast objašnjene varijanse. Optimizovani multimodalni model ostvaruje najniže vrednosti MAE, RMSE i MAPE, uz najviši R^2 , što znači da smanjuje prosečnu apsolutnu grešku, bolje kontroliše veća odstupanja, ima manju procentualnu grešku i objašnjava veći deo varijacije u procenjenoj vrednosti korisnika.

Slika 4.5 prikazuje kako se relativni doprinos modaliteta menja po segmentima dugoročne vrednosti korisnika. Kod segmenata niže CLV vrednosti veći značaj imaju bihejvioralni signali, kao što su prethodno ponašanje, učestalost boravaka i transakcioni obrasci. Nasuprot tome, kod segmenata više vrednosti raste značaj emocionalnih signala iz recenzija, što ukazuje da pozitivno iskustvo, zadovoljstvo i reputacioni uticaj mogu biti važni za procenu dugoročne vrednosti gosta. Metapodaci zadržavaju stabilan doprinos u svim segmentima i predstavljaju dopunski kontekst koji povezuje ponašajne i tekstualne informacije.

4.9 Predikcija otkazivanja rezervacija kao hotelski bihejvioralni rizik

Pored recenzija, ocena i dugoročne vrednosti korisnika, hotelski domen uključuje i ponašanje koje nastaje pre samog boravka. Otkazivanje rezervacije predstavlja jedan od najvažnijih oblika takvog ponašanja, jer direktno utiče na prihod, popunjenost kapaciteta, planiranje osoblja i politiku cena. Za razliku od ocene ili recenzije, koje nastaju nakon iskustva, rizik otkazivanja mora se proceniti unapred, na osnovu informacija dostupnih u trenutku rezervacije ili tokom ranih promena rezervacionog statusa.



Slika 4.5: Raspodela doprinosa signala po CLV segmentima.

U tom smislu, predikcija otkazivanja rezervacija dopunjuje hotelski istraživački okvir: dok recenzije i ocene mere iskustvo gosta nakon boravka, rezervacioni podaci omogućavaju analizu ponašajnog rizika pre realizacije usluge. U okviru aktuelnog istraživačkog pravca ovaj zadatak se razmatra kroz javno dostupan skup podataka o hotelskim rezervacijama, sa više od 119.000 zapisa, u kojem se mogu analizirati period između rezervacije i planiranog dolaska, tip depozita, kanal rezervacije, tržišni segment, prosečna dnevna cena, prethodne izmene rezervacije i istorija gosta. Formalno, rizik otkazivanja može se zapisati kao:


$$\hat{p}_i^{cancel} = P(cancel_i = 1 \mid \mathbf{b}_i), \quad (4.26)$$

gde $\mathbf{b}_i$ označava vektor rezervacionih karakteristika za rezervaciju i , kao što su period između rezervacije i planiranog dolaska, tip depozita, kanal rezervacije, tržišni segment, broj prethodnih promena rezervacije, prosečna dnevna cena i broj posebnih zahteva. Konačna odluka može se doneti poređenjem sa pragom:

$$\hat{y}_i^{cancel} = \begin{cases} 1, & \hat{p}_i^{cancel} \geq \tau_c, \\ 0, & \hat{p}_i^{cancel} < \tau_c. \end{cases} \quad (4.27)$$

Međutim, za menadžment hotela nije dovoljno da model rezervaciju samo klasifikuje kao rizičnu ili nerizičnu. Upravljanje prihodima, politika rezervacija, depoziti, uslovi i proaktivna komunikacija zavise od nivoa rizika, a ne samo od binarne oznake.

Slika 4.6 prikazuje DNN/MLP arhitekturu za predikciju otkazivanja hotelskih rezervacija. Rezervacioni, cenovni i ponašajni atributi se nakon kodiranja i normalizacije prosleđuju kroz guste slojeve, koji uče nelinearne obrasce rizika. Izlaz modela je procenjena verovatnoća otkazivanja, pogodna za kalibraciju i poslovno tumačenje.



Slika 4.6: Predložena DNN/MLP arhitektura za procenu verovatnoće otkazivanja hotelskih rezervacija na osnovu rezervacionih, cenovnih i ponašajnih atributa.

4.10 Pouzdanost ulaznih signala u hotelskoj prediktivnoj analitici

Prethodne sekcije pokazale su da se hotelsko ponašanje može analizirati kroz više tipova digitalnih tragova: recenzije, ocene, rezervacione attribute, procenu zadovoljstva, dugoročnu vrednost korisnika i rizik otkazivanja rezervacije. Međutim, pre nego što se izlazi modela prevedu u menadžerske odluke, potrebno je proceniti i pouzdanost samih ulaznih signala. Recenzija, ocena ili rezervacioni zapis ne moraju uvek imati istu informativnu vrednost, naročito kada su komentari veoma kratki, kada postoji nesklad između ocene i teksta, kada se javljaju ponavljajući obrasci ili kada su podaci nepotpuni.

U okviru aktuelnog istraživačkog pravca, kredibilitet recenzija posmatra se kao kategorija informacionog rizika, a ne kao dokaz neautentičnosti. Takav pristup je važan jer javno dostupni skupovi podataka najčešće ne sadrže proverene oznake lažnih recenzija niti stabilne identifikatore korisnika. Zato se cilj ne postavlja kao automatsko označavanje pojedinačne recenzije kao neautentične, već kao procena da li određeni zapis ili tok recenzija zahteva dodatnu pažnju. Ovakvo tumačenje je posebno relevantno za informacionu podršku odlučivanju, jer model treba da pomogne u praćenju rizika, a ne da zameni domensku procenu.

U preliminarnoj evaluaciji ovog pristupa, sprovedenoj nad skupom *515K Hotel Reviews Data in Europe*, koji obuhvata više od pola miliona evropskih hotelskih recenzija [56], pokazano je da se kategorije kredibilitetnog rizika mogu učiti iz sirovih tekstualnih i kontekstualnih signala u strožem protokolu evaluacije, u kojem se model ne oslanja direktno na indikatore korišćene za formiranje oznaka rizika. Multimodalni model koji kombinuje tekstualne i strukturisane informacije ostvario je najuravnoteženije performanse, uz macro F1 od približno 0.60 i odziv za kategoriju niskog kredibiliteta blizu 0.70. Ovi rezultati znače da model ne prepoznaje samo dominantnu grupu pouzdanih recenzija, već uspeva da izdvoji i deo zapisa koji nose povećan informacioni rizik.

Dodatno, agregacija rezultata na nivou hotela pokazala je da visoka prosečna ocena ne mora nužno značiti i nizak kredibilitetni rizik. Drugim rečima, hotel može imati dobru prosečnu reputaciju, ali i tok recenzija koji zahteva dodatno praćenje zbog kratkih komentara, nesklada između ocena i teksta ili drugih indikatora smanjene informativnosti. Zato se ocena i kredibilitet recenzija moraju tumačiti zajedno: ocena pokazuje nivo zadovoljstva, dok kredibilitet pokazuje koliko je taj signal pouzdan za donošenje menadžerskih odluka. Istovremeno, dobijeni rezultati predstavljaju motivaciju za dalje usavršavanje modela, preciznije definisanje kredibilitetnih indikatora i ispitivanje novih tehnika za obradu tekstualnih, strukturisanih i multimodalnih hotelskih podataka.

Pouzdanost ulaznih signala zato se može posmatrati kao dodatni sloj hotelske analitike. Kod recenzija ona obuhvata kredibilitet teksta, odnos ocene i komentara, dužinu zapisa, ponavljanje obrazaca i agregaciju rizika na nivou hotela, dok kod rezervacionih podataka obuhvata dostupnost atributa u trenutku predikcije, kvalitet procenjene verovatnoće i odsustvo cure-

nja informacija iz budućnosti. Tabela 4.10 prikazuje kako se različiti tipovi hotelskih signala povezuju sa analitičkim zadacima i njihovim menadžerskim značenjem. Na taj način tabela povezuje tehničku procenu kvaliteta podataka sa konkretnim oblicima hotelskog odlučivanja, od praćenja reputacije do upravljanja prihodima i proaktivne komunikacije sa gostima.

Tabela 4.10: Slojevi pouzdanosti i poslovnog značenja hotelskih prediktivnih signala.

Tip signala	Šta se procenjuje	Analitički zadatak	Menadžersko značenje
Recenzije i ocene	Kredibilitet, sentiment, pritužbe i odnos teksta i ocene	Procena pouzdanosti recenzija i detekcija negativnih obrazaca	Praćenje reputacije i izdvajanje komentara koji zahtevaju dodatnu proveru
Zadovoljstvo gosta	Predviđena ocena, rizik nezadovoljstva i dominantni faktori iskustva	Predikcija zadovoljstva i objašnjenje korisničkog iskustva	Rano prepoznavanje problema u usluzi, lokaciji, higijeni ili komunikaciji
Dugoročna vrednost korisnika	Bihevioralni, emocionalni i kontekstualni doprinos CLV proceni	Regresiona procena i segmentacija korisnika	Personalizacija ponuda, lojalnost i prioritizacija vrednih gostiju
Rezervacioni podaci	Verovatnoća otkazivanja i stabilnost rezervacionog ponašanja	Predikcija otkazivanja i kalibracija rizika	Upravljanje prihodima, politika kontrolisanog prekomernog prihvatanja rezervacija (overbooking), depoziti i proaktivna komunikacija

Ovakav sloj pouzdanosti priprema prelaz ka objašnjivosti modela. Ako ulazni signali nisu jednako pouzdani, tada ni predikcije ne treba tumačiti samo kroz zbirne metrike performansi. Potrebno je razumeti koji podaci su najviše uticali na odluku modela, da li je signal stabilan i kako se rezultat može upotrebiti u konkretnom menadžerskom kontekstu. Zato se u nastavku poglavlja objašnjivost posmatra kao veza između tehničkog izlaza modela i odgovorne odluke hotelskog menadžmenta.

4.11 Objašnjivost modela i primena rezultata u hotelskom menadžmentu

Prediktivni modeli u hotelijerstvu imaju praktičnu vrednost samo ako se njihovi rezultati mogu prevesti u razumljive menadžerske uvide. Visoka tačnost, nizak MAE ili dobar F1 skor predstavljaju važne pokazatelje performansi, ali sami po sebi ne govore menadžeru zašto je neka recenzija negativna, zašto je ocena pogrešno predviđena, zašto je gost visokovredan ili

zašto postoji rizik otkazivanja rezervacije. Zbog toga objašnjivost nije dodatak modelu, već uslov njegove primenljivosti u analizi online recenzija i hotelskih predikcija [58, 59].

4.11.1 Globalna objašnjenja

Globalna objašnjenja omogućavaju da se razume koji faktori najviše utiču na ponašanje modela u celini. U hotelskim zadacima to mogu biti reči i izrazi povezani sa higijenom, osobljem, bukom, lokacijom, cenom, rezervacijom, periodom između rezervacije i planiranog dolaska, posebnim zahtevima ili ponovljenim rezervacijama. Na primer, u CLV modelovanju SHAP analiza može pokazati da ponovljene rezervacije, dužina boravka, posebni zahtevi, čistoća i kvalitet usluge doprinose proceni vrednosti korisnika. U modelovanju zadovoljstva SHAP može pokazati koji numerički i tekstualni signali povećavaju rizik nezadovoljstva. Ako se, na primer, izrazi povezani sa bukom, lošom čistoćom i ignorisanjem zahteva često javljaju među najvažnijim negativnim faktorima, hotel dobija jasniji uvid u oblasti koje zahtevaju operativnu reakciju. Na taj način globalna objašnjenja funkcionišu kao mapa opštih obrazaca, koja pomaže da se model ne posmatra samo kroz izlaznu metriku, već kroz strukturu faktora na kojima zasniva predikcije.

4.11.2 Lokalna objašnjenja

Lokalna objašnjenja odnose se na pojedinačne predikcije i važna su kada menadžer želi da razume zašto je recenzija označena kao negativna, pritužba svrstana u određenu kategoriju ili gost dodeljen određenom CLV segmentu. U ranijim istraživanjima veća prednost data je SHAP pristupu, jer omogućava konzistentno poređenje doprinosa obeležja na globalnom i lokalnom nivou, dobro se uklapa sa tabularnim i ansambl modelima i pruža stabilan osnov za rangiranje faktora. Međutim, u aktuelnom istraživačkom pravcu posebna pažnja posvećuje se i LIME metodi, naročito njenoj mogućnosti da objasni pojedinačne tekstualne predikcije kroz reči i fraze koje najviše utiču na odluku modela. Na primer, izrazi poput *no housekeeping*, *they ignored us* ili *bathroom smelled* mogu doprineti predikciji pritužbe, dok izrazi poput *very clean room* ili *excellent location* mogu podržati pozitivnu klasifikaciju.

4.11.3 Menadžerska upotreba rezultata

Rezultati hotelskih modela mogu se koristiti na više nivoa odlučivanja. Na operativnom nivou, modeli mogu pomoći u ranom prepoznavanju negativnih recenzija i kategorizaciji pritužbi. Na taktičkom nivou, mogu podržati alokaciju resursa, prioritizaciju intervencija i praćenje reputacije. Na strateškom nivou, mogu pomoći u proceni dugoročne vrednosti korisnika, personalizaciji ponuda, upravljanju lojalnošću i planiranju prihoda. Najveća praktična vrednost postiže se kada se modelski signali uklope u postojeće procedure kvaliteta, komunikacije sa gostima i upravljanja prihodima, umesto da ostanu izolovani analitički rezultati.

Ipak, ovi modeli ne treba da zamene menadžersku procenu. Njihova vrednost je u tome što velike količine nestrukturisanih i strukturisanih podataka pretvaraju u signale koji mogu usmeriti pažnju stručnjaka. U takvom pristupu, model služi kao sistem za usmeravanje pažnje i smanjenje informacionog opterećenja, dok konačna odluka ostaje deo šireg organizacionog i poslovnog konteksta. Model može označiti problem, ali odluka o organizacionoj reakciji mora uzeti u obzir domenski kontekst, reputacioni rizik, resurse hotela i očekivanja gostiju.

4.12 Sinteza nalaza u oblasti turizma i hotelijerstva

Hotelski domen predstavlja najrazvijeniji empirijski prostor ove disertacije, jer obuhvata gotovo ceo ciklus korisničkog ponašanja: od rezervacije, preko boravka i recenzije, do zadovoljstva, pritužbi, dugoročne vrednosti korisnika i rizika otkazivanja. Njegov značaj nije samo u broju modela i skupova podataka, već u tome što omogućava proveru integrativnog okvira kroz tekstualne, strukturisane, multimodalne, ponašajne i poslovno usmerene signale.

Prvi skup nalaza odnosi se na kvalitet i pouzdanost ulaznih podataka. Detekcija anomalija, nekonzistentnosti, kratkih komentara, ponavljanja i kredibilitetnog rizika pokazuje da hotelske recenzije ne treba posmatrati kao neutralan ulaz u model. One su istovremeno izvor informacija i potencijalni izvor šuma, pa se njihova informativnost mora procenjivati pre nego što se koriste za predikciju. Time se direktno podržava hipoteza H3, jer kvalitet podataka postaje sastavni deo validnosti modela, a ne samo tehnički korak preprocesiranja.

Drugi skup nalaza potvrđuje značaj tekstualnog i dubokog modelovanja, posebno u zadacima predikcije ocena, detekcije negativnih recenzija i prepoznavanja kategorija pritužbi. Transformer modeli pokazuju jasnu prednost u razumevanju konteksta hotelskih recenzija, ali rezultati istovremeno pokazuju da njihova prednost zavisi od cilja evaluacije: prosečna greška, odziv na retke negativne slučajeve, višelabelne kategorije pritužbi i stabilnost kroz vreme ne mere istu vrstu uspešnosti. Ovi nalazi najdirektnije podržavaju H1, uz važnu dopunu da se superiornost dubokih modela mora tumačiti kroz domenski cilj, a ne samo kroz jednu zbirnu metriku.

Treći skup nalaza odnosi se na multimodalnost. Modelovanje zadovoljstva i CLV procene pokazuje da tekstualni signali, rezervacioni atributi, ponašajni obrasci i kontekstualne informacije nose komplementarne uvide. Tekst objašnjava subjektivno iskustvo gosta, dok strukturisani podaci opisuju okolnosti boravka, prethodno ponašanje i poslovni značaj korisnika. Time se podržava H2, jer objedinjavanje različitih reprezentacija omogućava bogatije i poslovno korisnije modelovanje nego oslanjanje na jedan tip podataka.

Četvrti skup nalaza proširuje hotelsku analitiku sa tumačenja recenzija na proaktivno upravljanje rizikom. Predikcija otkazivanja rezervacija pokazuje da se ponašanje gosta može analizirati i pre realizacije usluge, na osnovu perioda između rezervacije i planiranog dolaska, tipa depozita, kanala rezervacije, promena rezervacije i drugih dostupnih atributa. Time

se hotelsko poglavlje ne završava analizom iskustva nakon boravka, već povezuje predikciju zadovoljstva, dugoročne vrednosti i rezervacionog rizika u širi okvir podrške odlučivanju.

Posebno važan rezultat odnosi se na objašnjivost. SHAP, LIME i analiza doprinosa pokazuju da zbirne metrike nisu dovoljne za razumevanje modela u hotelijerstvu. Menadžeru nije dovoljno da zna da je model tačan, već je potrebno da razume koji izrazi, atributi, segmenti ili obrasci ponašanja utiču na predikciju. Ovaj deo direktno podržava H4, jer pokazuje da interpretabilnost otkriva relevantne obrasce koji ostaju skriveni iza prosečnih metrika.

U odnosu na hipoteze disertacije, hotelski domen daje najpotpuniju empirijsku potvrdu istraživačkog okvira. H1 je podržana kroz prednost transformer i dubokih modela u tekstualnim zadacima, ali uz naglašenu potrebu za poređenjem sa jednostavnijim referentnim modelima. H2 je potvrđena kroz multimodalno modelovanje zadovoljstva, CLV-a i rezervacionog rizika. H3 je podržana kroz eksplicitno modelovanje anomalija, nekonzistentnosti i kredibiliteta recenzija. H4 je potvrđena kroz globalna i lokalna objašnjenja, analizu grešaka i tumačenje doprinosa pojedinačnih signala. H5 se ogleda u zaključku da najkorisniji model nije nužno najkompleksniji, već onaj koji ostvaruje najbolji odnos između performansi, stabilnosti, objašnjivosti, troška i menadžerske upotrebljivosti.

Zaključno, turizam i hotelijerstvo u ovoj disertaciji predstavljaju domen u kojem se najjasnije vidi ceo istraživački tok odgovorne prediktivne analitike ponašanja. Digitalni trag gosta se najpre procenjuje u pogledu kvaliteta i pouzdanosti, zatim se prevodi u tekstualne, strukturisane ili multimodalne reprezentacije, evaluira kroz više metrika i objašnjava u domenskom kontekstu. Tek nakon toga predikcija dobija praktičnu vrednost, jer se može povezati sa konkretnim hotelskim odlukama: prepoznavanjem pritužbi, procenom zadovoljstva, planiranjem prihoda, upravljanjem rizikom otkazivanja i prioritetizacijom intervencija.

5. TRANSPORTNI SISTEMI

5.1 Transportni sistemi kao domen prediktivne analitike

Transportni sistemi predstavljaju jedan od najznačajnijih domena za proveru prediktivnih modela ponašanja, jer objedinjuju individualne, operativne, tržišne i mrežne obrasce. Za razliku od hotelskog domena, u kojem su digitalni tragovi najčešće izraženi kroz tekstualne recenzije, ocene i korisničke narative, transportni domen uvodi podatke koji imaju izraženu vremensku, sekvencijalnu, prostornu i sistemsku strukturu. U kopnenom saobraćaju ponašanje se posmatra kroz stil vožnje, ubrzanja, usporavanja, interakcije sa drugim vozilima, vremenske uslove i kontekst puta. U avio-saobraćaju predmet analize nisu samo odluke putnika, već i uslovi koji oblikuju njihovo ponašanje: cena karte, tip prevoznika, struktura linije, raspored letova, dostupnost destinacije i pouzdanost sistema za procenu zadovoljstva putnika u realnim uslovima. Zajednička nit transportnog poglavlja jeste procena rizika, pouzdanosti i dostupnosti sistema na osnovu sekvencijalnih, cenovnih, segmentnih i mrežnih signala.

U okviru ove disertacije transportni sistemi se ne posmatraju kao tehnička oblast, već kao domen u kojem se ispituje da li integrativni metodološki okvir može da obuhvati ponašajne obrasce koji nisu dominantno tekstualni. Time se proverava primenljivost pristupa koji povezuje podatke, reprezentaciju, model, evaluaciju, objašnjenje i odluku. Transport uvodi dva važna metodološka izazova. Prvi se odnosi na redosled događaja: određeno ponašanje ne mora biti prepoznatljivo iz jedne izolovane vrednosti, već iz promene kroz vreme. Drugi se odnosi na segmentnu i sistemsku pouzdanost: model može imati dobru ukupnu performansu, ali nejednako funkcionisati u različitim grupama vozača, putnika, ruta ili destinacija.

Aktuelna istraživanja ponašanja vozača pokazuju da duboko učenje može biti korisno za profilisanje i prepoznavanje stilova vožnje kada su dostupni senzorski, kontekstualni i vremenski podaci [60]. Pregledi literature naglašavaju da se klasifikacija ponašanja vozača ne može svesti na izbor jednog algoritma, već zavisi od tipa podataka, kvaliteta obeležja, dužine sekvence, načina označavanja i evaluacionog protokola [61]. U avio-saobraćaju prediktivna analitika obuhvata cene karata, zadovoljstvo putnika, kašnjenja, strukturu mreže i dostupnost destinacija. Istraživanja predikcije cena ukazuju da cenu ne objašnjava samo fizička udaljenost, već i kombinacija rute, prevoznika, vremena, tržišne konkurencije i operativnih atributa [62]. Novija istraživanja pokazuju da mrežne mere centralnosti mogu doprineti modelima u avio-saobraćaju, jer položaj aerodroma u mreži utiče na operativne i tržišne obrasce [63].


Zbog toga je osnovni doprinos ovog poglavlja dvostruk. Prvo, poglavlje pokazuje kako se prediktivni modeli ponašanja mogu razvijati nad sekvencijalnim, tabularnim, vremenskim i mrežnim podacima. Drugo, pokazuje da kvalitet modela u transportu ne treba procenjivati samo prema globalnoj tačnosti, već i prema posledicama grešaka, stabilnosti po segmentima, interpretabilnosti faktora i mogućnosti korišćenja rezultata u bezbednosnom, operativnom i poslovnom odlučivanju. Inovativni doprinos nalazi se u povezivanju dubokog učenja, ansambl modela, segmentne evaluacije i poslovnih indikatora, tako da se transportni podaci ne koriste samo za predikciju, već i za tumačenje rizika, dostupnosti i pouzdanosti sistema.

Tabela 5.1 sistematizuje glavne istraživačke zadatke transportnog domena i pokazuje kako se različiti tipovi podataka, modeli i analitičke procedure povezuju sa konkretnim doprinosima. Zadaci obuhvataju više nivoa odlučivanja: od ponašanja vozača i zadovoljstva putnika, preko cena avio-karata i rasporeda letova, do systemske povezanosti destinacija. Na taj način transportni domen nije predstavljen kao jedan izolovan problem, već kao skup međusobno povezanih ponašajnih, tržišnih i infrastrukturnih obrazaca.

Tabela 5.1: Istraživački zadaci i doprinosi u transportnom domenu.

Zadatak	Dominantni podaci	Modeli i analize	Konkretni doprinos poglavlja
Agresivna vožnja	Senzorski, bihevioralni i kontekstualni podaci	DNN/MLP, LSTM, analiza sekvenci	Provera modelovanja rizičnog ponašanja na osnovu dinamičkih i okruženjskih faktora.
Cena avionske karte	Geografski, tržišni, mrežni i rasporedni atributi ruta	Linearna regresija, Random Forest, XGBoost, CatBoost, SHAP	Objašnjivo modelovanje cenovne varijacije i identifikacija faktora koji oblikuju tržišne obrasce.
Zadovoljstvo putnika	Kategorijalni, ordinalni i numerički podaci o putnicima i usluzi	Supervizovana klasifikacija, segmentna evaluacija, analiza FNR	Provera da li AI sistem jednako pouzdano funkcioniše u različitim putničkim segmentima.
Raspored letova	Nedeljna dostupnost ruta, frekvencija, tip prevoznika	Indeks asimetrije, neparametarska statistika	Uvođenje vremenske strukture rute kao merljivog indikatora transportnog ponašanja.
Povezanost destinacija	Rute, prevoznici, frekvencije, koncentracija operatora	BI indikatori, indeks zavisnosti, klasterizacija	Procena sistemskog rizika destinacija koje zavise od uskog skupa budžetskih prevoznika.

Slika 5.1 dopunjuje tabelarni pregled i prikazuje transportni domen kao jedinstven tok prediktivne analitike. Polazni sloj čine heterogeni transportni podaci: ponašajni signali vozača, vremenske sekvence, podaci o rutama, cene i tarife, ocene kvaliteta usluge putnika i pokazatelji povezanosti mreže. Ti izvori se zatim prevode u zajedničku reprezentaciju signala, koriste u prediktivnom modelu, proveravaju kroz segmentnu evaluaciju i objašnjavaju preko faktora koji povećavaju ili smanjuju predikciju. Završni korak predstavlja prevođenje rezultata modela u odluke o riziku, ceni, kvalitetu usluge ili povezanosti transportnog sistema.



Slika 5.1: Integrativni tok prediktivne analitike u transportnim sistemima: od heterogenih podataka i reprezentacije signala do modelovanja, evaluacije, objašnjenja i odluke.

5.2 Obrasci rizičnog ponašanja u kopnenom saobraćaju

U kopnenom saobraćaju ponašanje vozača predstavlja prediktivni zadatak zato što se rizik ne javlja kao izolovan događaj. Naglo ubrzanje, visoka brzina ili kratko rastojanje do prethodnog vozila mogu biti indikatori agresivne vožnje, ali njihovo značenje zavisi od konteksta. Ista vrednost brzine ne mora imati isto značenje na otvorenom putu, u gradskoj zoni, pri različitim vremenskim uslovima ili u različitoj gustini saobraćaja. Zbog toga se agresivna vožnja u ovom poglavlju ne tretira kao prekoračenje praga, već kao obrazac ponašanja koji se formira kroz kombinaciju bihejvioralnih, vozničkih i kontekstualnih signala.

Istraživanja faktora koji utiču na agresivno ponašanje u vožnji ukazuju da rizični stilovi vožnje mogu biti povezani sa ubrzanjem, kočenjem, brzinom, uslovima puta, karakteristikama vozača i situacionim faktorima [64]. Neuralni modeli za analizu ponašanja vozača dodatno potvrđuju da je za ovaj zadatak važno obuhvatiti nelinearne odnose između ulaznih obe-

ležja, jer agresivnost nije uvek posledica jednog faktora, već kombinacije više signala [65]. U disertaciji se zato koriste dva komplementarna pristupa: prvi pristup modeluje stil vožnje kroz duboku neuronsku mrežu nad strukturisanim obeležjima, dok drugi uvodi sekvencijalnu analizu pomoću LSTM mreža.

Dok hotelska recenzija predstavlja retrospektivni izraz iskustva, vožnja je proces koji se odvija kroz niz vremenski povezanih stanja. Model zato ne treba samo da odgovori da li je instanca agresivna, već da nauči kako se agresivno ponašanje razvija kroz promene brzine, uslova okruženja i interakcije sa vozilima. Na taj način transportni domen proširuje disertaciju sa predikcije korisničkog zadovoljstva na rano prepoznavanje ponašajnog rizika.

5.3 Detekcija agresivne vožnje pomoću dubokog učenja

Prvi empirijski pravac u kopnenom saobraćaju odnosi se na detekciju agresivne vožnje pomoću dubokog učenja. U ovom zadatku cilj je klasifikacija stila vožnje u kategorije koje odražavaju različit nivo rizika: oprezna vožnja, potencijalno agresivna vožnja i agresivna vožnja. Za razliku od binarne detekcije opasnog ponašanja, ovakav pristup omogućava finiju procenu rizika jer prepoznaje i granične obrasce koji još ne moraju biti jasno agresivni, ali mogu ukazivati na povećanu verovatnoću opasnog manevra.

5.3.1 Formulacija zadatka i ulazni signali

Skup podataka korišćen za ovaj zadatak potiče iz javno dostupnog repozitorijuma za agresivnu vožnju, koji sadrži zapise povezane sa ponašanjem vozača, karakteristikama vozila, uslovima puta i okruženja [66]. Podaci su zahtevali preprocesiranje, uključujući preimеноvanje nejasnih kolona, obradu nedostajućih vrednosti, normalizaciju numeričkih promenljivih i rekodiranje ciljne promenljive u interpretabilnije kategorije. Ovaj korak je metodološki važan jer pokazuje da performanse modela u zadacima ponašajne klasifikacije ne zavise samo od arhitekture, već i od kvaliteta reprezentacije i pripreme ulaznih obeležja. Formalno, neka je za svaku vožnju ili segment vožnje definisan vektor obeležja:

$$\mathbf{x}_i = [v_i, a_i, r_i, w_i, p_i, e_i], \quad (5.1)$$

gde v_i označava karakteristike kretanja vozila, a_i izvedene pokazatelje ubrzanja i usporavanja, r_i uslove puta, w_i vremenske i svetlosne uslove, p_i informacije o prethodnom vozilu, a e_i dodatne kontekstualne pokazatelje. Cilj modela jeste učenje funkcije:

$$f(\mathbf{x}_i) \rightarrow \hat{y}_i, \quad \hat{y}_i \in \{\text{oprezna, potencijalno agresivna, agresivna}\}. \quad (5.2)$$

Ova formulacija naglašava da se rizično ponašanje ne tumači kao posledica jednog izolovanog signala, već kao rezultat kombinacije ponašajnih, vozničkih i okruženjskih faktora.

5.3.2 DNN/MLP arhitektura i evaluacija

Model je zasnovan na dubokoj neuronskoj mreži tipa MLP, razvijenoj za obradu strukturisanih obeležja koja opisuju vozilo, okolinu i odnos sa drugim učesnicima u saobraćaju. Ulazna obeležja obuhvataju brzinu vozila, karakteristike vozila, traku puta, vremenske uslove, osvetljenje, parametre prethodnog vozila i druge faktore koji mogu doprineti proceni stila vožnje. Arhitektura uključuje više skrivenih slojeva, dropout regularizaciju, batch normalizaciju i optimizaciju hiperparametara, čime se nastoji povećati generalizacija i smanjiti rizik od preprilagođavanja. U objavljenom istraživanju ostvaren je rezultat od približno 87% tačnosti, što potvrđuje da se kombinovanjem bihejvioralnih i okruženjskih metrika mogu dobiti korisni modeli za klasifikaciju stilova vožnje [67]. Opšti oblik skrivenog sloja može se matematički definisati kao:

$$h^{(l)} = \sigma \left(W^{(l)} h^{(l-1)} + b^{(l)} \right), \quad (5.3)$$


gde je $h^{(l)}$ izlaz sloja l , $W^{(l)}$ matrica težina, $b^{(l)}$ slobodni član, a σ nelinearna aktivaciona funkcija. U kontekstu detekcije agresivne vožnje, ova jednačina pokazuje da se brzina, ubrzanje, uslovi puta, vremenski uslovi i interakcioni signali ne posmatraju odvojeno, već se u skrivenim slojevima prevode u zajedničku reprezentaciju rizika. Takva arhitektura je pogodna za tabularne i heterogene ulazne podatke zato što može naučiti nelinearne veze između ponašajnih, vozničkih i kontekstualnih obeležja.

Slika 5.2 prikazuje ovu logiku u obliku DNN/MLP arhitekture. Ulazni deo obuhvata ponašajne, vozne i kontekstualne signale, srednji slojevi uče njihove nelinearne kombinacije, dok izlaz softmax funkcije daje procenu stila vožnje. U takvom sistemu dropout i batch normalization nemaju samo tehničku ulogu, nego doprinose i stabilnijoj generalizaciji modela na vožnje koje se razlikuju po uslovima puta, vremenskim uslovima i intenzitetu saobraćaja. Slika dodatno pokazuje da se odluka modela ne zasniva na jednom obeležju, već na postepenom spajanju više grupa signala kroz duboke slojeve mreže.

5.3.3 Značenje grešaka i odgovorna primena

Kod detekcije agresivne vožnje nije dovoljno posmatrati ukupnu tačnost. Lažno pozitivan ishod može neopravdano označiti vozača kao rizičnog, dok lažno negativan ishod može propustiti obrazac koji prethodi opasnoj situaciji. Zbog toga se rezultati ovakvih modela ne smeju koristiti kao konačna presuda o vozaču, već kao signal za dodatnu proveru, preventivnu intervenciju ili unapređenje sistema podrške bezbednosti.

Doprinos ovog zadatka ne ogleda se samo u postignutoj tačnosti, već u pokazivanju da se ponašanje vozača može tretirati kao prediktivni problem nad heterogenim digitalnim tragovima. Time se hipoteza o korisnosti dubokog učenja proverava u domenu u kojem su greške operativno i bezbednosno značajne, što jača argument da evaluacija modela mora obuhvatiti i posledice pogrešne klasifikacije.



Slika 5.2: DNN/MLP arhitektura za klasifikaciju stila vožnje na osnovu ponašajnih, voznih i kontekstualnih signala.

5.4 Sekvencijalna analiza obrazaca u vožnji pomoću LSTM mreža

Drugi pravac u kopnenom saobraćaju uvodi sekvencijalnu perspektivu. Klasični modeli koji posmatraju instancu kao nezavisan red u tabeli mogu identifikovati faktore povezane sa stilom vožnje, ali ne mogu u potpunosti obuhvatiti način na koji se ponašanje menja kroz vreme. Agresivna vožnja često se razvija kao niz povezanih događaja: povećanje brzine, smanjenje rastojanja do vozila ispred, učestalija promena trake, naglo kočenje ili neujednačeno ubrzanje. Zbog toga je u ovom delu poglavlja primenjena LSTM arhitektura, koja je pogodna za učenje zavisnosti u vremenskim sekvencama.

U objavljenom istraživanju o sekvencijalnoj detekciji agresivne vožnje razvijen je okvir za rano prepoznavanje rizičnog ponašanja zasnovan na RNN/LSTM pristupu. Model koristi vremenske sekvence i izvedena obeležja, kao što su stopa ubrzanja, stopa usporavanja, pokretni prosek brzine, učestalost promene trake i vreme od poslednjeg rizičnog događaja. Time se ponašanje ne posmatra kao skup izolovanih merenja, već kao proces u kojem prethodna stanja doprinose razumevanju trenutnog rizika. Rezultati pokazuju poboljšanje tačnosti na oko 89%, uz poboljšanja preciznosti, odziva i F1 mere, pri čemu je odziv za kategoriju potencijalno agresivne vožnje povećan sa 71% na 80% [68].


Doprinos LSTM analize nije samo u višoj metriki tačnosti, već u načinu na koji se model približava realnom karakteru ponašanja u saobraćaju. Sekvencijalni model omogućava da se prepozna obrazac koji se razvija pre nego što postane jasno opasan, što je bliže stvarnoj dinamici vožnje nego posmatranje izolovanih merenja. To je posebno važno za sisteme napredne pomoći vozaču, inteligentne transportne sisteme i osiguravajuće modele zasnovane na ponašanju, jer u takvim kontekstima pravovremena detekcija ima veću vrednost od naknadne klasifikacije već nastalog incidenta.

Tabela 5.2 sažima metodološku razliku između statičkog i sekvencijalnog pristupa u analizi agresivne vožnje. Statički DNN/MLP model koristi strukturisana obeležja jedne instance vožnje i uči njihove nelinearne odnose, dok LSTM pristup uvodi vremenski redosled i omogućava da se rizično ponašanje posmatra kao proces koji se razvija kroz sekvencu događaja.

Tabela 5.2: Doprinos statičkog i sekvencijalnog modelovanja agresivne vožnje.

Pristup	Šta model uči	Konkretni doprinos
DNN/MLP nad strukturisanim obeležjima	Nelinearne odnose između brzine, okruženja, uslova puta i ponašajnih faktora.	Pokazuje da se agresivna vožnja može modelovati integracijom bihevioralnih i okruženjskih metrika.
LSTM nad vremenskim sekvencama	Redosled događaja, prelaze između stanja i promene kroz vreme.	Uvodi rano prepoznavanje rizičnih obrazaca i smanjuje oslanjanje na izolovane pragove.

Slika 5.3 vizuelno naglašava razliku između naknadne klasifikacije i rane detekcije agresivne vožnje. Kod sekvencijalnog modela odluka se ne zasniva samo na agregiranom opisu cele vožnje, već na nizu uzastopnih stanja kroz koja se menjaju brzina, ubrzanje, odnos prema prethodnom vozilu i kontekstualni uslovi. LSTM slojevi čuvaju memoriju prethodnih koraka preko stanja h_t i c_t , pa model može prepoznati rastući rizik pre nego što se pojavi eksplicitno opasan događaj, što je posebno značajno za sisteme upozorenja i preventivne intervencije.



Slika 5.3: LSTM tok za ranu detekciju agresivne vožnje kroz sekvencu ponašajnih i kontekstualnih signala.

Ovaj deo poglavlja direktno doprinosi hipotezi H1, jer pokazuje da sekvencijalne arhitekture imaju smisla u zadacima u kojima redosled događaja nosi informaciju. Istovremeno doprinosi hipotezi H5, jer potvrđuje da izbor modela treba da zavisi od prirode podatka. Kada je cilj analiza vremenskog procesa, LSTM nije samo složenija alternativa, već metodološki opravdan izbor.

5.5 Predikcija cena avionskih karata pomoću ansambl modela

Avio-saobraćaj uvodi drugačiji tip prediktivnog zadatka. Za razliku od agresivne vožnje, gde je ishod vezan za ponašanje pojedinačnog vozača, predikcija cena avionskih karata povezuje ponašanje tržišta, strukturu rute i dostupnost usluge. Cena karte nije samo finansijski iznos, već signal odnosa između potražnje, konkurencije, dužine rute, tipa prevoznika, frekvencije letova i položaja aerodroma u mreži. Zbog toga se u disertaciji ovaj zadatak tumači kao analiza uslova koji oblikuju ponašanje putnika i transportnog sistema, a ne kao neposredno modelovanje subjektivne odluke pojedinca.

5.5.1 Obeležja ruta i regresiona formulacija

U ovom delu koristi se skup evropskih avio-ruta koji obuhvata informacije o polaznim i dolaznim aerodromima, približnoj ceni karte, trajanju leta, nedeljnoj frekvenciji, raspoloživosti po danima u nedelji i metapodacima o prevoznicima. U aktuelnom istraživačkom pravcu o modelovanju varijacije cena avionskih karata analizirano je 18.111 usmerenih ruta iz 258 polaznih aerodroma u 46 zemalja, pri čemu je nakon filtriranja zadržano 16.094 zapisa. Prostor obeležja obuhvata četiri grupe prediktora: geografske attribute, mrežne mere, pokazatelje konkurencije i rasporedne promenljive. Formalno, za rutu i može se definisati vektor:

$$\mathbf{x}_i = [d_i, e_i, c_i, b_i, f_i, s_i, n_i], \quad (5.4)$$

gde d_i predstavlja udaljenost, e_i efikasnost rute, c_i mere centralnosti, b_i udeo budžetskih prevoznika, f_i frekvenciju letova, s_i rasporedne karakteristike, a n_i broj ili strukturu operatora. Cilj modela jeste procena približne cene:

$$\hat{p}_i = f(\mathbf{x}_i). \quad (5.5)$$


gde $\hat{p}_i$ označava predviđenu cenu karte za instancu i , x_i ulazne karakteristike leta i rute, a $f(\cdot)$ naučenu funkciju predikcije. Procena približne cene je važna zato što omogućava da se tržišna vrednost rute poveže sa njenim geografskim, mrežnim, konkurentskim i rasporednim karakteristikama. Metodološki doprinos ovog zadatka nalazi se u tome što cena nije modelovana samo kao funkcija distance. Pored Haversine udaljenosti, model uključuje efikasnost rute, stepen centralnosti aerodroma, betweenness centrality, broj operatora, udeo budžetskih prevoznika, nedeljnu frekvenciju i pokrivenost dana u nedelji.

5.5.2 Ansambl modeli kao osnova analitike cena

U modelovanju su upoređeni Linear Regression, Random Forest, XGBoost i CatBoost, a najbolji rezultat ostvario je CatBoost, sa MAE, odnosno srednjom apsolutnom greškom, od 33.84 EUR i $R^2 = 0.836$ na test skupu. Petostruka unakrsna validacija potvrdila je stabilnost, sa prosečnim CV MAE od 34.12 ± 1.05 EUR kroz validacione podele. Rezultati ukazuju da ansambl modeli imaju prednost u odnosu na linearne pristupe kada je potrebno obuhvatiti nelinearne odnose između distance, mrežne pozicije, konkurencije i rasporeda letova.

Značaj ovog nalaza nije samo u tačnosti procene cene, već i u tome što pokazuje da se tržišno ponašanje putnika oblikuje u širem kontekstu dostupnosti, konkurencije i organizacije ruta. Putnik ne bira rutu u praznom prostoru, već u okviru mreže cena, dostupnosti, prevoznika i rasporeda. Zbog toga se predikcija cena avio-karata u ovoj disertaciji ne tumači kao izolovani regresioni problem, već kao objašnjiva analiza tržišnog okruženja koje oblikuje ponašanje putnika i poslovne odluke prevoznika.

Slika 5.4 prikazuje kako se podaci o avio-ruti prevode u grupe obeležja koje ulaze u regresioni model za procenu približne cene karte. Važno je što se u istom toku povezuju atributi fizičke rute, tip prevoznika, konkurencija, vremenski i sezonski elementi, nedeljna frekvencija i mrežna centralnost. Na primer, jedan zapis iz skupa podataka može opisivati rutu VIE–QSR, odnosno vezu između Beča i Salerna, sa indikativnom cenom od 50 EUR i dostupnošću ponedeljkom, sredom kao najavljenim danom polaska i subotom, što daje vektor dostupnosti (1, 0, 1, 0, 0, 1, 0). Uz takav zapis se povezuju i metapodaci o prevozniku i operatorima, pa se cena ne posmatra kao izolovana vrednost, već kao ishod konkretne kombinacije rute, rasporeda, dostupnosti, konkurencije i tržišne pozicije.



Slika 5.4: Tok formiranja vektora obeležja za predikciju približne cene avionske karte.

5.6 Objašnjivost cenovnih faktora u avio-saobraćaju


Predikcija cene avio-karte ima ograničenu praktičnu vrednost ako model daje samo numeričku procenu bez objašnjenja. U poslovnom i transportnom odlučivanju važno je razumeti zašto je neka ruta skuplja ili jeftinija, koji faktori doprinose ceni i da li se isti faktori ponašaju jednako u različitim grupama ruta. Zbog toga je u ovom delu poglavlja poseban akcenat stavljen na objašnjivost ansambl modela.

Istraživanja evropskog tržišta avio-prevoza pokazuju da formiranje cena zavisi od kombinacije tržišnih i operativnih faktora, pri čemu kratkolinijske evropske rute često imaju posebne obrasce cenovne dinamike. Istraživanja niskotarifnih prevoznika dodatno ukazuju da prisustvo budžetskih operatora menja tržišne uslove, ali da efekat nije jednak na svim rutama [69]. Analiza kratkih evropskih ruta dodatno potvrđuje značaj udaljenosti, konkurencije i tržišnih atributa za formiranje tarifa [70]. Istovremeno, poremećaji potražnje i tržišni šokovi mogu promeniti cenovne reakcije avio-kompanija, što potvrđuje potrebu da se modeli cena tumače oprezno i u odnosu na konkretan tržišni kontekst [71].

U istom aktuelnom istraživačkom pravcu SHAP analiza pokazuje da uticaj budžetskih prevoznika i konkurencije nije homogen. Udeo budžetskih prevoznika bio je posebno značajan na kraćim rutama, dok je broj operatora imao veći značaj na konkurentnijim rutama. Ovaj nalaz je važan za disertaciju jer pokazuje da globalna važnost obeležja nije dovoljna. Potrebno je analizirati kako se doprinos faktora menja po grupama ruta, dužini linije, tipu tržišta i stepenu konkurencije.

Takav pristup povezuje prediktivnu performansu sa objašnjivom poslovnom logikom. Ako model pokaže da je cena na jednoj ruti visoka zbog udaljenosti, to ima drugačije značenje nego ako je visoka zbog niskog broja operatora ili ograničene frekvencije. U prvom slučaju cena odražava fizičke i operativne troškove, dok u drugom može ukazivati na slabiju konkurenciju ili ograničenu dostupnost. Time se SHAP objašnjenja ne koriste samo kao tehnički dodatak modelu, već kao sredstvo za prevođenje rezultata u uvide korisne za avio-kompanije, aerodrome, turističke organizacije i donosiocce odluka.

Slika 5.5 prikazuje kako se predikcija cene prevodi u njeno objašnjenje. Na slici je zato razdvojeno globalno rangiranje faktora, koje pokazuje šta je model najčešće koristio pri učenju, od lokalnog objašnjenja, koje pokazuje kako pojedinačni faktori pomeraju konkretnu procenu cene u odnosu na osnovnu očekivanu vrednost. Na globalnom nivou, SHAP vrednosti rangiraju faktore koji najviše utiču na varijaciju cena u skupu ruta, kao što su udaljenost, udeo budžetskih prevoznika i mrežna centralnost aerodroma. Na lokalnom nivou, isti pristup pokazuje zašto je konkretna ruta procenjena kao skuplja ili jeftinija od očekivanog nivoa. Takva dvoslojna interpretacija je posebno važna u avio-saobraćaju, jer isti faktor ne mora imati isti efekat na svakoj ruti. U prikazu je $\hat{p}_i$ procenjena cena za rutu i , $E[f(\mathbf{x})]$ očekivana vrednost modela, a ϕ_j SHAP doprinos pojedinačnog obeležja, odnosno njegov uticaj na povećanje ili smanjenje procenjene cene.



Slika 5.5: Objašnjivost faktora koji utiču na predikciju cena avionskih karata.

5.7 Pouzdanost sistema za procenu zadovoljstva putnika

Zadovoljstvo putnika u avio-saobraćaju predstavlja domenski važan zadatak zato što povezuje kvalitet usluge, iskustvo putovanja, lojalnost i poslovnu strategiju prevoznika. Međutim, za razliku od jednostavne klasifikacije zadovoljnih i nezadovoljnih putnika, u ovoj disertaciji naglasak je na pouzdanosti modela po segmentima. Model može ostvariti visoku ukupnu tačnost, ali istovremeno slabije prepoznavati nezadovoljstvo u pojedinim grupama, na primer kod putnika u ekonomskoj klasi, kod ličnih putovanja ili kod određenih dužina leta.

5.7.1 Podaci, modeli i performanse

U okviru istraživanja o pouzdanosti AI sistema za procenu zadovoljstva putnika korišćen je javni skup podataka sa 129.880 zapisa i 22 promenljive, uključujući kategorijalne opise putnika, numeričke operativne faktore i ordinalne ocene kvaliteta usluge. Podaci obuhvataju ciljnu promenljivu zadovoljstva, uz ulazne attribute kao što su tip korisnika, svrha putovanja, klasa usluge, udaljenost leta, kašnjenja i pojedinačne ocene aspekata usluge [72]. Korišćeni skup podataka potiče iz javno dostupnog repozitorijuma za zadovoljstvo putnika u avio-saobraćaju [73].

Eksperimentalni rezultati pokazuju da osnovni modeli ostvaruju visoku ukupnu performansu. Decision Tree postiže tačnost od 85.42%, Random Forest 88.91%, Gradient Boosting 89.67%, dok neuralna mreža ostvaruje 90.12% tačnosti i macro F1 meru 0.90. Međutim, najvažniji nalaz nije samo u visokoj ukupnoj tačnosti, već u tome što segmentna analiza otkriva neravnomernu raspodelu grešaka.

5.7.2 Segmentna evaluacija i lažno negativni ishodi


Segmentna evaluacija je uvedena zato što ukupna performansa modela može prikriti slabije ponašanje u specifičnim grupama putnika. Lažno negativni ishodi, odnosno slučajevi u kojima je nezadovoljan putnik pogrešno klasifikovan kao zadovoljan, nisu ravnomerno raspoređeni. U pojedinim segmentima ekonomske i economy-plus klase, naročito kod ličnih putovanja i kraćih letova, stopa lažno negativnih ishoda prelazi 45%. To znači da model upravo u cenovno osetljivim i operativno čestim segmentima može propustiti nezadovoljstvo putnika, iako ukupna tačnost na celom skupu ostaje visoka. Za putnički segment g stopa lažno negativnih ishoda može se zapisati kao:

$$FNR_g = \frac{\sum_{i \in g} I(y_i = 0 \wedge \hat{y}_i = 1)}{\sum_{i \in g} I(y_i = 0)}, \quad (5.6)$$

gde $y_i = 0$ označava nezadovoljnog putnika, $\hat{y}_i = 1$ predikciju da je putnik zadovoljan, a $I(\cdot)$ indikatorsku funkciju.

Ovaj rezultat je značajan za disertaciju jer pokazuje da zbirne metrike mogu prikriti važne slabosti modela. U sistemu za upravljanje korisničkim iskustvom lažno negativan ishod znači da organizacija ne prepoznaje nezadovoljnog putnika i propušta priliku za intervenciju. Zbog toga se zadovoljstvo putnika ne koristi samo kao klasifikacioni zadatak, već kao primer potrebe za segmentnom evaluacijom, analizom grešaka i proverom pouzdanosti modela u heterogenim korisničkim grupama.

Slika 5.6 prikazuje segmentnu pouzdanost modela kroz stopu lažno negativnih predikcija, odnosno kroz slučajeve u kojima su nezadovoljni putnici pogrešno klasifikovani kao zadovoljni. Toplotna mapa pokazuje da prosečna tačnost modela nije dovoljna za procenu njegove upotrebljivosti, jer se greške ne raspoređuju jednako po svim korisničkim grupama. Posebno se izdvajaju segmenti ličnih putovanja u ekonomskim klasama, naročito kod kraćih letova, gde viša vrednost FNR (*False Negative Rate*) ukazuje na potrebu za dodatnom pažnjom u tumačenju rezultata i poslovnom odlučivanju.



Slika 5.6: Toplotna mapa segmentne pouzdanosti modela za predikciju zadovoljstva putnika.

Segmentna evaluacija takođe ukazuje na ograničenje isključivo globalnog tumačenja modela. Iako ukupna tačnost i zbirne metrike daju opštu sliku performansi, one ne pokazuju da li se greške modela ravnomerno raspoređuju po različitim grupama putnika. Na primer, faktori zadovoljstva poslovnih putnika mogu biti povezani sa tačnošću, prioritarnom uslugom ili efikasnošću ukrcavanja, dok kod putnika u ekonomskoj klasi veći značaj mogu imati udobnost sedišta, higijena, odnos cene i usluge ili kašnjenje. Zbog toga segmentna analiza služi i za opreznije tumačenje modela u konkretnim korisničkim grupama.

Ovakav pristup je posebno važan za hipoteze H4 i H5, jer pokazuje da interpretabilnost i analiza grešaka dopunjuju zbirne metrike i omogućavaju pouzdaniju procenu primenljivosti modela. U kontekstu avio-kompanija, to znači da se model ne posmatra samo kroz prosečnu tačnost, već i kroz posledice grešaka u segmentima u kojima pogrešna klasifikacija može dovesti do slabijeg prepoznavanja nezadovoljstva putnika.

5.8 Nedeljna asimetrija rasporeda letova po tipu prevoznika

Pored cena i zadovoljstva putnika, transportni domen omogućava analizu vremenske organizacije usluge. Raspored letova predstavlja važan oblik ponašanja transportnog sistema, jer pokazuje kako prevoznici raspoređuju kapacitete kroz nedelju, koje rute se održavaju svakodnevno, a koje samo povremeno, i kako se poslovni model prevoznika odražava na dostupnost destinacija. Ova analiza je posebno značajna za evropski avio-saobraćaj, u kojem niskotarifni i tradicionalni prevoznici često imaju različite strategije frekvencije, rasporeda i pokrivenosti dana. U nedavnom istraživačkom radu o nedeljnoj asimetriji rasporeda letova razvijen je jednostavan i interpretabilan indikator zasnovan na binarnom vektoru dostupnosti po danima u nedelji. Svaka ruta predstavljena je vektorom:

$$\mathbf{d}_i = (d_{i1}, d_{i2}, \dots, d_{i7}), \quad (5.7)$$

gde $d_{ik} = 1$ označava da ruta i funkcioniše određenog dana u nedelji, dok $d_{ik} = 0$ označava da tog dana nema leta. Broj aktivnih dana može se definisati kao:

$$n_i = \sum_{k=1}^7 d_{ik}. \quad (5.8)$$

Na osnovu toga uveden je normalizovani indeks asimetrije:


$$A_i = \frac{7 - n_i}{7}, \quad (5.9)$$

pri čemu $A_i = 0$ označava svakodnevnu dostupnost, dok veće vrednosti označavaju ograničeniju i asimetričniju raspodelu letova tokom nedelje.

U analiziranom skupu od 18.111 ruta, nakon pretprocesiranja zadržano je 16.094 ruta. Rezultati pokazuju da samo 39.2% ruta niskotarifnih prevoznika funkcioniše svih sedam dana u nedelji, u odnosu na 55.4% ruta tradicionalnih prevoznika. Razlika u asimetriji statistički je potvrđena Mann–Whitney U testom, dok jaka negativna Spearman korelacija između asimetrije i nedeljne frekvencije pokazuje da su rute sa manjim brojem aktivnih dana znatno neravnomernije.

Ovaj nalaz je važan jer pokazuje da dostupnost destinacije ne zavisi samo od toga da li ruta postoji, već i od toga kako je raspoređena kroz vreme. Ruta koja funkcioniše jednom ili dva puta nedeljno ne pruža istu dostupnost kao svakodnevna linija, čak i kada povezuje iste gradove. U tom smislu, vremenska struktura rute postaje deo korisničkog iskustva, turističke pristupačnosti i regionalne povezanosti. Posebno je zanimljiv nalaz o cenovnom paradoksu: rute koje funkcionišu manji broj dana u nedelji mogu imati više medijalne cene, što ukazuje na moguće efekte koncentracije tržišta i slabije dostupnosti.

Slika 5.7 prikazuje nedeljnu asimetriju dostupnosti u posmatranom uzorku evropskih avio-ruta (pretežno ka italijanskim gradovima), izraženu kroz udeo aktivnih ruta po dani-ma i tipu prevoznika. Kod standardnih prevoznika udeo aktivnih ruta ostaje visok i stabilan tokom radne nedelje, dok se kod niskotarifnih prevoznika vidi niža aktivnost od ponedeljka do četvrtka i izraženiji rast pred vikend. Takav obrazac ukazuje da raspored nije samo operativni detalj, već signal poslovnog modela: stabilnija dostupnost više odgovara redovnim i poslovnim tokovima putovanja, dok koncentracija aktivnosti krajem nedelje može odražavati turističku i vikend potražnju, kao i optimizaciju kapaciteta kod niskotarifnih prevoznika.



Slika 5.7: Nedeljna asimetrija dostupnosti avio-ruta prema tipu prevoznika.

Analiza rasporedne asimetrije uvodi transparentan indikator dostupnosti ruta, koji se može koristiti u daljem modelovanju i poslovnom tumačenju avio-mreže. Iako nije složen prediktivni model, ovaj pokazatelj ima važnu ulogu u konstrukciji obeležja, jer povezuje dnevni raspored letova sa turističkom pristupačnošću, poslovnim modelom prevoznika i operativnom stabilnošću ruta.

5.9 Zavisnost destinacija od prevoznika na evropskim avio-rutama

5.9.1 Indeks zavisnosti povezanosti i profili rizika

Povezanost destinacija predstavlja sistemski aspekt transportnog domena. Za turističke destinacije, regionalne aerodrome i sekundarne gradove avio-linije nisu samo transportna usluga, već uslov tržišne dostupnosti, turističkog priliva i regionalnog razvoja. Niskotarifni prevoznici značajno su povećali dostupnost mnogih evropskih destinacija, ali su istovremeno otvorili pitanje zavisnosti od malog broja operatora. Ako destinacija zavisi od jednog ili dva budžetska prevoznika, povlačenje jedne linije, sezonsko smanjenje kapaciteta ili promena poslovne strategije može stvoriti visok rizik povezanosti.

U okviru tekućeg istraživačkog pravca razvija se poslovno-analitički okvir za procenu zavisnosti destinacija od budžetskih prevoznika i rizika turističke povezanosti. Empirijska osnova obuhvata 14.212 planiranih putničkih ruta koje povezuju 258 polaznih aerodroma u 46 zemalja sa 552 evropske destinacije. Rute opslužuje 292 prevoznika, uključujući 42 budžetska operatora, sa približno 162.000 nedeljnih letova. Na nivou destinacije konstruišu se indikatori kao što su udeo budžetskih prevoznika u rutama i frekvencijama, broj operatora, geografski domet izvorišnih tržišta, koncentracija frekvencija i prosečan intenzitet usluge. Jedan od centralnih pokazatelja ovog pravca jeste kompozitni indeks zavisnosti povezanosti, odnosno *Connectivity Dependence Index* (CDI). Indeks je uveden da bi se istovremeno obuhvatila dva aspekta rizika: visok oslonac destinacije na budžetske prevoznike i ograničena raznovrsnost operatora koji održavaju veze ka toj destinaciji:

$$CDI_j = \frac{BFS_j}{\log(1 + O_j)}, \quad (5.10)$$


gde BFS_j označava udeo frekvencija budžetskih prevoznika u destinaciji j , a O_j broj operatora. Ovakva formulacija povećava vrednost indeksa za destinacije koje imaju visok udeo budžetskih prevoznika i mali broj operatora. Time se ne meri samo prisustvo niskotarifnih linija, već strukturna zavisnost destinacije od ograničenog skupa prevoznika.

Deskriptivni rezultati tekućeg istraživanja pokazuju izraženu heterogenost evropskih destinacija. Prosečan udeo letova budžetskih prevoznika iznosi 33.6%, ali 46% destinacija prelazi prag od 50%, dok 15.2% prelazi 80%. Veliki hubovi, kao što su Frankfurt, Minhen i Ciri, imaju niže udele budžetskih letova, dok sekundarni aerodromi i turističke destinacije, uključujući Beauvais, Paphos, Treviso, Charleroi, Hahn i Modlin, pokazuju znatno veću zavisnost od budžetskih operatora. Na takvim destinacijama visoka dostupnost često zavisi od ograničenog broja prevoznika, pa promena jedne poslovne odluke može imati vidljiv uticaj na ukupnu povezanost. Klaster analiza dodatno izdvaja profile destinacija, uključujući diversifikovane hubove, uravnotežena regionalna tržišta, periferne aerodrome sa niskom frekvencijom i turističke destinacije zavisne od budžetskih prevoznika. Ovaj nalaz je posebno važan jer pokazuje da veći broj ruta ne znači nužno veću otpornost, ako su kapaciteti koncentrisani kod malog broja operatora.

U ovoj disertaciji ovaj pravac ima aplikativni i metodološki doprinos. Aplikativno, rezultati mogu pomoći turističkim organizacijama, aerodromima i regionalnim donosiocima odluka da prate zavisnost od ranjivih pristupnih kanala. Metodološki, analiza pokazuje kako se podaci o rutama mogu transformisati u indikatore otpornosti i rizika povezanosti.

Slika 5.8 prikazuje raspodelu zavisnosti evropskih destinacija od budžetskih prevoznika i konkretne destinacije sa najvišim vrednostima CDI indeksa. Gornji panel pokazuje da značajan deo destinacija prelazi prag od 50% udela budžetskih frekvencija, dok se manja, ali posebno rizična grupa nalazi iznad praga od 80%. Donji panel izdvaja destinacije kod kojih

je visoka zavisnost povezana sa ograničenim brojem low-cost operatora. Takav prikaz povezuje opšti obrazac u skupu podataka sa konkretnim primerima destinacija koje mogu biti osetljivije na promenu strategije pojedinačnih prevoznika.



Slika 5.8: Raspodela zavisnosti evropskih destinacija od budžetskih prevoznika i destinacije sa najvišim CDI skorom.

5.9.2 Mogućnosti i ograničenja podataka o evropskim avio-rutama

Za analize cena, rasporeda i povezanosti korišćen je javno dostupan skup podataka o evropskim aerodromima i avio-rutama, koji sadrži informacije o polaznim i dolaznim aerodromima, dnevnoj dostupnosti, frekvencijama, indikativnim cenama i podacima o prevoznicima [74]. Ovaj skup podataka je koristan zato što omogućava da se avio-saobraćaj posmatra kao mreža ruta, a ne samo kao zbir nezavisnih letova. Takva perspektiva je važna jer putnici, destinacije i prevoznici funkcionišu unutar strukture dostupnosti, konkurencije i rasporeda.

Istovremeno, ovaj skup podataka ima ograničenja. Cene su indikativne i prikupljene u određenom trenutku, pa ih ne treba tumačiti kao stvarne transakcione cene ili prihod avio-kompanija. Raspored letova predstavlja snimak mreže u jednom periodu, što ograničava zaključivanje o sezonskim promenama i dugoročnim trendovima. Podaci o prevoznicima zahtevaju dodatnu obradu i klasifikaciju, naročito zbog hibridnih poslovnih modela i povezanih budžetskih grupa. CDI indeks i pragovi zavisnosti zato nisu konačna mera ranjivosti destinacije, već uporedni pokazatelj za izdvajanje ruta i aerodroma koji zahtevaju detaljniju analizu. Zato se rezultati iz ovog dela disertacije tumače kao analitički pokazatelji strukture i rizika.

Ovo ograničenje nije slabost istraživanja, već deo odgovorne metodologije. U transportnim sistemima podaci su dinamični, tržišno uslovljeni i zavisni od spoljnih faktora. Zato svaki model mora jasno navesti šta predviđa, na kom vremenskom preseku, na osnovu kojih atributa i uz koje granice tumačenja. Takav pristup povezuje transportni domen sa centralnom idejom disertacije: model nije vredan samo kada daje predikciju, već kada su jasni njegovi podaci, pretpostavke, ograničenja i uslovi primene.

5.10 Sinteza nalaza u oblasti transportnih sistema

Transportni domen potvrđuje da prediktivna analitika ponašanja ne mora biti zasnovana samo na tekstualnim podacima. U ovom poglavlju ponašanje je analizirano kroz sekvence vožnje, strukturisana obeležja, cene avionskih karata, zadovoljstvo putnika, rasporede letova i mrežne indikatore dostupnosti. Time je pokazano da se isti integrativni istraživački okvir može primeniti na više nivoa kompleksnosti: od mikroponašanja pojedinačnog vozača, preko iskustva putnika, do makrostrukture evropske avio-mreže.

Prvi skup nalaza odnosi se na kopneni saobraćaj i pokazuje da rizično ponašanje ne treba tumačiti kao izolovano prekoračenje praga, već kao obrazac koji nastaje kroz kombinaciju bihevioralnih, voznih i kontekstualnih signala. DNN/MLP model potvrđuje da se nelinearne veze između brzine, uslova puta, vremenskih faktora i interakcije sa drugim vozilima mogu koristiti za klasifikaciju stilova vožnje, uz tačnost od približno 87%. LSTM pristup pokazuje da je redosled događaja važan za rano prepoznavanje rizičnih promena, pri čemu je tačnost povećana na oko 89%, a odziv za potencijalno agresivnu vožnju sa 71% na 80%.

Drugi skup nalaza odnosi se na avio-saobraćaj i pokazuje da se tržišno i operativno ponašanje sistema može analizirati kroz cenu, raspored, dostupnost i segmentnu pouzdanost. Modelovanje cena avionskih karata pokazuje da cenu ne određuje samo udaljenost, već i mrežna pozicija aerodroma, konkurencija, udeo budžetskih prevoznika i nedeljna organizacija usluge. CatBoost model je ostvario MAE od 33.84 EUR i $R^2 = 0.836$, što ukazuje da ansambl pristupi mogu obuhvatiti nelinearne odnose između geografskih, tržišnih, mrežnih i rasporednih faktora. Objašnjivost modela dodatno omogućava da se cena tumači kao posledica strukture rute i tržišnih uslova, a ne samo kao numerički ishod.

Treći skup nalaza odnosi se na pouzdanost modela po segmentima. Analiza zadovoljstva putnika pokazuje da visoka ukupna tačnost, u ovom slučaju 90.12% uz macro F1 vrednost od 0.90, ne garantuje jednako pouzdano ponašanje modela u svim grupama. U pojedinim segmentima stopa lažno negativnih ishoda prelazi 45%, što pokazuje da zbirne metrike mogu prikriti greške sa direktnim poslovnim značenjem. Zbog toga segmentna evaluacija u ovom poglavlju nije dodatak osnovnoj tačnosti, već deo procene odgovorne primene modela.

Četvrti skup nalaza odnosi se na sistemsku dostupnost ruta. Indeks rasporedne asimetrije pokazuje da nije dovoljno znati da ruta postoji, već je potrebno analizirati koliko ravnomerno funkcioniše kroz nedelju. Nalaz da 39.2% ruta niskotarifnih prevoznika i 55.4% ruta tradicionalnih prevoznika funkcioniše svih sedam dana ukazuje na različite obrasce dostupnosti i poslovne logike prevoznika. Indeks zavisnosti povezanosti dodatno pokazuje da dostupnost destinacije može biti ranjiva kada je veliki deo frekvencija koncentrisan kod malog broja budžetskih operatora. U oba slučaja ključni problem nije odsustvo informacije, već njena neravnomerna raspodela: model može biti tačan u proseku, a ruta formalno dostupna, dok se stvarni rizik pojavljuje tek u pojedinačnim segmentima i danima.

U odnosu na hipoteze disertacije, transportni domen najdirektnije podržava H1, H2, H4 i H5, uz dopunski oslonac za H3. H1 je podržana kroz primenu dubokog učenja u zadacima u kojima se ponašanje razvija kroz vreme, posebno kroz LSTM modelovanje sekvenci vožnje. H2 se potvrđuje kroz značaj reprezentacije podataka: sekvencijalna obeležja u vožnji, mrežna i cenovna obeležja u avio-saobraćaju, rasporedni indikatori i segmentne metrike grešaka daju različite nivoe uvida. H3 se ogleda u potrebi za pretprocesiranjem, konstrukcijom indikatora i proverom pouzdanosti podataka pre modelovanja. H4 je potvrđena kroz SHAP objašnjenja, segmentnu evaluaciju i analizu lažno negativnih ishoda, dok H5 pokazuje da najkorisniji model nije uvek onaj sa najvećom tačnošću, već onaj koji odgovara tipu podataka, riziku primene i potrebi za objašnjenjem.

Zaključno, transportni domen pokazuje da modeli moraju biti provereni ne samo globalno, već i po vremenu, segmentima, rutama i sistemskim uslovima. Njegov doprinos disertaciji nije samo u dodavanju još jedne oblasti primene, već u uvođenju drugačijeg oblika digitalnog traga ponašanja, koji istovremeno obuhvata individualne odluke, operativne obrasce i mrežnu strukturu sistema. Ponašanje u transportu izražava se kroz kretanje, frekvenciju, cenu, raspored, dostupnost i mrežnu povezanost, zbog čega ovo poglavlje snažno podržava integrativni karakter disertacije.

Naredno poglavlje prelazi na oblast internet trgovine i parfemske industrije, gde se ponašanje potrošača analizira kroz recenzije, subjektivne preference, mirisne note, emocionalne signale, popularnost proizvoda i fuzzy kategorizaciju potrošačkih narativa. Time se istraživački okvir dodatno proširuje na domene u kojima su korisničke odluke izrazito subjektivne, emocionalne i višeznačne.

6. INTERNET TRGOVINA I PARFEMSKA INDUSTRIJA

6.1 Potrošačko ponašanje u internet trgovini

Internet trgovina predstavlja značajan empirijski domen za razvoj i evaluaciju prediktivnih modela ponašanja korisnika, jer se potrošačke odluke sve češće formiraju i izražavaju kroz digitalne tragove. Ti tragovi obuhvataju numeričke ocene proizvoda, tekstualne recenzije, učestalost kupovine, pretrage, rangiranje proizvoda, reakcije na cenu, komentare, liste želja, preporuke i ponašanje na platformama. Za razliku od domena u kojima se ponašanje korisnika meri kroz relativno jasno definisane događaje, internet trgovina obuhvata veliki broj proizvoda čija se vrednost formira kroz kombinaciju funkcionalnih, emocionalnih, simboličkih i društvenih faktora. U tom okviru parfemska industrija služi kao posebno pogodan testni domen, jer se potrošački izbor zasniva na subjektivnom doživljaju, emocionalnom jeziku, mirisnim asocijacijama i delimično nepreciznim kategorijama proizvoda.

U ovoj disertaciji internet trgovina se ne posmatra samo kao poslovni kanal, već kao prostor u kojem se potrošačko ponašanje može kvantifikovati, modelovati i objasniti pomoću podataka nastalih u interakciji korisnika sa proizvodima i platformama. Savremena istraživanja korisničkih recenzija pokazuju da se digitalni tragovi potrošača mogu koristiti za razumevanje stavova, preferencija, sentimenta i tržišnih obrazaca, ali da izbor reprezentacije i evaluacionog protokola značajno utiče na pouzdanost rezultata [75]. U kontekstu platformskog odlučivanja, tekstualni i strukturisani signali korisnika mogu doprineti tržišnoj inteligenciji samo ako su povezani sa objašnjivim i proverljivim analitičkim postupkom [76]. Takav pristup pomera fokus sa same predikcije ka upotrebljivoj tržišnoj interpretaciji.

Posebna pažnja u ovom poglavlju usmerava se na parfemsku industriju. Parfemi predstavljaju proizvode kod kojih je potrošačka odluka izrazito subjektivna i višedimenzionalna. Za razliku od proizvoda čije se karakteristike mogu jednostavno meriti, kao što su dimenzije, brzina, kapacitet ili tehničke performanse, parfemi se vrednuju kroz mirisni doživljaj, emocionalne asocijacije, identitet, sećanje, brend, trajnost, projekciju, cenu, dizajn i društveni kontekst upotrebe. Zbog toga parfemski domen ima posebnu metodološku vrednost: on omogućava proveru da li se prediktivni modeli mogu primeniti i onda kada su korisnički signali subjektivniji i ne mogu lako da se prevedu u jednu numeričku oznaku.

U okviru istraživačkog okvira disertacije, ovaj domen ima četiri povezane uloge. Prvo, on proverava kako se atributi proizvoda, kao što su mirisne note, akordi, brend i godina lansiranja, mogu pretvoriti u reprezentacije pogodne za mašinsko učenje. Drugo, on pokazuje kako se potrošačke preference i emocionalne reakcije mogu analizirati kroz tekstualne recenzije i izvedene indikatore popularnosti. Treće, on uvodi fuzzy i reprezentaciono modelovanje kao način da se uhvati činjenica da jedna recenzija ili jedan proizvod mogu istovremeno pripadati većem broju evaluativnih i tržišnih kategorija. Četvrto, ovaj domen proverava kako se modeli mogu koristiti u uslovima nepotpunih i neujednačenih podataka, što je čest problem komercijalnih baza podataka nastalih u realnom platformskom okruženju. Digitalni zapis o proizvodu u internet trgovini može se formalno predstaviti kao:

$$p_i = (a_i, b_i, r_i, c_i, t_i, m_i), \quad (6.1)$$

gde je a_i skup atributa proizvoda, b_i brend ili proizvođač, r_i korisnička ocena ili izvedeni indikator vrednosti, c_i tržišni kontekst proizvoda, t_i tekstualni opis ili recenzija, a m_i skup metapodataka. U slučaju parfema, skup atributa a_i dodatno obuhvata gornje, srednje i bazne mirisne note, glavne akorde, koncentraciju, pol, godinu lansiranja i imena kreatora parfema, ukoliko su dostupna.

Tabela 6.1 pokazuje da internet trgovina i parfemska industrija proširuju disertaciju izvan klasičnih prediktivnih zadataka. U ovom domenu model ne treba samo da predvidi ocenu ili klasu, već da pomogne u razumevanju zašto se određeni proizvod doživljava kao privlačan, po čemu se razlikuje od sličnih proizvoda i kako se subjektivni potrošački doživljaj povezuje sa tržišnim ishodima.

Tabela 6.1: Analitička uloga internet trgovine i parfemske industrije u disertaciji.

Nivo analize	Primeri signala	Doprinos istraživačkom okviru
Proizvod	Note, akordi, brend, godina lansiranja, koncentracija	Reprezentacija subjektivno vrednovanih proizvoda kroz strukturisane i semantičke attribute
Korisnik	Ocene, recenzije, emocionalni opisi, preferencije	Analiza potrošačkog doživljaja, sentimenta i višeznačnih narativa
Tržište	Popularnost, broj ocena, brend dominacija, trendovi nota	Predikcija i objašnjenje tržišnih obrazaca i strateškog pozicioniranja
Model	Klasterovanje, LSTM, sentiment analiza, fuzzy kategorizacija, vektorske reprezentacije	Provera modela u domenu sa subjektivnim, nepotpunim i emocionalno obojenim podacima

6.2 Parfemi kao proizvodi zasnovani na ličnom doživljaju i preferencijama

Parfemi su pogodan domen za proveru prediktivnih i interpretabilnih modela zato što istovremeno poseduju jasno definisane atributske opise i izrazito subjektivnu korisničku vrednost. Sa jedne strane, svaki parfem se može opisati kroz mirisne note, akorde, brend, koncentraciju i godinu lansiranja. Sa druge strane, odluka korisnika ne zavisi samo od tih objektivno navedenih atributa, već i od ličnog iskustva, emocionalnog odgovora, asocijacija, sećanja, identiteta i društvene upotrebe proizvoda.

U marketinškom i analitičkom smislu, parfem nije samo proizvod već interpretativni objekat. Isti mirisni akord može biti opisan kao elegantan, nostalgican, težak, svež, zavodljiv, svakodnevan ili luksuzan u zavisnosti od korisnika, konteksta i očekivanja. Zbog toga prosečna ocena parfema ne može u potpunosti objasniti njegovu tržišnu poziciju. Potrebno je analizirati kombinaciju atributa i narativa: koje note se ponavljaju, koji brendovi dominiraju, kako korisnici opisuju emocije, koliko je proizvod ocenjen, koliko je komentara dobio i kako se slični proizvodi grupišu u latentnom prostoru. Zbog toga se parfemski proizvod u analitičkom smislu posmatra kao spoj hemijskih, semantičkih, emocionalnih i tržišnih obeležja. Mirisna struktura parfema najčešće se posmatra kroz tri sloja:

$$F_i = (T_i, M_i, B_i), \quad (6.2)$$

gde T_i predstavlja skup gornjih nota, M_i skup srednjih nota, a B_i skup baznih nota parfema i . Gornje note obično opisuju prvi utisak, srednje note karakter parfema nakon početnog isparavanja, dok bazne note utiču na trajnost i završni doživljaj. Iako je ova struktura hemijski i tržišno korisna, u korisničkim recenzijama granice između slojeva nisu uvek jasno izražene. Korisnik često ne komentariše samo notu, već njen doživljaj: toplinu, svežinu, slatkoću, ozbiljnost, sezonalnost ili emocionalni efekat. Zbog toga je za potrebe modelovanja korisno definisati širu reprezentaciju parfema:

$$z_i = \phi(F_i, A_i, B_i, R_i), \quad (6.3)$$

gde F_i označava slojeve mirisnih nota, A_i glavne akorde, B_i brend i tržišne karakteristike, a R_i korisničke signale, kao što su ocene, broj ocena i recenzije. Funkcija ϕ predstavlja postupak kojim se heterogeni podaci prevode u analitičku reprezentaciju pogodnu za klasterovanje, predikciju, objašnjenje ili preporuku.

Za disertaciju je naročito važno to što parfemski domen uvodi proizvode kod kojih se vrednost ne može potpuno izvesti iz funkcionalnih osobina. U hotelijerstvu se zadovoljstvo može povezati sa uslugom, čistoćom, lokacijom ili osobljem. U transportu se rizik ili zadovoljstvo mogu povezati sa sekvencom vožnje, cenom, rutom ili segmentom putnika. Upravo zato ovaj domen potvrđuje da istraživački okvir disertacije može obuhvatiti i proizvode čija je tržišna vrednost zasnovana na doživljaju, a ne samo na merljivim performansama.

Ovakva priroda proizvoda utiče i na način na koji treba tumačiti prediktivne rezultate. Kod tehničkih proizvoda greška modela se često može povezati sa nedostajućim informacijama o specifikaciji ili performansama. Kod parfema greška može nastati zato što dva proizvoda sa sličnim notama izazivaju potpuno različite asocijacije, zato što brend menja očekivanje korisnika ili zato što ista nota ima različitu ulogu u gornjem, srednjem i baznom sloju. Zbog toga se u ovom poglavlju predikcija ne odvajava od interpretacije.

6.3 Podaci i reprezentacija parfemskog domena

6.3.1 Pregled skupova podataka

Empirijska osnova ovog poglavlja zasnovana je na javno dostupnim skupovima podataka iz parfemske industrije i na dopunskim eksperimentima iz oblasti opšte e-commerce analitike. Korišćena su dva komplementarna izvora za parfeme: *Fragrantica* skup podataka i *Parfumo* skup podataka. *Fragrantica* podaci obuhvataju veliki broj zapisa sa nazivom parfema, polnom ciljnom grupom, prosečnom ocenom, brojem ocena, glavnim akordima, parfemerima, opisom i linkom ka profilu proizvoda [77]. *Parfumo* podaci dodatno sadrže strukturisanije informacije o brendu, godini lansiranja, koncentraciji, prosečnoj oceni, broju ocena, glavnim akordima, gornjim, srednjim i baznim notama, parfemerima i URL adresi proizvoda [78].

U očišćenoj verziji *Fragrantica* podataka nalazi se 70.103 zapisa i osam osnovnih atributa. Prosečna ocena dostupna je za 63.922 parfema, dok je broj ocena dostupan za 63.922 zapisa, uz to da se deo vrednosti mora dodatno standardizovati zbog formata zapisa. U javno dostupnoj *Parfumo* verziji nalazi se 59.325 zapisa i trinaest atributa. Prosečna ocena i broj ocena dostupni su za 30.046 parfema, godina lansiranja za 39.009 parfema, a podaci o mirisnim notama dostupni su za približno polovinu zapisa, u zavisnosti od sloja note.

Pored navedenih izvora, za širi e-commerce sloj korišćen je uravnotežen uzorak od 100.000 Amazon Customer Reviews recenzija, stratifikovan po kategoriji proizvoda i oceni, kao i Amazon Fine Food Reviews skup podataka [79] u okviru studentskog istraživačkog rada koji je nastao u saradnji sa studentima tokom izvođenja praktičnih vežbi iz predmeta Analiza velikih podataka. Ovi skupovi nisu primarni parfemski izvori, ali su važni za proveru istog problema u drugim proizvodnim domenima: kako se tekstualni sentiment, numerička ocena i metapodaci recenzije mogu povezati radi detekcije nelogičnih ili sumnjivih obrazaca. Time se parfemska analiza ne posmatra izolovano, već kao deo šireg problema kvaliteta i interpretacije korisničkih recenzija u internet trgovini.

Tabela 6.2 pokazuje da se u ovom poglavlju kombinuju specijalizovani parfemski izvori i opšti izvor iz oblasti internet trgovine. Takva kombinacija omogućava da se jedan istraživački problem sagleda iz dva ugla: parfemi pokazuju kako se modeluju subjektivni i emocionalni proizvodi, dok Amazon recenzije pokazuju kako se proverava usklađenost između tekstualnog i numeričkog korisničkog signala.

Tabela 6.2: Korišćeni skupovi podataka u oblasti parfemske industrije i internet trgovine.


Skup podataka	Broj zapisa	Ključni atributi	Analitička uloga
Fragrantica	70.103	Naziv, polna ciljna grupa, prosečna ocena, broj ocena, glavni akordi, parfemeri, opis proizvoda	Analiza akorda, ocena, emocionalnih opisa, nedostajućih vrednosti i alternativnog vrednovanja
Parfumo	59.325	Brend, godina lansiranja, koncentracija, ocena, broj ocena, akordi, gornje, srednje i bazne note	Analiza vremenskih trendova, popularnosti, LSTM modelovanja i slojevite mirisne reprezentacije
Amazon Customer Reviews	100.000	Kategorija proizvoda, ocena, korisnost recenzije, potvrđena kupovina, Vine oznaka, naslov, tekst recenzije i datum	Tekuće istraživanje fuzzy kategorizacije recenzija kroz dimenzije kvaliteta proizvoda, upotrebljivosti, isporuke, korisničke podrške i poverenja
Amazon Fine Food Reviews	568.454	Korisnik, proizvod, ocena, korisnost recenzije, naslov, tekst, vreme	Dopunska provera odnosa između numeričke ocene, sentimenta i kvaliteta recenzija u internet trgovini

Slika 6.1 prikazuje kako se različiti izvori i tipovi signala pretvaraju u zajednički analitički okvir. U prikazu je važno da budu odvojeni atributski sloj proizvoda, tekstualni sloj recenzija, tržišni sloj ocena i interpretativni sloj poslovne odluke.

6.3.2 Nedostajuće ocene i alternativno vrednovanje proizvoda

Jedan od izazova u analizi parfemskih skupova podataka jeste nedostatak potpunih i konzistentnih korisničkih ocena. U parfemskoj industriji veliki broj proizvoda ima mali broj ocena ili nema numeričku vrednost. Ako se takvi proizvodi uklone, gubi se veliki deo tržišne slike, naročito za manje poznate brendove, nove parfeme ili nišne kompozicije. Ako se, međutim, tretiraju kao jednako informativni kao ocenjeni proizvodi, model može biti pristrasan prema nepotpunim ili slabo potvrđenim signalima.

U ranijem radu je razvijen alternativni pristup vrednovanju parfema u uslovima nepotpunih ocena, zasnovan na analizi mirisnih nota, sličnosti nota, klastera i dizajnerskog uticaja [80]. Taj pristup ne pokušava da zameni stvarnu korisničku ocenu kao apsolutnu istinu, već uvodi izvedeni indikator koji pomaže da se proizvodi bez potpunog rejtinga uključe u analizu. Tako se povećava pokrivenost skupa podataka i otvara šire istraživanje tržišnih obrazaca.



Slika 6.1: Predložena arhitektura podataka za analizu parfema u internet trgovini.

U inicijalnoj Fragrantica bazi je preko 80.000 unosa bilo dostupno, ali je više od 90% vrednosti u koloni rejtinga bilo prazno ili neupotrebljivo za modelovanje. Ovaj rezultat je značajan za disertaciju jer pokazuje da prediktivna analiza u internet trgovini ne počinje izborom modela, već proverom da li je ciljna promenljiva dovoljno informativna. Kada cilj nije potpun, model mora da koristi pomoćne signale, ali uz ograničenje da takvi signali predstavljaju aproksimaciju, a ne direktno korisničko iskustvo. Osnovna ideja alternativnog vrednovanja može se predstaviti kroz dve komponente. Prva komponenta meri značaj mirisnog profila na osnovu pripadnosti klasterima nota. Druga komponenta meri tržišnu ili dizajnersku prisutnost na osnovu učestalosti brenda, parfemera ili dizajnera u skupu podataka. Kompozitna vrednost parfema može se prikazati kao:

$$S_i = \alpha C_i + \beta D_i, \quad (6.4)$$

gde je S_i alternativni skor parfema, C_i skor mirisnih klastera, D_i indikator dizajnerskog ili brend uticaja, a α i β težinski koeficijenti koji određuju relativan doprinos mirisne strukture i tržišne prisutnosti. U eksperimentu sa trendovima nota korišćena je konfiguracija $\alpha = 0.6$ i $\beta = 0.4$, čime je veći značaj dat mirisnom profilu, dok je dizajnerski uticaj zadržan kao dopunski signal. Skor mirisnih klastera može se dobiti kao prosečna težina klastera kojima pripadaju note parfema:

$$C_i = \frac{1}{|N_i|} \sum_{n \in N_i} w_{cluster(n)}, \quad (6.5)$$

gde je N_i skup nota parfema i , a $w_{cluster(n)}$ težina klastera kojem nota n pripada. Ovakav pristup omogućava da se u vrednovanje uključi struktura mirisnog profila, a ne samo postojanje ili odsustvo pojedinačnih nota.

Na primer, uklanjanje zapisa bez naziva ili opisa sprečava da se alternativni skor formira nad proizvodima čija mirisna struktura nije dovoljno poznata, dok standardizacija naziva nota smanjuje veštačko razdvajanje istih ili vrlo srodnih mirisnih oznaka. Na taj način čišćenje podataka nije samo tehnički preduslov, već deo interpretativne kontrole koja određuje koliko se izvedeni skor može smatrati smislenim pokazateljem tržišne vidljivosti.

Tabela 6.3 pokazuje da alternativni skor nije jednostavna imputacija, već rezultat više koraka koji povezuju mirisnu strukturu i tržišnu vidljivost. U rezultatima istraživanja posebno su se izdvojili klasteri u kojima dominiraju amber i bergamot, što ukazuje na njihovu veću zastupljenost i tržišni značaj u analiziranoj bazi. Pored toga, brendovi i dizajneri sa većim brojem proizvoda dobijaju veću težinu u delu skora koji se odnosi na tržišnu prisutnost. Ovaj nalaz treba tumačiti oprezno: učestalost ne znači nužno viši kvalitet ili bolju korisničku percepciju, ali ukazuje na veću vidljivost, dostupnost, tržišnu prisutnost i zastupljenost u analiziranom digitalnom katalogu.

Tabela 6.3: Postupak alternativnog vrednovanja parfema sa nepotpunim ocenama.

Korak	Operacija	Analitički značaj
Čišćenje podataka	Uklanjanje zapisa bez naslova ili opisa, standardizacija praznih ocena, zadržavanje relevantnih atributa	Smanjuje šum i priprema podatke za poređenje proizvoda
Obrada nota	Tokenizacija, lematizacija, uklanjanje stop-reči i standardizacija varijanti nota	Ujednačava tekstualne oznake i smanjuje broj veštački različitih zapisa
Sličnost i klasteri	Word2Vec, kosinusna sličnost i K-means klasterovanje u deset grupa	Formira šire mirisne grupe koje imaju domensko značenje
Dizajnerski uticaj	Skaliranje učestalosti dizajnera ili brenda na opseg od 1 do 5	Uvodi tržišnu vidljivost kao dopunski signal
Kompozitni skor	Kombinovanje skora nota i dizajnerskog skora uz težine 0.6 i 0.4	Omogućava uključivanje proizvoda bez dostupne korisničke ocene

Metodološki značaj ovog dela ogleda se u tome što se nedostajuća ocena posmatra kao signal ograničene vidljivosti proizvoda na tržištu. Parfem bez ocena može biti nov, nišan, slabio promovisan ili namenjen specifičnoj grupi korisnika. Alternativni skor zato treba tumačiti kao pomoćni indikator potencijalne vrednosti, a ne kao zamenu za realno korisničko iskustvo. Takvo tumačenje omogućava oprezniju upotrebu izvedenih vrednosti u daljoj analizi.

6.4 Modelovanje mirisne strukture i popularnosti parfema

6.4.1 Grupisanje mirisnih nota i analiza sličnosti proizvoda

Mirisne note predstavljaju osnovni atributski sloj parfema. Međutim, lista nota sama po sebi nije dovoljna za prediktivno modelovanje jer su note tekstualne oznake, često različito zapisane, delimično sinonimne i međusobno semantički povezane. Na primer, citrusi, limun, bergamot i mandarina mogu pripadati srodnom olfaktornom prostoru, ali se u podacima pojavljuju kao odvojeni tokeni. Zato je potrebno razviti postupke koji mogu uhvatiti sličnost između nota i grupisati ih u smislenije celine. U okviru ovog istraživačkog pravca primenjena je obrada tekstualnih oznaka nota kroz tokenizaciju, lematizaciju, uklanjanje stop-reči, standardizaciju varijanti i izračunavanje frekvencija. Nakon toga su korišćene vektorske reprezentacije i kosinusna sličnost, a K-means klasterovanje je primenjeno radi grupisanja srodnih mirisnih nota. Sličnost dve note može se izraziti kosinusnom merom:

$$\cos(v_a, v_b) = \frac{v_a \cdot v_b}{\|v_a\| \|v_b\|}, \quad (6.6)$$

gde su v_a i v_b vektorske reprezentacije dve mirisne note. Veća vrednost ukazuje na veću semantičku ili distribucionu sličnost. Klasterovanje nota omogućava da se pojedinačne note posmatraju kroz šire mirisne porodice ili tržišne grupe. Time se smanjuje fragmentacija nota i omogućava stabilnije tumačenje obrazaca koji se ponavljaju kroz veći broj parfema. K-means algoritam minimizuje odstupanje tačaka od centara klastera:

$$J = \sum_{j=1}^K \sum_{x_i \in C_j} \|x_i - \mu_j\|^2, \quad (6.7)$$


gde je C_j skup nota u klasteru j , a μ_j centroid tog klastera. U parfemskom domenu klasteri ne treba da budu tumačeni samo kao matematičke grupe, već kao tržišno i semantički korisne celine. Oni mogu ukazati na dominantne mirisne porodice, srodnost proizvoda, niše u portfoliju i potencijalne pravce preporuke.

Tabela 6.4 potvrđuje da parfem više nije posmatran samo kao lista karakteristika, već kao objekat u semantičkom i tržišnom prostoru. To omogućava poređenje, grupisanje i predikciju, ali i objašnjenje dobijenih rezultata. Redosled koraka u tabeli dodatno pokazuje da interpretabilna reprezentacija nastaje postepeno: od čišćenja i standardizacije nota, preko vektorizacije i merenja sličnosti, do formiranja klastera i izvedenog skora proizvoda.

Slika 6.2 povezuje tehnički i domenski deo analize: tačke u prostoru pokazuju matematičku sličnost, dok oznake dominantnih nota omogućavaju da se klasteri tumače kao prepoznatljive mirisne celine. Posebno označene note, kao što su amber, bergamot, ruža, vanila i sandalovina, olakšavaju povezivanje latentnog prostora sa poznatim parfemskim porodicama i pokazuju da se mirisne note ne grupišu slučajno, već prema srodnosti u opisu i upotrebi.

Tabela 6.4: Od atributa parfema do interpretabilne reprezentacije.

Korak	Postupak	Doprinos modelovanju
Čišćenje nota	Standardizacija zapisa, uklanjanje praznih i neinformativnih vrednosti	Smanjenje šuma i varijabilnosti u tekstualnim oznakama
Vektorizacija	Predstavljanje nota kroz vektorske reprezentacije ili frekvencijske vektore	Poređenje nota u zajedničkom prostoru
Sličnost	Kosinusna sličnost između nota ili proizvoda	Identifikacija bliskih mirisnih profila
Klasterovanje	Grupisanje nota u latentne mirisne celine	Objašnjiva struktura mirisnih porodica i tržišnih obrazaca
Skor proizvoda	Kombinovanje klastera nota i brend/dizajner uticaja	Alternativni indikator vrednosti kod nepotpunih ocena



Slika 6.2: Vizuelizacija klastera mirisnih nota. Dimenzije 1 i 2 predstavljaju dvodimenzionalnu projekciju prostora sličnosti između reprezentacija nota.

6.4.2 Predikcija popularnosti parfema kroz vremenske obrasce

Popularnost parfema može se posmatrati kao izvedeni indikator tržišne vidljivosti i potrošačke prihvaćenosti. Ona se ne svodi samo na prosečnu ocenu, jer proizvod sa visokom ocenom i malim brojem ocena ne mora imati istu tržišnu težinu kao proizvod sa nešto nižom ocenom, ali velikim brojem korisničkih interakcija. Zbog toga je za analizu popularnosti potrebno kombinovati ocenu, broj ocena, godinu lansiranja, brend i prisustvo mirisnih nota.

Jedan mogući indikator popularnosti može se definisati kao:

$$Pop_i = norm(r_i) \cdot \log(1 + q_i), \quad (6.8)$$

gde je r_i prosečna ocena parfema, q_i broj ocena ili korisničkih reakcija, a $norm(r_i)$ normalizovana vrednost ocene. Logaritamska transformacija broja ocena smanjuje dominaciju izuzetno popularnih proizvoda i omogućava stabilnije poređenje proizvoda različite vidljivosti.

U istraživanju popularnosti parfema, zasnovanom na Parfumo podacima, analizirane su mirisne note, godine lansiranja, ocene, broj recenzija i tržišna učestalost pojedinih kompozicija. Posebna pažnja usmerena je na vremensku dimenziju, jer popularnost parfema nije statična pojava. Trendovi mirisnih nota menjaju se kroz godine, a nove kompozicije nastaju u odnosu na tržišne cikluse, promene potrošačkih navika i dominaciju određenih brendova. U tom radu primenjen je LSTM pristup za modelovanje vremenskih obrazaca popularnosti i analizu evolucije potrošačkih preferencija [81]. Vremenska analiza može se predstaviti kao zadatak u kojem se za svaku notu ili grupu nota posmatra niz učestalosti kroz godine:

$$s_n = (f_{n,1}, f_{n,2}, \dots, f_{n,T}), \quad (6.9)$$

gde $f_{n,t}$ označava učestalost note n u vremenskom periodu t . Cilj modela je da nauči obrasce promene i proceni da li određene note ili mirisne porodice pokazuju rast, opadanje, sezonsku stabilnost ili cikličnu popularnost. LSTM arhitektura je pogodna za ovaj zadatak zato što omogućava učenje zavisnosti kroz vreme. Skriveno stanje modela zavisi od trenutnog ulaza i prethodnog stanja:

$$h_t = LSTM(x_t, h_{t-1}), \quad (6.10)$$


gde x_t predstavlja ulazne karakteristike u periodu t , a h_t latentnu reprezentaciju akumuliranog vremenskog obrasca. U kontekstu parfema, takav model može pomoći da se razume kako se menja interesovanje za određene note, brendove ili tipove kompozicija.

Tabela 6.5 pokazuje da optimizacija modela doprinosi tačnosti i boljem tumačenju promena u zastupljenosti mirisnih nota. Preciznije predikcije omogućavaju razlikovanje nota sa stabilnim trendom, kao što su mošus, sandalovina i jasmin, od nota kod kojih se očekuju izraženije promene, poput rasta popularnosti ruže ili slabije buduće zastupljenosti mandarine.

Slika 6.3 naglašava da se vremenski model ne gradi direktno na pojedinačnim recenzijama, već na agregiranim obrascima pojavljivanja nota kroz godine. Prozor od tri uzastopne godine uvodi vremenski kontekst u model, pa se popularnost note procenjuje na osnovu njenog kretanja kroz kraći niz prethodnih perioda. Prikazana arhitektura obuhvata normalizaciju ulaznog niza, formiranje *look-back* prozora od tri godine, LSTM sloj sa većim brojem jedinica, regularizaciju kroz *Dropout* i L_2 ograničenje, zatim manji LSTM sloj i završni *TimeDistributed Dense* sloj za procenu buduće zastupljenosti mirisnih nota.

Tabela 6.5: Rezultati LSTM modela za predikciju popularnosti mirisnih nota.

Faza modela	MSE	MAE	Tumačenje rezultata
Pre optimizacije	0.0201	0.1058	Model prati opšti tok vremenskih podataka, ali ostavlja prostor za bolju procenu manje zastupljenih nota
Posle optimizacije	0.0101	0.0801	Smanjena greška ukazuje da su dodatni slojevi, regularizacija, Adam optimizacija i TimeDistributed Dense sloj poboljšali predikcije



Slika 6.3: Predložena LSTM arhitektura za predikciju popularnosti mirisnih nota.

Važno je napomenuti da predikcija popularnosti parfema ne predstavlja samo tehnički zadatak predviđanja budućeg trenda. Njen aplikativni značaj nalazi se u podršci strateškom odlučivanju: planiranju portfolija, identifikaciji rastućih mirisnih pravaca, proceni tržišnih niša i usmeravanju marketinga. U tom smislu, dobijene metrike nisu samo numerički pokazatelji performansi modela, već signali koji pomažu da se razume da li se određeni mirisni profil razvija kao stabilan trend, kratkotrajna moda ili nišna preferencija.

6.4.3 Emocionalna analiza korisničkih recenzija parfema

Jedna od najvažnijih posebnosti parfemskog domena jeste veza između mirisa i emocija. Korisnici parfeme ne opisuju samo tehničkim terminima, već i kroz osećanja, slike, sećanja i društvene situacije. Recenzije parfema zato često sadrže izraze koji se odnose na romantiku, energiju, nostalgiju, smirenost, zavodljivost, agresivnost, eleganciju ili identitet. Ovakvi izrazi predstavljaju vredan, ali složen izvor podataka, jer emocionalni signal nije uvek eksplicitan i može zavisiti od konteksta.

U radu predstavljenom na konferenciji Sinteza 2025 analizirana je veza između korisničkih recenzija, mirisnih nota i emocionalnih kategorija parfema [82]. U tom istraživanju korišćen je Fragrantica skup podataka sa 84.136 obrađenih zapisa nakon čišćenja, pri čemu su zadržani naziv parfema, opis, dizajner, note, recenzije i ocena. Metodološki okvir je kombinovao VADER sentiment analizu, fine-tuned DistilBERT model i povezivanje nota sa emocionalnim kategorijama. Kategorije su obuhvatale romantične, energizujuće, melanholične, agresivne, opuštajuće i neutralne parfeme.

Ovaj deo istraživanja je važan za disertaciju zato što pokazuje da parfemske recenzije ne treba svoditi samo na pozitivan ili negativan sentiment. Dve pozitivne recenzije mogu opisivati potpuno različite emocionalne efekte: jedna može naglašavati smirenost i udobnost, druga energiju i svežinu. Slično tome, negativna recenzija ne mora ukazivati na nisku kvalitetnu vrednost proizvoda, već na neusklađenost mirisa sa ličnim očekivanjem korisnika. Zato se emocionalna analiza uvodi kao srednji sloj između osnovnog sentimenta i tržišne odluke. Emocionalni skor parfema može se zapisati kao vektor:

$$\mathbf{e}_i = (e_{i1}, e_{i2}, \dots, e_{i6}), \quad (6.11)$$

gde svaka komponenta označava stepen izraženosti jedne emocionalne kategorije. Ako se ovaj vektor kombinuje sa ocenom i notama, dobija se šira osnova za interpretaciju proizvoda.


U Tabeli 6.6 prikazani su rezultati emocionalnog povezivanja najčešćih mirisnih nota na osnovu Sinteza 2025 istraživanja. Rezultati pokazuju da se iste note ne mogu posmatrati samo kao deskriptivni elementi kompozicije, već i kao nosioci emocionalnog značenja u korisničkim narativima. Bergamot je najizraženije povezan sa energijom i svežinom, vanila sa smirenošću i prijatnošću, dok se ruža, amber i jasmin najčešće vezuju za romantičan doživljaj parfema. Ovakav nalaz je značajan jer pokazuje da se segmentacija i preporuka parfema mogu zasnivati ne samo na sličnosti mirisnih nota, već i na očekivanom emocionalnom efektu koji određene note proizvode kod korisnika.

Na slici 6.4 prikazan je model za emocionalnu kategorizaciju parfema koji objedinjuje više izvora signala. Struktura modela pokazuje da emocionalna klasifikacija ne nastaje iz jednog indikatora, već iz kombinovanja sentimentnog skora, dubinskog tekstualnog signala, numeričke ocene i veze između mirisnih nota i emocionalnih grupa. Važno je što se ovi ulazi spajaju u kompozitni emocionalni skor, koji zatim omogućava razvrstavanje parfema u kategorije kao što su romantično, energizujuće, melanholično, agresivno, opuštajuće i neutralno.

Reprezentaciono učenje proširuje analizu parfema tako što mirisne note, akorde i tržišne signale pretvara u kontinuirani prostor u kojem se mogu meriti bliskost, razlika, gustina i tržišna pozicija proizvoda. Za razliku od one-hot zapisa, koji samo beleži da li je neka nota prisutna ili odsutna, vektorske reprezentacije omogućavaju da se uoče relacije između nota koje se često javljaju u sličnim kompozicijama ili istim akordnim okruženjima.

Tabela 6.6: Najčešće mirisne note i dominantne emocionalne kategorije.

Mirisna nota	Frekvencija	Dominantna emocija	Kratko tumačenje
Musk	31.301	Agresivna	Senzualni, snažni i dugotrajni orijentalni profili
Bergamot	23.103	Energizujuća	Sveži, citrusni i letnji mirisi koji se povezuju sa vitalnošću
Amber	22.693	Romantična	Topli, slatki i smolasti profili
Sandalovina	22.400	Melanholična	Duboki, drvenasti i meditativni mirisi sa nostalgичnim tonom
Jasmin	22.153	Romantična	Bogati cvetni i elegantni mirisi sa izraženom zavodljivošću
Pačuli	20.578	Melanholična	Zemljani, misteriozni i blago začinski
Vanila	20.106	Opuštajuća	Topli, slatki i udobni gurmanski mirisi
Ruža	18.252	Romantična	Klasični cvetni i puderasti mirisi
Kedar	16.130	Melanholična	Suv, drvenast i čist karakter
Vetiver	11.144	Neutralna	Svež, travnat i zemljani profil sa širim uniseks značenjem



Slika 6.4: Model za emocionalnu kategorizaciju parfema na osnovu recenzija i mirisnih nota.

6.5 Reprezentaciono učenje za objašnjenje tržišne vrednosti proizvoda

U tekućem istraživanju razvijen je okvir u kojem se parfem tretira kao slojeviti objekat: gornje, srednje i bazne note čuvaju svoju poziciju u kompoziciji, dok se glavni akordi koriste kao viši semantički opis mirisnog profila. Cilj nije bio samo predviđanje vrednosne klase, već tumačenje tržišne geometrije: gde se nalaze zasićeni centri, gde postoje diferencirani segmenti i gde se nalaze ređe, ali potencijalno vredne niše. Jedan način da se potrošačka vrednost parfema stabilizuje jeste Bayes-ovo smanjenje ekstremnih ocena proizvoda sa malim brojem glasova:

$$v_i = \frac{n_i \bar{r}_i + k\mu}{n_i + k}, \quad (6.12)$$

gde je $\bar{r}_i$ prosečna ocena parfema i , n_i broj ocena, μ globalna prosečna ocena, a k parametar približavanja katalogu. Ovakav indikator sprečava da parfem sa malim brojem ocena dobije preveliku težinu zbog ekstremno visoke prosečne ocene. Time ocena postaje pouzdanija kada je podržana dovoljnim brojem korisničkih glasova. Cilj učenja vektorskih reprezentacija može se prikazati pojednostavljeno kao učenje vektora nota na osnovu ko-pojavljivanja u kompozicijama:

$$\mathcal{L}(\theta) = - \sum_{(i,j) \in \mathcal{C}} \log \sigma(v_i^T v_j) - \sum_{(i,k) \in \mathcal{N}} \log \sigma(-v_i^T v_k), \quad (6.13)$$


gde $\mathcal{C}$ označava skup pozitivnih parova nota koje se pojavljuju u istim ili srodnim kompozicijama, $\mathcal{N}$ skup negativnih parova, a v_i , v_j i v_k njihove vektorske reprezentacije. Ovakav zapis omogućava da note koje se pojavljuju u sličnim mirisnim kontekstima budu bliže u latentnom prostoru.

Tabela 6.7 pokazuje da slojevita vektorska reprezentacija pruža bolju osnovu za klasifikaciju vrednosnih klasa od jednostavnog one-hot zapisa. Dobijena tačnost iznad 87% i macro F1 iznad 0.83 ukazuju da model ne koristi samo dominantnu klasu, već prepoznaje razlike između nižih, srednjih i viših vrednosnih grupa. Dodatno, uočena je koherentnost prostora vektorskih reprezentacija iznad 0.75 u glavnim mirisnim porodicama, što znači da latentni prostor nije samo prediktivno koristan, već i interpretativno smislen.

Tabela 6.7: Poređenje modela za klasifikaciju parfema u tekućem istraživanju.

Model	Tačnost	Macro F1
Logistička regresija sa one-hot notama i akordima	0.741	0.687
Random forest sa one-hot notama i akordima	0.812	0.769
Slojeviti prikaz vektorskih reprezentacija i gradient-boosted trees	0.873	0.834

Na slici 6.5 prikazana je tržišna geometrija parfema u prostoru vektorskih reprezentacija, pri čemu svaka tačka predstavlja parfem, a boja njegovu dominantnu mirisnu porodicu. UMAP dimenzije 1 i 2 nisu pojedinačne note niti direktno merljive karakteristike parfema, već redukovane koordinate koje omogućavaju da se odnosi sličnosti iz višedimenzionalnog prostora prikažu u dve dimenzije. Blizina tačaka ukazuje na srodne mirisne profile i moguću blizinu proizvoda u percepciji korisnika, dok gušće zone označavaju konkurentska jezgra. Prelazne i ređe naseljene zone mogu ukazivati na hibridne segmente, prostor za diferenciranje i moguće tržišne niše.



Slika 6.5: UMAP mapa tržišne strukture parfema prema mirisnim porodicama i prostornoj bliskosti mirisnih profila.

6.6 Fuzzy kategorizacija potrošačkih recenzija u internet trgovini

Klasični klasifikacioni modeli najčešće dodeljuju svakoj recenziji jednu dominantnu kategoriju. Takav pristup je pogodan kada su klase jasno razdvojene, ali potrošačke recenzije često ne funkcionišu na taj način. Jedna recenzija može istovremeno govoriti o kvalitetu proizvoda, isporuci, korisničkoj podršci, poverenju, ceni i emocionalnom doživljaju. U parfemskom domenu je ovo preklapanje značenja još izraženije. Za razliku od klasične klasifikacije, fuzzy pristup omogućava da jedna instanca ima delimičnu pripadnost većem broju kategorija. Ovakvi pristupi su posebno korisni kada se sentiment, kvalitet proizvoda i korisničko iskustvo preklapaju u istom tekstu [83, 84]. Ako je K broj kategorija, pripadnost recenzije i

kategoriji k može se izraziti kao:

$$\mu_{ik} \in [0, 1], \quad \sum_{k=1}^K \mu_{ik} = 1. \quad (6.14)$$

Vrednost μ_{ik} označava stepen u kojem se recenzija odnosi na određenu kategoriju. Na primer, recenzija parfema može istovremeno imati visoku pripadnost kategoriji emocionalnog doživljaja, srednju pripadnost kategoriji trajnosti i nižu pripadnost kategoriji cene. Takva reprezentacija je mnogo bliža stvarnom jeziku korisnika nego striktna oznaka jedne klase, a fuzzy pravila dodatno mogu povećati interpretabilnost latentnih reprezentacija [85].

U tekućem istraživanju ovaj princip je razrađen na širem korpusu potrošačkih recenzija iz internet trgovine. Korišćen je balansiran uzorak od 100.000 recenzija iz pet kategorija proizvoda: knjige, elektronika, nameštaj, kancelarijski proizvodi i alati. Korpus je stratifikovan po kategoriji proizvoda i oceni, sa po 20.000 recenzija po kategoriji i po 4.000 recenzija u svakoj kombinaciji kategorije i rejtinga. Pored toga, uveden je nezavisan sloj ručne validacije na 1.000 slepo anotiranih recenzija, nakon čega je sprovedeno usaglašavanje oznaka. Fuzzy kategorizacija je korisna i za parfeme zato što korisnički narativi retko opisuju samo jedan aspekt proizvoda. Recenzija može istovremeno govoriti o mirisnom otvaranju, razvoju kroz vreme, trajnosti, projekciji, komplimentima, ličnom sećanju i odnosu cene i kvaliteta. U takvim situacijama model koji vraća samo jednu oznaku ne može adekvatno prikazati strukturu iskustva. Fuzzy zapis omogućava da se recenzija predstavi kao profil značenja:

$$\boldsymbol{\mu}_i = (\mu_{i1}, \mu_{i2}, \dots, \mu_{iK}), \quad (6.15)$$


gde svaki element vektora predstavlja stepen pripadnosti jednoj interpretativnoj dimenziji.

Tabela 6.8 prikazuje poređenje pristupa za fuzzy kategorizaciju potrošačkih recenzija, kroz tačnost (*accuracy*), Macro P, Macro R, Macro F1 i ponderisani F1 rezultat (*weighted F1*). Najbolji balans ostvaruje kombinacija TF-IDF reprezentacije i fuzzy skorova, sa macro F1 vrednošću 0.470 i ponderisanim F1 rezultatom 0.755. Važno je da je validacija izvršena prema nezavisno usaglašenim ljudskim oznakama, dok najčešća oznaka, uprkos solidnoj tačnosti, slabo pokriva ređe i preklapajuće kategorije.

Slika 6.6 vizuelno prikazuje intenzitet preklapanja između evaluativnih kategorija u potrošačkim recenzijama. Vrednosti u matrici pokazuju koliko se pojedine dimenzije korisničkog iskustva javljaju zajedno, na primer iskustvo isporuke sa korisničkom podrškom, podrška sa poverenjem, ili isporuka sa poverenjem i kredibilitetom. Time se pokazuje zašto je višestruka pripadnost korisna: recenzija se ne svodi na jednu izolovanu kategoriju, već često istovremeno obuhvata više povezanih aspekata iskustva. Isti princip se može preneti i na parfemske recenzije, gde se emocija, trajnost, projekcija, cena i brend mogu posmatrati kao međusobno povezane dimenzije vrednosti proizvoda.

Tabela 6.8: Poređenje modela za fuzzy kategorizaciju potrošačkih recenzija.

Model	Tačnost	Macro P	Macro R	Macro F1	Pond. F1
Najčešća oznaka	0.744	0.149	0.200	0.171	0.635
TF-IDF + Complement NB	0.759	0.493	0.317	0.349	0.704
Fuzzy skorovi	0.373	0.363	0.555	0.337	0.398
TF-IDF + Linear SVM	0.749	0.324	0.224	0.216	0.659
TF-IDF + Linear SVM, balansirano	0.771	0.475	0.322	0.353	0.722
TF-IDF + LogReg, balansirano	0.760	0.488	0.374	0.406	0.730
TF-IDF + fuzzy skorovi	0.770	0.488	0.480	0.470	0.755



Slika 6.6: Fuzzy matrica interakcija evaluativnih kategorija u potrošačkim recenzijama.

6.7 Provera kvaliteta recenzija i nesklad između ocene i teksta

Dopunski istraživački sloj ovog poglavlja odnosi se na kvalitet korisničkih recenzija u internet trgovini. Iako je centralni domen parfemska industrija, problemi u parfemskim podacima deo su šireg obrasca: korisničke ocene nisu uvek usklađene sa tekstualnim sadržajem. Recenzija sa pet zvezdica može sadržati negativan tekst, dok recenzija sa jednom zvezdicom može biti ironična. Takvi slučajevi mogu nastati zbog greške korisnika, sarkazma, šablonskog pisanja, nepažnje, botovskog ponašanja ili specifičnog konteksta koji model ne razume.

U istraživačkom projektu na Amazon Fine Food Reviews skupu analizirano je 568.454 recenzije, 256.059 korisnika i 74.258 proizvoda. Skup sadrži deset osnovnih atributa, uključujući identifikatore proizvoda i korisnika, ocenu, korisnost recenzije, vreme, naslov i tekst. Za disertaciju je ovaj projekat koristan kao dodatni primer zato što pokazuje kako se isti metodološki problem može pojaviti u drugom e-commerce domenu: potrebno je povezati numeričku ocenu, tekstualni sentiment i strukturne karakteristike recenzije pre nego što se rezultati koriste za poslovno odlučivanje. Nesklad ocene i sentimenta može se formalno prikazati kao indikator:

$$A_i = \mathbb{I}[(Score_i \geq 4 \wedge Sent_i < -\delta) \vee (Score_i \leq 2 \wedge Sent_i > \delta)], \quad (6.16)$$

gde je $Score_i$ numerička ocena recenzije, $Sent_i$ sentiment skor teksta, δ prag intenziteta sentimenta, a A_i indikator potencijalne anomalije. Ovaj indikator ne dokazuje da je recenzija lažna, ali označava slučajeve koji zahtevaju dodatnu proveru.

Tabela 6.9 pokazuje da su linearni modeli nad TF-IDF reprezentacijom, uz dopunske VADER i strukturne metapodatke, postigli stabilnu opštu tačnost oko 85%. Linear SVC je imao najbolji F1 u inicijalnom poređenju, dok je optimizacija kroz balans klasa i regulaciju parametra $C = 0.1$ poboljšala tretman neutralnih recenzija. Najvažniji metodološki nalaz nije samo vrednost tačnosti, već činjenica da neutralna klasa predstavlja najteži segment, jer često sadrži mešovite tvrdnje i granične izraze.


Tabela 6.9: Rezultati dopunskog istraživanja nad Amazon Fine Food Reviews skupom.

Model	Tačnost	Preciznost	Odziv	F1 mera
Logistička regresija	0.857	0.834	0.857	0.830
Linear SVC	0.857	0.835	0.857	0.841
XGBoost	0.849	0.827	0.849	0.820
Optimizovani Linear SVC	0.851	0.846	0.851	0.844

Ovaj dopunski primer direktno je povezan sa parfemima. U parfemskim recenzijama korisnik može dati visoku ocenu zbog kvaliteta, ali u tekstu naglasiti da miris nije za njega. Drugi korisnik može dati nižu ocenu jer je očekivao drugačiji stil, iako priznaje dobru trajnost ili kvalitet izrade. Zato se odnos ocene i teksta mora tretirati kao interpretativni signal, a ne kao jednostavna greška. Model za prepoznavanje nesklada može poslužiti kao filter za ručnu proveru, korekciju podataka ili izdvajanje neodređenih recenzija.

Slika 6.7 prikazuje tok provere kvaliteta recenzija kao deo prediktivnog modelovanja, od ulaznih signala kao što su ocena, naslov, tekst, korisnost, dužina teksta i odnos velikih slova, do izdvajanja obeležja pomoću VADER i TF-IDF reprezentacije. Linear SVC i logistička

regresija procenjuju nesklad između ocene i komentara, na primer negativan tekst uz visoku ocenu ili pozitivan tekst uz nisku ocenu. Takvi slučajevi se izdvajaju za ekspertsku proveru, kako modeli popularnosti, sentimenta i preporuke ne bi koristili nepouz dane ulazne signale. Na taj način se detekcija nesklada koristi kao filter za proveru kvaliteta recenzija, a ne kao konačna odluka o njihovoj validnosti.



Slika 6.7: Tok detekcije nesklada između numeričke ocene i tekstualnog sadržaja korisničke recenzije.

6.8 Integrisana arhitektura neuronskog modelovanja parfema

Na osnovu prethodnih istraživačkih slojeva, moguće je definisati integrisanu arhitekturu za analizu parfema u internet trgovini. Ova arhitektura povezuje četiri grupe signala: kompozicione attribute, tekstualne recenzije, tržišne indikatore i vremenske obrasce. Njen cilj nije da proizvede jedan univerzalni skor, već da omogući višedimenzionalno tumačenje proizvoda kroz popularnost, emocionalni profil, sličnost, tržišnu nišu i pouzdanost ulaznih podataka. Formalno, integrisana reprezentacija parfema može se zapisati kao:

$$\mathbf{z}_i = [\mathbf{z}_i^{notes}; \mathbf{z}_i^{text}; \mathbf{z}_i^{market}; \mathbf{z}_i^{time}], \quad (6.17)$$

gde $\mathbf{z}_i^{notes}$ predstavlja vektorski ili klusterski prikaz nota i akorda, $\mathbf{z}_i^{text}$ tekstualno-emocionalni signal recenzija, $\mathbf{z}_i^{market}$ ocene, broj ocena, brend i tržišne karakteristike, a $\mathbf{z}_i^{time}$ vremenske obrasce popularnosti. Ovakva fuzija omogućava da se model ne oslanja na jedan izvor, već da formira objedinjenu latentnu reprezentaciju u kojoj se mirisna struktura, korisnički doživljaj, tržišna vrednost i vremenska dinamika posmatraju kao povezani izvori značenja.


Tabela 6.10 dodatno razlaže ovu reprezentaciju na funkcionalne slojeve i pokazuje kako svaki tip ulaznih podataka doprinosi drugačijem izlazu modela, od mirisne srodnosti i emocionalnog profila do tržišne vidljivosti, trenda popularnosti i interpretabilnih poslovnih odluka. Time se naglašava da integrisana arhitektura ne povezuje samo različite izvore podataka, već i različite nivoe tumačenja proizvoda.

Tabela 6.10: Slojevi integrisane arhitekture za analizu parfema u internet trgovini.

Sloj	Ulazni podaci	Model	Izlaz
Kompozicioni sloj	Gornje, srednje i bazne note, akordi	Vektorske reprezentacije, K-means, sličnost	Mirisna srodnost i latentne porodice
Tekstualni sloj	Recenzije, opisi, naslovi	VADER, DistilBERT, RoBERTa	Sentiment, emocija i fuzzy profil značenja
Tržišni sloj	Ocena, broj ocena, brend, dizajner	Bayes-ov skor, kompozitni skor, stabla odluke	Vrednosna klasa i tržišna vidljivost
Vremenski sloj	Godina lansiranja, učestalost nota kroz vreme	LSTM i sekvencijalno modelovanje	Trend popularnosti i očekivana zastupljenost nota
Interpretativni sloj	Izlazi prethodnih modela	Pravila tumačenja, vizuelizacije, poslovne zone	Preporuke, niše, portfoliojski rizici i odluke

Slika 6.8 prikazuje neuronsku arhitekturu za parfemsku analitiku, zasnovanu na spajanju tri tipa ulaznih signala. Prva grana obrađuje note i akorde kroz sloj vektorskih reprezentacija i guste slojeve, čime se mirisna struktura parfema prevodi u vektorsku reprezentaciju. Druga grana koristi recenzije kao tekstualni ulaz, koji se obrađuje transformer enkoderom i pretvara u emocionalni ili fuzzy vektor. Treća grana obuhvata strukturisana tržišna obeležja, kao što su ocene, brend, godina i broj ocena, koja se najpre normalizuju, a zatim obrađuju kroz dense sloj. Sve tri reprezentacije se spajaju u zajednički fuzioni sloj, iz kojeg se kroz dense slojeve i regularizaciju dobijaju višestruki izlazi: popularnost, vrednosna klasa, emocionalni profil i preporuka za proveru.

Ovaj model je važan za disertaciju jer povezuje više istraživačkih pretpostavki u jednom domenu i pokazuje da duboko učenje može istovremeno obraditi tekst, sekvence i strukturisane atribute, dok interpretabilni i kontrolni izlazi omogućavaju da se tačnost modela dopuni ljudskim tumačenjem kada su podaci subjektivni, višeznačni ili nepotpuni.



Slika 6.8: Integrirana neuronska arhitektura za parfemsku analitiku sa fuzijom mirisnih, tekstualnih i strukturisanih tržišnih obeležja.

6.9 Interpretabilnost i poslovna vrednost parfemske analitike

Interpretabilnost ima posebnu vrednost u internet trgovini i parfemskoj industriji. Modeli u ovom domenu nisu korisni samo ako predvide popularnost proizvoda, izračunaju sličnost između parfema ili klasifikuju emocionalni ton recenzije. Njihova praktična vrednost zavisi od toga da li mogu objasniti zašto je određen proizvod popularan, zašto je sličan drugom proizvodu, koje emocije izaziva, koje note dominiraju u percepciji korisnika i koje kategorije značenja se najčešće pojavljuju u recenzijama.

Za menadžere proizvoda, marketing timove i platforme za preporuke nije dovoljno znati da dva parfema imaju sličan vektorski zapis. Potrebno je razumeti da li ih povezuje svežina, luksuzni identitet, trajnost, cena, brend, emocionalna asocijacija ili sezonska upotreba.

Objašnjenje rezultata može se realizovati na više nivoa. Na nivou atributa, model može pokazati koje note, akordi ili brendovi najviše doprinose predikciji. Na tekstualnom nivou, može se analizirati koje reči i izrazi nose emocionalni signal. Na tržišnom nivou, mogu se identifikovati proizvodi koji pripadaju dominantnim klasterima ili nišnim segmentima. Na strateškom nivou, model može ukazati da li se određena mirisna porodica približava zasićenju ili postoji prostor za diferencijaciju.

6.10 Sinteza nalaza u oblasti internet trgovine i parfemske industrije

Nalazi ovog poglavlja pokazuju da internet trgovina i parfemska industrija predstavljaju domen u kojem se ponašanje korisnika ne može dovoljno objasniti samo prosečnom ocenom, brojem recenzija ili jednom klasifikacionom oznakom. Vrednost parfema formira se kroz kombinaciju mirisnih nota, brenda, tržišne vidljivosti, emocionalnog doživljaja, tekstualnih narativa i promena preferencija kroz vreme. Zbog toga ovaj domen proverava istraživački okvir disertacije u uslovima subjektivnih, nepotpunih i semantički višeznačnih podataka.

Metodološki doprinos poglavlja ogleda se u povezivanju više analitičkih slojeva. Alternativno vrednovanje omogućava da se proizvodi sa nedostajućim ili slabim ocenama ne isključe iz tržišne analize, već da se njihova potencijalna vrednost proceni kroz mirisnu strukturu i tržišnu prisutnost. Klasterovanje i vektorske reprezentacije prevode note, akorde i parfeme u prostor u kojem se mogu tumačiti srodnost, tržišna bliskost i konkurentska jezgra. LSTM modelovanje uvodi vremensku dimenziju i omogućava praćenje promena u popularnosti mirisnih nota. Emocionalna analiza povezuje recenzije, ocene i mirisne note sa doživljajem korisnika, dok fuzzy kategorizacija čuva činjenicu da jedna recenzija može istovremeno govoriti o više aspektima proizvoda. Dopunska analiza kvaliteta recenzija uvodi proveru nesklada između numeričke ocene i tekstualnog sadržaja, čime se jača pouzdanost ulaznih signala.

U odnosu na hipoteze disertacije, ovo poglavlje najdirektnije podržava H2, H3 i H5. Hipoteza H2 potvrđuje se kroz pokazivanje da izbor reprezentacije podataka bitno menja analitičku vrednost modela: one-hot zapisi, TF-IDF reprezentacije, prostor vektorskih reprezenta-

cijai, fuzzy skorovi i integrisane neuronske reprezentacije ne daju isti nivo uvida, niti jednako dobro obuhvataju složenost potrošačkog iskustva. Hipoteza H3 povezuje se sa nepotpunim ocenama, neusklađenim recenzijama, preklapanjem kategorija i potrebom za proverom kvaliteta podataka pre njihove upotrebe u prediktivnim modelima. Hipoteza H5 podržana je kroz aplikativnu vrednost rezultata, jer se dobijeni modeli mogu povezati sa preporukama, segmentacijom tržišta, identifikacijom niša, praćenjem trendova i portfolijskim odlučivanjem u uslovima digitalne trgovine.

Poglavlje istovremeno daje dopunski oslonac i za H1 i H4. H1 se ogleda u primeni sekvencijalnih i transformer pristupa za vremenske obrasce i tekstualno-emocionalne signale, posebno kroz LSTM arhitekturu i model emocionalne kategorizacije. H4 se potvrđuje kroz insistiranje na interpretabilnosti, vizuelizaciji prostora vektorskih reprezentacija, fuzzy matrici interakcija i preporuci za ekspertsku proveru kada postoji nesklad između ocene i teksta. Time se model ne posmatra kao autonomni mehanizam odlučivanja, već kao alat koji mora ostati povezan sa domenskim tumačenjem.

Praktična vrednost ovih nalaza nalazi se u tome što parfemska analitika može podržati više tipova odluka: preporuku proizvoda, razumevanje emocionalnih reakcija, procenu popularnosti nota, prepoznavanje zasićenih tržišnih oblasti i izdvajanje prostora za diferenciranje. Za razliku od pristupa koji se oslanjaju samo na rangiranje po ocenama, ovde se potrošačka vrednost posmatra kao rezultat odnosa između mirisne kompozicije, korisničkog narativa, tržišne vidljivosti i pouzdanosti podataka.

Ovo poglavlje zato potvrđuje da prediktivni modeli ljudskog ponašanja imaju punu vrednost tek kada istovremeno obuhvate merljive, tekstualne, emocionalne i interpretativne signale. Parfemski domen posebno pokazuje da modeli moraju prihvatiti neizvesnost, višeznačnost i preklapanje značenja, jer se upravo u takvim podacima nalazi veliki deo stvarnog korisničkog ponašanja u internet trgovini.

Naredno poglavlje prelazi na društveno odgovornu poslovnu komunikaciju, gde se istraživački okvir pomera sa potrošačkih preferencija ka društveno osetljivoj primeni veštačke inteligencije. U tom domenu interpretabilnost, analiza grešaka i ljudska provera postaju još važniji uslovi odgovorne upotrebe prediktivnih modela.

7. DRUŠTVENO ODGOVORNA POSLOVNA KOMUNIKACIJA

Digitalna poslovna komunikacija predstavlja jedan od ključnih prostora u kojima se danas oblikuju organizaciona kultura, profesionalni odnosi, reputacija i poverenje u institucije. Komunikacija zaposlenih, kandidata, korisnika, menadžera, klijenata i šire javnosti sve češće se odvija kroz elektronsku poštu, kolaborativne platforme, interne komunikacione alate, društvene mreže, komentare, forume, korisničku podršku, ankete i javne objave. Takvi oblici komunikacije ostavljaju tekstualne tragove koji se mogu analizirati metodama obrade prirodnog jezika, mašinskog učenja i dubokog učenja. Njihova analitička vrednost nije samo u prepoznavanju eksplicitno uvredljivog sadržaja, već i u otkrivanju suptilnijih obrazaca pristrasnosti, isključivanja i komunikacionog rizika.

U ovoj disertaciji društveno odgovorna poslovna komunikacija posmatra se kao osetljiv domen za razvoj i evaluaciju prediktivnih modela. Za razliku od prethodnih domena, u kojima su centralni ishodi bili ocena, zadovoljstvo, cena, popularnost ili korisnička vrednost, ovde je cilj modelovanja prepoznavanje komunikacionih obrazaca koji mogu imati etičke, organizacione i reputacione posledice. Doprinos ovog poglavlja zato nije samo u primeni NLP modela na društveno osetljiv tekst, već u povezivanju klasifikacije, analize grešaka, pragova odlučivanja i ljudske provere u okvir odgovorne komunikacione analitike.

Značaj ovog domena ogleda se u tome što prediktivni model ne proizvodi samo tehnički rezultat, već signal koji može uticati na način na koji organizacija razume komunikacionu kulturu, inkluzivnost, odnose među zaposlenima i potrebu za stručnom intervencijom. U literaturi o pravičnosti mašinskog učenja posebno se naglašava da tehnički modeli ne funkcionišu izvan društvenog konteksta, već da njihove greške i pragovi odlučivanja mogu imati različite posledice po različite grupe i situacije [2]. Slično tome, kritički pregled pristrasnosti u NLP sistemima pokazuje da se modeli za analizu jezika moraju razvijati uz jasno objašnjenje koje oblike štete prepoznaju, za koga su ti oblici štetni i u kom društvenom kontekstu nastaju [11]. Zbog toga je u ovom domenu posebno važno da se model ne ocenjuje samo kroz tačnost, već i kroz objašnjivost, stabilnost, pravičnost i mogućnost ljudske provere. Model se zato u ovom poglavlju ne posmatra kao automatizovani sudija, već kao analitički sloj koji može da podrži prepoznavanje rizika, prioritizaciju slučajeva, objašnjenje i odgovornu interpretaciju.

Digitalna komunikaciona instanca može se predstaviti kao:

$$x_i = (T_i, C_i, S_i, A_i, M_i), \quad (7.1)$$

gde T_i označava tekst poruke, C_i komunikacioni kontekst, S_i izvor ili kanal komunikacije, A_i anotaciju ili ciljnu oznaku, a M_i dodatne metapodatke. U zavisnosti od zadatka, ciljna promenljiva može biti binarna oznaka seksističkog sadržaja, višeklasna oznaka tipa seksizma, višelabelna oznaka komunikacione strategije ili indikator potrebe za ljudskom proverom.

Tabela 7.1 pokazuje da ovaj domen ima metodološku funkciju u disertaciji. U hotelskom domenu lažno negativna predikcija može značiti propuštenu pritužbu, dok u transportnom domenu može značiti propušten bezbednosni ili operativni rizik. U komunikacionom domenu lažno negativan ishod može značiti da štetan govor ostaje neprepoznat, dok lažno pozitivan ishod može značiti nepravedno označavanje neutralnog, legitimnog ili kontekstualno drugačijeg sadržaja kao problematičnog. Komunikacioni domen povezuje kvalitet tekstualne reprezentacije i klasifikacije (H2), potrebu za interpretabilnim objašnjenjem odluke (H3), tumačenje grešaka u osetljivom kontekstu (H4) i višekriterijumsko vrednovanje modela (H5).

Tabela 7.1: Metodološka uloga domena društveno odgovorne poslovne komunikacije.

Istraživački pravac	Dominantni podaci	Prediktivni zadatak	Konkretni doprinos
Rodno pristrasan jezik	Tekstualni komentari i poruke	Binarna klasifikacija	Uvođenje društveno osetljivog NLP zadatka
Mizoginija i seksizam	Anotirani javni korpusi	Višeklasna i višelabelna klasifikacija	Detekcija eksplicitnih i implicitnih obrazaca
Poslovni diskurs	Formalna i neformalna organizaciona komunikacija	Procena komunikacionog rizika	Povezivanje modela sa organizacionom praksom
Lažno pozitivni i lažno negativni ishodi	Greške modela i granični slučajevi	Analiza pouzdanosti i pravičnosti	Tumačenje posledica grešaka, a ne samo metrika
Ljudska provera (human-in-the-loop)	Model, objašnjenje i stručna provera	Odgovorno odlučivanje	Sprečavanje automatizovanog sankcionisanja

Radi preglednog prikaza ključnih faza analize rizične poslovne komunikacije, na slici 7.1 prikazana je društveno odgovorna AI komunikaciona petlja, od ulaznog digitalnog teksta do stručne provere i organizacione odluke.



Slika 7.1: Društveno odgovorna AI petlja za analizu poslovne komunikacije.

Rodno pristrasan jezik u digitalnoj komunikaciji obuhvata izraze, formulacije i obrasce koji reprodukuju stereotipe, umanjuju profesionalnu vrednost određene grupe, normalizuju uvredljiv govor ili stvaraju neprijateljsko komunikaciono okruženje. Mizoginija predstavlja posebno štetan oblik takvog jezika, jer uključuje neprijateljstvo, omalovažavanje ili diskriminaciju žena i ženskih identiteta. Savremeni pregledi digitalne mizoginije pokazuju da se štetni obrasci u jeziku ne javljaju samo kroz direktne uvrede, već i kroz implicitne, kulturno oblikovane i kontekstualno zavisne strategije [30].

U poslovnom okruženju, rodno pristrasan ili mizogin jezik može imati višestruke posledice. On može uticati na psihološku sigurnost zaposlenih, poverenje u organizaciju, reputaciju kompanije, kvalitet timske komunikacije, inkluzivnost radnog okruženja i usklađenost sa etičkim i regulatornim očekivanjima. Zbog toga detekcija ovakvog jezika nije samo tehnički NLP zadatak, već deo šireg okvira odgovornog upravljanja digitalnom komunikacijom.

Važno je naglasiti da detekcija mizoginog jezika nije jednostavno prepoznavanje uvredljivih reči. Štetni sadržaj može biti eksplicitan, implicitan, ironičan, sarkastičan, kontekstualan ili prikriven kroz stereotipe. Isto tako, određeni tekst može sadržati problematičan izraz u kritičkom, edukativnom ili prijavljenom kontekstu, bez reprodukovanja šetnog obrasca. Empirijska istraživanja detekcije seksizma u digitalnom diskursu ukazuju da je za razumevanje ovih obrazaca potrebno analizirati lingvističke strategije, kontekst i način na koji se pristrasnost izražava kroz jezik [86]. Zbog toga je potrebno koristiti modele koji mogu uzeti u obzir kontekst, ali i jasno razlikovati predikciju modela od konačne ljudske procene.

Polazni istraživački sloj ovog poglavlja oslanja se na raniji autorski naučno-istraživački projekat, u kojem je razvijan model dubokog učenja za detekciju mizoginih obrazaca u interakcijama na društvenim mrežama. U tom projektu analizirani su javno dostupni, ručno anotirani tekstovi, sa fokusom na eksplicitne i implicitne oblike mizoginije, a razvijeni model kombinovao je Word2Vec reprezentacije, bidirekzione LSTM slojeve i self-attention mehanizam. Nakon optimizacije hiperparametara model je dostigao tačnost od 85.3%, uz razmatranje preciznosti, odziva i F1 mere kao ključnih metrika za uravnoteženu evaluaciju [87].


Takav rezultat pokazuje da sekvencijalne neuronske mreže mogu uspešno prepoznati deo mizoginih obrazaca, ali i da implicitni, ironični i kontekstualno zavisni oblici jezika zahtevaju snažnije reprezentacije i pažljiviju interpretaciju.

Nedavna istraživanja iz oblasti odgovorne AI podrške inkluzivnoj poslovnoj komunikaciji proširuju ovaj pravac prelaskom sa opšte digitalne komunikacije na formalni i neformalni poslovni diskurs. U tom okviru korišćeni su heterogeni tekstualni izvori povezani sa rodnom pristrasnošću u pretrazi, sintetičkim HR zapisima, opisima poslova i detekcijom seksizma u engleskim tekstovima. Posebno su relevantni Grep-BiasIR, Synthetic HR Dataset, City of Los Angeles Job Bias Corpus i Kaggle Sexism Detection Texts, jer zajedno povezuju kratke tekstualne upite, zapise iz radnog okruženja, opise poslova i anotirane primere seksističkog sadržaja. Nakon pretprocesiranja zadržano je 39.127 validnih tekstualnih instanci od početnih 42.424 zapisa, čime je formirana šira osnova za ispitivanje rodno pristrasnog jezika u poslovnom kontekstu. Sa metodološkog stanovišta, ovaj višedomenski skup podataka omogućava proveru stabilnosti modela u različitim domenskim uslovima, jer model ne uči samo površinske leksičke markere uvredljivosti, već obrasce pristrasnosti koji se pojavljuju u različitim tekstualnim formatima, komunikacionim funkcijama i profesionalnim kontekstima.

U modelskom smislu, ovaj istraživački pravac uvodi prelaz sa sekvencijalnih neuronskih mreža ka transformer arhitekturama. Optimizovani RoBERTa model, dopunjen attention i dropout slojevima, sentimentnim i stilskim obeležjima, klasnim težinama i augmentacijom podataka, ostvario je tačnost od 91.2%, preciznost od 88.7%, odziv od 90.5%, F1 meru od 89.6% i AUC-ROC od 0.93. Ovi rezultati ukazuju da poslovni diskurs zahteva domenski prilagođene modele, jer se rodno pristrasan ili mizogin obrazac ne mora pojaviti samo kao eksplicitna uvreda, već i kao suptilan komentar, stereotip, umanjivanje kompetencija ili komunikacioni obrazac koji dobija značenje tek u profesionalnom kontekstu.

Ovi rezultati su važni za disertaciju jer pokazuju razvoj istraživačkog pravca od sekvencijalnog modelovanja digitalne mizoginije ka transformer arhitekturama prilagođenim poslovnom diskursu. Istovremeno ukazuju da se performanse modela ne smeju tumačiti samo kao tehnički rezultat, već i kroz posledice grešaka. Lažno negativni ishodi mogu ostaviti štetan govor neprepoznatim, dok lažno pozitivni ishodi mogu narušiti poverenje u sistem i dovesti do neopravdanog označavanja neutralnog ili kontekstualno drugačijeg sadržaja.

Na osnovu dva istraživačka sloja, predlaže se arhitektura modela dubokog učenja koja povezuje tekstualnu reprezentaciju, dopunska obeležja, procenu rizika i ljudsku proveru. Model ne treba da funkcioniše kao autonomni mehanizam za sankcionisanje, već kao analitički sloj za prepoznavanje rizičnih obrazaca, objašnjenje i odgovornu stručnu procenu. Konceptualna arhitektura takvog modela prikazana je na slici 7.2. Slika naglašava fuzioni karakter arhitekture, u kojoj se tekstualni enkoder dopunjuje sentimentnim, stilskim i kontekstualnim obeležjima, a zatim kroz guste slojeve i regularizaciju formira skor rizika za dalju proveru. Time se jasno razdvaja faza automatske procene od faze ljudskog odlučivanja.



Slika 7.2: Arhitektura modela dubokog učenja za analizu rodno pristrasnog i mizoginog jezika u poslovnoj komunikaciji.

U formalnom smislu, ulaz modela može se predstaviti kao kombinacija tekstualnog sadržaja, komunikacionog konteksta i dopunskih signala. Tekstualni deo obrađuje se pomoću sekvencijalnog ili transformer enkodera, dok se sentimentna, stilska i obeležja metapodataka dodaju kao pomoćni sloj reprezentacije:

$$h_i = [Enc(T_i); f_{sent}(T_i); f_{style}(T_i); f_{meta}(C_i, M_i)], \quad (7.2)$$

gde $Enc(T_i)$ označava duboku reprezentaciju teksta, $f_{sent}(T_i)$ sentimentne signale, $f_{style}(T_i)$ stilska i pragmatička obeležja, a $f_{meta}(C_i, M_i)$ dopunske informacije o komunikacionom kontekstu i metapodacima. Ovakva formulacija omogućava modularno razdvajanje reprezentacionog i klasifikacionog dela modela, tako da se enkoder teksta može menjati ili nadograditi bez promene osnovne logike spajanja obeležja i procene verovatnoće. Na osnovu spojene reprezentacije model procenjuje verovatnoću da tekst sadrži rodno pristrasan, seksistički ili mizogin obrazac:

$$\hat{p}_i = \sigma(W_2 \cdot \text{Dropout}(\phi(W_1 h_i + b_1)) + b_2), \quad (7.3)$$

gde $\sigma(\cdot)$ označava sigmoidnu funkciju, $\phi(\cdot)$ nelinearnu aktivaciju, a dropout sloj smanjuje rizik od preprilagođavanja. Ovakva formulacija omogućava da model ne koristi samo semantičku reprezentaciju teksta, već i dodatne signale koji mogu biti važni za tumačenje implicitnog, ironičnog ili kontekstualno zavisnog jezika. U formalnom obliku, zadatak detekcije štetnog jezika može se zapisati kao:

$$y_i = \begin{cases} 1, & \text{ako tekst sadrži rodno pristrasan, seksistički ili mizogin obrazac,} \\ 0, & \text{ako tekst ne sadrži takav obrazac.} \end{cases} \quad (7.4)$$

U složenijoj formulaciji, tekst može pripadati jednoj od više kategorija:

$$y_i \in \left\{ \begin{array}{l} \text{neseksistički sadržaj, eksplicitni seksizam, implicitni seksizam,} \\ \text{omalovažavanje, stereotipizacija, pretnja, objektivizacija} \end{array} \right\}. \quad (7.5)$$

U višelabelnom obliku, tekst može sadržati više strategija istovremeno:

$$y_i = (y_{i1}, y_{i2}, \dots, y_{iK}), \quad (7.6)$$

gde $y_{ik} = 1$ označava prisustvo kategorije k .

Tabela 7.2 daje pregled osnovnih kategorija rodno pristrasnog i mizoginog jezika i ukazuje da se metodološki izazov ne sastoji samo u prepoznavanju eksplicitnih uvreda. Njena vrednost je u tome što naglašava potrebu za modelima koji mogu obuhvatiti implicitne, stereotipne, ironične i kontekstualno zavisne obrasce značenja, kao i pragmatičke nijanse poslovne komunikacije.

Tabela 7.2: Primeri kategorija rodno pristrasnog i mizoginog jezika.

Kategorija	Opis	Metodološki izazov
Eksplicitna uvreda	Direktno omalovažavanje ili vređanje	Relativno lakše za detekciju, ali zavisi od jezika i konteksta
Stereotipizacija	Pripisivanje osobina, uloga ili očekivanja na osnovu roda	Često implicitno i društveno normalizovano
Omalovažavanje kompetencija	Umanjivanje profesionalnih sposobnosti ili autoriteta	Može biti prikriveno kao humor, savet ili komentar
Objektivizacija	Svođenje osobe na fizički izgled ili seksualizovani opis	Zahteva razumevanje semantičkog i komunikacionog konteksta
Pretnja ili agresija	Direktan ili indirektan nasilni govor	Visok rizik lažno negativnih ishoda
Ironija i sarkazam	Štetna poruka izražena indirektno	Teško za modele zasnovane samo na ključnim rečima

7.1 Skupovi podataka, domenske granice i preprocesiranje

Za razvoj modela za detekciju seksističkog, mizoginog ili diskriminatornog jezika, nakon opisanih inicijalnih poduhvata, uključeni su anotirani skupovi podataka. Ovde se mogu posebno izdvojiti EDOS, EXIST i MAMI skupovi, jer obuhvataju različite oblike seksizma, mizoginije, online neprijateljstva i multimodalnog sadržaja.

EDOS skup podataka razvijen je u okviru SemEval zadatka za objašnjivu detekciju online seksizma i sadrži hijerarhijski organizovane oznake, od binarne detekcije seksizma do detaljnijih kategorija i strategija [31]. EXIST skupovi podataka fokusiraju se na identifikaciju i kategorizaciju seksizma kroz više jezika i godina, što omogućava proveru generalizacije modela kroz različite tekstualne izvore i anotacione postavke [32]. MAMI skup podataka uvodi multimodalnu dimenziju, jer razmatra mizoginiju u meme sadržaju, gde tekst i slika zajedno formiraju značenje [88]. Kao dopunski izvor za širu proveru tekstualnih primera može se koristiti i javni Kaggle skup za detekciju seksizma u engleskim tekstovima [89].

U eksperimentalnim pravcima koji su do sada razvijani korišćeni su engleski javni skupovi podataka, dok srpski poslovni korpus još nije formiran. Zbog toga se EDOS, EXIST, MAMI i srodni resursi ne tumače kao direktna zamena za internu poslovnu komunikaciju, već kao istraživačka osnova za razvoj, poređenje i validaciju modela pre eventualnog prilagođavanja realnom organizacionom kontekstu. Planirani naredni korak jeste prikupljanje i etički kontrolisana analiza komunikacionih primera u radnom okruženju kandidatkinje, uz anonimizaciju, jasno definisanu svrhu obrade i ljudsku validaciju. Pregled korišćenih i planiranih skupova podataka, njihovog fokusa, tipa zadataka i uloga dat je u tabeli 7.3.

Tabela 7.3: Skupovi podataka relevantni za analizu seksističkog i mizoginog jezika.

Skup	Fokus	Tip zadatka	Uloga u disertaciji
EDOS	Online seksizam, hijerarhijske kategorije	Binarna, višeklasna i hijerarhijska klasifikacija	Primarni tekst na engleskom jeziku
EXIST	Seksizam kroz više zadataka i jezika	Binarna i višeklasna klasifikacija	Provera stabilnosti modela
MAMI	Mizoginija u meme sadržaju	Multimodalna i višelabelna klasifikacija	Budući multimodalni pravac
Sexism detection	Seksizam u tekstovima na engleskom jeziku	Tekstualna klasifikacija	Dopunska provera primera
Planirani poslovni korpus	Anonimizovani organizacioni tekstovi	Procena komunikacionog rizika	Lokalna validacija na srpskom jeziku

7.1.1 Pretprocesiranje društveno osetljivog teksta

Pretprocesiranje društveno osetljivog teksta mora biti pažljivo, jer se značenje problematičnog sadržaja često nalazi upravo u elementima koji se u standardnim NLP procedurama rutinski uklanjaju. Velika slova mogu ukazivati na intenzitet, interpunkcija može nositi pragmatičku funkciju, emotikoni mogu označavati ironiju, a oblici namerno izmenjenog pisanja mogu predstavljati pokušaj zaobilaženja moderacije. Zbog toga pretprocesiranje ne sme automatski izbrisati sve površinske jezičke signale, već mora biti usklađeno sa ciljem detekcije komunikacionog rizika. Pretprocesiranje uključuje:

- uklanjanje tehničkog šuma bez gubitka semantički važnih signala;
- normalizaciju URL adresa, korisničkih oznaka i tehničkih tokena;
- čuvanje interpunkcije i kapitalizacije kada nose pragmatičko značenje;
- detekciju i standardizaciju obfuskovanih uvredljivih izraza;
- tokenizaciju prilagođenu transformer modelima;
- očuvanje rečeničnog i komunikacionog konteksta;
- dokumentovanje svih transformacija koje mogu uticati na interpretaciju teksta.

Ako je tekstualni ulaz označen kao T_i , tokenizacija daje sekvencu tokena:

$$T_i \rightarrow (w_{i1}, w_{i2}, \dots, w_{in}), \quad (7.7)$$

koja se zatim prosleđuje modelu za učenje reprezentacije:

$$h_i = \text{Encoder}_\theta(w_{i1}, w_{i2}, \dots, w_{in}). \quad (7.8)$$

Tokenizacija zato nije samo tehnički korak pripreme ulaza, već metodološka odluka koja omogućava modelima dubokog učenja da, pored leksičkog sadržaja, zadrže i signale stila, intenziteta, prikrivanja i komunikacionog konteksta.

7.1.2 Problem anotacije i domenske prenosivosti

Anotacija društveno osetljivog jezika posebno je zahtevna jer različiti anotatori mogu različito tumačiti ironiju, kontekst, intenzitet, nameru i kulturne reference. Zbog toga oznake u ovakvim skupovima ne treba posmatrati kao apsolutnu istinu, već kao operacionalizovanu procenu prema definisanom anotacionom protokolu. Ova činjenica je posebno važna kada se modeli razvijeni na javnim internet korpusima razmatraju za poslovnu komunikaciju, jer se norme, stil i posledice poruka mogu značajno razlikovati. U formalnom smislu, oznaka instance može se posmatrati kao funkcija teksta i anotacionog konteksta:

$$y_i = a(T_i, C_i, G), \quad (7.9)$$

gde je T_i tekst, C_i kontekst, a G skup smernica za anotaciju. Ova formulacija naglašava da promena smernica ili konteksta može promeniti oznaku. Zato evaluacija modela mora uključiti analizu grešaka, nesigurnih slučajeva i domenske prenosivosti, a ne samo jednu numeričku metriku.

Metodološki značaj ovog dela ogleda se u tome što se podaci ne tretiraju samo kao ulaz za klasifikator, već kao društveno uslovljen zapis komunikacije. Time se naglašava da kvalitativna priroda oznaka, jezika i konteksta mora biti deo prediktivnog okvira.

7.2 Modeli za detekciju diskriminatornog jezika

Transformer modeli predstavljaju dominantan pristup u savremenoj obradi prirodnog jezika jer omogućavaju kontekstualno učenje značenja. U detekciji diskriminatornog jezika to je posebno važno, pošto model mora razlikovati eksplicitnu uvredu, implicitni stereotip, citiranje problematičnog sadržaja, kritiku diskriminacije i neutralnu upotrebu identitetskih termina. Poređenja transformer arhitektura pokazuju da modeli kao što su BERT, RoBERTa, ALBERT, DistilBERT i XLNet mogu imati različite prednosti u zavisnosti od podataka, veličine modela, zadatka i domenske specifičnosti [90].

U ovoj disertaciji transformer modeli se koriste kao centralna klasa modela za analizu društveno odgovorne poslovne komunikacije. Posebno se razmatraju BERT, RoBERTa, DistilRoBERTa, XLM-RoBERTa i srodne arhitekture. Njihova uloga nije samo povećanje tačnosti,

već i kontekstualno razumevanje izraza koji mogu biti dvosmisleni ili implicitni. Savremeni pristupi detekciji mizoginije koriste napredne NLP tehnike i augmentaciju podataka kako bi se ublažili problemi malih i neuravnoteženih skupova [91]. Mehanizam pažnje u transformer modelu može se zapisati kao:

$$Attention(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V, \quad (7.10)$$

gde su Q , K i V matrice upita, ključeva i vrednosti, a d_k dimenzija ključeva. Ovaj mehanizam omogućava modelu da uči odnose između tokena u tekstu, bez oslanjanja na strogo sekvencijalnu obradu. Za binarnu klasifikaciju, izlazna reprezentacija transformer modela može se zapisati kao:

$$h_i = \text{Transformer}(T_i), \quad (7.11)$$

a verovatnoća pozitivne klase kao:

$$\hat{p}_i = \sigma(Wh_i + b). \quad (7.12)$$

Za višeklasnu klasifikaciju koristi se izlaz softmax funkcije:

$$\hat{p}_{ik} = \frac{\exp(z_{ik})}{\sum_{j=1}^K \exp(z_{ij})}. \quad (7.13)$$

U ovim jednačinama T_i predstavlja ulazni tekst komunikacione instance, dok h_i označava kontekstualnu reprezentaciju koju transformer formira na osnovu odnosa između tokena u poruci. Kod binarne klasifikacije vrednost $\hat{p}_i$ može se tumačiti kao verovatnoća da poruka pripada rizičnoj klasi, na primer seksističkom ili diskriminatornom sadržaju. Kod višeklasne klasifikacije vrednost $\hat{p}_{ik}$ označava verovatnoću da instanca i pripada kategoriji k , pri čemu softmax funkcija omogućava poređenje više mogućih tipova komunikacionog rizika. Zbog toga se isti reprezentacioni okvir može koristiti za binarnu detekciju, razlikovanje tipova seksizma i kasnije tumačenje modelskih odluka kroz verovatnoće i objašnjive signale.

7.2.1 Binarna, višeklasna i višelabelna formulacija

Detekcija diskriminatornog jezika može imati više nivoa složenosti. Najjednostavniji zadatak je binarna klasifikacija, gde model procenjuje da li je tekst problematičan ili nije. Složeniji zadatak je višeklasna klasifikacija, gde se prepoznaje tip problematičnog sadržaja. Još složeniji zadatak je višelabelna klasifikacija, gde jedna poruka može sadržati više strategija istovremeno. U poslovnom kontekstu dodatno se uvodi i risk scoring, jer organizaciju često ne zanima samo konačna klasa, već prioritet i stepen potrebe za ljudskom proverom. Pregled osnovnih formulacija zadatka, njihovog značenja i tipičnog izlaza prikazan je u tabeli 7.4. Na

primer, ista poruka može u binarnoj formulaciji biti označena samo kao problematična, dok u višelabelnoj formulaciji može istovremeno dobiti oznake stereotipizacije i omalovažavanja, što nastavniku ili analitičaru daje precizniji osnov za tumačenje komunikacionog rizika.

Tabela 7.4: Formulacije zadatka detekcije diskriminatornog jezika.

Formulacija	Opis	Primer izlaza
Binarna klasifikacija	Tekst jeste ili nije problematičan	seksistički / neseksistički
Višeklasna klasifikacija	Tekst pripada jednoj dominantnoj kategoriji	stereotipizacija, pretnja, omalovažavanje
Višelabelna klasifikacija	Tekst može sadržati više kategorija istovremeno	stereotipizacija + omalovažavanje
Hijerarhijska klasifikacija	Prvo se detektuje prisustvo problema, zatim detaljna kategorija	Zadatak A → Zadatak B → Zadatak C
Skor rizika	Model daje kontinuirani skor rizika	skor $\in [0, 1]$

7.2.2 Funkcija gubitka, neravnoteža klasa i pragovi

Društveno osetljivi skupovi podataka često imaju neravnotežu klasa. Eksplicitni oblici štetnog jezika mogu biti ređi od neutralnih poruka, dok su pojedine potkategorije seksizma znatno ređe od opštih ili implicitnih oblika. Ako se koristi standardna funkcija gubitka bez korekcije, model može favorizovati većinsku klasu i ostvariti visoku ukupnu tačnost, ali slabije prepoznavati upravo one instance koje su najvažnije za analizu komunikacionog rizika. Za binarnu klasifikaciju koristi se binarna unakrsna entropija (*binary cross-entropy*):

$$L_{BCE} = -\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{p}_i) + (1 - y_i) \log(1 - \hat{p}_i)]. \quad (7.14)$$

U ovoj formuli $y_i \in \{0, 1\}$ označava stvarnu oznaku instance, a $\hat{p}_i$ procenjenu verovatnoću da tekst pripada rizičnoj klasi. Funkcija gubitka kažnjava odstupanje procene od stvarne oznake, pri čemu veće greške snažnije utiču na ukupni gubitak. Kod neravnoteže klasa koristi se binarna unakrsna entropija (*weighted binary cross-entropy*):

$$L_{WBCE} = -\frac{1}{n} \sum_{i=1}^n [w_1 y_i \log(\hat{p}_i) + w_0 (1 - y_i) \log(1 - \hat{p}_i)], \quad (7.15)$$

gde su w_1 i w_0 težine pozitivne i negativne klase. U praksi se veća težina može dodeliti ređoj klasi, kako bi model dobio jači signal da greške nad manjinskim primerima nisu zanemarljive.

Alternativno se može koristiti fokalna funkcija gubitka (*focal loss*), koja dodatno naglašava teže klasifikovane instance:


$$L_{focal} = -\frac{1}{n} \sum_{i=1}^n [\alpha y_i (1 - \hat{p}_i)^\gamma \log(\hat{p}_i) + (1 - \alpha)(1 - y_i) \hat{p}_i^\gamma \log(1 - \hat{p}_i)]. \quad (7.16)$$

Parametar α kontroliše značaj pozitivne i negativne klase, dok γ smanjuje uticaj lakih primera i usmerava učenje ka težim instancama. Ovakav pristup je koristan kada su rizični oblici komunikacije retki, ali metodološki i organizaciono važni. Pored izbora funkcije gubitka, važnu ulogu ima i prag odlučivanja. Za binarni model konačna oznaka može se dobiti kao:

$$\hat{y}_i = \begin{cases} 1, & \hat{p}_i \geq \tau, \\ 0, & \hat{p}_i < \tau, \end{cases} \quad (7.17)$$

gde τ označava prag odlučivanja. Niži prag povećava osetljivost modela, ali može dovesti do većeg broja lažno pozitivnih ishoda, dok viši prag smanjuje broj označenih instanci, ali povećava rizik da deo štetnog sadržaja ostane neprepoznat. Izbor praga zato treba posmatrati kao deo podešavanja modela prema domenskom riziku, organizacionom kontekstu i potrebi za ljudskom proverom.

Konceptualni tok obrade teksta u transformer okviru prikazan je na slici 7.3. Prikaz ne obuhvata samo unutrašnju arhitekturu modela, već širi analitički tok u kojem se klasifikacioni izlaz dopunjuje skorom rizika, kalibracijom, objašnjenjem i stručnom proverom. To je posebno važno u društveno osetljivoj poslovnoj komunikaciji, gde se odluka ne sme zasnivati samo na izlaznoj oznaci modela, već i na pouzdanosti skora, objašnjivosti i mogućnosti ljudske intervencije.



Slika 7.3: Transformer okvir za detekciju diskriminatornog jezika u digitalnoj komunikaciji.

U metodološkom smislu, transformer modeli u ovom poglavlju nemaju ulogu samo naprednog klasifikatora. Njihova vrednost je u tome što omogućavaju proveru da li kontekstualno modelovanje može bolje obuhvatiti implicitne i semantički složene komunikacione obrasce, uz istovremenu potrebu za strožom evaluacijom grešaka i odgovornom primenom.

7.3 Eksperimentalni pravci i evaluacija modela

Evaluacija modela u ovom poglavlju razvija se kroz više istraživačkih slojeva. Prvi sloj čini raniji NIP projekat, u kojem je proverena mogućnost detekcije mizoginih obrazaca pomoću kombinacije Word2Vec reprezentacija, BiLSTM slojeva i self-attention mehanizma. Drugi sloj čine prihvaćena i tekuća istraživanja kandidatkinje o detekciji mizoginog i rodno pristrasnog jezika u poslovnom diskursu, u kojima se koristi RoBERTa arhitektura sa domenskom adaptacijom, sentimentnim i stilskim obeležjima, attention pooling slojem, dropout regularizacijom, ponderisanjem klasa i augmentacijom podataka. Treći sloj čini tekući rad u kojem se EDOS i EXIST koriste za odgovornu proveru transformer modela, kalibraciju verovatnoća i prioritizaciju slučajeva za ljudsku proveru. Ovaj pravac ostaje otvoren za dalji razvoj kroz postepeno formiranje anonimizovanih korpusa korporativne i profesionalne mizoginije, zasnovanih na etički prikupljenim primerima iz javno dostupnih i institucionalno relevantnih lokalnih komunikacionih okruženja.

7.3.1 RoBERTa za poslovni diskurs

U tekućem istraživanju o odgovornoj AI podršci inkluzivnoj poslovnoj komunikaciji, početni RoBERTa model ostvario je umerene rezultate: tačnost od 75.4%, preciznost od 71.2%, odziv od 68.6%, F1 meru od 69.1% i AUC-ROC od 0.74. Nakon domenske adaptacije, koja je uključila pažljivije pretprocesiranje, sentimentne i stilističke karakteristike, attention pooling, dropout regularizaciju, klasne težine, augmentaciju podataka i podešavanje hiperparametara, optimizovani RoBERTa model ostvario je 91.2% tačnosti, 88.7% preciznosti, 90.5% odziva, F1 meru od 89.6% i AUC-ROC od 0.93. Ovakav rast performansi ukazuje da kod društveno osetljivih tekstualnih zadataka presudan značaj nema samo izbor transformer arhitekture, već i način na koji se model prilagođava domenskim osobenostima, neravnoteži klasa i različitim nivoima eksplicitnosti pristrasnog jezika.

Tabela 7.5 pokazuje da poboljšanje ne proizlazi samo iz izbora snažnijeg modela, već iz pažljivog povezivanja arhitekture, pretprocesiranja, balansiranja klasa i domenskog razumevanja zadatka. Najvažniji napredak ogleda se u odzivu i F1 meri, jer propuštanje štetnog sadržaja može imati veće posledice od obične klasifikacione greške. Istovremeno, preciznost ostaje važna zato što prevelik broj lažnih alarma može smanjiti poverenje zaposlenih u sistem i stvoriti otpor prema analitičkim alatima.

Tabela 7.5: Evaluacija poslovnog RoBERTa modela iz tekućeg istraživačkog pravca.

Model	Tačnost	Preciznost	Odziv	F1 mera	AUC-ROC
Pretrenirani RoBERTa	75.4%	71.2%	68.6%	69.1%	0.74
Optimizovani RoBERTa	91.2%	88.7%	90.5%	89.6%	0.93

7.3.2 EDOS i EXIST kao osnova za odgovornu evaluaciju

U tekućem istraživanju radi se i na razvoju okvira koji proširuje klasičnu detekciju seksualnog sadržaja na kalibraciju verovatnoća, analizu nesigurnosti i prioritizaciju slučajeva za ljudsku proveru. EDOS se koristi kao primarni engleski skup za poređenje, dok se EXIST koristi kao šira provera nad dvojezičnim podacima. Kod EXIST skupa posebno se naglašava da je evaluacija sprovedena na dostupnom razvojnom skupu, a ne na zvaničnom test skupu, zbog čega rezultati imaju karakter radnog istraživačkog nalaza, a ne konačnog poređenja u okviru zajedničkog evaluacionog zadatka.

Jedan od važnih nalaza ovog pravca jeste da model sa dobrim klasifikacionim metrikama ne mora imati dovoljno pouzdane verovatnoće za operativnu primenu. Zbog toga se, pored makro F1 i pozitivne F1 mere, analiziraju ECE, Brier skor i NLL. ECE označava očekivanu grešku kalibracije, odnosno odstupanje između procenjene verovatnoće modela i stvarne tačnosti, dok NLL meri koliko se model kažnjava za pogrešno ili previše sigurno procenjene verovatnoće. U dosadašnjim rezultatima Platt kalibracija kod EDOS RoBERTa-base modela smanjuje ECE sa 0.1100 na 0.0378 i NLL sa 0.5579 na 0.3175. Kod EXIST XLM-RoBERTa modela ECE se smanjuje sa 0.1526 na 0.0363, a NLL sa 0.7260 na 0.4282. Ovi rezultati pokazuju da kalibracija ne mora značajno menjati klasifikacionu meru, ali može poboljšati kvalitet verovatnoća koje se koriste za pragove, prioritizaciju i ljudsku proveru.

Pregled početnih i kalibrisanih rezultata za EDOS i EXIST prikazan je u tabeli 7.6. Tabela pokazuje da Platt kalibracija gotovo ne menja makro F1 rezultat, ali znatno smanjuje ECE i NLL vrednosti, što je posebno važno kada se izlazne verovatnoće koriste za operativne pragove i odgovornu proveru rizičnih slučajeva.

Kalibracija se može formalno posmatrati kao transformacija sirove verovatnoće modela $\hat{p}_i$ u kalibrisanu verovatnoću $\tilde{p}_i$:

$$\tilde{p}_i = Cal(\hat{p}_i), \quad (7.18)$$

gde $Cal(\cdot)$ označava kalibracionu funkciju, na primer Platt skaliranje ili izotoničnu regresiju. Važnost ove funkcije leži u tome što se u primeni u realnom okruženju ne koristi samo klasa modela, nego i stepen poverenja u predikciju. Drugim rečima, cilj kalibracije nije nužno bolja klasifikacija, već pouzdanije značenje vrednosti kao što je $\hat{p}_i = 0.80$ u odnosu na očekivanu tačnost sličnih primera.

Tabela 7.6: Primer kalibracije transformer modela u tekućem istraživačkom pravcu.

Skup podataka i model	Metod	N	Macro F1	ECE	NLL
EDOS RoBERTa-base	raw	4000	0.8315	0.1100	0.5579
EDOS RoBERTa-base	Platt	4000	0.8302	0.0378	0.3175
EXIST XLM-RoBERTa	raw	561	0.8376	0.1526	0.7260
EXIST XLM-RoBERTa	Platt	561	0.8376	0.0363	0.4282

Očekivana kalibraciona greška može se zapisati kao:

$$ECE = \sum_{m=1}^M \frac{|B_m|}{n} |acc(B_m) - conf(B_m)|, \quad (7.19)$$

gde B_m označava m -ti kalibracioni interval, $|B_m|$ broj instanci u tom intervalu, $acc(B_m)$ empirijsku tačnost, a $conf(B_m)$ prosečno poverenje modela. Manja ECE vrednost znači da su procenjene verovatnoće bolje usklađene sa stvarnim ishodima, što smanjuje rizik da model bude previše siguran ili previše nesiguran u društveno osetljivim slučajevima.

7.3.3 Prioritizacija za ljudsku proveru

Poseban doprinos komunikacionog domena jeste prelazak sa pitanja „da li je model tačan” na pitanje „kako se izlaz modela koristi u odgovornom procesu”. U tekućim eksperimentima analizirana je strategija slanja dela slučajeva na ljudsku proveru. Kod EDOS RoBERTa-base modela, izabrana T2 strategija šalje 37.40% slučajeva na proveru i obuhvata 76.02% ukupnih grešaka, 62.55% lažno negativnih i 93.43% lažno pozitivnih ishoda. Kod EXIST XLM-RoBERTa modela, odgovarajuća strategija šalje 61.50% slučajeva na proveru i obuhvata 74.73% grešaka.

Nalazi iz tabele 7.7 ukazuju da u društveno osetljivim sistemima nije dovoljno model samo trenirati i testirati, već je potrebno osmisliti njegovo uključivanje u organizacioni tok rada. Stopa provere pokazuje koliko se instanci šalje evaluatorima, a otkrivene greške koliko ukupnih grešaka dodatna provera uspeva da izdvoji. Lažno negativni ishodi (FN) odnose se na propuštanje štetnog sadržaja, a lažno pozitivni ishodi (FP) na prekomerno označavanje neutralnog ili kontekstualno drugačijeg teksta kao rizičnog. Kolona za greške među proverama pokazuje koliki deo poslatih instanci zaista predstavlja grešku modela.

Tabela 7.7: Primer prioritizacije slučajeva za dodatnu ljudsku proveru u tekućem istraživačkom pravcu.

Skup podataka i model	Stopa provere	Otkrivene greške	Otkriveni FN	Otkriveni FP	Greške među proverenima
EDOS RoBERTa-base	37.40%	76.02%	62.55%	93.43%	24.80%
EXIST XLM-RoBERTa	61.50%	74.73%	52.08%	100.00%	19.71%

7.4 Lažno pozitivni i lažno negativni ishodi u društveno osetljivim sistemima

U društveno osetljivim sistemima, greške modela imaju drugačije posledice nego u standardnim klasifikacionim zadacima. Lažno pozitivan ishod znači da je neutralan ili legitimni tekst pogrešno označen kao problematičan. Lažno negativan ishod znači da problematičan tekst nije prepoznat. Obe vrste grešaka mogu biti štetne, ali na različite načine.

Lažno pozitivan ishod može dovesti do nepravednog označavanja autora poruke, narušavanja poverenja u sistem, prekomerne moderacije ili autocenzure. Lažno negativan ishod može omogućiti da štetan govor ostane prisutan u organizaciji, što može narušiti sigurnost i inkluzivnost komunikacionog prostora. Zbog toga se u ovom domenu ne može jednostavno optimizovati jedna metrika bez razumevanja posledica. Matrica konfuzije za binarni zadatak prikazana je kao:

$$C = \begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix}. \quad (7.20)$$

Raspored vrednosti (TP), (TN), (FP) i (FN) omogućava da se performanse modela posmatraju odvojeno po tipu greške, što je posebno važno kada lažno pozitivni i lažno negativni ishodi nemaju istu praktičnu težinu. Stopa lažno pozitivnih ishoda računa se kao:

$$FPR = \frac{FP}{FP + TN}, \quad (7.21)$$

dok se stopa lažno negativnih ishoda računa kao:

$$FNR = \frac{FN}{FN + TP}. \quad (7.22)$$

Tabela 7.8 prikazuje značenje osnovnih ishoda matrice konfuzije u detekciji diskriminatornog jezika. Važno je razlikovati lažno pozitivne i lažno negativne ishode, jer prvi mogu nepravedno označiti neutralan sadržaj, dok drugi znače da štetan govor ostaje neprepoznat.

7.4.1 Prag odlučivanja i zone rizika

Modeli često daju verovatnoću ili skor rizika. Konačna klasifikacija zavisi od praga τ :

$$\hat{y}_i = \begin{cases} 1, & \hat{p}_i \geq \tau, \\ 0, & \hat{p}_i < \tau. \end{cases} \quad (7.23)$$

Smanjenje praga povećava verovatnoću da će problematični sadržaji biti prepoznati, ali može povećati broj lažno pozitivnih ishoda. Povećanje praga smanjuje broj lažno pozitivnih ishoda, ali može povećati broj propuštenih problematičnih sadržaja. Zato izbor praga mora biti povezan sa namenom sistema, prihvatljivim rizikom i kapacitetom za ljudsku proveru. U poslovnom okruženju najodgovorniji pristup nije automatsko donošenje konačne odluke, već uvođenje zona rizika koje povezuju izlaznu verovatnoću modela sa različitim nivoima ljudske intervencije:

$$decision_i = \begin{cases} \text{no_flag}, & \hat{p}_i < \tau_1, \\ \text{human_review}, & \tau_1 \leq \hat{p}_i < \tau_2, \\ \text{priority_review}, & \hat{p}_i \geq \tau_2. \end{cases} \quad (7.24)$$

U ovoj formulaciji τ_1 predstavlja prag iznad kojeg sadržaj više nije dovoljno pouzdano neutralan da bi bio automatski odbačen, dok τ_2 označava viši prag rizika pri kojem se instanca prosleđuje na prioritetnu proveru. Srednja zona omogućava da se neizvesni slučajevi zadrže u procesu ljudske procene, umesto da se nad njima donosi neposredna automatska odluka. Time model dobija ulogu sistema za rangiranje rizika i podršku odlučivanju, dok konačna interpretacija ostaje u nadležnosti stručne osobe ili odgovarajućeg organizacionog tela.

7.4.2 Ograničenja procene nesigurnosti pomoću softmax funkcije


Jedan od važnih nalaza iz tekućeg istraživačkog pravca jeste da jednostavna procena nesigurnosti zasnovana na verovatnoći softmax funkcije nije dovoljna za pouzdano usmeravanje slučajeva ka ljudskoj proveru. U testiranim scenarijima, granična verovatnoća oko 0.5 predstavlja formalno dostupnu meru nesigurnosti, ali obuhvata veoma mali deo stvarnih grešaka. To znači da model može grešiti i onda kada je numerički samouveren, odnosno kada izlazna verovatnoća ne ukazuje na očiglednu nesigurnost. Ovaj nalaz je posebno važan za društveno osetljive sisteme, jer pokazuje da odgovorna primena zahteva jače metode procene nesigurnosti, kao što su ansambli modela (*ensembles*), Monte Karlo isključivanje neurona (*Monte Carlo dropout*), konformna predikcija (*conformal prediction*) ili dodatni slojevi provere (*audit layers*). Binarna entropija može se zapisati kao:

$$H_b(\hat{p}_i) = -\hat{p}_i \log_2(\hat{p}_i) - (1 - \hat{p}_i) \log_2(1 - \hat{p}_i). \quad (7.25)$$

Binarna entropija meri stepen neizvesnosti binarne odluke i dostiže najveću vrednost kada je procenjena verovatnoća blizu 0.5, odnosno kada model nema jasnu sklonost ka jednoj od dve klase. Nasuprot tome, kada je verovatnoća bliska vrednostima 0 ili 1, entropija opada, što ukazuje na veću samouverenost modela. Zbog toga je binarna entropija koristan dopunski indikator nesigurnosti, jer omogućava da se izdvoje slučajevi u kojima je odluka formalno granična, iako sama po sebi nije dovoljna da prepozna sve operativno rizične greške.

Iako entropija daje informaciju o blizini odluke granici, ona ne može sama identifikovati sve slučajeve u kojima je model samouvereno pogrešan. Zbog toga u ovom poglavlju nesigurnost nije predstavljena kao gotovo rešenje, već kao istraživački problem koji zahteva dodatnu metodološku proveru.

Ilustracija na slici 7.4 prikazuje kako se izlazna verovatnoća modela može prevesti u zone rizika i povezati sa odlukom o ljudskoj proveru. Prikaz naglašava da pragovi ne služe samo za tehničko razdvajanje klasa, već i za uravnoteženje rizika između propuštanja štetnog sadržaja i prekomernog označavanja neutralnih poruka. Posebno je važno to što se entropija može koristiti kao dodatni signal nesigurnosti, jer ukazuje na slučajeve u kojima skor rizika sam po sebi nije dovoljan za pouzdano razdvajanje bezbednih, graničnih i prioriternih instanci.



Slika 7.4: Pragovi rizika i ljudska provera u detekciji diskriminatornog jezika.

U praktičnom smislu, visoka entropija označava zonu u kojoj model ne prikriva sopstvenu nesigurnost, već je eksplicitno uključuje u proces odlučivanja i usmerava potencijalno osetljiv slučaj ka dodatnoj ljudskoj proveru.

Ova sekcija ima posebnu metodološku vrednost jer pokazuje da društveno osetljivi modeli ne mogu biti optimizovani samo prema jednoj numeričkoj meri. U zavisnosti od organizacione namene, prioritet može biti smanjenje lažno negativnih ishoda, smanjenje lažno pozitivnih ishoda ili uravnoteženje oba rizika kroz ljudsku proveru.

7.5 Stručna kontrola, odgovorno odlučivanje i etička primena modela

Modeli za detekciju diskriminatornog jezika ne smeju se koristiti kao autonomni sistemi za donošenje konačnih odluka o zaposlenima, kandidatima, korisnicima ili drugim učesnicima komunikacije. Njihova uloga treba da bude pomoćna i analitička: da prepoznaju sadržaje koji zahtevaju dodatnu pažnju, omoguće organizovanje prioriteta, pruže objašnjenja odluka i podrže stručnu procenu u složenim situacijama. Na taj način model ne zamenjuje institucionalnu odgovornost, već postaje deo šireg sistema za rano prepoznavanje rizika.

Stručna kontrola je neophodna zato što jezik nije izolovan tehnički signal, već kontekstualan oblik društvene i poslovne interakcije. Značenje poruke može zavisiti od odnosa između učesnika, namere, prethodne komunikacije, citiranja, ironije, tona ili šire situacije. Pored toga, anotacioni standardi nisu isti u svim organizacijama, pa ono što se u jednom kontekstu prepoznaje kao rizično u drugom može zahtevati dodatno tumačenje. Pogrešna klasifikacija može imati posledice i po osobu koja je poruku poslala i po osobu koja je porukom pogođena, dok model može reprodukovati pristrasnosti iz trening podataka. Zbog toga se izlaz modela mora posmatrati kao signal za proveru, a ne kao konačna odluka. Zato se odgovorna primena modela može organizovati kroz okvir ljudske kontrole i asistencije (*human-in-the-loop*):

$$Decision_i = H(\tilde{p}_i, E_i, C_i, R_i), \quad (7.26)$$

gde je $\tilde{p}_i$ kalibrisana verovatnoća ili skor rizika, E_i objašnjenje predikcije, C_i komunikacioni kontekst, R_i rezultat dodatne provere ili pravila politike, a H ljudska ili stručna odluka.

Tabela 7.8 dodatno povezuje ishode klasifikacije sa mogućim posledicama u sistemu ljudske kontrole, naglašavajući da greške modela nemaju samo tehničko, već i organizaciono i etičko značenje. Tabela pokazuje da greške modela u ovom domenu nisu samo tehničke, već mogu imati posledice po poverenje, moderaciju i bezbednost komunikacionog prostora.

Tabela 7.8: Značenje grešaka u detekciji diskriminatornog jezika.

Ishod	Značenje	Moguća posledica
Tačno pozitivno	Problematičan sadržaj je pravilno prepoznat	Mogućnost pravovremene stručne provere
Lažno pozitivno	Neutralan sadržaj je pogrešno označen kao problematičan	Nepravedna procena, gubitak poverenja, prekomerna moderacija
Lažno negativno	Problematičan sadržaj nije prepoznat	Štetan govor ostaje neprimećen
Tačno negativno	Neutralan sadržaj je pravilno prepoznat	Sistem ne opterećuje proces nepotrebnim signalima

Objašnjivost (*explainability*) je posebno važna u društveno osjetljivim modelima. Ako sistem označi poruku kao problematičnu, potrebno je prikazati koji delovi teksta su najviše doprineli takvoj proceni. Međutim, objašnjenje ne treba shvatiti kao apsolutnu istinu o unutrašnjem procesu modela. Ono je pomoćni alat za stručnu proveru, naročito u slučajevima kada tekst sadrži ironiju, citiranje, profesionalni žargon ili kontekst koji model ne može pouzdano obuhvatiti. Lokalno objašnjenje može imati aditivni oblik:

$$g_i = \phi_0 + \sum_{j=1}^M \phi_{ij} z_{ij}, \quad (7.27)$$

gde ϕ_{ij} označava doprinos tokena ili obeležja j predikciji instance i . U praksi, objašnjenje može uključivati istaknute reči, fraze, kategorije ili semantičke obrasce.

Konceptualni okvir ljudske kontrole u petlji prikazan je na slici 7.5. Slika naglašava da model ne završava proces automatskom odlukom, već daje skor rizika i objašnjenje, nakon čega stručna provera vodi ka odluci, edukativnoj meri ili audit zapisu.



Slika 7.5: Okvir ljudske kontrole u petlji za odgovornu upotrebu modela.

7.6 Veza sa inkluzivnim radnim okruženjem i održivim razvojem

Društveno odgovorna poslovna komunikacija povezana je sa širim ciljevima inkluzivnog, bezbednog i održivog radnog okruženja. Organizacije koje razvijaju kulturu poštovanja, jednakih mogućnosti i psihološke sigurnosti moraju obratiti pažnju ne samo na formalne politike, već i na svakodnevne komunikacione obrasce. Digitalni tekstovi, komentari i poruke mogu ukazati na probleme koji nisu uvek vidljivi kroz formalne izveštaje. Zato analiza komunikacije ima preventivnu vrednost, jer omogućava da se rizični obrasci prepoznaju pre nego što prerastu u konflikt, diskriminaciju ili dugoročan gubitak poverenja.

Prediktivni modeli ne zamenjuju organizacionu kulturu, etičke procedure ili ljudsku odgovornost. Oni mogu služiti kao dodatni analitički sloj koji pomaže da se problematični obrasci ranije uoče. Važno je da se AI sistemi ne koriste represivno ili mehanički, već kao podrška prevenciji, edukaciji i izgradnji inkluzivnog okruženja u kojem se tehnološka analiza kombinuje sa stručnim tumačenjem, transparentnim procedurama i zaštitom dostojanstva učesnika.

Veza sa održivim razvojem ogleda se u tome što inkluzivna komunikacija doprinosi kvalitetu rada, jednakosti, dostojanstvenom radnom okruženju i smanjenju diskriminatornih praksi. U poslovnom kontekstu, to može uticati na poverenje zaposlenih, zadržavanje talenata, reputaciju organizacije i kvalitet interne i eksterne komunikacije. Time se ovo poglavlje povezuje sa širim ciljevima održivog razvoja, posebno sa rodnom ravnopravnošću, dostojanstvenim radom i smanjenjem nejednakosti, ali i sa idejom da tehnologija treba da unapređuje, a ne narušava kvalitet ljudskog rada i međuljudskih odnosa.

Tabela 7.9 prikazuje vezu između analize poslovne komunikacije i širih organizacionih ciljeva. Ona naglašava da modeli mogu doprineti ranom prepoznavanju rizika, ali samo ako se njihova upotreba poveže sa ljudskom odgovornošću, kontekstualnim tumačenjem i zaštitom inkluzivnog radnog okruženja. Tabela zato ukazuje da se modeli za analizu komunikacije moraju vrednovati ne samo prema performansama, već i prema tome da li podstiču pažljivije, pravednije i kontekstualno odgovornije postupanje u organizaciji.

Tabela 7.9: Veza AI analize komunikacije sa organizacionim ciljevima.

Organizacioni cilj	Uloga modela	Ograničenje
Inkluzivna kultura	Rano prepoznavanje problematičnih obrazaca	Model ne sme zameniti edukaciju i menadžersku odgovornost
Psihološka sigurnost	Identifikacija štetnog jezika i komunikacionih rizika	Potrebna je poverljiva i pažljiva obrada slučajeva
Jednake mogućnosti	Praćenje obrazaca koji mogu ukazati na pristrasnost	Neophodna segmentna i kontekstualna analiza
Organizaciono učenje	Analiza agregiranih trendova u komunikaciji	Rezultati se ne smeju koristiti za neproporcionalno nadgledanje
Reputacija i usklađenost	Smanjenje rizika javno problematične komunikacije	AI mora biti deo šireg compliance procesa

U okviru ove disertacije, doprinos ovog poglavlja nije u tvrdnji da AI može rešiti problem diskriminacije u organizacijama. Doprinos je u definisanju metodološki odgovornog okvira u kojem se modeli mogu koristiti za podršku prepoznavanju rizičnog jezika, uz obaveznu interpretaciju, ljudsku proveru i razumevanje ograničenja.

7.7 Sinteza nalaza u oblasti društveno odgovorne poslovne komunikacije

Domen društveno odgovorne poslovne komunikacije pokazuje da se prediktivni modeli u društveno osetljivim zadacima ne mogu vrednovati samo prema klasifikacionoj tačnosti, već i prema načinu na koji se njihovi izlazi koriste u realnom organizacionom kontekstu. Za razliku od domena u kojima se model primarno koristi za predikciju ocene, cene, zadovoljstva ili popularnosti, ovde izlaz modela može uticati na poverenje, pravičnost, reputaciju i kvalitet komunikacione kulture. Zbog toga centralni nalaz poglavlja nije samo da se rodno pristrasan, seksistički ili mizogin jezik može modelovati NLP metodama, već da takvo modelovanje zahteva objašnjivost, kalibraciju, analizu grešaka i ljudsku proveru.

Metodološki doprinos poglavlja ogleda se u povezivanju podataka, modela i odgovorne primene. Na nivou podataka, javni skupovi kao što su EDOS, EXIST, MAMI i srodni resursi omogućavaju razvoj i evaluaciju modela, ali istovremeno pokazuju granice anotacije, domenske prenosivosti i primene opštih korpusa na poslovni diskurs. Na nivou modelovanja, poglavlje pokazuje prelaz od sekvencijalnih pristupa zasnovanih na Word2Vec, BiLSTM i attention mehanizmima ka transformer modelima koji bolje obuhvataju kontekstualne i implicitne obrasce jezika. Na nivou evaluacije, rezultati se tumače kroz metrike, greške, pragove, kalibraciju i potrebu za ljudskom proverom.

Nalazi ovog poglavlja doprinose proveru više istraživačkih hipoteza. Hipoteza H1 sagledava se kroz primenu dubokih i transformer modela na tekstualne podatke, pri čemu rezultati pokazuju da složenije arhitekture imaju posebnu vrednost kada zadatak zahteva razumevanje konteksta, implicitnosti i pragmatičkih nijansi. Hipoteza H2 povezuje se sa kvalitetom podataka, anotacijama i domenskim granicama, jer se pokazuje da performanse modela zavise od načina na koji su prikupljeni, označeni i pretprocesirani društveno osetljivi tekstovi. Hipoteza H3 podržana je kroz potrebu za objašnjivošću, kalibracijom i stručnom proverom, dok se hipoteza H4 posebno potvrđuje kroz analizu posledica lažno pozitivnih i lažno negativnih ishoda. Hipoteza H5 razmatra se kroz poređenje različitih modelskih pristupa, funkcija gubitka, pragova i mera pouzdanosti, čime se pokazuje da izbor modela mora zavisiti od odnosa između performansi, rizika i domenske primene.

Posebna vrednost komunikacionog domena jeste u tome što jasno pokazuje granice automatizovanog odlučivanja. Model u ovom kontekstu ne sme biti autonoman mehanizam za sankcionisanje, već pomoćni analitički sloj koji ukazuje na rizik, pruža objašnjenje i usmerava slučajeve ka stručnoj proveru. Time se integrativni okvir disertacije proširuje sa predikcije poslovnih ishoda na analizu komunikacionih rizika, gde interpretabilnost, analiza grešaka i ljudska odgovornost postaju neophodni uslovi praktične vrednosti modela.

Naredno poglavlje prelazi na održivi razvoj, projektno odlučivanje i analitičko izveštavanje, čime se istraživački okvir dalje proširuje na upotrebu poslovne inteligencije, generativnih modela i interpretabilnog odlučivanja u kontekstu održivog razvoja.

8. ODRŽIVI RAZVOJ, PROJEKTN ODLUČIVANJE I IZVEŠTAVANJE

Održivi razvoj u ovoj disertaciji posmatra se kao analitički okvir u kojem se poslovne, tehnološke i organizacione odluke ne procenjuju samo prema kratkoročnim performansama, već i prema dugoročnim ekološkim, društvenim, institucionalnim i operativnim posledicama. U takvom okviru podaci, modeli i izveštaji ne predstavljaju izolovane tehničke rezultate, već instrumente za bolje razumevanje odnosa između resursa, korisničkog ponašanja, organizacionih prioriteta i strateških ciljeva. Zbog toga se održivost u ovom poglavlju ne tretira kao opšti deklarativni cilj, već kao skup merljivih indikatora i objašnjivih postupaka koji mogu podržati odgovornije odlučivanje.

U kontekstu disertacije, održivost ima dvostruku ulogu. Sa jedne strane, ona je predmet analize, jer se kroz podatke mogu pratiti obrasci korišćenja kapaciteta, pouzdanosti rezervacija, projektnih ulaganja, istraživačkih prioriteta i institucionalne saradnje. Sa druge strane, ona je i kriterijum vrednovanja samih analitičkih sistema, jer se od modela očekuje da budu ne samo tačni, već i objašnjivi, proporcionalni problemu, energetske racionalni i korisni za donosioc odluka. Ova dvostruka uloga čini poglavlje važnim za povezivanje tehničkih performansi modela sa širim društvenim i organizacionim posledicama njihove primene.

Ovakav pristup se nadovezuje na osnovnu logiku disertacije. U prethodnim poglavljima analizirani su digitalni tragovi korisnika hotela, putnika, vozača, potrošača i učesnika digitalne komunikacije. U ovom poglavlju fokus se pomera ka organizacionom nivou: ka pitanjima kako se indikatori održivosti, projektni opisi, istraživački portfoliji, mreže saradnje, softverska efikasnost i generisani analitički narativi mogu pretvoriti u proverljive uvide za odlučivanje. Time se pokazuje da prediktivna i tekstualna analitika ne moraju služiti samo za klasifikaciju ponašanja pojedinaca, već i za podršku planiranju, izveštavanju i strateškoj koordinaciji u složenim sistemima. Zato ovo poglavlje zadržava fokus na proveru kako se prediktivni modeli, NLP klasifikacija i evaluacija generisanih narativa mogu koristiti za objašnjivo projektno i organizaciono odlučivanje.

Savremena istraživanja ukazuju da veštačka inteligencija može doprineti ciljevima održivog razvoja samo kada su modeli povezani sa jasno definisanim ciljevima, proverljivim indikatorima i odgovornim mehanizmima primene [92]. Istovremeno, literatura o veštačkoj inteligenciji za ekološku održivost naglašava da koristi analitičkih sistema ne treba posmatrati

odvojeno od ograničenja, računarske zahtevnosti, kvaliteta podataka, institucionalnog konteksta i mogućih neželjenih posledica [93]. Zato se centralni doprinos ovog poglavlja ogleda u povezivanju održivog razvoja sa metodološkim pitanjima koja se provlače kroz celu disertaciju, od izbora relevantnih indikatora i njihove obrade, preko modelovanja složenih odnosa i objašnjavanja rezultata, do sprečavanja da automatizovani izveštaji proizvode pogrešne, nepotpune ili preterano uverljive zaključke. U opštem obliku, održivo analitičko odlučivanje može se predstaviti kao funkcija više povezanih dimenzija:

$$D_i = f(E_i, S_i, G_i, B_i, T_i), \quad (8.1)$$

gde E_i označava ekološke pokazatelje, S_i društvene pokazatelje, G_i upravljačke ili *governance* pokazatelje, B_i poslovne pokazatelje, a T_i tehnološke pokazatelje. Cilj nije maksimizacija jedne dimenzije, već balansiranje više ciljeva u konkretnom domenu primene. Tako se odluka posmatra kao rezultat višekriterijumskog usklađivanja, u kojem se ekološki i društveni efekti povezuju sa poslovnom održivošću, tehnološkom izvodljivošću i kvalitetom upravljanja. Ukoliko se različiti indikatori moraju objediniti u zajednički analitički prikaz, kompozitni indeks može se zapisati kao:

$$SI_i = \sum_{j=1}^m w_j \cdot norm(x_{ij}), \quad (8.2)$$

gde SI_i predstavlja indeks održivosti instance i , x_{ij} vrednost indikatora j , w_j težinu tog indikatora, a $norm(\cdot)$ funkciju normalizacije. Ovakav indeks ne treba tumačiti kao univerzalnu meru održivosti, već kao transparentan alat za poređenje scenarija, perioda, projekata ili organizacionih jedinica u jasno definisanom istraživačkom kontekstu.

Tabela 8.1 pokazuje da održivi razvoj ima širi metodološki smisao. On obuhvata turističke indikatore, projektne i istraživačke podatke, automatizovano izveštavanje i održivost softverske implementacije. Zato ovo poglavlje predstavlja most između prediktivnog modelovanja, poslovne inteligencije, interpretabilnosti i odgovorne primene veštačke inteligencije.

8.1 Analitika održivog turizma i hotelskih podataka

8.1.1 Poslovna inteligencija i generativni modeli u održivom turizmu

Turizam je posebno pogodan domen za analizu održivosti jer spaja korisničko ponašanje, kapacitete, cenu, sezonalnost, otkazivanja, distribucione kanale i operativno planiranje. U hotelskim i turističkim sistemima održivost se ne može posmatrati samo kroz ekološke pokazatelje u užem smislu, već i kroz efikasno korišćenje kapaciteta, stabilnost tražnje, smanjenje nepotrebnih operativnih oscilacija, pouzdanost rezervacija i kvalitet izveštavanja za donosiocje odluka. Zbog toga se poslovna inteligencija u ovom delu poglavlja koristi kao sloj

Tabela 8.1: Dimenzije održivog analitičkog odlučivanja.

Dimenzija	Primeri indikatora	Uloga u odlučivanju
Ekonomska	Prihod, trošak, iskorišćenost kapaciteta, prosečna cena, povraćaj ulaganja	Procena poslovne efikasnosti i finansijske održivosti odluke
Ekološka	Potrošnja energije, voda, emisije, otpad, efikasnost resursa, digitalni karbonski otisak	Procena uticaja na resurse, životnu sredinu i dugoročnu otpornost sistema
Društvena	Zadovoljstvo korisnika, dostupnost usluge, inkluzivnost, uslovi rada, kvalitet komunikacije	Procena posledica odluka po korisnike, zaposlene i širu zajednicu
Upravljačka	Transparentnost, odgovornost, kvalitet izveštavanja, usklađenost sa pravilima	Praćenje poverenja, kontrole i institucionalne opravdanosti odluke
Tehnološka	Računarska zahtevnost, energetska efikasnost, složenost modela, održivost softvera	Procena da li je tehnološko rešenje proporcionalno problemu koji rešava

koji sirove rezervacione podatke pretvara u indikatore, a generativni modeli kao dodatni sloj koji te indikatore prevodi u kontrolisane analitičke narative.

Istraživanja o inteligentnoj automatizaciji u održivom turizmu pokazuju da AI sistemi mogu doprineti optimizaciji procesa, boljem upravljanju resursima i kvalitetnijem planiranju, ali samo ako su povezani sa jasnim ciljevima i odgovornom interpretacijom [37, 94]. U tom smislu, generativna veštačka inteligencija ne treba da zameni analitičke tabele, grafikone ili stručnu procenu, već da pomogne u objašnjavanju odnosa između više indikatora. Ovo je posebno važno u praksi, jer kontrolna tabla često prikazuje vrednosti i trendove, ali ne objašnjava uvek kako se oni zajedno mogu tumačiti.

U pratećem istraživačkom toku razvijen je okvir u kojem se javno dostupni podaci o hotelskim rezervacijama obrađuju kroz BI tok obrade, a zatim serijalizuju u strukturisane upite za generisanje kratkih analitičkih izveštaja. Ovaj pristup ne tretira generativni model kao samostalnog analitičara, već kao kontrolisanu komponentu sistema za izveštavanje. Model dobija samo unapred izračunate indikatore i oznake trenda, uz eksplicitnu instrukciju da ne izmišlja uzroke, vrednosti ili spoljašnji kontekst.

Ključna metodološka razlika u odnosu na opšte korišćenje generativnih modela jeste uvođenje provere narativa. Generisani tekst se ne prihvata samo zato što je gramatički dobar i čitljiv, već se proverava da li pokriva relevantne indikatore, da li pravilno opisuje trendove, da li koristi proporcionalan jezik i da li ima operativnu vrednost za odlučivanje.

8.1.2 Operativni indikatori održivosti u hotelskim podacima

U analitičkom okviru za održivi turizam korišćeni su operativni indikatori koji se mogu izvesti iz rezervacionih zapisa. Ovi indikatori ne predstavljaju direktne ekološke metrike kao što su potrošnja električne energije, emisije ugljen-dioksida ili potrošnja vode, već operativne proxy pokazatelje održivosti. Njihova vrednost je u tome što ukazuju na efikasnost korišćenja kapaciteta, stabilnost tražnje, rizik otkazivanja i pouzdanost rezervacionog ponašanja. U hotelijerstvu ovakvi indikatori mogu biti važni jer neefikasno planiranje kapaciteta utiče na troškove, radnu organizaciju, nabavku, pripremu soba, potrošnju resursa i kvalitet usluge. Za svaki period izveštavanja formira se vektor indikatora:

$$\mathbf{z}_t = [DL_t, DS_t, CU_t, LoS_t, LTS_t, ADR_t, CR_t, BR_t], \quad (8.3)$$

gde su DL_t nivo tražnje, DS_t stabilnost tražnje, CU_t iskorišćenost kapaciteta, LoS_t prosečna dužina boravka, LTS_t stabilnost vremena unapred rezervacije, ADR_t prosečna dnevna cena, CR_t stopa otkazivanja i BR_t pouzdanost rezervacija. Svi indikatori normalizuju se na interval $[0, 1]$ kako bi bili uporedivi u okviru zajedničkog izveštaja. Normalizacija indikatora može se zapisati kao:

$$x'_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}, \quad (8.4)$$

pri čemu se minimalna i maksimalna vrednost računaju u okviru posmatranog hotela i indikatora. Za indikatore stabilnosti koristi se koeficijent varijacije, tako da se veća stabilnost dobija kada je varijabilnost manja:

$$Stab_t(x) = 1 - \frac{\sigma_t(x)}{\mu_t(x)}. \quad (8.5)$$

Tabela 8.2 pokazuje da se održivost u turizmu može analitički operacionalizovati i onda kada nisu dostupni direktni senzorski ili ekološki podaci. Ovakav pristup ne zamenjuje punu ESG analizu, ali omogućava da se na osnovu dostupnih operativnih podataka prate signali efikasnosti, stabilnosti i odgovornog planiranja.

8.1.3 Evaluacija automatski generisanih analitičkih narativa

Automatsko generisanje izveštaja donosi posebnu metodološku odgovornost. Za razliku od klasične tabele, generisani tekst može čitaocu delovati autoritativno čak i kada je nedovoljno utemeljen. Zbog toga se u ovom poglavlju posebna pažnja posvećuje evaluaciji narativa. Savremena literatura o AI tekstualnom generisanju u održivom izveštavanju naglašava da generativni modeli mogu promeniti način pripreme i interpretacije izveštaja, ali istovremeno otvaraju pitanja tačnosti, odgovornosti, objašnjivosti i mogućih pogrešnih interpretacija [38].


Tabela 8.2: Operativni indikatori održivosti u BI okviru za turizam.

Indikator	Opis	Veza sa održivim odlučivanjem
Demand Level (<i>DL</i>)	Broj potvrđenih rezervacija u posmatranom periodu	Praćenje obima tražnje i opterećenja sistema
Demand Stability (<i>DS</i>)	Stabilnost rezervacija kroz period, zasnovana na koeficijentu varijacije	Procena predvidljivosti tražnje i potrebe za adaptivnim planiranjem
Capacity Utilization (<i>CU</i>)	Iskorišćenost kapaciteta kroz zauzete sobne dane	Procena efikasnosti korišćenja postojećih resursa
Length of Stay (<i>LoS</i>)	Prosečan broj noćenja po rezervaciji	Razumevanje intenziteta korišćenja kapaciteta i obrasca boravka
Stabilnost perioda između rezervacije i dolaska (<i>LTS</i>)	Stabilnost vremena između rezervacije i dolaska	Podrška planiranju nabavke, osoblja i operativnih aktivnosti
Average Daily Rate (<i>ADR</i>)	Prosečna dnevna cena u posmatranom periodu	Veza između prihoda, potražnje i cenovne dinamike
Cancellation Rate (<i>CR</i>)	Udeo otkazanih rezervacija	Signal rizika, gubitka kapaciteta i potencijalnog operativnog otpada
Booking Reliability (<i>BR</i>)	Pouzdanost zasnovana na prethodnom obrascu otkazivanja	Procena stabilnosti rezervacionog ponašanja i poverenja u projekcije

Da bi se prikazala veza između operativnih indikatora, generativnog modela i provere izlaznog teksta, na slici 8.1 dat je konceptualni tok automatskog analitičkog izveštavanja. Prikaz naglašava da se narativ ne generiše neposredno iz sirovih podataka, već iz prethodno obrađenih i normalizovanih indikatora.

U oznaci $P(y_t | z_t)$, z_t predstavlja vektor strukturisanih indikatora za posmatrani period, dok y_t označava analitički narativ generisan na osnovu tih indikatora. Izraz naglašava da tekstualni izlaz ne nastaje nezavisno od podataka, već uslovno, na osnovu prethodno pripremljenih, normalizovanih i semantički označenih ulaznih signala. Nakon generisanja, narativ se proverava kroz pokrivenost indikatora, doslednost tumačenja i usklađenost sa podacima.

Evaluacija generisanih izveštaja može se posmatrati kroz četiri kriterijuma: pokrivenost indikatora, vernost trenda, jezička proporcionalnost i operativna relevantnost. Pokrivenost indikatora meri da li se narativ osvrće na relevantne ulazne dimenzije, dok vernost trenda proverava da li su povećanje, smanjenje ili stabilnost indikatora pravilno opisani. Jezička proporcionalnost sprečava da se blage promene opišu izrazima kao što su „dramatično”, „naglo” ili „značajno”, a operativna relevantnost ocenjuje da li tekst povezuje više indikatora u korisnu interpretaciju za odlučivanje. Ovi kriterijumi omogućavaju da se generisani narativ proceni kao analitički izlaz povezan sa podacima, a ne samo kao stilski uverljiv tekst.



Slika 8.1: Arhitektura okvira za automatsko analitičko izveštavanje zasnovanog na BI toku podataka, modulu generativne AI i evaluaciji izlaznih narativa.

U sprovedenoj evaluaciji generisano je 40 izveštaja za dva različita hotelska profila i dva nivoa agregacije. Prosečna pokrivenost indikatora iznosila je 81.9%, dok je prosečna vernost trenda iznosila 0.81 na skali od 0 do 1. Uvođenje eksplicitne instrukcije za kontrolu jakih kvalifikatora smanjilo je upotrebu prejakog jezika sa 22.5% na 7.5%. Dodatna stručna evaluacija operativne relevantnosti dala je prosečnu ocenu 3.52 na skali od 1 do 5.


Tabela 8.3 sumira kriterijume evaluacije i rezultate eksperimentalnog toka. Dobijene vrednosti pokazuju da narativi uglavnom ostaju povezani sa ulaznim indikatorima, da relativno dobro čuvaju smer promena i da se dodatnim instrukcijama može smanjiti upotreba prejakih izraza u interpretaciji.

Kao ilustracija jednog generisanog analitičkog narativa, slika 8.2 prikazuje tri povezana operativna indikatora za resort hotel u Portugaliji: nivo tražnje i stabilnost planiranja, iskorišćenost kapaciteta i pouzdanost rezervacija. Prikaz pokazuje rast nivoa tražnje od juna ka avgustu, povećanje iskorišćenosti kapaciteta sa 76% na 97% i smanjenje stope otkazivanja na 16.2%, što ukazuje na jačanje sezonske potražnje uz stabilnije rezervaciono ponašanje. Takav primer pokazuje kako narativ može povezati više indikatora u oprezno tumačenje zasnovano na podacima.

Ovi rezultati pokazuju da evaluacija automatskih narativa ne treba da zavisi samo od opšteg utiska o kvalitetu teksta. U poslovnom i održivom izveštavanju važno je da narativ pokriva ključne indikatore, tačno opisuje smer promena, izbegava preterane zaključke i pruža korisnu osnovu za odlučivanje. Tako generativni model ostaje kontrolisani interpretativni sloj nad podacima, a ne samostalni izvor zaključaka.

Tabela 8.3: Kriterijumi evaluacije generisanih analitičkih narativa.

Kriterijum	Način tumačenja	Rezultat u eksperimentalnom toku
Pokrivenost indikatora	Udeo ulaznih indikatora koji su pomenuti ili obuhvaćeni u narativu	81.9% prosečne pokrivenosti
Vernost trenda	Usklađenost opisa sa oznakama rasta, pada ili stabilnosti indikatora	Prosečna vrednost 0.81
Jezička proporcionalnost	Izbegavanje prejakih izraza kada promene nisu velike	Smanjenje jakih izraza sa 22.5% na 7.5%
Operativna relevantnost	Stručna ocena da li narativ povezuje indikatore u korisnu interpretaciju	Prosečna ocena 3.52/5



Slika 8.2: Primer generisanog analitičkog narativa za resort hotel na osnovu indikatora potražnje, iskorišćenosti kapaciteta i pouzdanosti rezervacija.

8.2 Projektna analitika i strateško odlučivanje

8.2.1 Horizon Europe projekti

Drugi deo poglavlja proširuje analizu održivog razvoja sa turizma na istraživačke projekte i njihove tematske, organizacione i finansijske obrasce. Horizon Europe predstavlja jedan od najznačajnijih evropskih programa finansiranja istraživanja i inovacija, a njegovi javno dostupni podaci omogućavaju analizu istraživačkih prioriteta, mreža saradnje, tematskih klastera i tokova finansiranja. U ovom delu disertacije korišćeni su javno dostupni CORDIS podaci o projektima finansiranim u okviru programa Horizon Europe 2021–2027 [95].

Poseban fokus stavljen je na projekte koji se mogu povezati sa istraživačkim izrazom „zelene tehnologije” (*green tech*). U ovom radu taj pojam se ne tumači usko, samo kao razvoj pojedinačnih ekoloških tehnologija, već kao širi skup istraživačkih i inovacionih pravaca povezanih sa klimom, energetsom tranzicijom, zaštitom životne sredine, cirkularnom ekonomijom, održivom mobilnošću, efikasnim korišćenjem resursa, smanjenjem emisija i digitalnim rešenjima za održivost. Takvo polazište omogućava da se održivi razvoj ne posmatra samo kao opšti normativni cilj, već kao konkretan istraživački portfolio koji se može analizirati kroz tekstualne, tematske, finansijske i organizacione podatke.

CORDIS podaci omogućavaju da se svaki projekat posmatra kroz nekoliko povezanih slojeva. Tekstualni sloj obuhvata naslov, cilj i opis projekta, tematski sloj povezuje EuroSciVoc klasifikaciju i programske klastere, finansijski sloj uključuje EU doprinos, dok organizacioni sloj obuhvata koordinate, učesnike i zemlje iz kojih dolaze. Iz ovih podataka se može izvesti i mrežni sloj, zasnovan na saradnji organizacija u okviru projektnih konzorcijuma. Zbog takve strukture, CORDIS je pogodan ne samo za deskriptivnu statistiku, već i za NLP analizu, klasifikaciju, mrežnu analizu i strateško mapiranje istraživačkih portfolija.

U sprovedenoj analizi korišćena su četiri osnovna CSV izvorna fajla: `project.csv`, `euroSciVoc.csv`, `topics.csv` i `organization.csv`. Fokus je stavljen na projektne, tematske i organizacione podatke, jer povezuju tekst projekta, finansiranje i mrežu saradnje.

Analiza jezika pokazala je da su svi projektni zapisi u posmatranom skupu detektovani kao engleski tekstovi. Ovaj nalaz je važan za dalju obradu podataka, jer omogućava primenu jedinstvenih postupaka za čišćenje teksta, pretragu ključnih reči, izdvajanje tematskih obrazaca i pripremu obeležja za analitičke modele. Time se smanjuje potreba za dodatnim jezičkim prilagođavanjem, koje bi u višejezičnom skupu zahtevalo prevod, normalizaciju termina i usklađivanje značenja. Ipak, rezultat treba tumačiti i kao metodološko ograničenje, budući da se analiza odnosi na javno dostupne engleske opise projekata u CORDIS bazi, a ne na interne predloge, radne dokumente ili višejezične verzije projektne dokumentacije.

Pregled osnovnih izvornih CORDIS fajlova, njihovog obima i uloge u sprovedenoj analizi dat je u tabeli 8.4. Tabela pokazuje da se analiza ne oslanja samo na tekstualne opise projekata, već povezuje projektne, tematske i organizacione podatke.

Tabela 8.4: Glavni CORDIS fajlovi korišćeni u Horizon Europe analizi.

Fajl	Obim	Uloga u analizi
project.csv	20.170 projekata	Naslov, cilj projekta, budžet, datumi, šema finansiranja i osnovni tekstualni podaci
euroSciVoc.csv	43.285 redova	Hijerarhijska naučna klasifikacija i izvor za konstrukciju tematskih oznaka
topics.csv	20.337 redova	Povezivanje projekata sa Horizon Europe programskim klasterima
organization.csv	123.260 redova	Organizacije, zemlje, uloge, EU doprinosi i osnova za mrežu saradnje


Filtriranje projekata povezanih sa zelenim tehnologijama sprovedeno je kombinovanjem tri komplementarna kriterijuma. Prvi kriterijum zasnivao se na EuroSciVoc informacijama, drugi na Horizon tematskim klasterima, a treći na NLP pretrazi ključnih reči u tekstualnim poljima. Ovakav višekriterijumski pristup je koristan jer nijedan pojedinačni izvor oznaka nije potpun: EuroSciVoc klasifikacija može biti nedovoljno detaljna, programski klasteri su široki, dok pretraga ključnih reči može obuhvatiti i projekte koji zahtevaju dodatnu proveru.

Slika 8.3 prikazuje razmeru segmenta zelenih tehnologija u posmatranom Horizon Europe skupu. Udeo od 43.7% pokazuje da zelene tehnologije predstavljaju značajan istraživački pravac. Ipak, ovaj procenat ne treba tumačiti kao službenu oznaku programa, već kao rezultat eksplorativnog filtriranja koje kombinuje klasifikacije, tematske klastere i NLP pretragu.

Tabela 8.5 pokazuje da se održivi razvoj u istraživačkom ekosistemu može analizirati kao istraživački portfolio, a ne samo kao opšti strateški cilj. Ovde jedinica analize nije korisnik ili rezervacija, već istraživački projekat, konzorcijum ili tematska oblast. Time se integrativni okvir disertacije proširuje na domen u kojem tekstualni opisi, finansijski iznosi, organizacione veze i tematske oznake zajedno oblikuju osnovu za odlučivanje. Prosečna i medijalna finansijska vrednost u tabeli odnose se samo na projekte sa pozitivno evidentiranim EU doprinosom, čime se izbegava pogrešno tumačenje proseka kao prostog odnosa ukupnog iznosa i ukupnog broja identifikovanih zelenih projekata.

8.2.2 Klasifikacija projekata iz oblasti zelenih tehnologija

Jedan od najvažnijih budućih pravaca u ovom delu istraživanja jeste razvoj modela dubokog učenja za automatsku klasifikaciju projekata iz oblasti zelenih tehnologija na osnovu tekstualnih, tematskih i mrežnih obeležja. Osnovna ideja je da se projektni opis ne posmatra samo kao administrativni tekst, već kao semantički signal koji sadrži informacije o tehnologiji, cilju, području primene, uticaju i istraživačkom kontekstu. NLP modeli zasnovani na



Slika 8.3: Udeo projekata iz oblasti zelenih tehnologija u programu Horizon Europe na osnovu inicijalne analize.

Tabela 8.5: Sažetak inicijalne Horizon Europe analize zelenih tehnologija.

Pokazatelj	Vrednost	Tumačenje
Ukupan broj projekata	20.170	Polazni skup Horizon Europe projekata
Broj projekata iz oblasti zelenih tehnologija	8.814	Projekti identifikovani bar jednim kriterijumom filtriranja
Udeo projekata iz oblasti zelenih tehnologija	43.7%	Indikator značajne zastupljenosti zelenih tema
EU doprinos za zelene projekte	11.83 milijarde evra	Ukupna finansijska težina projekata sa evidentiranim EU doprinosom
Prosečan EU doprinos po finansiranom projektu	3.32 miliona evra	Srednja vrednost za projekte sa pozitivnim EU doprinosom
Medijana EU doprinosa po finansiranom projektu	2.00 miliona evra	Tipičniji iznos zbog asimetrične raspodele finansiranja
Prosečan broj učesnika	8.6	Indikator veličine konzorcijuma
Prosečan broj zemalja	4.6	Indikator međunarodne saradnje
Prosečan udeo MSP	15.4%	Učešće malih i srednjih preduzeća u konzorcijumima

dubokom učenju mogu izdvojiti složenije obrasce iz projektnih opisa, dok mrežna struktura konzorcijuma može pružiti dodatne informacije o tehnološkoj oblasti projekta. Na taj način moguće je prevazići ograničenja jednostavne pretrage ključnih reči, preciznije razlikovati podtipove zelenih tehnologija i dobiti pouzdaniju osnovu za mapiranje istraživačkih prioriteta i mreža saradnje.

Predložena arhitektura objedinjuje tri izvora informacija o projektu. Prvi izvor čine tekstualni opisi, koji se mogu predstaviti pomoću modela prilagođenih naučnom i tehničkom jeziku, kao što je SciBERT. Drugi izvor proizlazi iz mreže saradnje organizacija, u kojoj čvorovi predstavljaju institucije, a veze zajedničko učešće u projektima. Treći izvor čine strukturni metapodaci, među kojima su zemlja koordinatora, tip organizacije, trajanje projekta, šema finansiranja, broj učesnika i udeo malih i srednjih preduzeća. Spajanjem ovih reprezentacija formira se zajednički latentni prostor, na osnovu kog se može ispitati da li kombinovanje semantike teksta, mrežne pozicije i administrativnog konteksta daje stabilniju klasifikaciju od pojedinačnih izvora. Glavni zadatak može se formalno predstaviti kao klasifikacija sa više oznaka (*multi-label classification*). Za projekat p_i model predviđa vektor oznaka:

$$\hat{y}_i = [\hat{y}_{i1}, \hat{y}_{i2}, \dots, \hat{y}_{iK}], \quad (8.6)$$

gde je K broj podkategorija zelenih tehnologija, a svaka komponenta $\hat{y}_{ik}$ označava verovatnoću pripadnosti projekta kategoriji k . Za razliku od višeklasne klasifikacije, formulacija sa više oznaka pogodnija je jer jedan projekat može istovremeno pripadati, na primer, oblastima solarne energije, zelenih materijala i energetske efikasnosti. Izlazni signal nije jedna diskretna klasa, već vektor verovatnoća koji omogućava finije mapiranje tehnološkog profila projekta.

U inicijalnom istraživačkom okviru definisano je 12 podkategorija, uključujući: solar, wind, hydrogen, carbon, biodiversity, circular, energy_efficiency, transport, water, food_agri, climate_adapt i materials. Ove kategorije izvedene su kombinovanjem EuroSciVoc hijerarhijskih putanja, Horizon Europe klastera i semantički srodnih termina u opisima projekata. Njihova uloga je da pruže detaljniju analitičku strukturu od opšte oznake da projekat pripada oblasti održivosti.

Tabela 8.6 prikazuje predložene izvore obeležja i njihovu metodološku ulogu u klasifikaciji. Umesto oslanjanja samo na ključne reči ili postojeće oznake, predlaže se pristup koji povezuje značenje projektnog teksta, strukturu saradnje i administrativne karakteristike projekta. Time se održivi razvoj povezuje sa multimodalnim modelovanjem, interpretabilnošću i savremenim projektnim odlučivanjem.

Predložena struktura neuronske mreže prikazana je na slici 8.4. Tekstualni, mrežni i strukturni signali transformišu se u odgovarajuće reprezentacije, zatim se spajaju u fuzionom sloju i prosleđuju kroz skrivene slojeve. Sigmoid izlaz daje vektor verovatnoća $\hat{y}_i$, pri čemu svaka komponenta predstavlja procenu pripadnosti jednoj podkategoriji zelenih tehnologija. Na

taj način se ne predviđa samo da li je projekat povezan sa zelenim tehnologijama, već se dobija detaljniji profil oblasti kao što su obnovljiva energija, cirkularna ekonomija, održiva mobilnost, klimatske tehnologije, efikasno korišćenje resursa i digitalna rešenja za održivost.


Tabela 8.6: Predloženi tokovi obrade podataka za klasifikaciju projekata iz oblasti zelenih tehnologija.

Tok podataka	Primeri obeležja	Metodološka uloga
Tekstualni tok	Naslov, cilj projekta, opis, ključne reči, SciBERT vektorska reprezentacija	Prepoznavanje semantičkog sadržaja i tehnološke oblasti projekta
Mrežni tok	Degree, betweenness, PageRank, Louvain zajednice, GAT vektorska reprezentacija	Modelovanje pozicije organizacija i konzorcijuma u mreži saradnje
Strukturni tok	Zemlja koordinatora, tip organizacije, trajanje, šema finansiranja, broj partnera	Uvođenje administrativnog i organizacionog konteksta projekta
Fusion model	Spojeni vektor tekstualnih, mrežnih i strukturnih obeležja	Procena da li kombinovanje izvora daje stabilniju klasifikaciju

Važan deo ovog pravca jeste analiza doprinosa pojedinačnih izvora podataka. Ona bi omogućila da se uporede modeli koji koriste samo tekst, samo mrežu, samo strukturne podatke i puni fuzioni model. Takvo poređenje omogućilo bi da se doprinos svakog izvora empirijski proveriti, umesto da se prednost fuzije pretpostavi unapred. Dodatno, primena SHAP ili sličnih objašnjivih metoda omogućila bi tumačenje pojedinačne predikcije. Na primer, ako model projekat svrsta u podkategoriju *solar*, SHAP analiza bi mogla da pokaže da najveći pozitivan doprinos imaju termini kao što su *photovoltaic*, *solar cells*, *PV modules* i *renewable energy*, zatim pripadnost energetskom ili klimatskom klasteru, kao i mrežna pozicija koordinatora koji se često javlja u projektima iz oblasti obnovljive energije. Istovremeno, obeležja koja nisu povezana sa solarnom energijom, na primer termini iz oblasti zdravstva, hrane ili vodnih sistema, mogla bi imati slab ili negativan doprinos toj oznaci. Takvo objašnjenje ne bi služilo samo za proveru tačnosti predikcije, već i za razumevanje zbog čega je model projekat povezao sa oznakom zelenih tehnologija.

8.2.3 Istraživački portfolio i strateško mapiranje tema

Eksplorativna Horizon Europe analiza pokazuje da se istraživački projekti mogu koristiti za strateško mapiranje prioriteta zelenih tehnologija. U inicijalnoj obradi identifikovani su projekti sa veoma velikim EU doprinosom, kao što su EIT Urban Mobility Business Plan 2026–2028, Partnership for the Assessment of Risks from Chemicals, EIT RawMaterials Business Plan 2023–2025, The European Biodiversity Partnership, Open Fan for Environmental




Slika 8.4: Predložena arhitektura modela dubokog učenja za predikciju podkategorija zelenih tehnologija na osnovu tekstualnih, tematskih i mrežnih obeležja projekta.

Low Impact of Aviation, Water4All i drugi veliki projektni okviri. Takvi projekti ukazuju da održivost nije samo skup izolovanih tehnoloških tema, već portfoliojski prostor u kojem se susreću mobilnost, hemijska bezbednost, biodiverzitet, sirovine, zdravstvo, voda, agroekologija i energetska efikasnost. Na primer, veći iznosi finansiranja u oblastima urbane mobilnosti, hemijske bezbednosti, biodiverziteta i upravljanja vodama ukazuju na tematske oblasti koje Evropska unija prepoznaje kao strateški važne za zelenu tranziciju.

Geografska analiza koordinatora pokazuje da se najveći broj projekata iz oblasti zelenih tehnologija u posmatranom skupu vezuje za Španiju, Nemačku, Italiju, Francusku, Holandiju i Belgiju. U top 15 zemalja pojavljuju se i Ujedinjeno Kraljevstvo, Danska, Grčka, Norveška, Švedska, Finska, Portugal, Austrija i Irska. Ovakav rezultat ne treba tumačiti kao meru uspešnosti zemalja, nego kao indikator koncentracije koordinatorskih uloga u CORDIS preseku podataka. Za efikasniju komparativnu analizu rezultati se mogu normalizovati prema veličini istraživačkog sistema, ukupnom broju organizacija, stanovništvu ili nacionalnom ulaganju u istraživanje.

Slika 8.5 dodatno naglašava geografsku koncentraciju koordinatorskih uloga. Španija i Nemačka se izdvajaju kao vodeće zemlje po broju projekata iz oblasti zelenih tehnologija, dok Italija i Francuska čine sledeći nivo koncentracije. Ovaj rezultat je značajan za disertaciju jer pokazuje da podaci o održivosti ne otkrivaju samo tematske prioritete, već i institucionalnu i geografsku strukturu istraživačkog prostora. Drugim rečima, analitika zelenih tehnologija ne daje samo odgovor na pitanje šta se finansira, već i ko koordinira, gde se nalazi istraživački kapacitet i kako se formiraju potencijalni centri uticaja u evropskim projektima.



Slika 8.5: Top koordinatorske zemlje prema broju identifikovanih projekata iz oblasti zelenih tehnologija u inicijalnoj CORDIS/Horizon analizi.

Na nivou organizacija, najveći broj koordinatorskih uloga u projektima iz oblasti zelenih tehnologija vezuje se za evropske istraživačke i univerzitetske institucije. Među najzastupljenijima su CNRS, Agencia Estatal Consejo Superior de Investigaciones Científicas, Katholieke Universiteit Leuven, Technische Universiteit Delft, Politecnico di Milano, Københavns Universitet, Danmarks Tekniske Universitet, Aarhus Universitet, Universiteit Gent i Max-Planck-Gesellschaft. Ovaj nalaz ukazuje da su projekti iz oblasti zelenih tehnologija snažno povezani sa institucionalnim kapacitetom, mrežnom pozicijom i sposobnošću koordinacije velikih međunarodnih konzorcijuma.

Istovremeno, ovakav prikaz može imati i praktičnu vrednost za institucije iz Srbije, jer ukazuje na zemlje i organizacije koje imaju razvijeno iskustvo u koordinaciji projekata iz oblasti zelenih tehnologija. Takvi uvidi mogu pomoći pri prepoznavanju potencijalnih partnera, uspostavljanju prvih kontakata, razmeni iskustava, učenju iz primera dobre prakse i pripremi budućih projektnih prijava u oblastima održivog razvoja i zelenih tehnologija.

Za projektno odlučivanje posebno je važna mreža saradnje. Prosečan broj učesnika od 8.6 i prosečan broj zemalja od 4.6 pokazuju da projekti iz oblasti zelenih tehnologija u posmatranom skupu imaju izraženu međunarodnu dimenziju. Takva struktura otvara mogućnost analize centralnosti, posredničke uloge organizacija, povezivanja klastera i tematske raznovrsnosti konzorcijuma. U praktičnoj primeni, ovakva analitika može pomoći istraživačima, menadžerima projekata i institucijama da razumeju gde se nalaze u istraživačkoj mreži, koje teme su zasićene, gde postoje praznine i koji partneri mogu biti strateški važni.

Pored toga, ovakva analiza ima vrednost i za fazu pripreme novih projektnih predloga. Ako se poznaje struktura postojećeg portfolija, istraživački tim može proceniti da li se njegov predlog uklapa u dominantne prioritetne pravce, da li se oslanja na već zasićenu oblast ili otvara nišu koja je slabije pokrivena. Na nivou institucije, isti podaci mogu pomoći u identifikaciji potencijalnih partnera, proceni konkurentskog položaja i planiranju dugoročnog istraživačkog portfolija. Time Horizon Europe analiza prelazi iz deskriptivnog prikaza u instrument strateškog odlučivanja.

Tabela 8.7 pokazuje da Horizon Europe analiza ima i naučni i aplikativni doprinos. Naučno, ona omogućava ispitivanje kako se tekst, mreža i metapodaci mogu povezati u jedinstven model. Aplikativno, ona može podržati strateško planiranje istraživanja, pripremu projektnih predloga, izbor partnera i praćenje portfolija zelenih tehnologija.

8.3 Napomena o održivosti softverske implementacije

Održivi razvoj u digitalnom okruženju ne zavisi samo od toga koje podatke modeli analiziraju, već i od načina na koji su softverski sistemi projektovani, implementirani i korišćeni. Razvoj velikih modela, učestalo treniranje, nepotrebno složeni tokovi obrade, neoptimizovani resursi korisničkog interfejsa i prekomerni prenos podataka mogu povećati računarsku

Tabela 8.7: Primeri doprinosa Horizon Europe analitike projektnom odlučivanju.

Analički pravac	Šta se analizira	Doprinos odlučivanju
Tematsko mapiranje	Tekstualni opisi, EuroSciVoc oznake i Horizon klasteri	Identifikacija dominantnih i nedovoljno zastupljenih oblasti zelenih tehnologija
Finansijska analiza	EU doprinos, prosečno i medijalno finansiranje, raspodela po temama	Razumevanje finansijske težine pojedinih istraživačkih pravaca
Geografska analiza	Zemlje koordinatora i učesnika	Uvid u prostornu raspodelu istraživačkih kapaciteta
Mreža saradnje	Organizacije, konzorcijumi, centralnost i zajednice saradnje	Otkrivanje ključnih institucija, posrednika i potencijalnih partnera
Objašnjiva klasifikacija	SHAP vrednosti, tekstualni i mrežni doprinosi klasifikaciji	Tumačenje zašto je projekat povezan sa određenom kategorijom zelenih tehnologija

zahtevnost, potrošnju energije i digitalni karbonski otisak. Zbog toga se u disertaciji održivost softverske implementacije posmatra kao dopunski, ali važan sloj odgovorne analitike, jer se kvalitet sistema ne ogleda samo u tačnosti modela, već i u njegovoj efikasnosti, racionalnoj upotrebi resursa i proporcionalnosti u odnosu na zadatak koji rešava.

Istraživanja o emisijama povezanim sa računarskim procesima pokazuju da digitalni sistemi imaju materijalne posledice, čak i kada se korisniku čine nematerijalnim [96]. U domenu veb tehnologija, energetska efikasnost može se poboljšati optimizacijom koda, smanjenjem veličine fajlova, kompresijom resursa, uklanjanjem suvišnih skripti, optimizacijom slika i boljim upravljanjem zahtevima ka serveru [97]. Ove mere nisu dovoljne same po sebi da reše pitanje održivosti AI sistema, ali pokazuju da se odgovornost mora posmatrati kroz ceo softverski životni ciklus.

U okviru istraživanja o održivijem veb razvoju analizirana je veza između minifikacije CSS i JavaScript fajlova, fragmentacije resursa i smanjenja digitalnog opterećenja [98]. Analiza je sprovedena u Python okruženju, korišćenjem biblioteka `requests`, `BeautifulSoup` i `matplotlib`, dok su predmet provere bili HTML struktura stranice, CSS i JavaScript fajlovi, multimedijalni resursi i njihov uticaj na performanse i digitalno opterećenje. U analizi veb stranice identifikovana su 34 CSS i 35 JavaScript fajlova, odnosno ukupno 69 resursa sa potencijalom za minifikaciju i konsolidaciju. Procena je pokazala da bi smanjenje veličine fajlova za oko 40% moglo da redukuje prenos podataka za približno 2.08 MB po učitavanju stranice, što odgovara uštedi od oko 4.9 g CO₂ po jednom učitavanju. Kod sajta sa 10.000 mesečnih poseta, takva optimizacija bi mogla dati približno 593 kg CO₂ uštede godišnje. Ovaj rezultat je relevantan za disertaciju jer pokazuje da se održivost ne nalazi samo u do-

menu podataka ili modela, već i u konkretnim softverskim praksama koje utiču na prenos podataka, broj zahteva, brzinu učitavanja i potrošnju računarskih resursa.

Ova napomena je važna i za koncept green AI. Model sa neznatno boljim rezultatom, ali višestruko većim troškom treniranja, izvršavanja i održavanja, ne mora biti opravdan u svim domenima. Zbog toga se budući sistemi ne bi smeli vrednovati samo kroz tačnost, F1 meru ili grešku predikcije, već i kroz odnos performansi, objašnjivosti, računarske efikasnosti i praktične koristi. U tom smislu, održiva implementacija obuhvata i izbor modela, učestalost treniranja, veličinu podataka koji se prenose, optimizaciju korisničkog interfejsa i racionalno korišćenje serverskih resursa. Ovaj višekriterijumski pogled povezuje održivost softverske implementacije sa metodološkim principom odgovorne evaluacije modela.

8.4 Sinteza nalaza u oblasti održivog razvoja i projektnog odlučivanja

Poglavlje o održivom razvoju, projektnom odlučivanju i analitičkom izveštavanju proširuje istraživački okvir disertacije sa neposrednog korisničkog ponašanja na organizacione, istraživačke i strateške procese. Njegov doprinos ogleda se u tome što pokazuje da se prediktivni modeli mogu primeniti i u domenima u kojima odluke zavise od više povezanih indikatora, od tumačenja kompleksnih podataka i od odgovorne interpretacije rezultata.

Prvi nalaz poglavlja jeste da se održivost može predstaviti kroz merljive signale pogodne za modelovanje. U turizmu se oni odnose na potražnju, kapacitet, cenu, otkazivanja i pouzdanost rezervacija. U Horizon Europe analitici obuhvataju tematske oznake, EU doprinos, organizacione mreže i podkategorije zelenih tehnologija. U softverskoj implementaciji odnose se na veličinu resursa, efikasnost koda, broj zahteva, trajanje izvršavanja i potrošnju računarskih resursa, kao što su memorija, procesorsko vreme i energija. Na taj način održivost se ne posmatra samo kao opšti cilj, već kao skup indikatora koji mogu ući u modele, izveštaje i odluke.

Drugi nalaz odnosi se na evaluaciju automatski generisanih analitičkih narativa. Rezultati pokazuju da generativni modeli mogu imati vrednost u poslovnom i održivom izveštavanju samo ako su vezani za strukturisane ulazne indikatore i proveru izlaznog teksta. Kriterijumi kao što su pokrivenost indikatora, vernost trenda, jezička proporcionalnost i operativna relevantnost proširuju evaluaciju sa tačnosti predikcije na kvalitet objašnjenja i upotrebljivost narativa za odlučivanje.

Treći nalaz proizlazi iz analize javno dostupnih CORDIS/Horizon Europe podataka. Identifikacija 8.814 projekata iz oblasti zelenih tehnologija, njihov udeo od 43.7% u posmatranom skupu i EU doprinos od 11.83 milijarde evra pokazuju da se održivi razvoj može analizirati kao veliki skup istraživačkih i portfolijskih obrazaca. Time se disertacija povezuje sa istraživačkom analitikom, mapiranjem tehnoloških prioriteta, evropskim finansiranjem i prepoznavanjem organizacionih obrazaca u projektima.

Četvrti nalaz i metodološki doprinos poglavlja predstavlja predloženi model dubokog učenja za klasifikaciju projekata iz oblasti zelenih tehnologija. Model integriše tekstualne opise projekata, tematske oznake i mrežna obeležja konzorcijuma, a izlazni sloj daje vektor verovatnoća za više podkategorija zelenih tehnologija. Takva arhitektura omogućava da se projekat ne svrstava samo u jednu opštu oblast održivosti, već da se dobije detaljniji profil njegovog tehnološkog usmerenja. Time se poglavlje direktno povezuje sa osnovnom temom disertacije, jer pokazuje kako duboko učenje podržava klasifikaciju, interpretaciju i projektno odlučivanje.

Peti nalaz odnosi se na održivost same softverske implementacije. Rezultati ranijeg istraživanja o minifikaciji CSS i JavaScript fajlova pokazuju da tehničke odluke, kao što su smanjenje veličine resursa, konsolidacija fajlova i optimizacija prenosa podataka, mogu imati merljiv uticaj na performanse i digitalni karbonski otisak. Ovaj deo poglavlja naglašava da odgovorna analitika ne obuhvata samo ono što modeli predviđaju, već i način na koji se sistemi treniraju, izvršavaju, održavaju i koriste.

U odnosu na hipoteze disertacije, ovo poglavlje posebno podržava H3 i H5. H3 se podržava kroz pokazivanje da kvalitet, potpunost i pouzdanost ulaznih signala utiču na vrednost analitičkih rezultata, bilo da je reč o indikatorima održivog turizma, generisanim narativima, projektnim opisima ili klasifikaciji zelenih tehnologija. Ako su indikatori nepotpuni, projektni opisi neujednačeni ili generisani narativi nedovoljno proverljivi, i rezultat modela može biti manje pouzdan za odlučivanje. H5 se podržava kroz potrebu za višekriterijumskim izborom modela i analitičkih postupaka, jer održivo odlučivanje zahteva ravnotežu između tačnosti, objašnjivosti, računarske efikasnosti, domenske relevantnosti i praktične koristi. Predloženi model dubokog učenja i napomena o održivoj implementaciji dodatno pokazuju da se kvalitet modela ne može procenjivati izolovano od njegove potrošnje računarskih resursa, upotrebljivosti i odgovornosti.

Zaključno, ovo poglavlje pokazuje da se modeli razvijeni u disertaciji mogu koristiti i izvan neposredne predikcije ponašanja. Njihova vrednost ogleda se u mapiranju istraživačkih prioriteta, praćenju portfolija, evaluaciji indikatora, objašnjavanju rezultata i razvoju odgovornijih digitalnih sistema. Time se održivi razvoj, projektno odlučivanje i analitičko izveštavanje povezuju u jedinstven metodološki okvir zasnovan na podacima, modelima, interpretabilnosti i odgovornoj primeni.

Naredno poglavlje prelazi na oblast obrazovanja i studentskih ishoda u eri generativnih modela. U njemu se istraživački okvir primenjuje na analizu studentskih radova, prepoznavanje promena u obrascima učenja, procenu prekomernog oslanjanja na generativne alate i podršku nastavničkom odlučivanju.

9. OBRAZOVANJE U ERI GENERATIVNIH MODELA

9.1 Generativni modeli u visokoškolskom obrazovanju

Generativni modeli predstavljaju jedan od najznačajnijih faktora promene u savremenom visokoškolskom obrazovanju, u programiranju, softverskom inženjerstvu, analizi podataka i izradi istraživačkih zadataka. Za razliku od ranijih digitalnih alata, koji su uglavnom služili za pretragu informacija, proveru pravopisa, komunikaciju ili organizaciju nastavnih materijala, savremeni veliki jezički modeli mogu generisati programski kod, objašnjenja, pseudokod, komentare, test primere, sažetke, argumentaciju, bibliografske navode i refleksivne tekstove. Zbog toga oni ne utiču samo na brzinu izrade studentskih zadataka, već menjaju strukturu studentskog rada, obrasce traženja pomoći, način razumevanja grešaka i uslove procene akademskog postignuća. Upravo zato obrazovni domen postaje pogodan za proveru prediktivnih i interpretabilnih modela, jer se promene u učenju mogu posmatrati kroz konkretne digitalne tragove, a ne samo kroz konačne ocene ili subjektivne nastavničke procene.

Obrazovni domen predstavlja prostor u kojem se ponašanje studenata analizira kroz digitalne tragove nastale tokom učenja, rešavanja zadataka, izrade koda, pripreme projekata i korišćenja generativnih alata. Poseban značaj ovog domena ogleda se u tome što generativni modeli ne predstavljaju samo spoljašnji tehnološki faktor, već menjaju način na koji studenti traže objašnjenja, oblikuju rešenja, proveravaju kod i razumeju nastavne zahteve. Osnovno pitanje zato nije da li su generativni modeli korisni ili štetni, već kako njihova upotreba menja obrasce studentskog rada i kako se ti obrasci mogu odgovorno analizirati u realnom obrazovnom kontekstu. Savremena istraživanja ukazuju da generativni modeli mogu doprineti personalizovanom objašnjavanju, vežbanju i motivaciji, ali istovremeno otvaraju pitanja akademskog integriteta, površnog učenja, validnosti ocenjivanja i potrebe za novim nastavnim strategijama [99, 100]. Zbog toga se modeli u ovom poglavlju posmatraju kao podrška nastavniku u razumevanju obrazaca rada i potreba za dodatnim objašnjenjem, a ne kao mehanizam za automatsko sankcionisanje ili etiketiranje studenata. Generativni model u obrazovnom kontekstu može se posmatrati kao posredni faktor između nastavnog zadatka, studenta i konačnog rada. Ako je A_i akademski zadatak, S_i student, G_i generativni alat, C_i nastavni i institucionalni kontekst, a R_i predati rad, tada se nastanak studentskog rada može predstaviti kao:

$$R_i = f(A_i, S_i, G_i, C_i). \quad (9.1)$$

U tradicionalnom okruženju komponenta Gi je odsutna ili ima ograničenu ulogu, dok u eri generativnih modela ona može uticati na stil pisanja, strukturu koda, nivo objašnjenja, prisustvo šablonskih izraza, kvalitet komentara i odnos između razumevanja i konačnog proizvoda. Upravo zato se studentski rad ne može tumačiti samo kao ishod individualnog znanja, već kao rezultat interakcije između zadatka, studenta, dostupnih alata i nastavnog dizajna.

U nastavi programiranja i informatičkih predmeta ove promene su posebno vidljive, jer studenti mogu koristiti generativne modele za generisanje rešenja, objašnjavanje sintakse, otkrivanje grešaka, pisanje komentara, refaktorisanje koda, izradu izveštaja i pripremu usmenih ili pisanih odgovora [101]. U tom kontekstu, istraživački pravac zasnovan na primeni NLP-a i pedagoške analitike u analizi studentskih radova predstavlja važnu empirijsku osnovu ovog poglavlja [102]. Da bi se obrazovni domen jasnije povezao sa širim istraživačkim okvirom disertacije, u tabeli 9.1 prikazani su ključni analitički pravci, tipovi digitalnih tragova i njihov doprinos modelovanju studentskog ponašanja u eri generativnih alata.

Tabela 9.1: Analitički pravci u obrazovnom domenu i njihov doprinos disertaciji.

Pravac analize	Tip digitalnog traga	Doprinos disertaciji
Studentski kod i zadaci	Kod, komentari, metapodaci rada, sličnost rešenja	Modelovanje promene studentskog ponašanja u eri generativnih alata
Procena prekomernog oslanjanja na AI	Semantička sličnost, šablonski obrasci, anomalije u radovima	Razvoj signala rizika koji ne služe automatskom kažnjavanju, već nastavničkoj proverbi
Analiza programerskih grešaka	Opisi grešaka, uzročno-posledične veze, neispravni testovi	Korišćenje LLM-a za strukturisanje povratne informacije i pedagoško objašnjenje
Anonimizovana prolaznost	Predmet, program, izlaznost, prolaznost, prosečna ocena	Povezivanje mikronivoa studentskog rada sa institucionalnim ishodima
Pouzdanost izvora u studentskim radovima	Bibliografski navodi, DOI, URL, metapodaci, usklađenost citata	Planirani pravac za detekciju bibliografskih halucinacija i procenu pouzdanosti akademskog pisanja

Obrazovni domen pokazuje kako generativni modeli oblikuju studentsko ponašanje, nastavničke intervencije i kriterijume evaluacije. Dok se u hotelijerstvu analiziraju recenzije, u transportu sekvence i tržišni obrasci, u trgovini potrošačke preference, a u poslovnoj komunikaciji društveno osetljivi tekstovi, ovde se analiziraju tragovi učenja i akademskog rada.

9.2 Promena ponašanja studenata u nastavi programiranja

U nastavi programiranja generativni modeli menjaju prirodu studentskog rada na nekoliko nivoa. Prvi nivo odnosi se na tehničku izradu zadatka: studenti mogu brže dobiti sintaksno ispravan kod, predloge za funkcije, objašnjenja biblioteka i primere upotrebe. Drugi nivo odnosi se na semantičko razumevanje: student može dobiti objašnjenje greške, ali to ne znači da je razumeo zašto je određeno rešenje ispravno. Treći nivo odnosi se na stil i strukturu rada: AI-generisani kod često sadrži uredne komentare, generičke nazive promenljivih, opšta objašnjenja i obrasce koji mogu delovati formalno kvalitetnije od rada koji je student samostalno pisao. Četvrti nivo odnosi se na akademsku procenu: nastavnik više ne procenjuje samo konačni kod, već i proces razumevanja, obrazloženje, sposobnost izmene i odbrane rešenja.

U autorskom istraživanju sprovedenom u nastavi programiranja i informatičkih predmeta analizirani su podaci iz tri predmeta: Osnovi programiranja, Softversko inženjerstvo i Analiza velikih podataka. Posmatrani su C, Java i Python zadaci, pri čemu su zadaci obuhvatali direktne vežbe iz nastavnih tema i realistične scenarije, kao što su sistemi za upravljanje bibliotekama, e-commerce hijerarhije, sistemi zakazivanja, analiza hotelskih i Twitter podataka i izrada analitičke kontrolne table. Ukupno je tokom dve akademske godine prikupljeno skoro 4.500 studentskih radova, od studenata prve i treće godine osnovnih strukovnih studija i druge godine master strukovnih studija. Struktura korpusa po predmetu, programskom jeziku i broju zapisa nakon pripreme podataka prikazana je u tabeli 9.2.

Tabela 9.2: Pregled korpusa studentskih radova u autorskom istraživanju.

Predmet	Jezik	Početni broj zapisa	Broj zapisa nakon pripreme
Osnovi programiranja	C	2.323	2.103
Softversko inženjerstvo	Java	1.413	1.297
Analiza velikih podataka	Python	697	652
Ukupno	–	4.433	4.052

Ova analiza pokazuje da generativni modeli ne stvaraju samo pitanje akademskog integriteta, već i novu vrstu obrazovnog signala. Sličnost među radovima, iznenadne promene stila, neuobičajeno dugi komentari, šablonska objašnjenja, nagla poboljšanja u strukturi koda i nesklad između kvaliteta koda i sposobnosti usmenog obrazloženja mogu ukazivati na promene u načinu rada. Međutim, nijedan od ovih signala ne sme se tumačiti kao direktan dokaz nedozvoljene upotrebe AI alata. Njihova naučna i pedagoška vrednost nalazi se u tome što nastavniku ukazuju gde je potrebna dodatna provera, razgovor, usmena odbrana ili prilagođena povratna informacija. Promena ponašanja studenata može se opisati kroz skup

indikatora:

$$B_i = (Sim_i, Style_i, Time_i, Comm_i, Err_i, Expl_i), \quad (9.2)$$

gde Sim_i označava semantičku ili strukturnu sličnost rada sa drugim radovima i poznatim šablonima, $Style_i$ stilske karakteristike koda i objašnjenja, $Time_i$ vremenske karakteristike predaje rada, $Comm_i$ prisustvo i kvalitet komentara, Err_i tipove grešaka, a $Expl_i$ kvalitet studentskog obrazloženja. Ovakav vektor omogućava da se studentski rad analizira kao obrazovna instanca koja uključuje kod, tekst, metapodatke i nastavnički kontekst.

9.3 Analiza i procena studentskih radova pomoću NLP i mašinskog učenja

Analiza studentskih radova u eri generativnih modela zahteva multimodalni pristup, jer konačan rad nije samo programski kod, niti samo tekstualno objašnjenje. Ona obuhvata sintaksu, semantiku, stil, komentare, strukturu rešenja, metapodatke rada, eventualne refleksivne beleške i odnos prema nastavnom zadatku. Zbog toga je u autorskom istraživanju primenjen hibridni okvir koji kombinuje CodeBERT reprezentacije, TF-IDF vektore, XGBoost klasifikaciju, DBSCAN klasterovanje i sentiment analizu.

Tekstualna obeležja obuhvataju komentare u kodu, objašnjenja rešenja, opise algoritama i refleksivne beleške. Ona se mogu predstaviti TF-IDF vektorima:

$$x_{ij} = tf_{ij} \cdot \log \frac{N}{df_j}, \quad (9.3)$$

gde tf_{ij} označava učestalost termina j u radu i , df_j broj radova u kojima se termin javlja, a N ukupan broj radova. TF-IDF omogućava poređenje leksičkih obrazaca, ali ne zahvata dovoljno duboko semantičku sličnost programskog koda. Zbog toga su korišćene i reprezentacije zasnovane na CodeBERT modelu, koje omogućavaju zajedničko predstavljanje koda i prirodnog jezika. Ako je c_i programski kod, a t_i njegovo tekstualno objašnjenje, tada se kombinovana reprezentacija može zapisati kao:

$$z_i = [CodeBERT(c_i); TextEmb(t_i); m_i], \quad (9.4)$$

gde m_i označava metapodatke o predaji rada, kao što su vreme predaje, dužina koda, broj predatih radova, broj komentara ili interval između zadataka. Pre spajanja vektora, pojedinačne reprezentacije mogu se normalizovati ili projektovati u prostor uporedive dimenzionalnosti, kako nijedan modalitet ne bi dominirao zajedničkom reprezentacijom. Vektor z_i predstavlja objedinjenu reprezentaciju predatih studentskih radova u zajedničkom prostoru obeležja, u kojem se kodna semantika, tekstualno objašnjenje i ponašajni metapodaci povezuju radi učenja obrazaca sličnosti, odstupanja i mogućeg oslanjanja na generativne alate.

9.3.1 Nadgledana klasifikacija i interpretabilnost

U okviru nadgledanog učenja korišćen je XGBoost, jer omogućava rad sa heterogenim obeležjima i interpretaciju rezultata preko važnosti karakteristika. Model je primenjen na klasifikaciju studentskih radova i prepoznavanje obrazaca koji mogu zahtevati nastavničku proveru. Nakon optimizacije hiperparametara i integracije semantičkih, leksičkih i obeležja metapodataka, prosečna tačnost iznosila je 91.4%, uz preciznost od 0.900, odziv od 0.895 i F1 meru od 0.897. Pregled rezultata po predmetima prikazan je u tabeli 9.3, pri čemu se vidi da su kraći Java zadaci ostvarili najviše rezultate, dok su deskriptivni Python zadaci imali nešto niže performanse zbog veće raznolikosti mogućih rešenja.

Tabela 9.3: Rezultati hibridnog modela za analizu predatih studentskih radova.


Predmet	Tačnost	Preciznost	Odziv	F1 mera
Osnovi programiranja (C)	92.5%	0.910	0.900	0.906
Softversko inženjerstvo (Java)	93.1%	0.920	0.921	0.921
Analiza velikih podataka (Python)	88.3%	0.870	0.861	0.865
Prosek	91.4%	0.900	0.895	0.897

Ove rezultate ne treba tumačiti kao dokaz da sistem može nepogrešivo razlikovati samostalan rad od rada uz AI asistenciju. Njihova uloga je da formiraju analitički sloj koji nastavniku pomaže da uoči obrasce, proveru razumevanje i prilagodi povratnu informaciju.

9.3.2 Klasterovanje i anomalije u studentskim radovima

Pored nadgledanog modela, korišćen je i DBSCAN za identifikaciju grupa i anomalija u studentskim radovima. Ovaj pristup je pogodan jer ne zahteva unapred zadat broj klastera i može izdvojiti tačke niske gustine kao anomalije. U obrazovnom kontekstu odstupanja često ne formiraju jasne klase, već se pojavljuju kao pojedinačni slučajevi ili manje grupe.

U analiziranom korpusu izdvojene su tri glavne grupe. Prvu grupu čine studenti sa konzistentnim stilom implementacije, radovima očekivane dužine i relativno stabilnim obrascem rada. Drugu grupu čine studenti sa nepravilnijim angažovanjem, npr. naglim promenama u dužini koda, brzim završavanjem složenih zadataka ili neujednačenim intervalima predaje. Treću grupu čine radovi koji imaju neuobičajeno visok nivo formalne uređenosti u ranoj fazi semestra, što može ukazivati na intenzivniju upotrebu spoljne pomoći ili generativnih alata. Približno 12% radova označeno je kao anomalno, dok je koeficijent siluete (*silhouette score*) od 0.67 ukazao na relativno dobro razdvajanje klastera, odnosno na to da su radovi unutar istih grupa međusobno sličniji nego radovi iz različitih grupa. Vizuelna projekcija izdvojenih grupa i anomalnih instanci prikazana je na slici 9.1.



Slika 9.1: Vizuelizacija klastera predatih studentskih radova i anomalnih instanci u prostoru semantičko-leksičkih i ponašajno-vremenskih obeležja.

Studentski radovi, nakon projekcije u prostor semantičko-leksičkih i ponašajno-vremenskih obeležja, ne raspoređuju se nasumično, već formiraju prepoznatljive grupe. Stabilni klasteri ukazuju na ujednačene obrasce rada, dok izdvojene tačke predstavljaju radove čije se karakteristike razlikuju od dominantnih obrazaca u korpusu. Takva odstupanja mogu biti posledica različitog ritma rada, neujednačene strukture koda, nagle promene stila, povećane formalne uređenosti ili mogućeg oslanjanja na spoljne alate. Zbog toga se anomalija uvodi kao binarna oznaka koja pokazuje da li studentski rad odstupa od stabilnih klastera:

$$Anom_i = \begin{cases} 1, & \text{ako je rad označen kao anomalija,} \\ 0, & \text{ako rad pripada stabilnom klasteru.} \end{cases} \quad (9.5)$$

U pedagoškom smislu, anomalija ne znači automatsku nepravilnost. Ona označava obrazac koji odstupa od uobičajenog toka i koji može zahtevati objašnjenje, proveru ili razgovor sa studentom. Analitički signal samo ukazuje na potrebu za pažljivim tumačenjem, dok konačna nastavna odluka zavisi od konteksta zadatka, prethodnog rada studenta i procene nastavnika. Ako je rad označen kao anomalija, preporučljivo je sprovesti dodatnu ručnu proveru, uporediti ga sa prethodnim predatim radovima tog studenta i po potrebi obaviti razgovor ili usmenu proveru razumevanja rešenja.

9.3.3 Detekcija prekomernog oslanjanja na generativne alate

Jedna od najosetljivijih tema u obrazovanju jeste procena prekomernog oslanjanja studenata na generativne alate. Problem se ne sme postaviti kao jednostavno pitanje da li je student koristio AI, jer takav pristup nije ni metodološki pouzdan ni pedagoški poželjan. U savremenom obrazovanju nije realno očekivati potpunu odsutnost generativnih alata. Mnogo je važnije razlikovati konstruktivnu upotrebu, u kojoj student koristi alat za objašnjenje, proveru i učenje, od nekritičke upotrebe, u kojoj se gotov izlaz preuzima bez razumevanja. Zbog toga se u disertaciji uvodi pojam rizika prekomernog oslanjanja, koji se može predstaviti kao:

$$Risk_i = \alpha Sim_i + \beta Pattern_i + \gamma Time_i + \delta ExplGap_i, \quad (9.6)$$

gde Sim_i označava sličnost sa drugim radovima ili generisanim šablonima, $Pattern_i$ prisustvo stilskih obrazaca tipičnih za generativni izlaz, $Time_i$ vremenske karakteristike predaje rada, a $ExplGap_i$ nesklad između kvaliteta predatog rešenja i sposobnosti studenta da ga objasni. Težinski koeficijenti α , β , γ i δ zavise od nastavnog konteksta i ne treba ih tumačiti kao univerzalne vrednosti. Primeri takvih signala i njihovo moguće pedagoško tumačenje prikazani su u tabeli 9.4.

Tabela 9.4: Primeri signala za procenu rizika prekomernog oslanjanja na generativne alate.

Signal	Moguće značenje	Pedagoška interpretacija
Visoka semantička sličnost više radova	Korišćenje istog šablona, tutorijala ili generativnog izlaza	Potrebna dodatna provera razumevanja
Iznenadna promena stila koda	Promena izvora pomoći ili načina izrade zadatka	Indikator za razgovor, ne automatski dokaz
Dugi komentari bez odgovarajućeg razumevanja	Formalno objašnjenje generisano van nastave i konsultacija	Potrebna usmena odbrana ili dodatni zadatak
Brza izrada kompleksnog zadatka	Moguća upotreba gotovog rešenja ili alata veštačke inteligencije	Provera procesa izrade i sposobnosti modifikacije
Kvalitetan kod uz slabo objašnjenje	Nesklad između proizvoda i znanja	Fokus na konceptualnu proveru

Ključna vrednost ovog pristupa jeste razdvajanje procene rizika od etiketiranja studenata. Model ne donosi zaključak o akademskom integritetu, već nastavniku predlaže prioritet za proveru, dok se konačno tumačenje zasniva na kontekstu zadatka, prethodnom radu i mogućnosti legitimne upotrebe alata. Pedagoški cilj je da se AI koristi kao podrška učenju, a ne kao zamena za razumevanje.

9.4 LLM pristupi i obrazovna prediktivna analitika

9.4.1 LLM pristupi u analizi grešaka i edukativnih sadržaja

Veliki jezički modeli mogu imati korisnu ulogu u analizi programerskih grešaka, pod uslovom da se ne koriste za zamenu nastavnika ili generisanje gotovih rešenja bez provere. U obrazovnom kontekstu njihova vrednost posebno dolazi do izražaja kada pomažu u strukturisanju greške, formiranju povratne informacije i objašnjavanju uzroka. Time se LLM pomera iz uloge generatora rešenja ka ulozi asistenta za pedagošku dijagnostiku. Ako je e_i greška u studentskom radu, ona se može predstaviti kroz tip greške, deo koda, neuspešan test, konceptualni uzrok i preporučenu intervenciju:

$$e_i = (Type_i, Code_i, Test_i, Cause_i, Feedback_i). \quad (9.7)$$

U ovom okviru, LLM može pomoći da se greška kategorizuje, ali nastavnik mora proveriti da li je objašnjenje tačno i pedagoški primereno. Treba izbegavati situaciju u kojoj model generiše uverljivo, ali netačno objašnjenje. Zbog toga se LLM analiza grešaka mora kombinovati sa test primerima, proverom izlaza, nastavničkom ekspertizom i transparentnim ograničenjem odgovornosti.

Kategorizacija programerskih grešaka može obuhvatiti sintaksne greške, logičke greške, pogrešno korišćenje struktura podataka, neadekvatno rukovanje graničnim slučajevima, pogrešnu modularizaciju, nedostatak testiranja i nerazumevanje algoritamskog koncepta. Za svaku od ovih kategorija može se formirati drugačija pedagoška intervencija: dodatni primer, kratko objašnjenje, usmeni razgovor, dopunski zadatak ili zajedničko ispravljanje koda. Time se analiza grešaka ne koristi samo za identifikovanje problema u predaji, već i za oblikovanje nastavne podrške koja odgovara tipu greške i nivou razumevanja studenta.

Doprinos ove sekcije nalazi se u tome što obrazovna analitika ne ostaje na nivou predikcije uspeha ili detekcije anomalija, već prelazi ka objašnjenju. Za nastavnika je često važnije da razume zašto student greši nego samo da predvidi da će grešiti. Zato se interpretabilnost u obrazovnom domenu direktno povezuje sa kvalitetom povratne informacije.

9.4.2 Analiza uspeha studenata na osnovu anonimizovanih podataka

Pored analize pojedinačnih zadataka, obrazovni domen omogućava i institucionalnu analizu ishoda. Anonimizovani podaci studentske službe mogu sadržati informacije o predmetima, studijskim programima, broju upisanih, izlaznosti, prolaznosti, broju prijavljenih, broju položenih i prosečnim ocenama. U ovoj disertaciji takvi podaci se tretiraju kao dopunski empirijski pravac, metodološki važan jer povezuje ponašanje u nastavnom procesu sa zbirnim ishodima. Time se obrazovna analitika proširuje sa nivoa pojedinačne studentske radove na nivo predmeta, programa i institucionalnog odlučivanja.

Za zimski semestar analizirana su dva skupa kolokvijumskih podataka sa po 33 predmetno-programska zapisa, za prvi i drugi kolokvijum. Takvi zapisi povezuju određeni predmet sa konkretnim studijskim programom i sadrže zbirne pokazatelje, kao što su broj studenata, izlaznost, prolaznost ili prosečna ocena. Za januarski ispitni rok analizirano je ukupno 125 zapisa po studijskim programima: ITS, KOT, RKTS i SRT. Ovi podaci ne sadrže identitet pojedinačnih studenata i koriste se isključivo za identifikaciju obrazaca na nivou predmeta, programa i ispitnog roka. Struktura korišćenih izvora podataka i njihova analitička uloga u proceni prolaznosti prikazani su u tabeli 9.5.

Tabela 9.5: Primeri agregiranih izvora za analizu prolaznosti.

Izvor podataka	Obuhvat	Analitička uloga
Kolokvijumi u zimskom semestru	Dva skupa od po 33 predmetna zapisa	Poređenje izlaznosti i prolaznosti između prvog i drugog kolokvijuma
Januarski ispitni rok	125 zapisa kroz ITS, KOT, RKTS i SRT	Analiza prijava, položenih ispita, prosečne ocene i rizičnih predmeta
Programski segmenti	ITS, KOT, RKTS, SRT	Segmentna analiza obrazaca uspeha i identifikacija potreba za podrškom
Predmetni nivo	Naziv predmeta, broj slušalaca, prijavljenih, položenih i prosečna ocena	Pedagoško planiranje, praćenje opterećenja i interpretacija prolaznosti

Za svaki predmet mogu se izračunati izlaznost i prolaznost:

$$\text{Izlaznost}_j = \frac{\text{Prijavljeni}_j}{\text{Sluali}_j} \cdot 100, \quad (9.8)$$


$$\text{Prolaznost}_j = \frac{\text{Poloili}_j}{\text{Prijavljeni}_j} \cdot 100. \quad (9.9)$$

Na ovih pokazatelja formira se eksplorativni indikator rizika na nivou predmeta. Ideja indikatora nije da rangira kvalitet nastave ili nastavnika, već da izdvoji predmete kod kojih se istovremeno javljaju niža prolaznost, slabiji prosečan rezultat i potreba za dodatnim tumačenjem obrazaca studentskog uspeha. Jednostavan oblik indikatora može se zapisati kao:

$$\text{RiskScore}_j = 0.6 \cdot (100 - \text{Prolaznost}_j) + 0.4 \cdot (8 - \overline{\text{Ocena}_j}), \quad (9.10)$$

pri čemu se veća težina daje niskoj prolaznosti, dok prosečna ocena služi kao dodatni signal o nivou uspeha. Ovaj indikator nije normativna mera kvaliteta predmeta ili nastavnika, već pokazatelj koji može pomoći u identifikaciji predmeta gde je potrebno dublje sagledati uslove rada, težinu gradiva, strukturu zadataka, izlaznost, termin ispita i pripremljenost studenata.

Kao ilustracija primene ovakvog pristupa, prolaznost se može prikazati po predmetima i studijskim programima u okviru januarskog ispitnog roka. Toplotna mapa na slici 9.2 omogućava da se uoče predmeti sa visokom prolaznošću, ali i zone u kojima se pojavljuju izrazito niski procenti položenih studenata. Posebno su vidljivi primeri u kojima se prolaznost kreće od 0% do 10%, što predstavlja signal za dodatno tumačenje ispitne aktivnosti, strukture zadataka i prethodne pripremljenosti studenata.



Slika 9.2: Mapa prolaznosti po predmetima i studijskim programima u januarskom ispitnom roku na Akademiji tehničko-vaspitačkih strukovnih studija u Nišu.

U ovoj analizi posebno je važno razdvojiti nisku izlaznost od niske prolaznosti. Predmet može imati visoku prolaznost među malim brojem prijavljenih studenata, što ne mora značiti da je ukupan obrazovni rizik mali. Suprotno tome, predmet sa velikom izlaznošću i srednjom prolaznošću može ukazivati na drugačiji tip pedagoškog izazova. Zbog toga se mogu razlikovati osnovni tipovi odnosa između izlaznosti i prolaznosti, prikazani u tabeli 9.6.

Doprinos ove sekcije ogleda se u povezivanju mikronivoa studentskih radova sa makronivoom institucionalnih ishoda. Dok se ranije sekcije bave konkretnim radovima, kodom i greškama, ovde se uvode prolaznost, izlaznost, rizični obrasci i mogućnost rane podrške. Time se obrazovna analitika približava organizacionoj analitici, uz obaveznu zaštitu studenata.

Tabela 9.6: Značenje različitih obrazaca izlaznosti i prolaznosti.

Obrazac	Moguće značenje	Pedagoška reakcija
Visoka izlaznost i niska prolaznost	Studenti izlaze, ali teško savladavaju ishod učenja	Analiza zadataka, dodatne vežbe, provera usklađenosti ishoda i evaluacije
Niska izlaznost i visoka prolaznost	Ispit polažu samo spremniji studenti	Rad na motivaciji, pripremnim terminima i ranijim signalima rizika
Niska izlaznost i niska prolaznost	Kombinovani rizik slabog angažovanja i slabog uspeha	Potrebna rana intervencija i segmentna analiza po grupama
Visoka izlaznost i visoka prolaznost	Stabilan obrazovni ishod	Praćenje kontinuiteta i identifikacija dobrih praksi

9.5 Pouzdanost, etika i pedagoške implikacije

9.5.1 Bibliografske halucinacije i pouzdanost izvora

Pored programerskih zadataka, generativni modeli sve više utiču i na izradu seminarskih, istraživačkih i projektnih radova. Poseban problem predstavljaju bibliografske halucinacije, odnosno nepostojeće, nepotpune ili pogrešno kombinovane reference koje deluju formalno uverljivo, ali se ne mogu potvrditi kroz DOI, izdavača, časopis, konferenciju ili stvarni URL [103]. Ovaj problem je naročito važan u studentskim radovima, jer studenti često ne razlikuju stilistički uverljiv navod od stvarno proverljivog izvora. U okviru daljeg istraživačkog pravca predviđa se analiza studentskih radova iz predmeta Analiza velikih podataka, Softversko inženjerstvo, Elektronsko poslovanje i Poslovna softverska OS rešenja. Korpus bi mogao obuhvatiti do približno 200 radova i omogućiti razvoj interpretabilnog modela za procenu pouzdanosti izvora. Cilj modela nije da automatski zaključi da li je student koristio generativni alat, već da proceni bibliografsku pouzdanost rada i identifikuje obrasce neverifikovanih, pogrešno formatiranih ili sadržajno neusaglašenih referenci. Pouzdanost jedne reference može se formalno posmatrati kroz više komponenti:

$$RefScore_r = w_1 V_r + w_2 M_r + w_3 S_r + w_4 C_r, \quad (9.11)$$

gde V_r označava proverljivost izvora, M_r usklađenost metapodataka, S_r akademski kvalitet izvora, a C_r kontekstualnu usklađenost reference sa tvrdnjom uz koju se citira. Sve komponente normalizuju se na interval $[0, 1]$, dok težine w_1 , w_2 , w_3 i w_4 treba da budu nenegativne i podešene tako da važi $\sum_{k=1}^4 w_k = 1$. Komponente obuhvataju proveru DOI-ja, postojanje časopisa ili konferencije, usklađenost autora i godine, dostupnost URL-a, poklapanje naslova i stvarnog izvora, kao i semantičku vezu između citiranog rada i tvrdnje koju podržava.

Na nivou celog studentskog rada pojedinačni skorovi referenci mogu se agregirati u zbirni pokazatelj bibliografske pouzdanosti:

$$BiblioScore_i = \frac{1}{|R_i|} \sum_{r \in R_i} RefScore_r, \quad (9.12)$$

gde R_i označava skup referenci u studentskom radu i , pri čemu se izraz primenjuje kada rad sadrži najmanje jednu referencu. Radovi bez bibliografskih navoda predstavljaju poseban slučaj i mogu se tretirati kao nedovoljno dokumentovani, a ne kao radovi sa numerički izračunatim skorom. Pragovi za tumačenje skora mogu se odrediti u odnosu na tip zadatka, broj očekivanih izvora i nivo studija, kako bi se izbeglo mehaničko poređenje radova različite namene i obima. Na ovaj način moguće je razlikovati radove u kojima se javlja samo manji broj spornih navoda od radova u kojima je bibliografska nepouzdanost sistemska. Kao ilustracija primene ove metrike može se posmatrati studentski rad u kojem je deo referenci moguće potvrditi kroz DOI, URL ili bibliografske baze, dok se kod dela izvora javljaju neusaglašeni metapodaci ili slaba povezanost sa tvrdnjama u tekstu. Ako su za taj rad procenjene prosečne vrednosti komponenti $V = 0.75$, $M = 0.80$, $S = 0.65$ i $C = 0.70$, a težine postavljene ilustrativno na $w_1 = 0.35$, $w_2 = 0.20$, $w_3 = 0.25$ i $w_4 = 0.20$, skor bibliografske pouzdanosti može se izračunati kao:

$$\begin{aligned} BiblioScore &= 0.35 \cdot V + 0.20 \cdot M + 0.25 \cdot S + 0.20 \cdot C \\ &= 0.35 \cdot 0.75 + 0.20 \cdot 0.80 + 0.25 \cdot 0.65 + 0.20 \cdot 0.70 \\ &= 0.725. \end{aligned} \quad (9.13)$$

Dobijena vrednost ne predstavlja automatsku ocenu kvaliteta rada, već signal da bibliografski deo treba dodatno proveriti. Na skali od 0 do 1, vrednost 0.725 ukazuje na umerenu pouzdanost, dok bi niži skor upućivao na veći rizik, a viši na stabilniju bibliografsku osnovu. U ovom primeru rad ne bi bio označen kao potpuno nepouzdan, ali bi niža vrednost komponente S ukazala na potrebu da se proverí akademski kvalitet i relevantnost izvora, dok bi niža vrednost komponente C ukazivala na slabiju vezu između citiranog izvora i tvrdnje u tekstu. Zbog toga se skor tumači zajedno sa indikatorima, jer ista vrednost može nastati iz različitih kombinacija problema u proverljivosti, metapodacima, kvalitetu izvora ili kontekstu citiranja. Osnovni indikatori koji se mogu koristiti u takvoj proveri prikazani su u tabeli 9.7.

Ovaj istraživački pravac posebno je relevantan za disertaciju jer proširuje obrazovnu analitiku sa programskog koda na akademsko pisanje. Bibliografska halucinacija može se posmatrati kao jedan od mogućih digitalnih tragova nekritičke upotrebe generativnog alata, ali i kao širi indikator nedovoljne informacione pismenosti, površnog čitanja izvora ili slabog razumevanja akademskog citiranja. Zbog toga je pedagoški korisnije govoriti o pouzdanosti izvora i potrebi za proverom nego o automatskom dokazivanju AI upotrebe.

Tabela 9.7: Indikatori bibliografske pouzdanosti studentskih radova.

Indikator	Opis	Rizik koji se detektuje
Proverljiv DOI ili URL	Da li izvor postoji i vodi ka stvarnom radu	Nepostojeća ili izmišljena referenca
Usklađenost autora, naslova i godine	Da li se metapodaci slažu kroz baze i dokument	Kombinovana ili pogrešno preuzeta referenca
Relevantnost za tvrdnju u tekstu	Da li citirani rad podržava rečenicu uz koju se nalazi	Formalno citiranje bez stvarne veze sa sadržajem
Kvalitet izvora	Časopis, konferencija, knjiga, repozitorijum ili nepouzdan web izvor	Slaba akademska osnova rada
Obrazac ponavljanja grešaka	Slične nevalidne reference kroz više radova	Mogući šablonski ili generativni izvor greške

Pored ručno definisanog skora bibliografske pouzdanosti, ovaj istraživački pravac može se proširiti modelom dubokog učenja koji povezuje tekstualni kontekst citiranja, bibliografske metapodatke i proverljive identifikatore izvora. Osnovna ideja nije da model automatski donosi odluku o akademskom integritetu, već da proceni rizik bibliografske nepouzdanosti i izdvoji reference koje zahtevaju dodatnu proveru. Na taj način se bibliografske halucinacije ne posmatraju samo kao formalna greška u spisku literature, već kao analitički obrazac koji nastaje u odnosu između studentskog teksta, citirane tvrdnje i stvarno dostupnog izvora.

Za svaku referencu r mogu se formirati tri grupe ulaza. Prvu grupu čini tekstualni kontekst, odnosno rečenica ili pasus u kojem se referenca koristi. Drugu grupu čine bibliografski metapodaci, kao što su autori, godina, naslov, naziv časopisa ili konferencije, DOI i URL. Treću grupu čine verifikacioni signali, koji pokazuju da li se DOI može potvrditi, da li se metapodaci slažu sa pronađenim izvorom i da li citirani rad semantički odgovara tvrdnji koju podržava. Takva struktura omogućava da se svaka referenca posmatra kao kombinacija tekstualnog signala, metapodataka i proverljivog signala. Predložena arhitektura može se formalizovati kao fuzioni model dubokog učenja. Tekstualni kontekst citiranja najpre se transformiše pomoću jezičkog enkodera, bibliografski zapis pomoću posebnog tekstualnog enkodera, dok se verifikacioni i strukturni signali uvode kroz gusto povezani sloj. Dobijene reprezentacije se zatim spajaju u zajednički latentni prostor:

$$h_r = [Enc_{text}(c_r); Enc_{ref}(m_r); Dense(v_r)], \quad (9.14)$$


gde c_r predstavlja kontekst citiranja, m_r bibliografske metapodatke, a v_r skup verifikacionih obeležja. Na taj način model istovremeno uzima u obzir da li je izvor formalno proverljiv,

da li su njegovi metapodaci usklađeni i da li je njegova upotreba u studentskom tekstu sadržajno opravdana. Na osnovu spojene reprezentacije model računa izlaznu verovatnoću da je referenca pouzdana:

$$\hat{p}_r = \sigma(Wh_r + b), \quad (9.15)$$

pri čemu veća vrednost $\hat{p}_r$ označava veću procenjenju bibliografsku pouzdanost, dok niža vrednost ukazuje na potrebu za dodatnom proverom. Vektor (h_r) zato predstavlja objedinjenu reprezentaciju teksta, reference i verifikacionih obeležja, dok sigmoidni izlaz daje procenu njihove ukupne bibliografske pouzdanosti.

Konceptualna struktura predloženog modela prikazana je na slici 9.3. Ilustracija objedinjuje tri ulazna toka, kontekst citiranja, bibliografski zapis i verifikacione signale, njihove zasebne enkodere, sloj fuzije i izlaznu procenu bibliografske pouzdanosti. Na taj način se vizuelno naglašava da model ne procenjuje referencu samo na osnovu njenog formalnog zapisa, već na osnovu veze između studentskog teksta, metapodataka i proverljivosti izvora.



Slika 9.3: Predložena arhitektura modela dubokog učenja za procenu bibliografske pouzdanosti studentskih radova.

Ovakav model je značajan jer kombinuje semantičko predstavljanje teksta sa eksplicitnim pravilima provere izvora. Na primer, referenca može imati pravilno formatiran zapis, ali slabu vezu sa tvrdnjom u tekstu. Isto tako, izvor može biti stvaran, ali pogrešno naveden ili povezan sa neodgovarajućim kontekstom. Zato model ne treba da se oslanja samo na DOI ili URL, već i na semantičku usklađenost između studentskog argumenta i citiranog izvora.

U pedagoškom smislu, izlaz modela treba tumačiti kao signal za nastavničku proveru, a ne kao automatsku ocenu rada. Reference sa niskom procenjenom pouzdanošću mogu se izdvojiti za ručnu proveru, razgovor sa studentom ili dodatni zadatak u kojem student objašnjava zašto je određeni izvor relevantan. Time se model dubokog učenja uklapa u osnovni princip ovog poglavlja: algoritamska analiza treba da podrži učenje, proveru i razvoj informacione pismenosti, a ne da zameni nastavničku procenu.

9.5.2 Etičke implikacije upotrebe generativnih modela u nastavi

Upotreba generativnih modela u nastavi zahteva etički i pedagoški okvir koji obuhvata akademski integritet, pravičnost, validnost ocenjivanja i zaštitu obrazovnih podataka. Potrebno je razlikovati dozvoljenu pomoć od preuzimanja gotovog rešenja, uvažiti nejednak pristup alatima i digitalnim veštinama, ali i prepoznati da korektan kod ili tekst više ne mora nužno dokazivati razumevanje. Zbog toga se u ovoj disertaciji polazi od modela odgovorne obrazovne analitike, u kojem algoritamski signal služi za usmeravanje pažnje nastavnika, a ne za automatsko sankcionisanje. Mogući ishodi takvog sistema i njihove pedagoške posledice prikazani su u tabeli 9.8.

Tabela 9.8: Značenje grešaka u obrazovnoj analitici.

Ishod	Značenje	Pedagoška posledica
Tačno pozitivan rizik	Student ili predmet kome treba podrška je prepoznat	Moguća rana intervencija
Lažno pozitivan rizik	Student ili predmet je pogrešno označen kao rizičan	Nepotrebna intervencija ili stigmatizacija
Lažno negativan rizik	Potreba za podrškom nije prepoznata	Propuštena prilika za pomoć
Tačno negativan rizik	Nema označenog rizika kada signal podrške nije potreban	Sistem ne opterećuje nastavnika dodatnim proverama

U obrazovnom domenu posebno je važan lažno negativan ishod, jer znači da student kome je potrebna podrška nije prepoznat. Međutim, lažno pozitivan ishod takođe može imati ozbiljnu posledicu ako student bude nepravedno označen kao problematičan. Zbog toga metrike evaluacije ne treba posmatrati samo kao tehničke brojke, već kao pedagoške signale. Odziv (*recall*) je važan kada je cilj da se ne propuste studenti kojima treba podrška, dok je preciznost (*precision*) važna kada se želi smanjiti broj neopravdanih intervencija. Nijedna metrika sama po sebi nije dovoljna, jer se obrazovna odluka mora donositi u odnosu na kontekst, nastavne ciljeve i posledice po studente.

Odgovorna primena generativnih modela podrazumeva jasna pravila, transparentne kriterijume, zadatke koji traže objašnjenje procesa, usmenu odbranu, refleksivne beleške, proveru bibliografije i nastavničku povratnu informaciju. Umesto zabrane alata, ovakav pristup motiviše studente da generativne modele koriste kritički, etički i uz razumevanje.

9.6 Sinteza nalaza u oblasti obrazovanja i studentskih ishoda

Obrazovni domen uvodi u disertaciju poseban oblik ljudskog ponašanja, jer se ovde ne analiziraju samo korisničke odluke, tržišni obrasci ili komunikacioni sadržaji, već proces učenja, izrade zadataka, korišćenja digitalnih alata i ostvarivanja akademskih ishoda. Generativni modeli u tom kontekstu nisu samo tehnička novina, već faktor koji menja način na koji studenti pišu, programiraju, traže pomoć, objašnjavaju rešenja i dokazuju razumevanje.

Rezultati ukazuju da se studentski rad može posmatrati kao multimodalna obrazovna instanca koja objedinjuje kod, tekst, komentare, metapodatke, vreme predaje, obrasce sličnosti, greške i nastavnički kontekst. Zbog toga analiza ne treba da bude usmerena samo na detekciju upotrebe generativnih alata, već na prepoznavanje obrazaca koji mogu ukazati na potrebu za dodatnim objašnjenjem, proverom razumevanja ili pedagoškom podrškom.

Poseban doprinos poglavlja jeste što se obrazovna analitika ne zadržava na jednom tipu podatka ili zadatku, već povezuje analizu studentskih radova, procenu rizika prekomernog oslanjanja na AI, LLM podršku u tumačenju grešaka, anonimizovanu analizu prolaznosti i procenu bibliografske pouzdanosti. U tom okviru predloženi fuzioni model dubokog učenja za bibliografsku pouzdanost pokazuje kako se tekstualni kontekst citiranja, metapodaci reference i verifikacioni signali mogu objединiti u jedinstvenu procenu rizika. Takvo povezivanje proširuje okvir disertacije sa predikcije ishoda na razumevanje procesa učenja, pri čemu interpretabilnost modela dobija pedagošku vrednost kroz mogućnost da se analitički signali pretvore u proveru, objašnjenje i nastavničku podršku.

U svim analiziranim pravcima naglašava se da algoritamski rezultat ne sme zameniti nastavničku procenu. Model može pomoći da se uoči obrazac, anomalija, rizičan predmet, problematična referenca ili potreba za dodatnom proverom, ali konačno tumačenje mora ostati vezano za kontekst zadatka, nivo studenta, nastavne ciljeve i posledice po studente. Time se obrazovna analitika u ovoj disertaciji oblikuje kao instrument podrške učenju, a ne kao mehanizam automatizovane kontrole.

Na taj način obrazovni domen zaokružuje empirijski deo disertacije. Prethodna poglavlja pokazala su primenu prediktivnih modela u hotelijerstvu, transportu, internet trgovini, poslovnoj komunikaciji i održivom odlučivanju, dok ovo poglavlje dodaje kontekst u kojem su posledice modelskih odluka posebno osetljive. Njegov doprinos je istovremeno metodološki, aplikativni i pedagoški, jer povezuje različite informacije, podržava nastavničko odlučivanje i insistira na razumevanju, proveru i podršci umesto na automatizovanom sankcionisanju.

10. INTEGRATIVNA SINTEZA REZULTATA I NAUČNIH DOPRINOSA

10.1 Povezivanje empirijskih domena disertacije

Prethodna empirijska poglavlja prikazala su razvoj i evaluaciju prediktivnih modela u više savremenih poslovnih i društvenih domena: turizmu i hotelijerstvu, transportnim sistemima, internet trgovini i parfemskoj industriji, društveno odgovornoj poslovnoj komunikaciji, održivom razvoju, projektnom odlučivanju i visokoškolskom obrazovanju u eri generativnih modela. Iako se ovi domeni razlikuju po sadržaju, tipovima podataka i neposrednoj oblasti primene, njihova zajednička istraživačka osnova nalazi se u analizi digitalnih tragova ljudskog ponašanja i njihovom prevođenju u prediktivne, interpretabilne i praktično korisne modele. Na taj način raznovrsnost empirijskih oblasti služi kao osnova za proveru primenljivosti istog istraživačkog pristupa u različitim kontekstima odlučivanja. Integrativni doprinos zato se ne nalazi u zbiru pojedinačnih eksperimenata, već u uporedivom načinu na koji se kroz svaki domen povezuju podaci, reprezentacija, model, evaluacija, objašnjenje i odluka.

Empirijski domeni u ovoj disertaciji su tretirani kao povezani prostori za proveru istog metodološkog okvira. Hotelijerstvo omogućava analizu zadovoljstva korisnika kroz recenzije, ocene, pritužbe, sentiment, dugoročnu vrednost korisnika, rizik otkazivanja rezervacija i pouzdanost ulaznih signala. Transport uvodi sekvencijalne, sigurnosne, cenovne i segmentne obrasce ponašanja. Internet trgovina i parfemska industrija omogućavaju ispitivanje subjektivnih, emocionalnih i fuzzy obrazaca potrošačkih preferencija. Poslovna komunikacija uvodi društveno osetljiv domen u kojem posledice grešaka modela imaju etičko i organizaciono značenje. Održivi razvoj i projektno odlučivanje proširuju okvir ka indikatorima, projektnim opisima, generativnim narativima i održivoj implementaciji modela. Obrazovanje uvodi pedagoški osetljiv domen u kojem prediktivni modeli moraju podržati učenje, razumevanje i akademsku pravičnost. Zajedno, ovi domeni pokazuju da se ljudsko ponašanje može modelovati samo kada se podaci tumače zajedno sa kontekstom u kojem nastaju.

Takva struktura pokazuje da disertacija nije tematski zbir različitih oblasti, već metodološki povezan istraživački rad. Zajednička nit nije specifična industrija, već postupak kojim se heterogeni digitalni tragovi ponašanja pretvaraju u modele koji mogu da predviđaju, objasnjavaju i podrže odlučivanje. U svim domenima postoji ulazni trag ponašanja, ciljni ishod,

model koji uči odnos između ulaza i ishoda, evaluacija rezultata i odluka ili intervencija koju rezultat modela može da podrži. Opšti integrativni problem može se zapisati kao:

$$\hat{y}_i^{(d)} = f_{\theta}^{(d)}(x_i^{(d)}), \quad (10.1)$$

gde d označava empirijski domen, $x_i^{(d)}$ ulaznu instancu u domenu d , $f_{\theta}^{(d)}$ model prilagođen domenu, a $\hat{y}_i^{(d)}$ predviđeni ishod. Iako se konkretni podaci i modeli razlikuju, zajednički metodološki princip ostaje isti: potrebno je definisati ulazne podatke, ciljnu promenljivu, model, metrike evaluacije, analizu grešaka, interpretabilnost i domensko značenje rezultata. U širem obliku, istraživački tok disertacije može se prikazati kao:

$$\begin{aligned} &Data \rightarrow Repräsentacija \rightarrow Predikcija \\ &\rightarrow Evaluacija \rightarrow Objanjenje \rightarrow Odluka. \end{aligned} \quad (10.2)$$

Tehnički posmatrano, svaki domen predstavlja posebnu instancu istog eksperimentalnog protokola, u kojoj se menjaju modaliteti ulaza, tip ciljnog ishoda i arhitektura modela, dok kriterijumi evaluacije i interpretacije ostaju uporedivi.

U hotelijerstvu se tekstualni i numerički tragovi pretvaraju u predikcije ocena, pritužbi, dugoročne vrednosti korisnika i rizika otkazivanja rezervacija. U transportu se ponašajni i tržišni signali pretvaraju u procenu rizika vožnje, cene karte ili zadovoljstva putnika. U internet trgovini i parfemskoj industriji se recenzije, atributi proizvoda, mirisne note i emocionalni izrazi pretvaraju u reprezentacije preferencija i popularnosti. U komunikacionom domenu se tekstualni diskurs pretvara u signal komunikacionog rizika. U obrazovanju se kod, tekst, greške i institucionalni podaci pretvaraju u signale kvaliteta, rizika i potrebe za podrškom.

10.2 Poređenje domena prema tipu podataka i istraživačkom zadatku

Empirijski domeni disertacije razlikuju se prema tipu podataka i tipu istraživačkog zadatka. Ovo poređenje je važno jer pokazuje da se doprinos disertacije ne zasniva na ponavljanju istog modela na sličnim skupovima podataka, već na proveru metodološkog okvira u različitim uslovima. Svaki domen uvodi specifičan oblik ponašanja, drugačiji izvor podataka i poseban evaluacioni izazov.

U hotelijerstvu dominiraju tekstualni i multimodalni podaci, dok transport kombinuje sekvencijalne, tabelarne, vremenske i tržišne signale. Internet trgovina i parfemska industrija uvode subjektivne preferencije, emocionalne reakcije i fuzzy kategorije. Poslovna komunikacija predstavlja društveno osetljiv tekstualni zadatak, održivi razvoj uvodi indikatorske, mrežne i narativne podatke, a obrazovanje povezuje tekst, kod, greške, institucionalne podatke i pedagoški kontekst. Zbog toga je korisno ove razlike sažeti kroz opštu formalizaciju ciljnih ishoda, jer ona pokazuje da se isti istraživački okvir može primeniti nezavisno od toga

da li model predviđa vrednost, klasu, skup oznaka ili stepen pripadnosti određenoj kategoriji. U formalnom smislu, ciljni ishodi u disertaciji mogu biti numerički, binarni, višeklasni, višelabelni ili fuzzy definisani:

$$y_i \in \mathbb{R}, \quad y_i \in \{0, 1\}, \quad y_i \in \{1, 2, \dots, K\}, \quad y_i = (y_{i1}, \dots, y_{iK}), \quad \mu_{ik} \in [0, 1]. \quad (10.3)$$


Ova formalizacija pokazuje da integrativni okvir disertacije ne zavisi od jednog tipa ciljne promenljive. Zadovoljstvo gosta može biti numeričko, pritužba višelabelna, preferencija fuzzy, vožnja sekvencijalna, a obrazovni rizik pedagoški uslovljen. Nije presudno da svi domeni imaju isti oblik ulaza ili isti tip izlaza, već da se u svakom domenu ponašajni tragovi mogu prevesti u ishod koji je merljiv, evaluabilan i interpretabilan. Zbog toga se istraživački zadaci kreću od regresije i klasifikacije, preko višeklasne i višelabelne klasifikacije, do sekvencijalne predikcije, klasterizacije, fuzzy kategorizacije i mrežne analize.

Slika 10.1 sažima heterogenost empirijskih domena tako što ih povezuje sa dominantnim tipovima podataka i reprezentacija korišćenim u disertaciji. Redovi predstavljaju analizirane domene, dok kolone obuhvataju tekstualne, tabelarne, sekvencijalne, multimodalne, fuzzy, mrežne i narativne podatke. Intenzitet polja označava relativnu zastupljenost ili metodološki značaj određenog tipa podataka u konkretnom domenu, pri čemu tamnija polja ne predstavljaju vrednosnu prednost, već veću ulogu tog tipa podataka u datom istraživačkom kontekstu. Matrica istovremeno pokazuje da pojedini domeni prirodno zahtevaju kombinovanje više reprezentacija: hotelijerstvo i obrazovanje snažno se oslanjaju na tekstualne i multimodalne tragove, transport uvodi sekvencijalne i tabelarne obrasce, dok održivi razvoj povezuje indikatore, mreže i narative. Time se vizuelno potvrđuje centralna ideja integrativnog poglavlja: empirijski domeni su različiti po sadržaju, ali su povezani istim analitičkim postupkom prevođenja digitalnih tragova ponašanja u upotrebljive i objašnjive uvide.

10.3 Poređenje modela i uslova njihove najbolje primene

Rezultati disertacije pokazuju da ne postoji univerzalno najbolji model za analizu ponašanja korisnika i učesnika digitalnih sistema. Performansa i upotrebljivost modela zavise od tipa podataka, veličine skupa, strukture ciljne promenljive, stepena šuma, potrebe za interpretabilnošću, računarske zahtevnosti i domenskih posledica greške. Zato je poređenje modela zasnovano na principu uslovne primenljivosti, a ne na jednostavnom rangiranju algoritama.

Tradicionalni modeli mašinskog učenja, kao što su logistička regresija, Ridge regresija, SVM i Naive Bayes, imaju važnu ulogu kao referentni pristupi. Njihova prednost je jednostavnost, brzina, interpretabilnost i mogućnost poređenja sa složenijim modelima. Ansambl modeli, kao što su Random Forest, Gradient Boosting, XGBoost, LightGBM i CatBoost, pokazuju posebnu vrednost u tabularnim i kombinovanim zadacima. Sekvencijalni modeli, uključujući LSTM, imaju posebnu ulogu kada je redosled događaja važan, dok transformer



Slika 10.1: Matrica heterogenosti podataka i zadataka u empirijskim domenima.

modeli imaju najveću vrednost u zadacima bogate tekstualne semantike. Multimodalni i fuzzy pristupi opravdani su kada ponašanje ne može biti dovoljno opisano jednim izvorom podataka ili jednom isključivom kategorijom.

U disertaciji se, prema tome, duboko učenje ne tretira kao automatski superiorno, već kao metodološki opravdano u domenima u kojima tekstualna semantika, sekvencijalnost ili multimodalnost zahtevaju složenije reprezentacije. Nasuprot tome, jednostavniji i interpretabilniji modeli ostaju važni kada daju stabilne rezultate, kada je skup podataka manji ili kada je objašnjivost važnija od marginalnog povećanja performansi. Ova logika može se prikazati kao višekriterijumski problem izbora modela:

$$M^* = \arg \max_{M \in \mathcal{M}} \left[\lambda_1 Performance(M) + \lambda_2 Interpretability(M) + \lambda_3 Stability(M) - \lambda_4 Cost(M) - \lambda_5 Risk(M) \right], \quad (10.4)$$

gde M označava jedan od modela koji se poredi u procesu izbora, dok M^* predstavlja model sa najpovoljnijom ukupnom vrednošću zadatog kriterijuma. $Performance(M)$ označava prediktivnu performansu, $Interpretability(M)$ objašnjivost, $Stability(M)$ stabilnost rezultata, $Cost(M)$ računarski ili implementacioni trošak, a $Risk(M)$ domenski rizik pogrešne primene. Koeficijenti $\lambda_1, \dots, \lambda_5$ izražavaju relativni značaj kriterijuma u konkretnom domenu, pri čemu se njihov smisao ne tumači kao univerzalna numerička vrednost, već kao formalni način da se prikaže zavisnost izbora modela od istraživačkog i praktičnog konteksta.

Ovakva formulacija pokazuje da najbolji model nije nužno model sa najvišom tačnošću. U društveno osetljivoj komunikaciji model sa nešto manjom ukupnom tačnošću, ali boljom kontrolom lažno pozitivnih ishoda, može biti odgovorniji izbor. U obrazovanju model koji

nastavniku daje objašnjenje može biti vredniji od neobjašnjivog modela sa minimalno boljom performansom. U održivom razvoju model koji ostvaruje dobar balans između performanse i računarske zahtevnosti može biti primereniji od znatno složenijeg modela.

10.4 Interpretabilnost, pouzdanost i pravičnost rezultata po domenima

Interpretabilnost, pouzdanost i pravičnost predstavljaju tri ključna kriterijuma za procenu vrednosti prediktivnih modela u ovoj disertaciji. Prediktivna performansa je neophodna, ali nije dovoljna. Model koji dobro predviđa, ali se ne može objasniti, nije stabilan po segmentima ili proizvodi neprihvatljive greške u osetljivom domenu, ne može se smatrati metodološki potpuno uspešnim.

Interpretabilnost označava sposobnost da se rezultat modela objasni u jeziku koji je razumljiv domenskim korisnicima. U hotelijerstvu to znači povezivanje predikcije sa pritužbama, sentimentom, čistoćom, osobljem, CLV signalima, rizikom otkazivanja i pouzdanošću ulaznih podataka. U transportu to znači objašnjenje faktora koji utiču na cenu, rizičnu vožnju ili zadovoljstvo putnika. U komunikaciji znači objašnjenje zašto je tekst označen kao rizičan, a u obrazovanju zašto je rad označen za proveru ili koja greška zahteva pedagošku intervenciju.

Pouzdanost označava stabilnost i proverljivost rezultata. Model treba da zadrži performanse na test skupu, da ne zavisi od curenja informacija, da bude otporan na šum i da ne prikriva loše rezultate u manjinskim segmentima. Pravičnost se u disertaciji posmatra kroz pitanje da li model proizvodi greške koje mogu nepravедno pogoditi određene korisnike, putnike, studente ili učesnike komunikacije. U tehničkom smislu, performansa modela se zato tumači kao rezultat koji mora biti proverljiv kroz stabilnost po segmentima, objašnjivost ulaznih faktora i prihvatljivost posledica grešaka. Ukupna vrednost modela može se posmatrati kao višedimenzionalna funkcija:

$$\text{Value}(M) = g\left(\text{Performance}(M), \text{Interpretability}(M), \text{Reliability}(M), \text{Fairness}(M), \text{Practicality}(M)\right). \quad (10.5)$$

Ova funkcija nema značenje jedinstvene numeričke mere koja se jednako primenjuje u svim domenima, već predstavlja konceptualni okvir za tumačenje vrednosti modela. Ako bilo koja od ovih dimenzija ima veoma nisku vrednost, ukupna upotrebljivost modela može biti ograničena, čak i kada je prediktivna performansa dobra.

Da bi se pokazalo da se interpretabilnost, pouzdanost i pravičnost ne javljaju kao opšti zahtevi nezavisni od konteksta, tabela 10.1 prikazuje njihovo domensko značenje u empirijskim poglavljima disertacije. Tabela ne rangira domene, već pokazuje kako se isti kriterijumi odgovorne evaluacije različito ispoljavaju u zavisnosti od tipa podataka, korisnika modela i odluka koje model podržava.

Tabela 10.1: Interpretabilnost, pouzdanost i pravičnost po empirijskim domenima.

Domen	Interpretabilnost	Pouzdanost	Pravičnost/ odgovornost
Hotelijerstvo	Objašnjenje ocena, pritužbi i CLV signala	Hronološka validacija i procena pouzdanosti recenzija	Sprečavanje pogrešnog tumačenja korisničkih pritužbi
Transport	Objašnjenje rizične vožnje, cena i zadovoljstva	Segmentna evaluacija i analiza grešaka	Bezbednosne posledice i pouzdanost po putničkim segmentima
Internet trgovina i parfemska industrija	Objašnjenje emocija, atributa proizvoda, nota i popularnosti	Validacija sličnosti i fuzzy kategorija	Izbegavanje pojednostavljivanja subjektivnih preferencija
Poslovna komunikacija	Lokalna objašnjenja rizičnih izraza	Analiza FP/FN ishoda i pragova odlučivanja	Ljudska provera i sprečavanje automatizovane nepravde
Održivi razvoj i projektno odlučivanje	Objašnjenje indikatora, projektnih opisa i narativa	Provera utemeljenosti generisanih izveštaja	Odgovorno odlučivanje i transparentnost preporuka
Obrazovanje	Objašnjenje grešaka, rizika i ishoda	Segmentna i pedagoška validacija	Zaštita studenata od nepravednih automatizovanih zaključaka

Posebno važan deo integrativnog okvira jeste analiza grešaka. Za binarnu klasifikaciju, lažno pozitivni i lažno negativni ishodi mogu se izraziti kao:

$$FPR = \frac{FP}{FP + TN}, \quad FNR = \frac{FN}{FN + TP}. \quad (10.6)$$


Njihovo domensko značenje se razlikuje. U hotelijerstvu lažno negativan ishod može značiti da pritužba nije prepoznata. U transportu može značiti da agresivna vožnja ili nezadovoljan putnik ostaju neotkriveni. U poslovnoj komunikaciji može značiti da štetan sadržaj ostaje prisutan. U obrazovanju može značiti da student kome treba podrška ostane neprepoznat. Zbog toga se analiza grešaka ne posmatra samo kao tehnička evaluacija modela, već kao način procene posledica koje model može imati u realnom domenskom okruženju. Zbog toga se u disertaciji kao deo odgovornog evaluacionog okvira koristi princip zona odlučivanja, kojim se osetljivi ishodi ne prevode odmah u automatske binarne odluke, već u različite nivoe provere

i intervencije:

$$decision_i = \begin{cases} \text{no_action,} & \hat{p}_i < \tau_1, \\ \text{review,} & \tau_1 \leq \hat{p}_i < \tau_2, \\ \text{priority_review,} & \hat{p}_i \geq \tau_2. \end{cases} \quad (10.7)$$

Ovaj princip ima širu primenu. U komunikacionom domenu srednja zona znači stručnu proveru. U obrazovanju znači razgovor, dodatnu proveru ili usmenu odbranu. U hotelijerstvu može značiti ručnu analizu recenzije pre menadžerske intervencije. Na taj način model ne zamenjuje ljudsko odlučivanje u osetljivim slučajevima, već služi kao sistem ranog upozorenja i podrška odgovornijem odlučivanju.

Slika 10.2 sažima prošireni evaluacioni okvir disertacije. Model dobija punu vrednost tek kada njegova predikcija nije samo tačna, već i objašnjiva, proverena, segmentno pouzdana i odgovorno primenjena. Time se završna sinteza pomera od pitanja koji model je najtačniji ka pitanju pod kojim uslovima je određen model zaista upotrebljiv u konkretnom poslovnom ili društvenom domenu.



Slika 10.2: Interpretabilnost, pouzdanost i pravičnost kao kriterijumi evaluacije modela.

10.5 Naučni, metodološki i aplikativni doprinosi disertacije

Doprinosi disertacije proizlaze iz povezivanja više empirijskih domena u jedinstven istraživački okvir za razvoj, evaluaciju i interpretaciju prediktivnih modela ponašanja. Oni se mogu posmatrati kroz naučnu, metodološku i aplikativnu dimenziju, pri čemu se ove dimenzije međusobno dopunjuju. Za razliku od uvodnog dela disertacije, gde su doprinosi formulisani kao istraživačka namera, u ovom poglavlju oni se izводе iz konkretnih empirijskih nalaza, poređenja modela, analiza grešaka i domenskih interpretacija rezultata.

Naučni doprinos disertacije ogleda se u tome što se ponašanje korisnika, potrošača, putnika, vozača, studenata i učesnika digitalne komunikacije analizira kroz zajedničku metodološku logiku. Disertacija pokazuje da se oblici ponašanja mogu posmatrati kao digitalni tragovi koji zahtevaju odgovarajuću reprezentaciju, modelovanje i interpretaciju. Dodatni doprinos rada ogleda se u povezivanju tekstualnih narativa sa numeričkim, kategorijalnim, emocionalnim i poslovnim ishodima. Takav pristup omogućava da se prediktivno modelovanje ne posmatra samo kao tehnički postupak, već kao način pretvaranja heterogenih i šumovitih podataka u objašnjive uvide o ponašanju u realnim poslovnim i društvenim sistemima.

Metodološka dimenzija doprinosa ogleda se u višeslojnom protokolu koji obuhvata kontrolu kvaliteta podataka, pretprocesiranje, reprezentaciju, modelovanje, evaluaciju, analizu grešaka, interpretabilnost i domensko odlučivanje. Ovaj protokol se proverava kroz više tipova podataka i zadataka, čime se pokazuje da je dovoljno stabilan da obezbedi uporedivost, a dovoljno fleksibilan da se prilagodi specifičnostima domena. U hotelskom domenu, hronološka validacija i modelovanje pouzdanosti recenzija pokazali su značaj kontrole vremenskog curenja i kvaliteta ulaznih signala. U zadatku predikcije hotelskih ocena, transformer pristup je na test okviru ostvario nižu grešku od klasičnog TF-IDF Ridge modela, čime je potvrđena vrednost kontekstualnih tekstualnih reprezentacija u zadacima bogate semantike. Istovremeno, u drugim zadacima jednostavniji i interpretabilniji modeli ostaju važni kao stabilni referentni pristupi i kao metodološka kontrola složenijih arhitektura.


Aplikativni doprinosi proističu iz mogućnosti da se razvijeni okvir primeni u sistemima odlučivanja. U hotelijerstvu rezultati mogu podržati praćenje recenzija, detekciju pritužbi, predikciju ocena i reputacionu analitiku. U transportu mogu podržati detekciju rizične vožnje, analizu cena i procenu zadovoljstva putnika. U internet trgovini i parfemskoj industriji doprinose razumevanju preferencija, emocija, subjektivnih opisa i tržišne vrednosti proizvoda. U poslovnoj komunikaciji, održivom razvoju i obrazovanju rezultati imaju vrednost samo uz pažljivo tumačenje, stručnu proveru i jasno definisane granice primene. Time aplikativni doprinos disertacije nije samo u mogućnosti automatizacije, već u oblikovanju odgovornih sistema podrške odlučivanju koji kombinuju predikciju, objašnjenje i ljudsku procenu.

Tabela 10.2 prikazuje empirijsku osnovu iz koje su doprinosi izvedeni. Tabela istovremeno pokazuje razliku između domena, zadataka i tipova podataka, ali i zajedničku logiku po kojoj se empirijski nalazi prevode u doprinos sintezi, od hotelskih recenzija i transportnih segmenata do projektnih narativa i studentskih radova.

Slika 10.3 prikazuje da empirijski domen nisu sami sebi cilj, već osnova iz koje se razvijaju metodološki nalazi, integrativni okvir i odgovorna primena prediktivnih modela. Najniži sloj čine domenski podaci i konkretni empirijski zadaci, srednji sloj čine metodološki postupci reprezentacije, modelovanja, evaluacije i interpretacije, dok najviši sloj predstavljaju naučni i aplikativni doprinosi. Na taj način se pokazuje da doprinos disertacije ne proizlazi iz jedne izolovane studije, već iz konvergencije rezultata dobijenih u različitim domenima.

Tabela 10.2: Empirijska osnova naučnih, metodoloških i aplikativnih doprinosa disertacije.

Domen	Zadatak / podaci	Ključni empirijski nalaz	Doprinos sintezi
Hotelijerstvo	Recenzije, ocene, pritužbe i CLV signali	U predikciji hotelskih ocena DistilBERT ostvaruje MAE = 0.4370, RMSE = 0.6979 i $R^2 = 0.8217$, u odnosu na TF-IDF Ridge sa MAE = 0.5913 i $R^2 = 0.7182$	Povezivanje tekstualne semantike, pouzdanosti recenzija i poslovnih ishoda
Transport	Agresivna vožnja i zadovoljstvo putnika	DNN pristup za stil vožnje ostvaruje približno 87% tačnosti; za zadovoljstvo putnika neural network ostvaruje accuracy = 90.12%, macro F1 = 0.90 i FNR = 12.94%	Potvrda značaja sekvencijalnih, ponašajnih i segmentnih signala
Transportni segmenti	Putnički segmenti, klase usluge i objašnjenja	Iako je ukupna performansa visoka, FNR u pojedinim economy/economy-plus segmentima prelazi 45%, dok seat comfort ima relativni značaj od približno 46–57%	Pokazivanje da agregirane metrike moraju biti dopunjene segmentnom evaluacijom
Internet trgovina i parfemska industrija	Recenzije, ocene, mirisne note, atributi proizvoda i fuzzy preferencije	Subjektivne preferencije i emocionalni opisi ne mogu se uvek svesti na jednu isključivu klasu ili numeričku ocenu	Uvođenje fuzzy i interpretabilnih pristupa za modelovanje višeznačnosti
Poslovna komunikacija	Društveno osetljiv tekstualni diskurs	Transformer klasifikacija ima vrednost samo uz analizu FP/FN ishoda, pragova odlučivanja i ljudsku proveru	Odgovorna primena modela u domenu sa etičkim i organizacionim posledicama
Održivi razvoj i projektno odlučivanje	Indikatori, projektni opisi, mreže saradnje i generativni narativi	Vrednost modela zavisi od utemeljenosti objašnjenja, transparentnosti preporuke i odnosa performanse i računarske zahtevnosti	Povezivanje predikcije, održivosti, mrežne analize i odgovornog odlučivanja
Obrazovanje	Studentski radovi, kod, tekst, greške i institucionalni podaci	Modeli mogu ukazati na obrasce rizika, kvaliteta i potrebe za podrškom, ali zaključci moraju biti pedagoški, a ne kazneni	Ljudska provera (human-in-the-loop) i zaštita akademske pravičnosti



Slika 10.3: Slojevita struktura naučnih, metodoloških i aplikativnih doprinosa.

10.6 Odnos rezultata prema postavljenim hipotezama

Rezultati disertacije povezuju se sa hipotezama kroz objedinjeno tumačenje nalaza iz više empirijskih domena. Takav pristup omogućava da se svaka hipoteza sagleda kroz različite tipove podataka, modele i evaluacione uslove, čime se potvrđuje njena uloga u širem istraživačkom okviru disertacije.

Hipoteza H1 podržana je u domenima gde postoje bogati tekstualni, semantički ili sekvencijalni signali. U hotelskom domenu transformer pristup je ostvario bolju predikciju ocena od klasičnog TF-IDF Ridge referentnog modela. DistilBERT je ostvario MAE od 0.4370, dok je TF-IDF Ridge ostvario MAE od 0.5913. Ovaj nalaz pokazuje da duboko učenje ima posebnu vrednost kada tekst sadrži implicitne semantičke i emocionalne signale. Slično tome, DNN i LSTM pristupi imaju metodološku važnost u zadacima u kojima je redosled događaja ili struktura ponašajnog signala važna, kao što je analiza obrazaca rizične vožnje. Ipak, rezultati istovremeno pokazuju da duboko učenje nije automatski najbolji izbor za svaki zadatak, već da njegova opravdanost zavisi od strukture podataka i cilja modelovanja.

Hipoteza H2 podržana je kroz nalaze koji pokazuju da kvalitet reprezentacije podataka utiče na performanse i domensko značenje modela. U hotelijerstvu se vidi razlika između klasične TF-IDF reprezentacije, sekvencijalne neuralne reprezentacije i kontekstualne transformer reprezentacije. U transportu ponašajni, okolinski, cenovni i segmentni signali uvode različite nivoe reprezentacije istog domena. U internet trgovini i parfemskoj industriji mirisne note, recenzije, sentiment i fuzzy kategorije omogućavaju da se subjektivne preferencije predstave na način koji nije moguć kroz jednu numeričku promenljivu. Time se potvrđuje da izbor tekstualnih, numeričkih, sekvencijalnih, fuzzy i multimodalnih obeležja neposredno utiče na kvalitet predikcije.

Hipoteza H3 potvrđena je kroz nalaze koji pokazuju da kvalitet podataka, šum, anomalije, nekonzistentnost, pristrasnost i neravnoteža klasa značajno utiču na pouzdanost modela. U hotelijerstvu su hronološka podela, kontrola curenja informacija, analiza anomalija, procena pouzdanosti recenzija i kvalitet rezervacionih signala pokazali da performansa modela zavisi od načina pripreme i validacije podataka. U internet trgovini i parfemskoj industriji nedostajuće ocene, neravnomerna vidljivost proizvoda i subjektivnost korisničkih opisa pokazuju da podaci nisu neutralan odraz tržišta. U komunikaciji i obrazovanju kvalitet podataka se mora tumačiti u odnosu na kontekst, manjinske klase i posledice grešaka.

Hipoteza H4 podržana je kroz nalaze o značaju interpretabilnosti, analize grešaka i segmentne evaluacije. U svim domenima objašnjenje povezuje predikcije sa značenjem rezultata: pritužbama i CLV signalima u hotelijerstvu, cenovnim faktorima i segmentima putnika u transportu, notama i emocijama u parfemskoj industriji, komunikacionim rizikom u poslovnom diskursu i pedagoškim signalima u obrazovanju. Posebno u transportu, komunikaciji i obrazovanju, agregirane metrike nisu dovoljne, pa su potrebni makro pokazatelji, matrice konfuzije, FPR, FNR, analiza pragova i zone odlučivanja.

Hipoteza H5 potvrđena je kroz nalaze da izbor modela, arhitekture i reprezentacije mora biti prilagođen domenu, uz istovremeno uvažavanje tačnosti, interpretabilnosti, stabilnosti, troška i odgovorne primene. U disertaciji se zato ne uspostavlja hijerarhija modela u kojoj su složeniji modeli uvek bolji, već se pokazuje da vrednost modela zavisi od ravnoteže između performanse i uslova primene. Na primer, DistilBERT u hotelijerstvu ostvaruje bolju prediktivnu performansu od TF-IDF Ridge modela, ali zahteva veću računarsku i interpretativnu pažnju; u tabularnim i kombinovanim zadacima ansambli i jednostavniji modeli često ostaju praktično opravdani.

Tabela 10.3 pokazuje da hipoteze nisu potvrđivane kroz jedan izolovani eksperiment, već kroz konvergenciju nalaza iz više empirijskih domena. Pojedini domeni daju direktniju podršku određenim hipotezama, kao što su hotelski i komunikacioni domen za tekstualne i transformer modele, transport za sekvencijalno modelovanje, a obrazovanje i komunikacija za interpretabilnost, analizu grešaka i odgovornu primenu. Time se potvrda hipoteza ne zasniva na jednostavnom zbiru rezultata, već na poređenju različitih tipova podataka, modela, metrika i domenskih posledica grešaka.

Na osnovu sinteze može se zaključiti da su hipoteze disertacije podržane, ali uz važna metodološka razjašnjenja. Rezultati ukazuju da se uspeh prediktivnog modelovanja ponašanja ne može vezati za jedan univerzalni model, već zavisi od pravilnog povezivanja podataka, reprezentacije, evaluacije, interpretacije i domenske odgovornosti. Rezultati pokazuju da uspeh prediktivnog modelovanja ponašanja zavisi od pravilnog povezivanja podataka, reprezentacije, modela, evaluacije, interpretacije i domenske odgovornosti. Time se hipoteze ne potvrđuju kao pojednostavljene tehničke tvrdnje, već kao uslovni, empirijski podržani zaključci o tome kada, zašto i pod kojim ograničenjima prediktivni modeli imaju naučnu i praktičnu vrednost.

Tabela 10.3: Sinteza odnosa rezultata prema hipotezama.

Hipoteza	Ključni zaključak	Glavni empirijski oslonac
H1	Duboko učenje unapređuje analizu tekstualnih i sekvencijalnih obrazaca	DistilBERT MAE = 0.4370 naspram TF-IDF Ridge 0.5913; LSTM za rizičnu vožnju
H2	Izbor reprezentacije podataka bitno menja performanse	Razlika TF-IDF, BiLSTM i transformera; spajanje više modaliteta
H3	Šum, pristrasnost i neravnoteža klasa smanjuju pouzdanost	Kontrola curenja informacija, pouzdanost recenzija, rezervacioni signali, balansiranje klasa
H4	Interpretabilnost i segmentna analiza otkrivaju ono što zbirne metrike kriju	FPR/FNR i SHAP objašnjenja; segmentni FNR preko 45% u transportu
H5	Najopravdaniji model je uslovan, a ne univerzalan	Poređenje referentni pristup, ansambla, LSTM, transformera, fuzzy i multimodalnih modela

10.7 Zaključna razmatranja integrativne sinteze

Ovo poglavlje povezano je rezultate iz svih empirijskih domena disertacije u jedinstvenu naučnu i metodološku celinu. Pokazano je da se hotelijerstvo, transport, internet trgovina, poslovna komunikacija, održivi razvoj i obrazovanje mogu posmatrati kao različiti empirijski prostori za proveru istog istraživačkog okvira: razvoja i evaluacije prediktivnih modela za analizu obrazaca ljudskog ponašanja u savremenom poslovnom okruženju.

Važan zaključak jeste da prediktivna performansa sama po sebi nije dovoljna. Modeli ponašanja moraju biti interpretabilni, pouzdani, segmentno provereni i odgovorno primenjeni. Ovaj nalaz posebno dolazi do izražaja u društveno osetljivoj komunikaciji i obrazovanju, ali je relevantan i za hotelijerstvo, transport, internet trgovinu i održivo odlučivanje.

Integrativni doprinos disertacije ogleda se u definisanju uslova za odgovornu i korisnu primenu različitih klasa modela. Transformer modeli, LSTM, ansambli, fuzzy pristupi i multimodalne arhitekture dobijaju naučnu vrednost tek kada su povezani sa validnim podacima, odgovarajućom evaluacijom, objašnjenjem i domenskom odlukom. Time se tehnička predikcija pretvara u interpretabilnu i odgovornu analitiku ponašanja.

Integrativna sinteza zato predstavlja centralni dokaz naučne zrelosti disertacije. Ona pokazuje da je empirijska raznovrsnost usmerena ka jedinstvenom cilju: razvoju prediktivnih modela koji ne samo da predviđaju ponašanje, već omogućavaju njegovo razumevanje, objašnjenje i odgovornu primenu.

11. INDUSTRIJSKA PRIMENA I POSLOVNI UTICAJ REZULTATA

Rezultati disertacije imaju praktičnu vrednost zato što pokazuju kako se prediktivni modeli mogu koristiti kao podrška odlučivanju u realnim poslovnim, organizacionim, obrazovnim i društveno osetljivim sistemima. U prethodnim poglavljima modeli su razvijani i evaluirani u različitim empirijskim domenima, dok se u ovom poglavlju njihov značaj posmatra iz perspektive industrijske primene, poslovnog uticaja, implementacije i mogućnosti razvoja softverskih rešenja.

Industrijska primena prediktivnih modela ne podrazumeva samo ugradnju algoritma u postojeći informacioni sistem. Ona zahteva usklađivanje modela sa poslovnim procesima, kvalitetom podataka, dostupnom infrastrukturom, pravnim ograničenjima, etičkim pravilima i očekivanjima korisnika. Model koji ima dobru eksperimentalnu performansu može imati ograničenu praktičnu vrednost ako ne može biti objašnjen, održavan, integrisan u radni tok ili prihvaćen od strane korisnika.

Zbog toga se u ovoj disertaciji poslovni uticaj rezultata posmatra kroz pet dimenzija: mogućnost primene u konkretnom domenu, vrstu odluke koju model podržava, kvalitet i dostupnost podataka, potrebu za interpretabilnošću i nivo ljudske kontrole. Ovakvo posmatranje omogućava da se industrijska vrednost rezultata ne svede na tehničku performansu modela, već na širu sposobnost sistema da podrži korisnu, proverljivu i odgovornu odluku. U formalnom smislu, poslovna vrednost modela može se posmatrati kao funkcija:

$$\begin{aligned} BusinessValue(M) = h \Big(&Accuracy(M), Interpretability(M), Cost(M), \\ &Integration(M), Risk(M), Adoption(M) \Big). \end{aligned} \quad (11.1)$$

gde *Accuracy* označava prediktivnu performansu, *Interpretability* mogućnost objašnjenja, *Cost* trošak implementacije i održavanja, *Integration* sposobnost uključivanja u postojeći sistem, *Risk* rizik pogrešne primene, a *Adoption* prihvatanje od strane korisnika. Ova formulacija pokazuje da model sa najboljom metrikom nije nužno model sa najvećom poslovnom vrednošću.

11.1 Primena rezultata u poslovnim, društvenim i obrazovnim sistemima

Domenska primena rezultata može se grupisati u dve šire celine. Prvu čine poslovni i tržišni domeni, kao što su hotelijerstvo, transport i internet trgovina. U hotelijerstvu modeli mogu podržati praćenje recenzija, detekciju pritužbi, reputacionu analitiku, predikciju zadovoljstva, procenu dugoročne vrednosti korisnika i procenu rizika otkazivanja rezervacija. U transportu mogu doprineti ranom prepoznavanju rizičnih obrazaca vožnje, analizi cena, proceni zadovoljstva putnika i identifikaciji povezanosti destinacija. U internet trgovini i parfemskoj industriji mogu pomoći u razumevanju preferencija, emocija, popularnosti proizvoda i tržišne vrednosti brenda.

Drugu celinu čine društveno, organizaciono i pedagoški osetljivi domeni: poslovna komunikacija, održivi razvoj i obrazovanje. U poslovnoj komunikaciji modeli mogu služiti kao sistemi za stručnu proveru i edukativnu intervenciju, ali ne kao automatski mehanizmi sankcionisanja. U održivom razvoju i projektnom odlučivanju mogu podržati konstrukciju indikatora, evaluaciju narativa, klasifikaciju projekata, mrežnu analizu i strateško mapiranje portfolija. U obrazovanju mogu pomoći u analizi studentskih radova, identifikaciji obrazaca grešaka i ranom prepoznavanju potrebe za podrškom, uz obavezno pedagoško tumačenje rezultata.

Tabela 11.1 pokazuje da poslovni uticaj rezultata zavisi od vrste odluke koju model podržava. U komercijalnim domenima naglasak je na kvalitetu usluge, reputaciji, zadovoljstvu i tržišnoj inteligenciji. U društveno i obrazovno osetljivim domenima naglasak je na podršci stručnom odlučivanju, transparentnosti i zaštiti od pogrešnog automatskog zaključivanja.

11.2 Mogućnosti komercijalizacije i razvoja softverskih rešenja


Rezultati disertacije otvaraju mogućnost razvoja više softverskih rešenja i analitičkih modula koji bi mogli imati komercijalnu, institucionalnu ili istraživačku primenu. Komercijalizacija u ovom kontekstu ne znači prodaju jednog modela, već razvoj modularnih sistema za podršku odlučivanju koji se mogu prilagoditi različitim domenima.

Najprirodniji oblik komercijalizacije jeste razvoj platforme za prediktivnu i objašnjivu analitiku ponašanja. Takva platforma mogla bi imati više modula: modul za analizu recenzija, modul za detekciju pritužbi, modul za CLV procenu, modul za procenu rizika otkazivanja rezervacija, modul za analizu transportnih obrazaca, modul za potrošačke preference, modul za odgovornu komunikaciju, modul za projektno izveštavanje i modul za obrazovnu analitiku. Zajednička osnova svih modula bila bi ista: prikupljanje i priprema podataka, predikcija, interpretacija, kontrola grešaka i izveštavanje.

Slika 11.1 prikazuje moguću arhitekturu softverskog sistema zasnovanog na rezultatima disertacije. Takav sistem ne bi bio jedinstvena zatvorena aplikacija, već skup prilagodljivih modula koji dele zajedničku metodološku osnovu.

Tabela 11.1: Mogući oblici praktične primene rezultata disertacije.

Domen	Moguća primena	Uslov odgovorne upotrebe
Hotelijerstvo	Praćenje recenzija, pritužbi, reputacije, CLV signala i rizika otkazivanja	Tumačenje rezultata u kontekstu kvaliteta usluge
Transport	Detekcija rizične vožnje, analiza cena i povezanosti destinacija	Segmentna provera i oprez kod bezbednosnih odluka
Internet trgovina	Analiza preferencija, emocija, popularnosti i vrednosti proizvoda	Izbegavanje pojednostavljivanja subjektivnih preferencija
Poslovna komunikacija	Signalizacija rizičnog ili diskriminatornog jezika	Stručna provera i zabrana automatskog sankcionisanja
Održivi razvoj	Analiza projekata, indikatora, mreža i narativa	Provera utemeljenosti i transparentnost izvora
Obrazovanje	Analiza radova, grešaka, ishoda i potrebe za podrškom	Pedagoško tumačenje i zaštita studenata



Slika 11.1: Arhitektura potencijalnog softverskog sistema zasnovanog na eksperimentalnim rezultatima disertacije.

Sa aspekta implementacije, sistem bi mogao da obuhvati sloj za unos podataka, sloj za proveru kvaliteta, sloj za reprezentaciju podataka, sloj modela, sloj interpretabilnosti, sloj za izveštavanje i sloj za korisničku proveru. U domenima niskog rizika moguće je veću ulogu dati automatizovanim preporukama, dok u osetljivim domenima model mora ostati deo procesa ljudske kontrole.

Tabela 11.2 prikazuje kako se rezultati disertacije mogu prevesti u potencijalne softverske module, pri čemu svaki modul odgovara jednom domenskom pravcu primene, skupu funkcionalnosti i grupi korisnika kojima bi takav sistem mogao da pruži podršku u odlučivanju.

Tabela 11.2: Potencijalni softverski moduli zasnovani na rezultatima disertacije.

Modul	Funkcija	Mogući korisnici
Hotelska analitika	Sentiment, pritužbe, reputacija, CLV i rizik otkazivanja	Hoteli, platforme, menadžment kvaliteta
Transportna analitika	Rizična vožnja, cene, povezanost ruta	Transportne kompanije, osiguranje, destinacijske organizacije
Tržišna analitika proizvoda	Preferencije, emocije, popularnost, fuzzy kategorije	Online prodavnice, brendovi, marketinški timovi
Odgovorna komunikacija	Detekcija rizičnog jezika i prioritet za proveru	Organizacije, HR timovi, edukativni programi
Obrazovna analitika	Analiza radova, grešaka i potrebe za podrškom	Nastavnici, institucije, studentske službe

Ovakva modularna logika ima dodatnu prednost jer omogućava postepeni razvoj sistema. Umesto da se odmah razvija kompleksna platforma, moguće je prvo implementirati jedan domen, zatim proširivati funkcionalnosti i povezivati module koji dele slične metode pripreme, modelovanja, evaluacije i interpretacije.

11.3 Ograničenja praktične primene i uslovi implementacije

Iako rezultati disertacije pokazuju značajan potencijal za industrijsku primenu, praktična implementacija prediktivnih modela ima važna ograničenja. Ona se odnose na kvalitet podataka, promene u ponašanju korisnika, tehničku infrastrukturu, pravne zahteve, etičke rizike, prihvatanje od strane korisnika i troškove održavanja. Zbog toga se poslovni uticaj modela mora procenjivati realno, uz jasno definisane uslove primene. Kvalitetna implementacija dodatno zahteva praćenje promene distribucije podataka, periodičnu proveru performansi, rekalkulaciju modela i jasno evidentiranje slučajeva u kojima je potrebna ljudska kontrola.

Kvalitet podataka predstavlja osnovni preduslov. Ako su podaci nepotpuni, pristrasni, zastareli ili slabo dokumentovani, model može proizvesti pogrešne zaključke. Drugo ograničenje odnosi se na promenu ponašanja kroz vreme. Model treniran na istorijskim podacima može izgubiti performansu ako se promeni tržište, komunikacioni obrasci, studentske navike ili očekivanja korisnika. Treće ograničenje odnosi se na prihvatanje rezultata, jer korisnici sistema moraju razumeti šta model predviđa, šta ne predviđa i kada i u kojoj meri je potrebna ljudska provera.

U osetljivim domenima važno je jasno definisati granice automatizacije. Sistemi za detekciju rizičnog jezika, obrazovnu analitiku ili procenu rizika u transportu ne treba da donose konačne odluke, već da služe kao podrška ljudskoj proceni. Njihovi rezultati treba da predstavljaju signal za dodatno razmatranje, a ne osnov za automatsko odlučivanje.

Tabela 11.3 sistematizuje ključne uslove za odgovornu implementaciju prediktivnih modela i povezuje ih sa njihovim značenjem i praktičnim posledicama. Prva kolona izdvaja osnovne preduslove primene, druga objašnjava zašto su oni važni za pouzdanost sistema, dok treća pokazuje šta se u praksi može dogoditi ako se ti uslovi zanemare.

Tabela 11.3: Uslovi za odgovornu implementaciju prediktivnih modela.

Uslov	Značenje	Praktična posledica
Kvalitet podataka	Podaci moraju biti provereni, dokumentovani i relevantni	Smanjuje se rizik pogrešnih zaključaka
Stabilnost modela	Model mora biti proveravan na novim i segmentnim podacima	Sprečava se oslanjanje na zastarele obrasce
Interpretabilnost	Korisnik mora razumeti razloge predikcije	Povećava se poverenje i mogućnost provere
Ljudska kontrola	Osetljive odluke zahtevaju stručnu proveru	Smanjuje se rizik automatizovane nepravde
Održavanje	Model zahteva praćenje, rekalkulaciju, audit logove i dokumentovanje	Obezbeđuje se dugoročna upotrebljivost sistema

Praktična primena rezultata disertacije zato treba da bude postepena: od istraživačkog prototipa, preko pilot primene u ograničenom domenu, do evaluacije sa korisnicima, prilagođavanja modela realnim uslovima i šire implementacije. Takav pristup je posebno važan jer se modeli ponašanja zasnivaju na podacima koji opisuju iskustva, odluke, komunikaciju, učenje i rad ljudi, pa njihova primena zahteva tehničku proveru, domensko tumačenje i odgovornu kontrolu.

11.4 Zaključna razmatranja o industrijskoj primeni

Industrijska i poslovna vrednost rezultata disertacije nalazi se u mogućnosti da se prediktivni modeli pretvore u odgovorne sisteme podrške odlučivanju. U hotelijerstvu, transportu, internet trgovini, komunikaciji, održivom razvoju i obrazovanju modeli mogu doprineti boljem razumevanju ponašanja, ranijem prepoznavanju problema i kvalitetnijem odlučivanju.

Ipak, praktična primena zahteva više od dobre metrike. Potrebni su provereni podaci, objašnjivi rezultati, stabilna evaluacija, jasno definisane granice automatizacije i prihvatanje od strane korisnika. Najveća vrednost disertacije u ovom poglavlju ogleda se u tome što pokazuje kako se rezultati istraživanja mogu prevesti u softverske module i poslovne procese, bez gubitka naučne odgovornosti i domenskog konteksta.

Prediktivni model u realnom sistemu ne treba da zameni čoveka, već da proširi njegovu sposobnost da prepozna obrasce, razume podatke i donese utemeljenu odluku. Upravo u toj vezi između modela, objašnjenja i odgovorne primene nalazi se industrijski značaj rezultata disertacije.

12. ZAKLJUČAK

Istraživanje sprovedeno u ovoj disertaciji usmereno je na razvoj i evaluaciju prediktivnih modela za analizu obrazaca ljudskog ponašanja primenom dubokog učenja, mašinskog učenja, obrade prirodnog jezika, multimodalnog modelovanja i interpretabilne veštačke inteligencije u savremenom poslovnom okruženju. Polazna pretpostavka istraživanja jeste da se ponašanje korisnika, potrošača, putnika, studenata i učesnika digitalne komunikacije sve češće izražava kroz digitalne tragove. Ti tragovi mogu biti tekstualni, numerički, vremenski, sekvencijalni, emocionalni, multimodalni ili institucionalni. Njihova vrednost ne nalazi se samo u tome što se mogu čuvati i obrađivati, već u tome što mogu doprineti boljem razumevanju potreba, odluka, rizika, zadovoljstva, nezadovoljstva, poverenja, lojalnosti, grešaka i obrazaca ponašanja ljudi u digitalno posredovanim sistemima.

U savremenom poslovnom okruženju organizacije sve češće donose odluke na osnovu podataka. Međutim, sama količina podataka nije dovoljna za kvalitetnije odlučivanje. Dobijene metrike zato ne predstavljaju samo brojčane pokazatelje performansi, već važne signale o tome koliko se rezultati mogu pouzdano tumačiti i koristiti kao podrška poslovnom odlučivanju. Takvo razumevanje metrika posebno je važno jer poslovne odluke ne zavise samo od tačnosti predikcije, već i od toga koliko su rezultati stabilni, objašnjivi i primenljivi u konkretnom domenu. Podaci mogu biti nepotpuni, pristrasni, neujednačeni, vremenski ograničeni ili pogrešno protumačeni. Zbog toga se istraživački problem ove disertacije oblikuje oko pitanja kako razviti prediktivne modele koji ne daju samo tačne rezultate, već su metodološki opravdani, pažljivo evaluirani, interpretabilni i korisni za odgovorno odlučivanje.

Rezultati disertacije pokazuju da se empirijski domeni mogu povezati kroz zajednički istraživački okvir. Turizam i hotelijerstvo, transportni sistemi, internet trgovina i parfemska industrija, društveno odgovorna poslovna komunikacija, održivi razvoj, projektno odlučivanje i obrazovanje predstavljaju različite prostore u kojima se javlja ista metodološka potreba: iz digitalnih tragova ponašanja izvesti korisne predikcije i pretvoriti ih u objašnjive uvide koji mogu podržati odluke. U toj vezi između domena nalazi se integrativni karakter disertacije. Zaključci po pojedinačnim oblastima zato se posmatraju kao delovi šire istraživačke celine.

U oblasti turizma i hotelijerstva pokazano je da online recenzije, ocene, pritužbe, sentiment, pouzdanost recenzija i dugoročna vrednost korisnika predstavljaju bogat izvor podataka za prediktivnu analitiku. Hotelske recenzije nisu samo tekstualni komentari gostiju,

već nose informacije o zadovoljstvu, nezadovoljstvu, operativnim problemima, reputaciji i budućem odnosu gosta prema hotelu. Kroz modele za detekciju anomalija, negativnih recenzija, pritužbi, predikciju ocena, forecasting, CLV modelovanje i procenu rizika otkazivanja pokazano je da tekstualni, rezervacioni i multimodalni signali mogu imati visoku poslovnu vrednost. Rezultat modela može pomoći hotelu da ranije prepozna pritužbu, bolje razume pad zadovoljstva, proceni rizik otkazivanja, prioritetno reaguje na recenzije i identifikuje korisnike od veće dugoročne vrednosti.

Transportni domen je pokazao da prediktivna analitika ponašanja ne mora biti zasnovana samo na tekstu. Ponašanje vozača, dinamika cena karata, zadovoljstvo putnika, evropske avio-rute i zavisnost destinacija od prevoznika zahtevaju kombinovanje sekvencijalnih, tabularnih, vremenskih, mrežnih i segmentnih podataka. U ovom domenu posebno dolazi do izražaja važnost redosleda događaja i segmentne pouzdanosti. Agresivna vožnja ne može se uvek prepoznati iz jedne izolovane vrednosti, već iz obrasca ponašanja kroz vreme. Zadovoljstvo putnika i povezanost destinacija ne mogu se tumačiti samo kroz ukupnu tačnost modela, jer segmenti, rute i prevoznici mogu imati različite profile rizika. Time je transportni domen potvrdio da modeli moraju biti provereni ne samo globalno, već i po segmentima, posebno kada njihove greške mogu imati bezbednosne, operativne ili poslovne posledice.

Internet trgovina i parfemska industrija otvorile su prostor za analizu subjektivnih, emocionalnih i fuzzy obrazaca potrošačkog ponašanja. Parfemi su posebno važan primer jer se njihova vrednost ne formira samo kroz objektivne karakteristike proizvoda, već kroz doživljaj, emociju, mirisnu asocijaciju, brend, sećanje i lični identitet. Jedna recenzija može istovremeno govoriti o kvalitetu, ceni, emociji, trajnosti, ambalaži i poverenju u brend. Zbog toga fuzzy kategorizacija i reprezentaciono učenje imaju posebnu vrednost. Oni omogućavaju da se potrošački narativi ne svode na jednu oznaku, već da se prikaže njihova višedimenzionalna struktura. Time je disertacija proširila prediktivno modelovanje ponašanja i na domene u kojima su granice značenja mekše, subjektivnije i emocionalno bogatije.

Domen društveno odgovorne poslovne komunikacije pokazao je da prediktivni modeli mogu imati ozbiljne etičke, organizacione i reputacione posledice. Detekcija seksističkog, mizoginog, diskriminatornog ili rizičnog jezika ne može se posmatrati kao običan klasifikacioni zadatak, jer se rezultati mogu odraziti na komunikacione obrasce i zaštitu učesnika u digitalnom radnom okruženju. Lažno pozitivan ishod može nepravedno označiti neutralan sadržaj kao problematičan, dok lažno negativan ishod može propustiti štetan obrazac komunikacije. Zato je u ovom domenu posebno naglašena potreba za analizom grešaka, pragovima odlučivanja i pristupom ljudske provere. Model ne sme zameniti ljudsku i stručnu procenu, već treba da služi kao pomoćni sistem za dodatnu proveru i organizaciono učenje.

Održivi razvoj, projektno odlučivanje i analitičko izveštavanje proširili su istraživački okvir na strateški i organizacioni nivo. U ovom delu disertacije pokazano je da prediktivni modeli, NLP pristupi i generativni narativi mogu pomoći u analizi održivih indikatora,

projektnih opisa, pravaca zelenih tehnologija, istraživačkih portfolija i mreža saradnje. Održivost se pritom ne posmatra samo kao opšti razvojni cilj, već kao složen analitički okvir koji zahteva merljive indikatore, proverljive modele, transparentno izveštavanje i odgovornu interpretaciju rezultata. Na taj način održivi razvoj postaje prostor u kojem se povezuju podaci, tehnologija, organizacione strategije i dugoročne posledice odlučivanja. Posebno je značajna evaluacija automatski generisanih narativa, jer generativni modeli mogu pomoći u komunikaciji rezultata, ali mogu proizvesti i netačne ili preterano uverljive zaključke.

Obrazovni domen zaokružio je empirijski deo disertacije kroz analizu studentskog ponašanja u eri generativnih modela. Ovaj domen je posebno blizak savremenom akademskom okruženju, jer generativni alati menjaju način na koji studenti pišu, programiraju, objašnjavaju, uče i traže pomoć. U disertaciji je naglašeno da cilj obrazovne analitike ne sme biti automatsko optuživanje studenata, već razumevanje promena u obrascima rada i identifikacija potrebe za podrškom. Studentski radovi mogu se analizirati kroz kod, tekst, komentare, greške, metapodatke i institucionalne ishode, ali svaki rezultat mora biti pedagoški protumačen. Model može ukazati na rizik, ali ne može samostalno dokazati akademski prekršaj. Ovaj domen je posebno važan jer pokazuje da prediktivni modeli mogu podržati razvoj znanja samo ako su primenjeni pažljivo, transparentno i uz nastavničku odgovornost.

Kroz sve ove domene potvrđena je osnovna ideja disertacije: prediktivno modelovanje ljudskog ponašanja zahteva više od izbora algoritma. Potrebno je razumeti podatke, njihov nastanak, ograničenja, značenje i posledice njihove upotrebe. Potrebno je birati modele prema prirodi zadatka, a ne prema popularnosti određene arhitekture. Potrebno je uporediti složene modele sa referentnim pristupima i pokazati kada napredni modeli zaista donose dodatnu vrednost. Potrebno je analizirati greške, posebno u manjinskim klasama i osetljivim segmentima. Potrebno je objašnjavati rezultate i prevoditi ih u jezik domena. Najzad, potrebno je jasno razlikovati predikciju od odluke.

Integrativni doprinos disertacije ogleda se u povezivanju različitih tipova podataka, modela i domena kroz logiku odgovornog izbora modela. Transformer modeli imaju posebnu vrednost kada je potrebno razumeti tekstualnu semantiku, LSTM i sekvencijalni pristupi kada redosled događaja nosi informaciju, ansambl modeli u tabularnim i strukturisanim zadacima, multimodalni modeli kada ponašanje ostavlja više vrsta tragova, a fuzzy pristupi kada kategorije nisu strogo razdvojene. Objašnjiva veštačka inteligencija dodatno povezuje rezultat modela sa domenskim tumačenjem i proverljivošću. Na taj način izbor modela proizilazi iz odnosa između podataka, zadatka, domena i posledica primene.

Jedan od važnih doprinosa rada jeste povezivanje prediktivne analitike ponašanja sa odgovornom primenom. U mnogim istraživanjima performansa modela ostaje centralni kriterijum. Ova disertacija pokazuje da performansa jeste važna, ali nije dovoljna. Model može imati dobru tačnost, a ipak biti neprihvatljiv ako greši u osetljivim slučajevima, ako nije objašnjiv, ako je pristrasan, ako prikriva slabosti po segmentima ili ako se koristi bez ljudske

provere. Zato se u disertaciji insistira na proširenoj evaluaciji, koja obuhvata tačnost, grešku, stabilnost, interpretabilnost, segmentnu pouzdanost, pragove odlučivanja, potrošnju resursa i domensko značenje rezultata.

Metodološki doprinos disertacije ogleda se u integrativnom okviru koji povezuje podatke, reprezentaciju, model, evaluaciju, objašnjenje i odluku. Taj okvir može se primeniti na različite domene, ali ne mehanički. Njegova vrednost je u tome što pruža istraživačku logiku koja se može prilagoditi novim podacima, novim zadacima i različitim oblicima ponašajnih obrazaca. U tom smislu, okvir ne propisuje jedan univerzalni model, već način razmišljanja o tome kako se prediktivni sistemi odgovorno razvijaju i proveravaju. U svakom novom domenu potrebno je postaviti ista osnovna pitanja: koji trag ponašanja se analizira, kakav je kvalitet podataka, koji model odgovara zadatku, kako se meri uspeh, koje greške su najvažnije, kako se rezultat objašnjava i ko donosi konačnu odluku. Upravo ova pitanja čine okvir prenosivim i naučno korisnim.

Aplikativni doprinos disertacije vidi se u mogućnosti razvoja softverskih i analitičkih sistema za podršku odlučivanju. Rezultati se mogu koristiti za hotelsku reputacionu analitiku, detekciju pritužbi, CLV procenu, transportnu bezbednost, analizu zadovoljstva putnika, tržišnu analizu potrošačkih preferencija, odgovornu komunikacionu analitiku, održivo projektno odlučivanje i obrazovnu analitiku. Posebna vrednost ovih rezultata ogleda se u tome što povezuju tehničke performanse modela sa konkretnim potrebama organizacija i korisnika sistema. Ipak, disertacija jasno naglašava da se ovi sistemi ne smeju razvijati kao sistemi koji automatski zamenjuju ljude. Njihova prava vrednost nalazi se u podršci stručnjacima, menadžerima, nastavnicima i organizacijama da odluke donose brže, informisanije i odgovornije.

Tokom istraživanja otvorena su i važna ograničenja. Heterogenost domena omogućila je širu proveru metodološkog okvira, ali istovremeno znači da se rezultati iz jednog domena ne mogu direktno preneti u drugi bez dodatne validacije. Skupovi podataka razlikuju se po obimu, kvalitetu, dostupnosti, jeziku i načinu nastanka. U nekim zadacima postoje javni i veliki skupovi podataka, dok su u drugim domenima podaci ograničeniji, agregirani ili osetljiviji. Oznake u društveno osetljivim i obrazovnim zadacima posebno zahtevaju oprez, jer nisu uvek apsolutne, već zavise od konteksta, smernica i ljudske interpretacije. Zbog toga je pouzdanost zaključaka potrebno posmatrati u odnosu na konkretan domen, način prikupljanja podataka i uslove u kojima se model primenjuje. Duboki modeli i transformer arhitekture donose veću reprezentacionu snagu, ali i veću računarsku zahtevnost, potrebu za validacijom i rizik od preteranog oslanjanja na model.

Ova ograničenja pokazuju da je odgovorno istraživanje u oblasti veštačke inteligencije neodvojivo od svesti o granicama modela. Modeli ne otkrivaju apsolutnu istinu o ljudskom ponašanju. Oni uče obrasce iz dostupnih podataka. Ako su podaci ograničeni, model je ograničen. Ako se ponašanje promeni, model se mora proveriti. Ako je odluka osetljiva, čovek mora ostati u procesu. Upravo zato ova disertacija ne završava tvrdnjom da su razvijeni mo-

deli konačna rešenja, već da predstavljaju metodološki zasnovan korak ka odgovornijoj i interpretabilnijoj primeni prediktivne analitike.

Planovi za dalja istraživanja prirodno se nadovezuju na rezultate disertacije. Budući rad može ići u pravcu proširenja skupova podataka, posebno kroz višegodišnje, višejezičke i međudomske skupove koji bi omogućili proveru generalizacije modela kroz vreme, jezik i tržišni kontekst. U hotelijerstvu bi bilo posebno korisno povezati recenzije sa dodatnim operativnim podacima, kao što su realni odgovori hotela, istorija rezervacija, sezonalnost, tip gosta i podaci o uslužnim intervencijama. Takvo proširenje omogućilo bi preciznije razumevanje veze između korisničkog iskustva, menadžerske reakcije i dugoročne lojalnosti.

U transportnom domenu dalja istraživanja mogu se usmeriti ka real-time modelima za ranu detekciju rizika, integraciji telematičkih podataka sa vremenskim i infrastrukturnim uslovima, kao i ka detaljnijoj analizi segmentne pouzdanosti modela za zadovoljstvo putnika. Posebno bi bilo značajno razviti modele koji ne samo da klasifikuju rizično ponašanje, već objašnjavaju koji obrasci vožnje najviše doprinose riziku i kako se oni mogu koristiti u edukaciji vozača ili unapređenju sigurnosnih sistema.

U oblasti internet trgovine i parfemske industrije budući rad može proširiti fuzzy i emocionalnu analizu na veće skupove proizvoda, različite jezike i različite kulturne kontekste. Potrošačke preferencije nisu univerzalne i ne zavise samo od proizvoda, već i od tržišta, trenda, cene, dostupnosti, sezone i identiteta korisnika. Zbog toga bi dalja istraživanja mogla povezati recenzije, vizuelne elemente proizvoda, podatke o prodaji, društvene mreže i preporuke korisnika u širi multimodalni sistem za razumevanje tržišne percepcije.

U oblasti društveno odgovorne komunikacije potrebno je nastaviti rad na modelima koji bolje razumeju kontekst, ironiju, implicitne stereotipe i kulturne razlike. Posebno je važno razvijati modele koji imaju jasne mehanizme nesigurnosti i koji mogu razlikovati slučajeve za automatsko odbacivanje, slučajeve za stručnu proveru i slučajeve visokog prioriteta. Dalja istraživanja treba da uključe i evaluaciju modela sa ljudskim ekspertima, jer se u ovom domenu ne može osloniti samo na automatske metrike.

U oblasti održivog razvoja i projektnog odlučivanja budući rad može ići ka razvoju analitičkih platformi koje povezuju indikatore održivosti, projektne baze, mreže saradnje, generativne narative i objašnjive modele. Posebno je važna evaluacija automatski generisanih izveštaja, jer će poslovna i istraživačka praksa sve više koristiti generativne modele za pripremu izveštaja, sažetaka i preporuka. U tom kontekstu biće neophodno razviti metode koje proveravaju tačnost, utemeljenost, potpunost i rizik interpretacije generisanog teksta.

Obrazovni domen otvara posebno važan nastavak istraživanja. Generativni modeli će nastaviti da menjaju način učenja, izrade zadataka i provere znanja. Zato buduća istraživanja treba da se usmere na razvoj pravednih, transparentnih i pedagoški korisnih sistema obrazovne analitike. Potrebno je razvijati metode koje ne pokušavaju da jednostavno detektuju da li je student koristio AI, već da procene da li student razume rešenje, kako koristi alat, koje gre-

ške pravi i kakva mu je podrška potrebna. Posebno važan pravac je povezivanje automatske analize radova sa usmenom odbranom, refleksijom studenta i nastavničkom procenom.

Jedan od najvažnijih budućih pravaca odnosi se na razvoj integrisane softverske platforme zasnovane na rezultatima disertacije. Takva platforma mogla bi imati modularnu arhitekturu i podržavati različite domene: hotelijerstvo, transport, internet trgovinu, poslovnu komunikaciju, održivost i obrazovanje. Njena osnovna logika bila bi ista kao i integrativni okvir disertacije: unos podataka, kontrola kvaliteta, izbor reprezentacije, modelovanje, evaluacija, objašnjenje, kontrolna tabla i odgovorna odluka. Takav sistem mogao bi biti korišćen kao istraživački prototip, nastavna platforma, BI alat ili osnova za buduće komercijalno rešenje. Ključni pravac daljeg rada jeste dodatno produbljivanje empirijskih rezultata u oblastima hotelijerstva i transporta, u kojima je istraživački kontinuitet već nastavljen kroz nekoliko prihvaćenih radova koji čekaju objavljivanje. Na taj način disertacija predstavlja polaznu osnovu za dalje metodološko, aplikativno i publikaciono razvijanje istraživačkog okvira.

Dalji rad treba da uključi i jaču vezu sa konceptom green AI i održive softverske implementacije. Kako modeli postaju sve veći i složeniji, pitanje računarske zahtevnosti, energije, vremena treniranja i održavanja sistema postaje sve važnije. Budući modeli ne treba da budu vrednovani samo prema tome koliko su tačni, već i prema tome koliko su efikasni, objašnjivi i proporcionalni problemu koji rešavaju. U tom smislu, buduća istraživanja treba da nastave da razvijaju višekriterijumski pristup optimizaciji modela.

Ovaj istraživački put se, dakle, ne završava ovom disertacijom. Naprotiv, disertacija predstavlja osnovu za dalji rad na odgovornoj, interpretabilnoj i primenljivoj veštačkoj inteligenciji u poslovnim, društvenim i obrazovnim sistemima. Njena vrednost nalazi se u tome što povezuje različite oblasti, ali ih ne svodi na jednostavno poređenje modela. Ona pokazuje da se iza svake predikcije nalazi čovek, korisnik, student, gost, putnik, zaposleni, nastavnik ili donosilac odluke. Zbog toga je neophodno da modeli koje razvijamo budu ne samo tehnički uspešni, već i razumljivi, proverljivi i odgovorni.

Zaključno, disertacija potvrđuje da savremeno poslovno okruženje zahteva prediktivne modele koji mogu obraditi kompleksne digitalne tragove ponašanja i prikazati rezultate na način koji podržava razumevanje i odlučivanje. Najznačajniji doprinos rada nalazi se u integraciji modelovanja, interpretabilnosti, odgovorne evaluacije i domenske primene. Time je razvijen okvir koji može poslužiti kao osnova za dalja istraživanja, razvoj softverskih rešenja i praktičnu primenu veštačke inteligencije u sistemima u kojima se odluke donose na osnovu podataka, ali ljudsko razumevanje, stručna procena i odgovornost ostaju nezamenljivi.

LITERATURA

- [1] Verhoef, P. C., Broekhuizen, T., Bart, Y., Bhattacharya, A., Qi, J., Fabian, N., & Haenlein, M. (2021). Digital transformation: A multidisciplinary reflection and research agenda. *Journal of Business Research*, 122, 889–901. doi: 10.1016/j.jbusres.2019.09.022.
- [2] Barocas, S., Hardt, M., & Narayanan, A. (2023). *Fairness and machine learning: Limitations and opportunities*. MIT Press. <https://fairmlbook.org>
- [3] Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685–695. doi: 10.1007/s12525-021-00475-2.
- [4] Grinsztajn, L., Oyallon, E., & Varoquaux, G. (2022). Why do tree-based models still outperform deep learning on typical tabular data? In S. Koyejo et al. (Eds.), *Advances in Neural Information Processing Systems 35* (pp. 507–520). Curran Associates. doi: 10.52202/068431-0037.
- [5] Salih, A. M., Raisi-Estabragh, Z., Galazzo, I. B., Radeva, P., Petersen, S. E., Lekadir, K., & Menegaz, G. (2025). A perspective on explainable artificial intelligence methods: SHAP and LIME. *Advanced Intelligent Systems*, 7, 2400304. doi: 10.1002/aisy.202400304.
- [6] Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2, 160. doi: 10.1007/s42979-021-00592-x.
- [7] Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2021). Deep learning–based text classification: A comprehensive review. *ACM Computing Surveys*, 54(3), Article 62. doi: 10.1145/3439726.
- [8] Tay, Y., Dehghani, M., Bahri, D., & Metzler, D. (2022). Efficient transformers: A survey. *ACM Computing Surveys*, 55(6), Article 109. doi: 10.1145/3530811.
- [9] Siino, M., Tinnirello, I., & La Cascia, M. (2024). Is text preprocessing still worth the time? A comparative survey on the influence of popular preprocessing methods on transformers and traditional classifiers. *Information Systems*, 121, 102342. doi: 10.1016/j.is.2023.102342.

- [10] Pessach, D., & Shmueli, E. (2022). A review on fairness in machine learning. *ACM Computing Surveys*, 55(3), Article 51. doi: 10.1145/3494672.
- [11] Blodgett, S. L., Barocas, S., Daumé III, H., & Wallach, H. (2020). Language (technology) is power: A critical survey of “bias” in NLP. In *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics* (pp. 5454–5476). Association for Computational Linguistics. doi: 10.18653/v1/2020.acl-main.485.
- [12] Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S. I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67. doi: 10.1038/s42256-019-0138-9.
- [13] Gebru, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Daumé III, H., & Crawford, K. (2021). Datasheets for datasets. *Communications of the ACM*, 64(12), 86–92. doi: 10.1145/3458723.
- [14] Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. *Communications of the ACM*, 63(12), 54–63. doi: 10.1145/3381831.
- [15] Doborjeh, Z., Hemmington, N., Doborjeh, M., & Kasabov, N. (2022). Artificial intelligence: A systematic review of methods and applications in hospitality and tourism. *International Journal of Contemporary Hospitality Management*, 34(3), 1154–1176. doi: 10.1108/IJCHM-06-2021-0767.
- [16] Della Corte, V., Cascella, C., Luongo, S., & Sepe, F. (2025). Unlocking Pandora’s box: Unravelling nested futures directions of the AI in tourism and hospitality through an umbrella review. *International Journal of Hospitality Management*, 129, 104189. doi: 10.1016/j.ijhm.2025.104189.
- [17] Liu, J., Hu, S., Mehraliyev, F., & Liu, H. (2023). Text classification in tourism and hospitality: A deep learning perspective. *International Journal of Contemporary Hospitality Management*, 35(12), 4177–4190. doi: 10.1108/IJCHM-07-2022-0913.
- [18] Roumeliotis, K. I., Tselikas, N. D., & Nasiopoulos, D. K. (2024). Leveraging large language models in tourism: A comparative study of the latest GPT Omni models and BERT NLP for customer review classification and sentiment analysis. *Information*, 15(12), 792. doi: 10.3390/info15120792.
- [19] Ben Brahim, S., Ghazzai, H., Besbes, H., & Massoud, Y. (2022). A machine learning smartphone-based sensing for driver behavior classification. In *2022 IEEE International Symposium on Circuits and Systems (ISCAS)* (pp. 610–614). doi: 10.1109/ISCAS48785.2022.9937801.

- [20] Talebloo, F., Mohammed, E. A., & Far, B. H. (2021). Deep learning approach for aggressive driving behaviour detection. *arXiv preprint arXiv:2111.04794*. doi: 10.48550/arXiv.2111.04794.
- [21] Zachariah, R. A., Sharma, S., & Kumar, V. (2023). Systematic review of passenger demand forecasting in aviation industry. *Multimedia Tools and Applications*, 82, 46483–46519. doi: 10.1007/s11042-023-15552-1.
- [22] Korkmaz, H. (2024). Prediction of airline ticket price using machine learning method. *Journal of Transportation and Logistics*, 9(2), 205–218. doi: 10.26650/JTL.2024.1486696.
- [23] Wong, P., Thant, P., Yadav, P., Antaliya, R., & Woo, J. (2023). Using Spark machine learning models to perform predictive analysis on flight ticket pricing data. *arXiv preprint arXiv:2310.07787*. doi: 10.48550/arXiv.2310.07787.
- [24] Guimarães, M., Soares, C., & Ventura, R. (2022). Decision support models for predicting and explaining airport passenger connectivity from data. *IEEE Transactions on Intelligent Transportation Systems*, 23(9), 16005–16015. doi: 10.1109/TITS.2022.3147155.
- [25] Liu, Y., Lu, J., Yang, J., & Mao, F. (2020). Sentiment analysis for e-commerce product reviews by deep learning model of Bert-BiGRU-Softmax. *Mathematical Biosciences and Engineering*, 17(6), 7819–7837. doi: 10.3934/mbe.2020398.
- [26] Balakrishnan, V., Shi, Z., Law, C. L., Lim, R., & Fan, Y. (2022). A deep learning approach in predicting products' sentiment ratings: A comparative analysis. *The Journal of Supercomputing*, 78, 7206–7226. doi: 10.1007/s11227-021-04169-6.
- [27] Amirifar, T., Lahmiri, S., & Kazemi Zanjani, M. (2024). An NLP-deep learning approach for product rating prediction based on online reviews and product features. *IEEE Transactions on Computational Social Systems*, 11(6), 8156–8168. doi: 10.1109/TCSS.2023.3290558.
- [28] Ezugwu, A. E., Ikotun, A. M., Oyelade, O. O., Abualigah, L., Agushaka, J. O., Eke, C. I., & Akinyelu, A. A. (2022). A comprehensive survey of clustering algorithms: State of the art machine learning applications, taxonomy, challenges, and future research prospects. *Engineering Applications of Artificial Intelligence*, 110, 104743. doi: 10.1016/j.engappai.2022.104743.
- [29] Suh, J., Hong, Y., & Park, C. (2025). A comparative study of machine learning models on molecular fingerprints for odor decoding. *Communications Chemistry*, 8, 278. doi: 10.1038/s42004-025-01651-7.

- [30] Fontanella, L., Chulvi, B., Ignazzi, E., Sarra, A., & Tontodimamma, A. (2024). How do we study misogyny in the digital age? A systematic literature review using a computational linguistic approach. *Humanities and Social Sciences Communications*, 11, Article 488. doi: 10.1057/s41599-024-02978-7.
- [31] Kirk, H. R., Yin, W., Vidgen, B., & Röttger, P. (2023). SemEval-2023 Task 10: Explainable detection of online sexism. In *Proceedings of the 17th International Workshop on Semantic Evaluation (SemEval-2023)* (pp. 2193–2210). Association for Computational Linguistics. doi: 10.18653/v1/2023.semeval-1.305.
- [32] Plaza, L., Carrillo-de-Albornoz, J., Morante, R., Amigó, E., Gonzalo, J., & Spina, D. (2023). Overview of EXIST 2023: sEXism Identification in Social neTworks. In *Experimental IR Meets Multilinguality, Multimodality, and Interaction: 14th International Conference of the CLEF Association, CLEF 2023* (pp. 593–599). Springer. doi: 10.1007/978-3-031-28241-6_68.
- [33] Franklin, D., Denny, P., Gonzalez-Maldonado, D. A., & Tran, M. (2025). *Generative AI in computer science education: Challenges and opportunities*. Cambridge University Press. doi: 10.1017/9781009581738.
- [34] Prather, J., Denny, P., Leinonen, J., Becker, B. A., Albluwi, I., Craig, M., & Savelka, J. (2023). The robots are here: Navigating the generative AI revolution in computing education. In *Proceedings of the 2023 Working Group Reports on Innovation and Technology in Computer Science Education* (pp. 108–159). ACM. doi: 10.1145/3623762.3633499.
- [35] Phung, T., Pădurean, V. A., Cambronero, J., Gulwani, S., Kohn, T., Majumdar, R., & Soares, G. (2023). Generative AI for programming education: Benchmarking ChatGPT, GPT-4, and human tutors. In *Proceedings of the 2023 ACM Conference on International Computing Education Research, Vol. 2* (pp. 41–42). ACM. doi: 10.1145/3568812.3603476.
- [36] Walters, W. H., & Wilder, E. I. (2023). Fabrication and errors in the bibliographic citations generated by ChatGPT. *Scientific Reports*, 13, 14045. doi: 10.1038/s41598-023-41032-5.
- [37] Majid, G. M., Tussyadiah, I., Kim, Y. R., & Pal, A. (2023). Intelligent automation for sustainable tourism: A systematic review. *Journal of Sustainable Tourism*, 31(11), 2421–2440. doi: 10.1080/09669582.2023.2246015.
- [38] De Villiers, C., Dimes, R., & Molinari, M. (2024). How will AI text generation and processing impact sustainability reporting? Critical analysis, a conceptual framework

- and avenues for future research. *Sustainability Accounting, Management and Policy Journal*, 15(1), 96–118. doi: 10.1108/SAMPJ-02-2023-0097.
- [39] Puh, K., & Bagić Babac, M. (2023). Predicting sentiment and rating of tourist reviews using machine learning. *Journal of Hospitality and Tourism Insights*, 6(3), 1188–1204. doi: 10.1108/JHTI-02-2022-0078.
- [40] Nikolić, M., Stojanović, M., & Marjanović, M. (2024). Anomaly detection in hotel reviews: Applying data science for enhanced review integrity. In *2024 32nd Telecommunications Forum (TELFOR)* (pp. 1–4). IEEE. doi: 10.1109/TELFOR63250.2024.10819036.
- [41] Hutto, C. J., & Gilbert, E. (2014). VADER: A parsimonious rule-based model for sentiment analysis of social media text. In *Proceedings of the International AAAI Conference on Web and Social Media*, 8(1), 216–225. doi: 10.1609/icwsm.v8i1.14550.
- [42] Nikolić, M., Stojanović, M., & Marjanović, M. (2024). Integrating data science and predictive modeling for detecting inconsistent hotel reviews. In *UNITECH 2024: Selected Papers* (pp. 104–110). Technical University of Gabrovo. doi: 10.70456/DHXA1258.
- [43] Nikolić, M., Stojanović, M., & Marjanović, M. (2025). Integrating deep learning for automated detection of negative hotel reviews. *Facta Universitatis, Series: Automatic Control and Robotics*, 24(1), 1–16. doi: 10.22190/FUACR241218002N.
- [44] Nikolić, M., Stojanović, M., & Marjanović, M. (2025). The power of words: Leveraging deep learning techniques to predict hotel ratings from user reviews. In *2025 24th International Symposium INFOTEH-JAHORINA* (pp. 1–6). IEEE. doi: 10.1109/INFOTEH64129.2025.10959201.
- [45] Nikolić, M., Stojanović, M., & Marjanović, M. (2026). Hotel rating prediction from online guest feedback using reliability modeling and neural text analysis. *Computers*, 15(6), 374. doi: 10.3390/computers15060374.
- [46] Xu, W., Yao, Z., Ma, Y., & Li, Z. (2025). Understanding customer complaints from negative online hotel reviews: A BERT-based deep learning approach. *International Journal of Hospitality Management*, 126, 104057. doi: 10.1016/j.ijhm.2024.104057.
- [47] Nikolić, M., Minić, N., & Marjanović, M. (2025). Leveraging transformer-based architectures for multi-label complaint detection and sentiment analysis in hotel feedback systems. *International Journal of Scientific Engineering and Science*, 9(11), 72–78. <https://ijses.com/wp-content/uploads/2025/11/58-IJSES-V9N11.pdf>

- [48] Larxel. (2020). *Trip Advisor Hotel Reviews* [Dataset]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/andrewmvd/trip-advisor-hotel-reviews>
- [49] Consumer Financial Protection Bureau. (n.d.). *Consumer Complaint Database* [Data set]. Dostupno na: <https://www.consumerfinance.gov/data-research/consumer-complaints/>
- [50] Nikolić, M., Rađenović, Ž., & Marjanović, M. (2026). Integracija multimodalnih modela mašinskog učenja za predikciju zadovoljstva korisnika hotelskih usluga. *Zbornik radova Akademije tehničko-vaspitačkih strukovnih studija*, 135–138. Dostupno na: https://akademijanis.edu.rs/akademijanis.edu.rs/wp-content/uploads/2026/03/Zbornik_radova_ATVSS_2025.pdf
- [51] Manosuthi, N., Lee, J. S., & Han, H. (2021). Causal-predictive model of customer lifetime value: Mediating roles of memorable experiences and customer engagement in hotels and airlines. *Journal of Travel & Tourism Marketing*, 38(5), 461–477. doi: 10.1080/10548408.2021.1943600.
- [52] Dursun-Cengizci, A., & Caber, M. (2024). Using machine learning methods to predict future churners: An analysis of repeat hotel customers. *International Journal of Contemporary Hospitality Management*, 36(10), 3432–3452. doi: 10.1108/IJCHM-06-2023-0844.
- [53] Nikolić, M., Rađenović, Ž., & Marjanović, M. (2025). Enhancing hotel management through predictive AI models for customer lifetime value (CLV). *Balkans Journal of Emerging Trends in Social Sciences*, 8(2), 123–137. doi: 10.31410/Balkans.JETSS.2025.8.2.123-137.
- [54] Antonio, N., de Almeida, A., & Nunes, L. (2019). Hotel booking demand datasets. *Data in Brief*, 22, 41–49. doi: 10.1016/j.dib.2018.11.126.
- [55] Mostipak, J. (2019). *Hotel Booking Demand* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/jessemostipak/hotel-booking-demand>
- [56] Liu, J. (2017). *515K Hotel Reviews Data in Europe* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/jiashenliu/515k-hotel-reviews-data-in-europe>
- [57] Nikolić, M., Marjanović, M., & Rađenović, Ž. (2026). Bridging behavioral and emotional intelligence: An interpretable multimodal deep learning framework for customer lifetime value estimation in the hospitality industry. *Mathematical and Computational Applications*, 31(2), 39. doi: 10.3390/mca31020039.

- [58] Zhang, D., & Wu, C. (2023). What online review features really matter? An explainable deep learning approach for hotel demand forecasting. *Journal of the Association for Information Science and Technology*, 74(9), 1100–1117. doi: 10.1002/asi.24807.
- [59] Binder, M., Heinrich, B., Hopf, M., & Schiller, A. (2022). Global reconstruction of language models with linguistic rules: Explainable AI for online consumer reviews. *Electronic Markets*, 32, 2123–2138. doi: 10.1007/s12525-022-00612-5.
- [60] Al-Hussein, W. A., Por, L. Y., Kiah, M. L. M., & Zaidan, B. B. (2022). Driver behavior profiling and recognition using deep-learning methods: In accordance with traffic regulations and expert guidelines. *International Journal of Environmental Research and Public Health*, 19(3), 1470. doi: 10.3390/ijerph19031470.
- [61] Bouhsissin, S., Sael, N., & Benabbou, F. (2023). Driver behavior classification: A systematic literature review. *IEEE Access*, 11, 14128–14153. doi: 10.1109/ACCESS.2023.3243344.
- [62] Kalampokas, T., Tziridis, K., Kalampokas, N., Nikolaou, A., Vrochidou, E., & Papakostas, G. A. (2023). A holistic approach on airfare price prediction using machine learning techniques. *IEEE Access*, 11, 46627–46643. doi: 10.1109/ACCESS.2023.3274669.
- [63] Ajayi, J., Xu, Y., Li, L., & Wang, K. (2024). Enhancing flight delay predictions using network centrality measures. *Information*, 15(9), 559. doi: 10.3390/info15090559.
- [64] Adavikottu, A., & Velaga, N. R. (2021). Analysis of factors influencing aggressive driver behavior and crash involvement. *Traffic Injury Prevention*, 22(Suppl. 1), S21–S26. doi: 10.1080/15389588.2021.1982960.
- [65] Martinelli, F., Marulli, F., Mercaldo, F., & Santone, A. (2021). Neural networks for driver behavior analysis. *Electronics*, 10(3), 342. doi: 10.3390/electronics10030342.
- [66] Ailurophile. (2019). *Aggressive Driving Data* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/veeralakrishna/aggressive-driving-data>
- [67] Nikolić, M., Stanković, M., Stojanović, M., & Marjanović, M. (2025). A deep learning approach to detecting aggressive drivers using behavioral and environmental metrics. In M. Zdravković, M. Trajanović, Z. Konjović, N. Filipović, & M. Ivković (Eds.), *ICIST 2025 Proceedings* (pp. 55–70). Dostupno na: <https://www.eventiotic.com/eventiotic/files/Papers/URL/c3775127-3481-49fa-ace4-51b1fc273c2f.pdf>

- [68] Stojanović, M., Nikolić, M., & Marjanović, M. (2025). Early detection of aggressive driving using LSTMs for sequential behavior analysis. In *2025 60th International Scientific Conference on Information, Communication and Energy Systems and Technologies (ICEST)* (pp. 1–4). IEEE. doi: 10.1109/ICEST66328.2025.11098181.
- [69] Gualini, A., Martini, G., & Porta, F. (2024). Are low cost carrier airfares still lower? A comparison with full service carriers in Europe. *Journal of the Air Transport Research Society*, 2, 100012. doi: 10.1016/j.jatrs.2024.100012.
- [70] Otręba, P., & Sawik, B. (2026). Determinants of airfares in the short-haul European market: An empirical study. *Expert Systems with Applications*, 301, 130266. doi: 10.1016/j.eswa.2025.130266.
- [71] Borsati, M., & Fageda, X. (2024). Airline price responses in the face of demand shocks: European lessons from the COVID-19 pandemic. *Transportation Research Part E: Logistics and Transportation Review*, 186, 103537. doi: 10.1016/j.tre.2024.103537.
- [72] Stojanović, M., & Nikolić, M. (2026). Evaluating passenger segment sensitivity and reliability in airline satisfaction AI systems. In *Zbornik radova XXV međunarodnog simpozijuma INFOTEH-JAHORINA 2026* (pp. 97–102). Dostupno na: <https://infotech.etf.ues.rs.ba/zbornik/2026/radovi/343.pdf>
- [73] Yakhyojon. (2023). *Customer Satisfaction in Airline* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/yakhyojon/customer-satisfaction-in-airline>
- [74] Laputsky, V. (lunthu). (2025). *European Airports & Air Routes* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/lunthu/european-airlines-routes>
- [75] Alantari, H. J., Currim, I. S., Deng, Y., & Singh, S. (2022). An empirical comparison of machine learning methods for text-based sentiment analysis of online consumer reviews. *International Journal of Research in Marketing*, 39(1), 1–19. doi: 10.1016/j.ijresmar.2021.10.011.
- [76] Kyriakidis, A., & Tsafarakis, S. (2025). Extracting knowledge from customer reviews: An integrated framework for digital platform analytics. *International Transactions in Operational Research*, 32(4), 2061–2086. doi: 10.1111/itor.13537.
- [77] Olga G. (Miufana1). (2024). *Fragrantica.com Fragrance Dataset* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/olgagmiufana1/fragrantica-com-fragrance-dataset>

- [78] R4DS TidyTuesday. (2024). *The Scent of Data: Exploring the Parfumo Fragrance Dataset* [Data set]. GitHub. Podaci izvorno potiču sa platforme Parfumo i prikupljeni su web-scrape postupkom od strane Olga G. Dostupno na: <https://github.com/rfordatascience/tidytuesday/blob/main/data/2024/2024-12-10>
- [79] McAuley, J., & Leskovec, J. (2013). From amateurs to connoisseurs: Modeling the evolution of user expertise through online reviews. In *Proceedings of the 22nd International Conference on World Wide Web* (pp. 897–908). ACM. doi: 10.1145/2488388.2488466.
- [80] Nikolić, M., Stojanović, M., & Marjanović, M. (2024). Data science techniques for analyzing note trends and brand progression in the perfume industry. *International Journal of Management and Applied Science*, 10(11), 20–25. Dostupno na: https://www.iraj.in/journal/journal_file/journal_pdf/14-1052-174409594620-25.pdf
- [81] Nikolić, M., Marjanović, M., & Rađenović, Ž. (2025). Primena mašinskog učenja za predikciju popularnosti parfema: analiza mirisnih nota i potrošačkog ponašanja. *Zbornik radova Akademije tehničko-vaspitačkih strukovnih studija*, 64–67. Dostupno na: https://akademijanis.edu.rs/akademijanis.edu.rs/wp-content/uploads/2025/04/Zbornik_radova_ATVSS_2024.pdf
- [82] Nikolić, M., & Marjanović, M. (2025). Data science meets fragrance: Analyzing user reviews to decode emotional connections to perfume notes. In *Sinteza 2025 – International Scientific Conference on Information Technology, Computer Science, and Data Science* (pp. 213–220). Singidunum University. doi: 10.15308/Sinteza-2025-213-220.
- [83] Vashishtha, S., Gupta, V., & Mittal, M. (2023). Sentiment analysis using fuzzy logic: A comprehensive literature review. *WIREs Data Mining and Knowledge Discovery*, 13(5), e1509. doi: 10.1002/widm.1509.
- [84] Subhashini, L. D. C. S., Li, Y., Zhang, J., & Atukorale, A. S. (2020). Integration of fuzzy and deep learning in three-way decisions. In *2020 IEEE International Conference on Data Mining Workshops (ICDMW)* (pp. 71–78). IEEE. doi: 10.1109/ICDMW51313.2020.00019.
- [85] Fumanal-Idocin, J., Jamalifard, M., & Andreu-Perez, J. (2026). Interpreting contrastive embeddings in specific domains with fuzzy rules. *arXiv preprint arXiv:2603.12227*. doi: 10.48550/arXiv.2603.12227.

- [86] Rodríguez-Sánchez, F., Carrillo-De-Albornoz, J., & Plaza, L. (2024). Detecting sexism in social media: An empirical analysis of linguistic patterns and strategies. *Applied Intelligence*, 54(21), 10995–11019. doi: 10.1007/s10489-024-05795-2.
- [87] Nikolić, M. (2025). *Razvoj modela dubokog učenja za detekciju mizoginih obrazaca u interakcijama na društvenim mrežama* [Studentski naučno-istraživački projekat]. Univerzitet Singidunum, Departman za posleddiplomske studije, Doktorske akademske studije, studijski program Inteligentno softversko inženjerstvo.
- [88] Fersini, E., Gasparini, F., & Rizzi, G. (2022). SemEval-2022 Task 5: Multimedia Automatic Misogyny Identification. In *Proceedings of the 16th International Workshop on Semantic Evaluation (SemEval-2022)* (pp. 533–549). Association for Computational Linguistics. doi: 10.18653/v1/2022.semeval-1.74.
- [89] Singh, A. (2024). *Sexism Detection in English Texts* [Data set]. Kaggle. Dostupno na: <https://www.kaggle.com/datasets/aadyasingh55/sexism-detection-in-english-texts>
- [90] Areshey, A., & Mathkour, H. (2024). Exploring transformer models for sentiment classification: A comparison of BERT, RoBERTa, ALBERT, DistilBERT, and XLNet. *Expert Systems*, 41(11), e13701. doi: 10.1111/exsy.13701.
- [91] Mohasseb, A., Amer, E., Chiroma, F., & Tranchese, A. (2025). Leveraging advanced NLP techniques and data augmentation to enhance online misogyny detection. *Applied Sciences*, 15(2), 856. doi: 10.3390/app15020856.
- [92] Vinuesa, R., Azizpour, H., Leite, I., Balaam, M., Dignum, V., Domisch, S., Felländer, A., Langhans, S. D., Tegmark, M., & Fuso Nerini, F. (2020). The role of artificial intelligence in achieving the Sustainable Development Goals. *Nature Communications*, 11, 233. doi: 10.1038/s41467-019-14108-y.
- [93] Nishant, R., Kennedy, M., & Corbett, J. (2020). Artificial intelligence for sustainability: Challenges, opportunities, and a research agenda. *International Journal of Information Management*, 53, 102104. doi: 10.1016/j.ijinfomgt.2020.102104.
- [94] Belkaid, O., & Kummitha, H. R. (2026). Artificial intelligence in sustainable tourism development: A critical review of governance and managerial implications. *Discover Sustainability*. doi: 10.1007/s43621-026-03251-4.
- [95] Publications Office of the European Union. (n.d.). *CORDIS – EU Research Projects under HORIZON EUROPE (2021–2027)* [Data set]. Dostupno na: <https://data.europa.eu/data/datasets/cordis-eu-research-projects-under-horizon-europe-2021-2027?locale=en>

- [96] Patterson, D., Gonzalez, J., Le, Q., Liang, C., Munguia, L. M., Rothchild, D., So, D., Texier, M., & Dean, J. (2021). Carbon emissions and large neural network training. *arXiv preprint*. doi: 10.48550/arXiv.2104.10350.
- [97] Rani, P., Zellweger, J., Kousadianos, V., Cruz, L., Kehrer, T., & Bacchelli, A. (2024). Energy patterns for web: An exploratory study. In *Proceedings of the 46th International Conference on Software Engineering: Software Engineering in Society (ICSE-SEIS)* (pp. 12–22). ACM. doi: 10.1145/3639475.3640110.
- [98] Blagojević, D., & Nikolić, M. (2026). Minifikacija CSS i JavaScript fajlova u okviru Green Coding principa. *Zbornik radova Akademije tehničko-vaspitačkih strukovnih studija*, 139–142. Dostupno na: https://akademijanis.edu.rs/akademijanis.edu.rs/wp-content/uploads/2026/03/Zbornik_radova_ATVSS_2025.pdf
- [99] Kasneci, E., Sessler, K., Küchemann, S., Bannert, M., Dementieva, D., Fischer, F., Gasser, U., Groh, G., Günemann, S., Hüllermeier, E., Krusche, S., Kutyniok, G., Michaeli, T., Nerdel, C., Pfeffer, J., Poquet, O., Sailer, M., Schmidt, A., Seidel, T., Stadler, M., Weller, J., Kuhn, J., & Kasneci, G. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. doi: 10.1016/j.lindif.2023.102274.
- [100] Yilmaz, R., & Yilmaz, F. G. K. (2023). The effect of generative artificial intelligence (AI) based tool use on students' computational thinking skills, programming self-efficacy and motivation. *Computers and Education: Artificial Intelligence*, 4, 100147. doi: 10.1016/j.caeai.2023.100147.
- [101] Boguslawski, S., Deer, R., & Dawson, M. G. (2025). Programming education and learner motivation in the age of generative AI: Student and educator perspectives. *Information and Learning Sciences*, 126(1/2), 91–109. doi: 10.1108/ILS-10-2023-0163.
- [102] Nikolić, M., & Marjanović, M. (2025). When students asked ChatGPT instead of me: Investigating generative AI in programming education through NLP and pedagogical analytics. *Engineering and Technology Journal*, 10(11), 7939–7946. doi: 10.47191/etj/v10i11.25.
- [103] Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y. J., Chen, D., Dai, W., Madotto, A., & Fung, P. (2023). Survey of hallucination in natural language generation. *ACM Computing Surveys*, 55(12), Article 248. doi: 10.1145/3571730.