

Razvoj metodološkog pristupa u optimizaciji biciklističkih ruta integracijom višekriterijskih GIS analiza i strojnog učenja

Đerek, Jurica

Doctoral thesis / Disertacija

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture / Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:179:578887>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2025-02-20**



Repository / Repozitorij:

[Repository of the Faculty of Electrical Engineering, Mechanical Engineering and Naval Architecture - University of Split](#)



SVEUČILIŠTE U SPLITU
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I BRODOGRADNJE

Jurica Đerek

**RAZVOJ METODOLOŠKOG PRISTUPA U
OPTIMIZACIJI BICIKLISTIČKIH RUTA
INTEGRACIJOM VIŠEKRITERIJSKIH GIS
ANALIZA I STROJNOG UČENJA**

DOKTORSKA DISERTACIJA

Split, 2024.

SVEUČILIŠTE U SPLITU
FAKULTET ELEKTROTEHNIKE, STROJARSTVA I BRODOGRADNJE

Jurica Đerek

***Razvoj metodološkog pristupa u optimizaciji biciklističkih
ruta integracijom višekriterijskih GIS analiza i strojnog
učenja***

DOKTORSKA DISERTACIJA

Split, 2024.

Doktorska disertacija je izrađena na Zavodu za elektroniku i računarstvo, Fakulteta elektrotehnike, strojarstva i brodogradnje.

Mentor: Marjan Sikora

Rad br. 201

PODACI ZA BIBLIOGRAFSKU KARTICU

Ključne riječi: Optimizacija biciklističkih ruta, višekriterijska GIS analiza, strojno učenje, neuronske mreže, hibridni model, ruralna područja, turistička atraktivnost

Znanstveno područje: Tehničke znanosti

Znanstveno polje: Računarstvo

Znanstvena grana: Obradba informacija

Institucija na kojoj je rad izrađen: Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje

Mentor rada: prof. dr. sc. Marjan Sikora

Broj stranica: 140

Broj slika: 68

Broj tablica: 18

Broj korištenih bibliografskih jedinica: 149

Povjerenstvo za ocjenu doktorske disertacije:

1. prof. dr. sc. Vladan Papić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
2. prof. dr. sc. Sven Gotovac, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
3. izv. prof. dr. sc. Ante Šiljeg, Sveučilište u Zadru, Odjel za geografiju, Zadar
4. prof. dr. sc. Ljiljana Šerić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
5. izv. prof. dr. sc. Marin Bugarić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split

Povjerenstvo za obranu doktorske disertacije:

1. prof. dr. sc. Vladan Papić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
2. prof. dr. sc. Sven Gotovac, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
3. izv. prof. dr. sc. Ante Šiljeg, Sveučilište u Zadru, Odjel za geografiju, Zadar
4. prof. dr. sc. Ljiljana Šerić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split
5. izv. prof. dr. sc. Marin Bugarić, Sveučilište u Splitu, Fakultet elektrotehnike, strojarstva i brodogradnje, Split

Disertacija obranjena dana: 13. rujna 2024.

Razvoj metodološkog pristupa u optimizaciji biciklističkih ruta integracijom višekriterijskih GIS analiza i strojnog učenja

Sažetak:

Tema ove doktorske disertacije je razvoj metodološkog pristupa za optimizaciju biciklističkih ruta u ruralnom području koristeći metode višekriterijske GIS analize (engl. Multi-Criteria Decision Analysis - Geographic Information Systems MCDA-GIS) i strojnog učenja. Biciklističke rute u ruralnim područjima obogaćuju turističku ponudu, a pažljivim odabirom adekvatne i personalizirane rute osigurava se zadovoljstvo posjetitelja. Kriteriji relevantni za odabir biciklističkih ruta odabrani su pregledom literature i provođenjem intervjua i anketa među ispitanicima koji su aktivni u biciklizmu. Prikupljene informacije o njihovim preferencijama prilikom odabira biciklističke rute poslužile su u pristupu višekriterijske GIS analize da se pomoću AHP (engl. *Analytical Hierarchy Method*) metode odredi ponderirana linearna kombinacija vrijednosti kojom se opisuje razina prikladnost za svaki segment promatrane cestovne mreže. Optimalna biciklistička ruta kojom se povezuju točke od interesa određuje se Dijkstra algoritmom koji koristi informacije o prikladnosti rute. Nadalje, disertacija istražuje zamjenu tradicionalnih metoda optimizacije biciklističkih ruta s pristupom temeljenim na strojnim učenju, što predstavlja moderniji i manje zahtjevan pristup koji je manje podložan subjektivnim procjenama, neizbježnima u tradicionalnim metodama. U kreiranju ruta korišten je hibridni model koji kombinira model strojnog učenja s Dijkstra algoritmom. Model strojnog učenja treniran je na područjima s postojećim biciklističkim stazama. Istrenirani model testiran je na poznatom području, a dobivene rute uspoređene su s rutama dobivenim tradicionalnim pristupom. Kvalitativna validacija modela provedena je usporedbom s rutama temeljenim na podacima iz karte intenziteta (engl. *heatmap*), pri čemu je uočeno značajno preklapanje. Ovi rezultati potvrđuju potencijal primjene strojnog učenja za optimizaciju biciklističkih ruta, predstavljajući objektivniju alternativu tradicionalnim metodama.

Ključne riječi:

Optimizacija biciklističkih ruta, višekriterijska GIS analiza, strojno učenje, neuronske mreže, hibridni model, ruralna područja, turistička atraktivnost

Development of a Methodological Approach for Optimization of Bicycle Routes Through the Integration of Multi-Criteria GIS Analysis and Machine Learning

Abstract:

The topic of this doctoral dissertation is the development of a methodological approach for optimizing cycling routes in rural areas using Multi-Criteria Decision Analysis - Geographic Information Systems (MCDA-GIS) and machine learning methods. Cycling routes in rural areas enrich the tourist offering, and the careful selection of adequate and personalized routes ensures visitor satisfaction. The criteria relevant for selecting cycling routes were chosen through a review of the literature and by conducting interviews and surveys among respondents active in cycling. The collected information on their preferences when choosing a cycling route was used in the multi-criteria GIS analysis approach to determine a weighted linear combination of values describing the level of suitability for each segment of the observed road network using the Analytical Hierarchy Method (AHP). The optimal cycling route connecting points of interest is determined by the Dijkstra algorithm, which uses information about route suitability. Furthermore, the dissertation explores the replacement of traditional methods for optimizing cycling routes with a machine learning-based approach, representing a more modern and less demanding method that is less susceptible to subjective assessments inherent in traditional methods. A hybrid model combining a machine learning model with the Dijkstra algorithm was used in route creation. The machine learning model was trained in areas with existing cycling paths. The trained model was tested in a known area, and the obtained routes were compared with those generated by the traditional approach. Qualitative validation of the model was conducted by comparing it with routes based on heatmap data, revealing significant overlap. These results confirm the potential of applying machine learning for optimizing cycling routes, presenting a more objective alternative to traditional methods.

Keywords:

Bicycle route optimization, Multi-criteria GIS analysis, Machine learning, Neural networks, Hybrid model, Rural areas, Touristic attractiveness

Zahvala

Hvala svima koji su mi pružili podršku svojim savjetima, podržavajućim riječima, strpljenjem i poticajem tijekom nastanka ove disertacije.

Posebnu zahvalu dugujem mentoru prof. dr. sc. Marjanu Sikori na strpljenju, inspirativnoj podršci i neizmjernom angažmanu koji su mi omogućili da ostvarim ovu disertaciju.

Sadržaj

Sažetak	iv
Abstract	vi
Zahvala	ix
Popis tablica	xii
Popis slika	xv
1. UVOD	1
1.1. Hipoteze	3
1.2. Organizacija rada	4
2. PREGLED POSTOJEĆIH METODA	5
2.1. Višekriterijska GIS analiza	5
2.1.1. AHP metoda	8
2.1.2. Neizrazita AHP metoda	13
2.1.3. Teorija grafova i višekriterijska analiza	19
2.2. Strojno učenje	24
2.2.1. Klasifikacijska analiza	27
2.2.2. Regresijska analiza	28
2.2.3. Support Vector Machine - SVM	30
2.2.4. Duboko učenje	32
2.2.5. GIS i duboko učenje	41
3. METODE ISTRAŽIVANJA	47
3.1. Ulazni podaci	47
3.2. Višekriterijska GIS analiza	54

3.2.1.	Provođenje istraživanja preferencija među biciklistima	55
3.2.2.	Modeliranje biciklističkih ruta koristeći višekriterijsku analizu	63
3.3.	Primjena strojnog učenja	70
3.3.1.	Modeliranje biciklističkih ruta koristeći hibridni model	71
4.	REZULTATI I DISKUSIJA	83
4.1.	Rezultati kvantitativne analize istraživanja	83
4.2.	Biciklističke rute generirane pomoću višekriterijske GIS analize	93
4.2.1.	Provjera rezultata višekriterijske GIS analize	95
4.3.	Biciklističke rute generirane pomoću strojnog učenja i neuronskih mreža u hibridnom modelu	103
4.3.1.	Korištenje rekurentne neuronske mreže za izračun staza	104
4.3.2.	Korištenje SVM za izračun staza	109
4.3.3.	Korištenje <i>Feed Forward</i> NN za izračun staza	111
4.3.4.	Usporedba rezultata triju modela strojnog učenja	113
4.4.	Usporedba korištenja višekriterijske GIS analize i hibridnog modela sa ne- uronskim mrežama	115
5.	ZAKLJUČAK	123
	LITERATURA	127
	KRATICE	137

Popis tablica

3.1. Pregled pondera za kriterije u višekriterijskoj analizi	67
3.2. AHP: usporedba svaki-sa-svakim	69
3.3. AHP: normalizirana tablica usporedbe svaki-sa-svakim	69
3.4. Pomoćna tablica za izračun indeksa konzistentnosti	69
3.5. Slučajni indeksi (RI) za različite dimenzije tablice	70
3.6. Podaci o stazama	72
3.7. Dio ulaznih podataka dobiveni od staze "Mate Svjetskog", Vrgorac	77
3.8. Broj segmenata po gradu	77
3.9. Parametri treninga neuronske mreže	81
4.1. Rangiranje kriterija pri odabiru rute - osobno	90
4.2. Rangiranje kriterija pri odabiru rute - drugi	91
4.3. Preklapanje duljine i broja segmenata za radijus 20 px (A - anaterska, P - profesionalna)	101
4.4. Srednja kvadratna pogreška (MSE) izračunata unakrsnom validacijom za modele slojevite rekurentne NN.	104
4.5. Rezultati verifikacije modela	105
4.6. Broj segmenata koji ulaze u mrežu kao dio odabrane staze.	108
4.7. Usporedba MSE različitih SVM algoritama	110
4.8. Usporedba rezultata LR NN, SVM i FFNN	115
4.9. Usporedba biciklističkih ruta u Imotskom dobivenih modelom višekriterijske GIS analize i neuronske mreže treniranom na području Vrgorca i Knina	118

Popis slika

2.1. Hijerarhijska struktura problema odluke	9
2.2. Trokutasti neizraziti broj	14
2.3. Dijagram metoda izračuna težina iz neizrazite trokutaste matrice	15
2.4. Grafički prikaz vjerojatnosti $\tilde{S}_i \geq \tilde{S}_j$	16
2.5. Primjer grafa	19
2.6. Ilustracija pretraživanja po dubini	20
2.7. Ilustracija pretraživanja po širini	21
2.8. Grafikon vrsta strojnog učenja	27
2.9. Model linearne regresije	33
2.10. Veza dvaju neurona	34
2.11. Troslojna feedforward neuronska mreža	35
2.12. Feedback neuronska mreža	36
2.13. Rekurentna mreža prikazana u vremenskim koracima	41
3.1. TK25 i sloj cesta na području Imotskog	50
3.2. Slojnice na području Imotskog	51
3.3. TIN (Triangulated Irregular Network) model reljefa	52
3.4. Dijalog s parametrima Network Analysta	67
3.5. Primjer rezultata korištenja Network Analysta za izračun rute	68
3.6. Staza "Tri polja" Vrgorac	73
3.7. Staza "Mate Svjetskog" Vrgorac	73
3.8. Staza "Lopuška glavica" Knin	74
3.9. "Napoleonova staza" Knin.	74
3.10. Mreža cesta Knin	75

3.11. Mreža cesta Vrgorac	76
3.12. Dijagram s objašnjenjem postupka izračuna rute.	78
3.13. Arhitektura slojevite rekurentne neuronske mreže	79
3.14. Usporedba grafova i derivacija tansig i tanh aktivacijskih funkcija	81
4.1. Rod sudionika (%)	84
4.2. Dobna struktura sudionika	84
4.3. Članstvo u biciklističkim udrugama/klubovima	85
4.4. Učestalost bicikliranja	85
4.5. Svrha korištenja bicikla	86
4.6. Graf prijeđenih kilometara u uobičajenom radnom tjednu	86
4.7. Graf prijeđenih kilometara u uobičajenom godišnjem odmoru	87
4.8. Graf najduže prijeđene rute	87
4.9. Usporedba prosječne prijeđene kilometraže kod sudionika koji koriste bicikl za turizam i onih koji ga ne koriste	88
4.10. Graf važnih kriterija pri odabiru biciklističke rute - spontano dosjećanje	89
4.11. Graf ocjene važnosti pojedinog kriterija odabira staze	90
4.12. Graf usporedbe osobnih i tuđih prioriteta pri odabiru rute	91
4.13. Graf usporedbe izvora informiranja o biciklističkim rutama	92
4.14. Grafički prikaz alata korištenih za planiranje rute	92
4.15. Graf interesa za korištenje nove aplikacije	93
4.16. Amaterska biciklistička ruta izabrana višekriterijskom GIS analizom	94
4.17. Profesionalna biciklistička ruta izabrana višekriterijskom GIS analizom	95
4.18. Segment Vinjani Donji - Most Runović na aplikaciji Strava	97
4.19. Stravina biciklistička karta intenziteta na području Imotskog	98
4.20. Obradena slika karte intenziteta biciklizma na području Imotskog	98
4.21. Histogram frekvencije piksela	99
4.22. Točke karte intenziteta nakon korištenja Raster to points alata	99
4.23. Nakon korištenja Feature Vertices to Points alata na sredini svakog segmenta je točka koja predstavlja segment	100

4.24. Prikaz točki karte intenziteta jednog segmenta i radijusa 230 m oko centroida	101
4.25. Grafički prikaz preklapanja postotka duljine staze i postotka broja segmenata	102
4.26. Primjer preklapanja profesionalne staze radijusa preklapanja 20 px	103
4.27. Rezultati verifikacije modela - postotak preklapanja duljine u kod unakrsne provjere.	106
4.28. LRNN - Vrgorački amaterski model na kninskim cestama	106
4.29. LRNN - Vrgorački profesionalni model na kninskim cestama	107
4.30. LRNN - Kninski amaterski model na vrgoračkim cestama	108
4.31. LRNN - Kninski profesionalni model na vrgoračkim cestama	109
4.32. Obuhvat cesta u Kninu za različit broj segmenata	110
4.33. SVM amaterski model treniran na kninskim cestama, iskorišten u Vrgorcu .	111
4.34. SVM profesionalni model treniran na kninskim cestama, iskorišten u Vrgorcu	112
4.35. FFNN amaterski model treniran na kninskim cestama, iskorišten u Vrgorcu	113
4.36. FFNN profesionalni model treniran na kninskim cestama, iskorišten u Vrgorcu	114
4.37. Grafički prikaz postotka preklapanja duljine i broja segmenata kod različitih pristupa hibridnom modelu	115
4.38. Usporedba - amaterska staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Vrgorcu	116
4.39. Usporedba - profesionalna staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Vrgorcu	117
4.40. Postotak preklapanja duljine između rezultata višekriterijske GIS analize i neuronske mreže trenirane na području Vrgorca i Knina za biciklističke rute u Imotskom	118
4.41. Usporedba - profesionalna staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Kninu	119

1. UVOD

Razvijanje cikloturizma kao grane turizma donosi brojne prednosti, uključujući poboljšanje zdravlja, ekonomske koristi za odredište te povezivanje s drugim oblicima sportskih i rekreacijskih aktivnosti [1]. Biciklistički turizam ima važnu ulogu u turističkoj ponudi ruralnih područja jer pruža mogućnost da se takva okolina doživi na jedinstven način [2]. Kako bi se potaknula upotreba bicikala, potrebna je infrastruktura koja omogućuje sigurniju i praktičniju vožnju biciklom [3].

Ova doktorska disertacija bavi se optimizacijom biciklističkih ruta kao dijela turističke ponude, koristeći napredne metode višekriterijske GIS analize i strojnog učenja.

Kreiranje ruta koje zadovoljavaju potrebe kako amaterskih, tako i zahtjevnijih, profesionalnih biciklista zahtijeva sveobuhvatnu analizu i integraciju različitih faktora – od topografskih karakteristika do sigurnosnih aspekata. U ovom radu razvijen je metodološki okvir koji omogućuje takvu analizu. Istraživanje je provedeno u području grada Imotskog, zanimljivom zbog svog položaja: udaljen je od gužve tradicionalnih turističkih mjesta, a istovremeno je blizu obale.

Cilj ovog rada je razvoj i validacija metodološkog pristupa za kreiranje biciklističkih ruta u ruralnim područjima. To uključuje identifikaciju ključnih faktora koji utječu na planiranje biciklističkih ruta u ruralnim kontekstima. U istraživanju su korišteni kvantitativni i kvalitativni pristupi za ispitivanje preferencija biciklista, pri čemu su aktivni biciklisti anketirani o svojim preferencijama prilikom bicikliranja.

Kao izvor podataka su korišteni prethodno vektorizirani podaci s pridodanim atributima. Kao podloga je korištena topografska karta Državne geodetske uprave u mjerilu 1:25000. Sloj cesta sastoji se od polilinja, gdje je osnovna jedinica za informaciju o prikladnosti za bicikliste segment ceste između dva raskrižja.

Razmotreni kriteriji su integrirani u višekriterijsku GIS analizu (MCDA-GIS, eng. *Multi-Criteria Decision Analysis*), koja služi kao alat za izradu modela za odabir optimalne rute između turističkih točaka interesa. U analizi se koriste Analitički hijerarhijski proces (AHP - engl. *Analytical Hierarchy Process*) za dodjelu težina kriterijima te Dijkstra algoritam i teorija grafova za povezivanje točaka interesa. Na temelju rezultata višekriterijske GIS analize, u ovom radu su predložene dvije vrste ruta koje povezuju devet turistički atraktivnih lokacija.

Višekriterijska GIS analiza prikazana u radu verificirana je usporedbom s kartama intenziteta (engl. *heatmaps*) dostupnih na servisu Strava. Ovaj servis skuplja informacije o učestalosti korištenja pojedinih segmenata cesta od strane biciklista, što se može smatrati *ground truth* podacima. Ovi podaci su javno objavljeni u obliku mapa, koje su nakon obrade upotrijebljene za provjeru rezultata modela višekriterijske GIS analize.

Nakon višekriterijske analize, postavilo se pitanje kako integrirati ekspertno znanje saržano u rutama koje je odabrao ljudski ekspert u model i primijeniti ga na sličnim topografskim područjima. Stoga je istraživanje uključilo primjenu strojnog učenja, uključujući duboko učenje, kao njegovu podvrstu. Za treniranje modela korištene su postojeće biciklističke rute u Dalmatinskoj zagori (Vrgorac i Knin), kako bi se modelu prenijelo znanje o preferencijama pri bicikliranju. Razvijeni modeli dubokog učenja dodijelili su svakom segmentu mreže cesta vrijednost prikladnosti prema preferencijama biciklista. Nadalje, u radu je predstavljen hibridni model koji kombinira Dijkstra algoritam s algoritmima strojnog i dubokog učenja.

Hibridni model je evaluiran kroz unakrsnu verifikaciju. Biciklističke rute koje su poslužile za treniranje modela strojnog i dubokog učenja su međusobno kombinirane na sljedeći način: model treniran na lokaciji 1 je kreirao rute na lokaciji 2, koje su zatim uspoređene s rutama kreiranim od strane stručnjaka na lokaciji 2. Postupak je ponovljen zamjenom lokacija, pri čemu je model treniran na lokaciji 2 kreirao rute na lokaciji 1, uspoređujući ih s rutama koje su eksperti kreirali na lokaciji 1. Nakon unakrsne provjere, hibridni model je primijenjen za generiranje biciklističkih ruta na području Imotskog. Rezultati generirani pomoću hibridnog modela su uspoređeni s rutama koje su stvorene pomoću modela višekriterijske

GIS analize na istom području.

Rezultati su pokazali da je metodološki pristup baziran na višekriterijskoj analizi efikasan, gdje odabrani kriteriji i pripadajući ponderi odražavaju stvarne preferencije pri odabiru biciklističke rute u ruralnom području. Nadalje, korištenje hibridnog modela se pokazalo korisnim i efikasnim u kreiranju biciklističkih ruta. Oba pristupa su identificirala potrebe biciklista i tako generirali rute u kojima su izbalansirani kriteriji sigurnosti, pristupačnosti i turističke atraktivnosti, pri čemu hibridni model olakšava planiranje biciklističkih ruta. Evaluacija modela pokazala je njihovu sposobnost da predvide rute koje zadovoljavaju potrebe i preferencije korisnika, što ukazuje na praktičnu primjenjivost modela u stvarnim uvjetima ruralne okoline.

1.1. Hipoteze

Za istraživanje su postavljene sljedeće hipoteze:

- Moguće je korištenjem MCDA-GIS i AHP metode i teorijom grafova napraviti sustav koji će odrediti najpovoljniju biciklističku rutu između dvije ili više točaka unutar mreže na ruralnom području. Pri tome treba voditi računa o broju kriterija, vrsti kriterija i ponderu kojim će se množiti svaki od kriterija, odnosno, koliko određeni kriterij pridonosi ukupnoj slici o odabiru pojedinog segmenta staze. Ova hipoteza će se ispitati koristeći dva pristupa: prvi pristup uključuje kriterije koji će biti odabrani za bicikliste amatere, dok drugi model uključuje kriterije za zahtjevnije bicikliste.
- Moguće je stvoriti hibridni model GIS analize i strojnog ili dubokog učenja koji će odrediti najpovoljniju biciklističku rutu između dvije ili više točaka unutar mreže na ruralnom području. Ovakav model bi se istrenirao na cestovnoj mreži s labeliranim segmentima koji čine ground truth podatke. Model bi treniranjem preuzeo ekspertno znanje, koje bi se onda primijenilo na drugom području. Ovu hipotezu će se ispitati tako da izlaz iz treniranog modela bude informacija koliko je određeni segment prigodan za namjenu staze koja treba biti izabrana. Nakon dobivene informacije o pogodnosti segmenta, koristi se graf i odgovarajući algoritam traženja putanje da poveže

točke interesa i tako se dobije najpogodniji put između točaka.

1.2. Organizacija rada

Doktorska disertacija se sastoji od 5 numeriranih poglavlja; disertacija počinje s uvodnim poglavljem u kojem se ističe važnost biciklizma kao održivog načina prijevoza i turističke aktivnosti, posebno u ruralnim područjima. Detaljno se opisuje motivacija za istraživanje, ciljevi disertacije i predstavljene su hipoteze koje će se provjeriti. Uvod obuhvaća kratki opis i motivaciju istraživanja, sažeto se opisuju metodologije istraživanja, rezultati i pripadajući zaključci. Drugo poglavlje posvećeno je pregledu postojećih metoda u optimizaciji biciklističkih ruta. Analiziraju se prednosti višekriterijske GIS analize, kao i različiti pristupi strojnom učenju relevantni za modeliranje ruta. Poglavlje također uključuje opis različitih algoritama i tehnika dubokog učenja koje se mogu koristiti u kontekstu biciklizma. Treće poglavlje detaljno opisuje metodologiju koja se koristi u istraživanju. Pojašnjava se kako su korištene višekriterijska GIS analiza i kombinacije metoda strojnog učenja s Dijkstra algoritmom u svrhu optimizacije ruta. Poglavlje obuhvaća opis korištenih podataka, opis provedenog istraživanja na biciklistima da bi se dobila informacija o preferencijama prilikom odabira rute, opis kriterija za evaluaciju ruta, kao i proces prikupljanja i obrade podataka. U četvrtom poglavlju predstavljeni su rezultati dobiveni primjenom razvijenog metodološkog pristupa. Uspoređuje se učinkovitost višekriterijske GIS analize i hibridnog modela te analiziraju prednosti i moguća ograničenja svakog pristupa. Poglavlje također sadrži diskusiju o praktičnoj primjenjivosti rezultata u planiranju biciklističke infrastrukture. Zaključno poglavlje sumira ključne nalaze istraživanja i završava preporukama za buduća istraživanja i potencijalne primjene razvijenog metodološkog pristupa.

2. PREGLED POSTOJEĆIH METODA

U ovom poglavlju su uvedene metode višekriterijske GIS analize i strojnog učenja kao uvod u teme koje su obrađene u radu, pružajući pregled relevantne znanstvene literature i prethodnih istraživanja. Detaljno su razmotrene AHP (Analitički hijerarhijski proces) i FAHP (Neizraziti analitički hijerarhijski proces) kao pristupi u domeni višekriterijske analize. Također su objašnjene vrste algoritama strojnog učenja s posebnim naglaskom na dubokom učenju.

2.1. Višekriterijska GIS analiza

Geografski informacijski sustavi (GIS) predstavljaju računalne sustave za prikupljanje, spremanje, ispitivanje, analizu i prikaz geoprostornih podataka [4]. Geoprostorni podaci istovremeno opisuju lokaciju i atribute prostornih značajki. GIS daje mogućnost izmjene atributa prostornih značajki prema njihovoj lokaciji. Ovisno o načinu prikaza obilježja u prostoru, geoprostorni podaci mogu biti prikazani kao diskretni ili kontinuirani podaci, odnosno, u rasterskom ili vektorskom obliku [5]. Hardver GIS-a uključuje računala za obradu podataka, pohranu podataka i ulaz/izlaz; printere i plottere za tiskanje karata; digitalizatore i skenere za digitalizaciju prostornih podataka; te Globalni sustav pozicioniranja (GPS) i prijenosne uređaje za terenski rad. GIS softver, bilo komercijalan ili otvorenog koda, obuhvaća programe i aplikacije koje se izvršavaju na računalu za upravljanje podacima, analizu podataka, prikaz podataka i druge zadatke. Dodatne aplikacije mogu se koristiti u GIS-u za specifične analize podataka.

Donošenje odluka temeljenih na analizi dostupnih podataka je jedna od najvažnijih primjena GIS-a [6]. Da bi se donijela što utemeljenija odluka, u izračun je potrebno uključiti što

veći broj kriterija. Takva analiza se naziva višekriterijska GIS analiza [7]. Postoje dva pristupa na koji se realizira višekriterijska GIS analiza; prvi pristup uzima u obzir da su ulazni podaci u binarnom obliku, odnosno, da imaju vrijednosti 0 ili 1 što predstavlja laž ili istinu. Korišteniji i često bolji pristup je onaj u kojem se za odluku koriste podaci s kontinuiranim vrijednostima. Takvi podaci s kontinuiranim vrijednostima se skaliraju na zajednički raspon i nakon toga kombinirani zajedno s pridijeljenim težinskim faktorima. Takav pristup se naziva Ponderirana linearna kombinacija [8] (engl. *Weighted Linear Combination - WLC*).

Uvođenje ponderirane linearne kombinacije u GIS predstavlja ključni korak prema praktičnijoj analizi prostornih podataka. Ova metoda, koja obuhvaća dodjeljivanje različitih težina različitim slojevima podataka, omogućuje integraciju više informacija i pravilno uzimanje u obzir važnosti svakog sloja u konačnom rezultatu analize. Ponderiranje se temelji na pravilnom određivanju relevantnosti i utjecaja svakog prostornog podatka, što doprinosi preciznijem donošenju odluka u različitim kontekstima. Kroz ovaj pristup, GIS postaje snažan alat za istraživanje prostornih odnosa, planiranje prostornog razvoja te analizu rizika. Primjena ponderirane linearne kombinacije često se susreće u prostornim modelima, pružajući poboljšanu prediktivnu snagu i dublju interpretaciju rezultata. Analizom rizika od požara u ruralnim područjima kao primjer [9], GIS koristi ovu tehniku za kombiniranje različitih faktora poput vrsta vegetacije, udaljenosti od vodenih izvora i drugih, pridavajući svakom faktoru odgovarajuću težinu prema njegovom značaju. Kroz ovakav pristup, GIS postaje ključan alat u donošenju informiranih odluka u raznim sektorima, prilagodljiv specifičnim potrebama projekta i pružajući cjelokupni uvid u kompleksne prostorne probleme.

Ponderirana linearna kombinacija, ključna metoda u višekriterijskoj analizi u Geografskom informacijskom sustavu (GIS), pristup je koji proizlazi iz zbroja pojedinačnih kriterija pomnoženih s odgovarajućim faktorima težine. Ovaj pristup se često primjenjuje u GIS-u kako bi se integrirali različiti aspekti prostornih podataka i stvorila cjelovita analiza. Izraz za izračun ponderirane linearne kombinacije glasi:

$$S = \sum w_i x_i \quad (2.1)$$

gdje S predstavlja mjeru prikladnosti određene lokacije temeljene na višekriterijskoj analizi,

w_i predstavlja težinu i -tog kriterija, a x_i vrijednost i -tog kriterija.

U kontekstu višekriterijske analize, svaki kriterij dobiva specifičnu težinu, odražavajući njegovu relativnu važnost u konačnom rezultatu. Faktori težine određuju se temeljem stručnog znanja ili kriterija relevantnosti za istraživanje. Kroz ovu metodologiju, GIS omogućava donositeljima odluka da kvantificiraju i integriraju raznolike prostorne informacije kako bi donijeli informirane odluke. Ponderirana linearna kombinacija pruža sustavan i kvantitativni pristup analizi prostornih podataka, omogućavajući istraživačima i planerima da uzmu u obzir kompleksnost višekriterijskih problema. Ovaj pristup se često koristi u istraživanjima prostornog planiranja, analizi rizika, ili bilo kojem kontekstu gdje je važno integrirati i valorizirati različite aspekte prostornih informacija kako bi se došlo do održivih i informiranih odluka. U praksi, višekriterijska GIS analiza se koristi kod projekata vezanih za gospodarstvo i planiranje prostora, također, svoju primjenu pronalazi i kod procjene utjecaja na ekosustav, onečišćenja i izgled okoliša. Konkretno, takvi projekti se mogu baviti određivanjem lokacija vjetroelektrana [10], nuklearnih reaktora [11], za procjenu rizika kao npr. rizik od poplava [12, 13], požara [14].

U okviru procesa višekriterijske GIS analize, ključan korak prije samog postupka objedinjavanja pojedinih kriterija jest standardizacija (normalizacija) podataka koji reprezentiraju svaki pojedini kriterij. Ovaj postupak se primjenjuje kako bi se omogućila usporedivost raznolikih kriterija koji se mogu razlikovati u jedinicama mjere, opsegu vrijednosti ili distribuciji podataka. Standardizacija se provodi kako bi se podaci prilagodili istim mjerilima, čime se eliminiraju potencijalne pristranosti uzrokovane različitim skalarnim vrijednostima među kriterijima. U praksi, postupak standardizacije može uključivati korake poput skaliranja podataka na određeni raspon ili njihove transformacije prema određenoj distribuciji, čime se osigurava relativna važnost svakog kriterija unutar analitičkog okvira. Ovaj korak ima ključnu ulogu u ispravnom tumačenju i usporedbi rezultata višekriterijske analize, čime se osigurava objektivnost i relevantnost konačne odluke ili ocjene. Važnost normalizacije kriterija proizlazi iz potrebe za eliminacijom potencijalnih iskrivljenja rezultata uzrokovanih različitim amplitudama ili varijacijama među pojedinim kriterijima. Ovaj pristup omogućuje postizanje dosljednih i usporedivih rezultata, čime se olakšava donošenje informiranih od-

luka temeljenih na integriranim kriterijima u geoinformacijskom sustavu. Stoga, prije nego što se pristupi fazi objedinjavanja kriterija, nužno je pažljivo provesti postupak standardizacije kako bi se osigurala kvalitetna i valjana analiza koja odražava stvarnu relativnu važnost svakog kriterija u analitičkom kontekstu.

Višekriterijska analiza se etablirala kao pouzdan alat u procesu donošenja odluka koje uključuju više mogućih ishoda na temelju određenih kriterija ili ciljeva. Njezina primjenjivost i potvrđena učinkovitost reflektiraju se kroz raznolike primjene u različitim domenama istraživanja. Kao što ilustrira studija [15], višekriterijska analiza uspješno se integrira u osjetljive i odgovorne zadatke, poput optimizacije raspodjele timova hitne medicinske pomoći prema pacijentima te njihovog usmjeravanja prema najprikladnijim ustanovama hitne pomoći. U sličnom kontekstu, još jedan relevantan primjer istraživanja, dokumentiran u radu [16], prikazuje primjenu višekriterijske analize za izračun najbrže rute do unesrećenih i bolnica. Daljnje proširenje spektra primjene uključuje planiranje optimalnih ruta za osobe s teškoćama u kretanju [17], odabir sigurnih prijevoznih ruta za opasne materijale [18] te učinkovito upravljanje tokom transporta paketa u mrežama [19].

2.1.1. AHP metoda


Analitički hijerarhijski proces (engl. *Analytical Hierarchy Process - AHP*), predstavlja pristup u domeni višekriterijske analize unutar geoinformacijskih sustava. Ova metoda koristi hijerarhijske strukture kako bi sustavno modelirala i reprezentirala kompleksnost problema, pružajući korisnicima mogućnost donošenja informiranih odluka temeljenih na jasno definiranim prioritetima [20]. Sukladno saznanjima iz literature [21], AHP proces obuhvaća sljedeće ključne korake [22]:

- Definicija nestrukturiranog problema, što uključuje prepoznavanje ključnih aspekata nestrukturiranog problema te jasno definiranje ciljeva i očekivanih ishoda.
- Razvoj AHP hijerarhije, počevši od dekompozicije kompleksnog problema u hijerarhijsku strukturu koja sastoji se od elemenata koji utječu na odabir [23]
- Usporedba svaki-sa-svakim u parovima, što podrazumijeva detaljnu analizu i ocjenu

svakog elementa hijerarhije u usporedbi s drugima.

- Procjena relativnih težina, omogućavajući kvantifikaciju važnosti svakog elementa unutar hijerarhije.
- Provjera konzistentnosti, što implicira ocjenu unutarnje logičke konzistentnosti u donesenim odlukama.
- Dobivanje rezultata, gdje se konačni prioriteti za alternative izvode iz prethodno navedenih koraka.

U prvom koraku koji uključuje definiciju nestrukturiranog problema, zadatak je prepoznati problem i jasno navesti ciljeve i ishode. Sami razvoj AHP hijerarhije započinje razbijanjem kompleksnog problema u hijerarhijsku strukturu koja se sastoji od elemenata koji imaju utjecaja na odabir [23] (Slika 2.1).



Slika 2.1. Hijerarhijska struktura problema odluke [22]

Usporedba svaki-sa-svakim u parovima se radi prema matrici usporedbe A:

$$A = \begin{bmatrix} 1 & \frac{w_1}{w_2} & \dots & \frac{w_1}{w_n} \\ \frac{w_2}{w_1} & 1 & \dots & \frac{w_2}{w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{w_n}{w_1} & \frac{w_n}{w_2} & \dots & 1 \end{bmatrix} \quad (2.2)$$

pri čemu su redci i stupci matrice predstavljaju individualne kriterije, a n broj kriterija. U matrici w_1 predstavlja težinu elementa 1, dok je w_n težina n -tog elementa.

Odnosi između pojedinih težina pružaju informacije o važnosti svakog kriterija. Računa se najveća svojstvena vrijednost matrice A označene kao λ_{max} . Procjena relativne težine kriterija (W), dobivena iz matrice A , provodi se sljedećim izrazom [23]:

$$(A - \lambda_{max}I) \times W = 0 \quad (2.3)$$

pri čemu je I jedinična matrica.

Osigurava se dosljednost dodijeljenih težina provjerom konzistencije. Indeks konzistentnosti (CI) izračunava se na sljedeći način:

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (2.4)$$

Zadnji korak je konačan izračun rezultata prema izrazu:

$$W_i^s = \sum_{j=0}^m w_{ij}^s w_j^a, i = 1, \dots, n \quad (2.5)$$

gdje je W_i^s ukupna težina područja i , w_{ij}^s predstavlja vrijednost kriterija j za područje i , w_j^a je vrijednost težine za kriterij j , m je ukupan broj kriterija, n broj područja.

Ovim sustavnim pristupom, AHP pruža ne samo kvantitativne prioritete, već i omogućuje integraciju subjektivnih procjena korisnika, čime se pojačava transparentnost i preciznost procesa donošenja odluka u GIS-u. Navedeni koraci odražavaju strukturu AHP-a kao učinkovitog alata za rješavanje višekriterijskih problema u geoinformacijskom okruženju. Rad [20] ističe relevantnost AHP-a u praksi, naglašavajući njegovu primjenu u optimizaciji procesa donošenja odluka u GIS-u.

Zanimljiv primjer primjene AHP metode u analizi prostornih podataka s više kriterija prikazan je u istraživanju [24]. U tom radu, autori su istražili postupak donošenja odluke o optimalnoj lokaciji industrijskog postrojenja u pokrajini Vojvodina, Republika Srbija. Prema njihovoj metodologiji, kriteriji su bili rangirani prema važnosti, ocjenjujući ih na skali od 1 do 10. Njihov zaključak bio je da su dostupnost kvalitetne radne snage i trošak rada najbitniji faktori, dok su prometna infrastruktura i dostupnost sirovina također visoko ocijenjeni. S druge strane, mogućnost smještaja (hoteli i sl.) dobila je najnižu ocjenu važnosti. Autori

tvrde da je kombinacija kriterija zajedno s njihovim težinama pružila kvalitetno rješenje za prostornu analizu Vojvodine u kontekstu odabira optimalne lokacije za industrijsko postrojenje.

Sekulić i suradnici [25] u svom radu prezentiraju višekriterijsku analizu (MCE - *engl. Multi-Criteria Evaluation*) koja integrira okolišne, društvene i ekonomske kriterije koristeći pristup procjene utjecaja na okoliš (EIA - *engl. Environmental Impact Assessment*) kako bi predložila alternative za trasiranje obilazne ceste. Prostorna MCE metoda temelji se na primjeni Analitičkog hijerarhijskog procesa (AHP) i ponderiranog zbroja (WS). Studija slučaja u području Tlokweg, Bocvana, koristi se za evaluaciju metode. Zaključak istraživanja je da je razvijeni prostorni model višekriterijske analize fleksibilan i može generirati četiri vrste rješenja - ekonomska, okolišna, društvena i kompromisna. Iako je istraživanje usmjereno na četiri vrste rješenja, metodologija se može prilagoditi za testiranje različitih rješenja unutar područja planiranja Tlokweg te pomoći praktičarima u donošenju pouzdanih odluka. Također, istraživanje je istaknulo važnost analize osjetljivosti u prostornoj višekriterijskoj evaluaciji, što može doprinijeti boljem razumijevanju robustnosti razvijenih modela.

Rad [26] predstavlja još jedan primjer upotrebe višekriterijske GIS analize temeljene na AHP metodi, fokusiran na područje turizma. Turizam predstavlja jednu od najdinamičnijih i najbrže rastućih industrija, prepoznatu kao prilika za generiranje prihoda i zapošljavanje u državnim ekonomijama [27]. Međutim, turizam, osim pozitivnih utjecaja, može imati i negativne, posebice na okoliš. Stoga je cilj višekriterijske analize smanjiti te negativne utjecaje. U spomenutom istraživanju, prikazana je procjena utjecaja turizma na okoliš u gradu Langroodu (Iran).

Istraživanje [28] fokusira se na utjecaj okolišnih čimbenika na odabir prikladne biciklističke staze, sprovedeno na području Seattlea, SAD, korištenjem mobilne aplikacije. Autori kategoriziraju faktore koji utječu na odabir biciklističke rute u tri glavne skupine: faktore usmjerenosti na udobnost (udaljenost, dostupnost biciklističkih parkirališta i mogućnost zaključavanja, mogućnost zaustavljanja), faktore usmjerenosti na sigurnost (ograničenje brzine, osvjetljenost), te faktore usmjerenosti na uživanje (sjene stabala, parkovi, povijesna mjesta, blizina vode). Podaci o korištenju bicikala, prikupljeni putem mobilne aplikacije

tijekom 3,5 godine, obuhvaćaju 4,9 milijuna GPS točaka koje su pretvorene u 3310 biciklističkih ruta. Autori zaključuju da je sigurnost ključni faktor u procesu donošenja odluka o biciklističkoj stazi, što se uzima u obzir prilikom odabira relevantnih kriterija. Značaj ovog istraživanja naglašava se obimom prikupljenih podataka i brojem faktora koji su uključeni u analizu.

Pritchard i suradnici [29] predstavljaju sustav BLOS (*engl. Bicycle Level of Service*) - GIS temeljen sustav za procjenu prikladnosti raskrižja i veza između tih raskrižja u prometnim mrežama. Prikladnost se odnosi na to koliko dobro određena ruta zadovoljava potrebe i preferencije korisnika, uzimajući u obzir faktore poput kvalitete infrastrukture, sigurnosti, izravnosti, udobnosti i atraktivnosti. Prikladna ruta je ona koja se percipira kao udobna i sigurna za namjeravani način prijevoza, u ovom slučaju biciklizam. Razina prikladnosti može varirati ovisno o preferencijama pojedinca i specifičnom kontekstu rute, uključujući okruženje i dostupnu infrastrukturu. Iako je istraživanje obuhvatilo mali broj generiranih ruta, autori zaključuju da bi BLOS mogao biti od pomoći pri generiranju biciklističkih ruta.

Wang i suradnici [30] predstavljaju pristup koji kombinira statičke i dinamičke podatke prilikom planiranja ruta, posebno u kontekstu prepreka koje se javljaju u slučaju šumskih požara. Također, autori predstavljaju svoju modifikaciju A* algoritma prilagođenu izbjegavanju prepreka u slučaju šumskog požara, uzimajući u obzir stanje cesta, vrijeme polaska i dolaska te brzinu vozila. Zaključuju da je ovaj pristup, koji uzima u obzir dinamičke podatke, testiran kroz simulacije širenja šumskog požara, te može pružiti sigurnu rutu u slučaju požara.

Huang i Ye [31] u svom istraživanju prikazuju proces odabira biciklističkih ruta koristeći GIS, primjenjujući ga na grad Berkeley. Cijeli postupak uključuje stvaranje baze podataka, odabir najprikladnijeg puta između svakog para početne i završne lokacije te prikupljanje podataka kako bi se odabrala najpovoljnija ruta. Poželjnost pojedine biciklističke rute računa se pomoću višekriterijske analize temeljene na kriterijima kao što su trajanje putovanja, gustoća cestovnog prometa, nagib i stanje površine. Vrijeme putovanja uključuje i elemente kašnjenja zbog raskrižja i udaljenosti. Autori zaključuju da je GIS koristan alat za odabir biciklističkih ruta jer omogućuje korištenje različitih izvora podataka i njihovu integraciju.

Također, prostorni kriteriji bitni za biciklizam mogu se prikazati i izračunati pomoću GIS-a. Ovaj rad pokazuje da se korištenjem višekriterijske analize, uz pomoć relativno jednostavnih matematičkih jednadžbi i GIS-a, mogu dobiti relevantni rezultati vezani uz pronalaženje najpovoljnije rute između polazišne i odredišne točke.

2.1.2. Neizrazita AHP metoda

Iako je AHP metoda popularna i relativno jednostavna zbog jednostavnih matematičkih operacija od kojih se sastoji, ima svojih ograničenja jer nije uvijek u mogućnosti precizno odražavati ljudski način razmišljanja pri donošenju odluka. Težina koju ljudi pridaju kriterijima često se teško može precizno numerički izraziti [32]. Kao alternativa, neizrazita (engl. *Fuzzy*) AHP metoda pristupa donošenju odluka na način koji je bliži ljudskom razmišljanju. Neizrazita AHP bolje podnosi nejasnoću i dvoznačnost [33, 34], uobičajene u ljudskom donošenju odluka.


Rad [32] detaljno objašnjava neizraziti pristup u AHP metodi kroz empirijsko istraživanje povezano s odabirom ponuda koje lokalna vlada u državi Victoria, Australija mora razmotriti. Ističe se kompleksnost takvih odluka i potreba za strukturalnim pristupom kako bi se donijele odgovarajuće i dosljedne odluke o ponudama. Autori naglašavaju da je donošenje odluka o najboljoj ponudi složen proces u kojem se ukupna kvaliteta treba uzeti u obzir kroz višekriterijsku analizu. Subjektivne procjene i neprecizni podaci često su uključeni, zbog čega autori preferiraju uporabu neizrazitog pristupa za rješavanje ovog problema.

Slična primjena neizrazitog pristupa AHP metodi prikazana je u radu [33], gdje je opisan imaginarni primjer odlučivanja o pružatelju usluga s kriterijima poput cijene, kvalitete usluge i vremena isporuke. Autori naglašavaju da čak i kod relativno jednostavnih problema s malim brojem kriterija, prednosti neizrazitog pristupa postaju očite i korisne u rješavanju složenijih problema. Slično, rad [34] koristi neizraziti AHP pristup kako bi pomogao tvrtkama u Turskoj u procjeni ključnih kompetencija tehnologije ili proizvoda, uzimajući u obzir subjektivne procjene od 16 menadžera iz različitih tvrtki.

Osim toga, [35] predstavlja matematičku podlogu Fuzzy teorije, ističući da je funkcija pripadnosti određene klase unutar raspona $[0,1]$. Glavna karakteristika neizrazite metode je

grupiranje podataka u klase koje nemaju jasno definirane granice [36]. Prikaz neizrazitih usporedbi obično se postiže pomoću fuzzy brojeva, a trokutasti neizraziti broj definira se s tri realna broja (l, m, u), što omogućuje fleksibilnost u rješavanju problema s nesigurnošću i nepreciznošću u ljudskom donošenju odluka (Slika 2.2).

$$\mu_a(x) = \begin{cases} \frac{x-l}{m-l} & \text{za } l \leq x \leq m \\ \frac{u-x}{u-m} & \text{za } m \leq x \leq u \\ 0 & \text{inače} \end{cases} \quad (2.6)$$




Slika 2.2. Trokutasti neizraziti broj [22]

Kao kod AHP metode, konstruira se matrica za usporedbu svaki-sa-svakim; definicija trokutaste neizrazite matrice je:

$$\tilde{A} = (\tilde{a}_{ij})_{n \times m} = \begin{bmatrix} (1, 1, 1) & (l_{12}, m_{12}, u_{12}) & \dots & (l_{1n}, m_{1n}, u_{1n}) \\ (l_{21}, m_{21}, u_{21}) & (1, 1, 1) & \dots & (l_{2n}, m_{2n}, u_{2n}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \dots & (1, 1, 1) \end{bmatrix} \quad (2.7)$$

Izračun težina iz trokutaste neizrazite matrice može se ostvariti putem različitih metoda. U ovom radu su prikazane dvije metode: analiza neizrazitog opsega i metoda temeljena na α -izrezu (Slika 2.3).



Slika 2.3. Dijagram metoda izračuna težina iz neizrazite trokutaste matrice

Analiza neizrazitog opsega

Ovu metodu, pod originalnim nazivom *engl. Fuzzy Extent Analysis*, predstavio je Chang u radu [37]. Koristi se pri izračunu težina iz trokutaste neizrazite matrice, a sam izračun provodi se u četiri koraka; u prvom koraku se radi izračun normaliziranih vrijednosti stupaca:

$$\tilde{S}_i = \sum_{j=1}^n \tilde{a}_{ij} \otimes \left[\sum_{k=1}^n \sum_{j=1}^n \tilde{a}_{kj} \right]^{-1} \quad (2.8)$$

pri čemu \otimes predstavlja množenje dvaju neizrazitih brojeva.


Idući korak je izračun vjerojatnosti da je $\tilde{S}_i \geq \tilde{S}_j$ prema izrazu:

$$V(\tilde{S}_i \geq \tilde{S}_j) = \begin{cases} 1 & \text{za } m_i \geq m_j \\ \frac{u_i - l_j}{(u_i - m_i) + (m_j - l_j)} & \text{za } l_j \leq u_i, \quad i, j = 1, \dots, n; j \neq i \\ 0 & \text{inače} \end{cases} \quad (2.9)$$

gdje je $\tilde{S}_i = (l_i, m_i, u_i)$ i $\tilde{S}_j = (l_j, m_j, u_j)$

Na Slici 2.4 je grafički prikaz vjerojatnosti $\tilde{S}_i \geq \tilde{S}_j$

Treći korak je izračun vjerojatnosti da \tilde{S}_i bude veći od svih ostalih $n - 1$ neizrazitih



Slika 2.4. Grafički prikaz vjerojatnosti $\tilde{S}_i \geq \tilde{S}_j$ [22]

brojeva S_j :

$$V(\tilde{S}_i \geq \tilde{S}_j | j = 1, \dots, n; j \neq i) = \min_{\substack{j \in \{1, \dots, n\} \\ j \neq i}} V(\tilde{S}_i \geq \tilde{S}_j), \quad i = 1, \dots, n \quad (2.10)$$

Četvrti korak je izračun vektora prioriteta $W = (w_1, \dots, w_n)^T$ iz neizrazite matrice usporedbe \tilde{A} prema izrazu:

$$w_i = \frac{V(\tilde{S}_i \geq \tilde{S}_j | j = 1, \dots, n, j \neq i)}{\sum_{k=1}^n V(\tilde{S}_k \geq \tilde{S}_j | j = 1, \dots, n, j \neq k)} \quad i = 1, \dots, n \quad (2.11)$$

Raznovrsne primjene višekriterijske GIS analize ilustrirane su u istraživanju [38], gdje je višekriterijska analiza, zasnovana na AHP metodi i analizi neizrazitog opsega, upotrijebljena za odabir lokacije vjetroelektrane. Integracija GIS višekriterijske analize u ovakvom kontekstu pokazuje se korisnom jer je prilikom planiranja lokacije vjetroelektrane ključno maksimalno iskoristiti energiju vjetra uz minimalni utjecaj na okoliš. Proučeno je područje Kozani u zapadnom dijelu Makedonije, Grčka, koje se izdvaja kao planinsko područje s visokim potencijalom vjetra. Budući da ovo područje već generira 50% ukupne energije u Grčkoj, postojeća infrastruktura minimizira potrebu za velikim dodatnim ulaganjima. Analiza je počela isključivanjem mjesta na kojima gradnja vjetroelektrane nije moguća prema određenim kriterijima, uzimajući u obzir površine veličine 150×150 metara:

- Društveni utjecaj vjetroelektrana (vizualni utjecaj, buka, estetika okoliša)
- Isključenost svih urbanih područja, s određenim udaljenostima od naselja i zaštićenih područja

- Udaljenost od arheoloških i kulturnih spomenika, turističkih objekata i drugih područja poput industrijskih zona
- Uvjeti brzine vjetra i nagiba

Nakon izdvajanja nesigurnih područja, analize se provode na preostalim područjima, koristeći kriterije poput nagiba, brzine vjetra, iskorištenosti zemljišta (s Likertovom ljestvicom [39] koja uključuje ekonomske i okolišne aspekte), udaljenosti do ceste i zaštićenih prirodnih područja te udaljenosti do povijesnih/arheoloških spomenika. Korištenjem neizrazitih skupova za izračun težina pojedinih kriterija, konačni indeks prikladnosti dobiva se kao zbroj umnožaka težine i vrijednosti pojedinog kriterija. Autori zaključuju da, iako njihovo istraživanje može biti dodatno unaprijeđeno, već je dovoljno precizno za upotrebu na nacionalnoj ili regionalnoj razini pri odabiru prikladne lokacije za vjetroelektranu.

Analiza temeljena na α -izrezu

Unatoč tome što je izračun metode temeljene na α -izrezu zahtjevniji, njegova prednost u odnosu na analizu neizrazitog opsega leži u sposobnosti uzimanja u obzir nesigurnosti donositelja odluke. U ovoj metodi, matrica performansi (P) izračunava se množenjem vektora neizrazitih težina pojedinog kriterija s matricom odluke za alternative za svaki kriterij, a rezultirajući vektori se zatim zbrajaju:

$$\tilde{p} = \begin{bmatrix} (l_1, m_1, u_1) \\ (l_2, m_2, u_2) \\ \vdots \\ (l_n, m_n, u_n) \end{bmatrix} \quad (2.12)$$

pri čemu je n broj alternativa. Temeljeno na [40], za provjeru i usporedbu neizrazitih brojeva, ako su s A i B označeni neizraziti brojevi s α -izrezom, $A_\alpha = [a_{\alpha-}, a_{\alpha+}]$, $B_\alpha = [b_{\alpha-}, b_{\alpha+}]$. Vrijedi da je $A \leq B$ ako vrijedi da je $a_{\alpha-} < b_{\alpha-}$ i $a_{\alpha+} < b_{\alpha+}$ za sve α u području $(0,1)$.

U sljedećem koraku se radi transformacija iz matrice performansi u intervalnu matricu

performansi:

$$\tilde{p} = \begin{bmatrix} (\alpha Left_1, \alpha Right_1) \\ (\alpha Left_2, \alpha Right_2) \\ \vdots \\ (\alpha Left_n, \alpha Right_n) \end{bmatrix} \quad (2.13)$$

pri čemu vrijedi:

$$\alpha Left = [a \times (m - l)] + l\alpha Right = u - [a \times (u - m)] \quad (2.14)$$

α -izrez predstavlja mjeru nesigurnosti u neizrazitom području, gdje pojedinac samostalno donosi odluku o njegovoj vrijednosti prema vlastitom nahođenju. Ta vrijednost varira između 0 i 1, označavajući razinu sigurnosti, pri čemu 0 predstavlja najmanju, a 1 najveću sigurnost.

Posljednji korak uključuje pretvaranje matrice intervala u jasnu (oštru, *engl. crisp*) vrijednost. Postupak uključuje upotrebu Lambda funkcije koja odražava stav pojedinca koji donosi odluku. Ta Lambda funkcija može odražavati pesimističan, optimističan ili umjeren stav, s vrijednostima u rasponu [0,1]. Konkretna vrijednost Lambda funkcije određuje se prema nahođenju pojedinca:

$$C_\lambda = \begin{bmatrix} C_{\lambda 1} \\ C_{\lambda 2} \\ \vdots \\ C_{\lambda n} \end{bmatrix} \quad (2.15)$$

pri čemu je:

$$C_\lambda = \lambda \times \alpha Right + [(1 - \alpha) \times Left] \quad (2.16)$$

C_λ predstavlja čistu (oštru) vrijednost.


Rad koji predstavlja još jednu metodu izračuna biciklističkih ruta opisan je u [41]. Autori su odabrali kriterije za odabir staza u gradskom okruženju, uključujući volumen prometa, širinu rubnjaka, širinu pločnika, ograničenje brzine, kvalitetu kolnika i postojeće prepreke.

Za dodatnu analizu i odabir težina kriterija, autori su primijenili neizrazitu AHP metodu temeljenu na α -izrezu.

2.1.3. Teorija grafova i višekriterijska analiza

Općenito, mreža je sustav točaka koje su određene udaljenosti između jedna druge [42]. U stvarnom svijetu, mreže mogu predstavljati ceste, mrežu cjevovoda, kablova i slično. Najčešći problem koji se veže za mreže uključuje pronalazak najkraćeg puta između točaka mreže pri čemu se, u stvarnim slučajevima, mora voditi računa o kriterijima koji utječu na udaljenost između točaka.

Grafovi su strukture podataka koje se sastoje od dvije komponente: čvorova i veza [43]. Koriste se za modeliranje odnosa između parova čvorova. Graf je par (V,E) gdje V predstavlja konačan set čvorova (*engl. Vertices*), dok E predstavlja odnos između čvorova (*engl. Edges*). Primjer grafa je prikazan na Slici 2.5. Svoju primjenu pronalaze u područjima u kojima je potrebno modeliranje različitih vrsta odnosa, kao što su računalna znanost, društvene znanosti, biologija, kemija i sl. [44]




Slika 2.5. Primjer grafa [42]

Grafovi pronalaze svoju primjenu u GIS-u kod pronalaženja optimalnih putanja između jednog ili više čvorova, što uključuje rješavanje problema trgovačkog putnika. U problemu trgovačkog putnika, svaki grad se može smatrati čvorom, dok udaljenost između gradova se smatra vezom. Problem traženja putanje između jednog ili više čvorova ima više načina rje-

šavanja. Neki od njih su: pretraživanje po dubini, pretraživanje po širini, Dijkstra algoritam i A* algoritam.


Algoritam pretraživanja po dubini (DFS - engl. *Depth First Alghoritm*) je temeljni algoritam za pretragu grafova koji sustavno istražuje i mapira graf. Počevši od početnog čvora, DFS ide prema unutrašnjosti grafa kako bi istražio što je moguće dublje u grafu prije nego se vrati unatrag kako bi istražio druga područja (Slika 2.6). To postiže pomoću stoga koji prati čvorove koji trebaju biti istraženi [45].



Slika 2.6. Ilustracija pretraživanja po dubini

Algoritam pretraživanja po širini (BFS - engl. *Breadth-First Search*) je algoritam pretrage grafova koji mapira graf stvarajući stablo pretrage u širinu. Počevši od odabranog korijenskog čvora, BFS najprije istražuje sve susjedne čvorove korijenskog čvora. Zatim istražuje susjedne čvorove tih čvorova i tako dalje, postupno proširujući pretragu na sve udaljenije dijelove grafa. Ilustracija pretraživanja je prikazana na Slici 2.7

Dijkstra algoritam [46] je važan algoritam u teoriji grafova koji se koristi za pronalaženje najkraćeg puta između dva čvora u grafu. Za razliku od DFS i BFS algoritama, Dijkstra algoritam kod izračuna uzima u obzir udaljenosti između točaka (tj. težine bridova). Počevši od početnog čvora, algoritam iterativno proširuje svoju pretragu na susjedne čvorove, prateći trenutno najkraće puteve od početnog čvora do svakog drugog čvora u grafu. U svakom koraku, algoritam odabire čvor s najmanjom ukupnom težinom do tog trenutka i ažurira



Slika 2.7. Ilustracija pretraživanja po širini

najkraće udaljenosti do svih njegovih susjeda. Algoritam se zaustavlja kada su sve najkraće udaljenosti od početnog čvora do svih ostalih čvorova u grafu određene. Dijkstra algoritam je optimalan u smislu pronalaženja najkraćih puteva u grafu, međutim, ne može se koristiti u grafu s negativnim težinama bridova. Dijkstra algoritam ima primjenu u područjima kao što su rutiranje u mrežama, planiranje putovanja i optimizacija transportnih sustava.

A* algoritam je heuristički pretraživački algoritam koji se koristi za pronalaženje najkraćeg puta ili optimalnog rješenja u grafu [47]. Ovaj algoritam kombinira karakteristike Dijkstrinog algoritma i heurističke pretrage kako bi efikasno pronašao put do cilja. A* algoritam koristi heurističku funkciju koja procjenjuje trošak putovanja od trenutne točke do cilja, što mu pomaže da odabere sljedeću točku za istraživanje na temelju najbolje procjene. Ovaj pristup omogućava A* algoritmu da efikasno pronađe rješenje u optimalnom vremenu, iako to rješenje ne mora uvijek biti najbolje moguće.

Prednosti korištenja Dijkstra algoritma za odabir ruta uključuju sposobnost rješavanja problema najkraćeg puta s optimalnim rezultatom. Međutim, nedostatak ovog algoritma je što može zahtijevati više vremena za pronalaženje najkraćeg puta u usporedbi s A* algoritmom, posebice u slučajevima gdje postoji veliki broj čvorova za istraživanje.

U GIS-u, grafovi su ekvivalentni mrežnim topologijama jer se u oba slučaja radi o povezanim skupovima čvorova i veza. Na primjer, vodovodna mreža može se modelirati kao graf u kojem su čvorovi vodospreme, a veze vodovodne cijevi. Cestovna mreža može se mode-

lirati kao graf u kojem su čvorovi raskrižja, a veze ceste. Elektroenergetski sustav može se modelirati kao graf u kojem su čvorovi trafostanice, a veze dalekovodi.

Tako se u radu [48] istražuje robustnost metro mreža kroz višekriterijsku analizu koristeći deset teorijskih i četiri numeričke metrike. Autori koriste grafove i teoriju grafova kako bi proučili mrežna svojstva metro sustava i kvantificirali njihovu robustnost. Višekriterijska analiza uključuje istraživanje različitih aspekata robustnosti metro sustava kroz deset teorijskih metrika, poput broja alternativnih putanja i duljine putanja. Ove metrike pružaju različite perspektive na robustnost sustava. Numeričke metrike su dobivene kroz simulacije i služe kao referentne točke za procjenu otpornosti metro sustava na slučajne kvarove i ciljane napade. Grafovi se koriste za modeliranje metro mreža kao neusmjerenih grafova, gdje čvorovi predstavljaju stanice, a veze poveznice između stanica. Kroz analizu grafova, istražuju se različita svojstva mreže poput povezanosti, otpornosti i efikasnosti pri otkazima i napadima. Kombinirajući teorijske i numeričke metrike, te koristeći radar dijagrame za vizualizaciju rezultata, autori su dobili cjelovitu sliku o robustnosti metro sustava i identificirati ključne faktore koji utječu na njihovu otpornost. Zaključuju da je višekriterijska analiza prikladna za procjenu robustnosti metro mreža, jer omogućuje sagledavanje različitih aspekata njihove otpornosti. Kombinirajući teorijske i numeričke metrike te koristeći radar dijagrame za vizualizaciju rezultata, istraživači su identificirali ključne faktore koji utječu na robustnost metro sustava, a to su broj alternativnih putanja, duljina putanja, povezanost stanica i efikasnost mreže.

Kombinacija korištenja višekriterijske analize i GIS-a je prikazana u [49] gdje autori koriste navedenu kombinaciju za optimizaciju ruta između lokacija u pokrajini Mojokerto, Istočna Java, Indonezija za logističku distribuciju. Graf čini 7 lokacija u navedenoj pokrajini koji predstavljaju čvorove, dok su putevi među njima veze. Grafovi se koriste za modeliranje mreže distribucije i predstavljanje veza između čvorova (lokacija) i njihovih udaljenosti. Dijkstra algoritam se primjenjuje na ovim grafovima kako bi se pronašao najbolji put od početnog čvora do svih ostalih čvorova, uzimajući u obzir kriterije višekriterijske analize koji uključuju troškove, udaljenost, zagušenje i rizik. Troškovi igraju važnu ulogu u procesu distribucije ruta jer utječu na ukupnu ekonomsku učinkovitost distribucijskog sustava,

udaljenost između različitih točaka distribucije također je bitan kriterij jer može utjecati na vrijeme isporuke i troškove prijevoza. Kriterij zagušenja se odnosi na prometne gužve ili preopterećenost određenih ruta, što može utjecati na brzinu isporuke i efikasnost distribucije. Rizik se uzima u obzir kao kriterij u procesu donošenja odluka o distribuciji ruta, jer je povezan s sigurnošću isporuke ili potencijalnim problemima tijekom transporta. Autori su istaknuli važnost normalizacije kriterija i korištenje Dijkstra algoritma kao ključnih elemenata u postizanju visoke točnosti u distribuciji ruta. Kombinacija ovih metoda omogućuje efikasnu procjenu različitih aspekata logistike i distribucije odabir optimalne rute distribucije uzimajući u obzir sve kriterija. Autori potvrđuju da njihov sustav pruža visoku točnost u donošenju odluka o distribuciji ruta, što ukazuje na uspješnost primjene kombinacije Dijkstrinog algoritma i višekriterijske analize u rješavanju problema logističke distribucije.

Rad [50] prikazuje pristup višekriterijskoj analizi za lociranje koridora, posebno za linearne objekte poput autocesta, cesta, željeznica, cjevovoda i prijenosnih vodova. Istražuje se kako GIS može biti iskorišten za optimizaciju lociranja koridora, kao i važne faktore koji treba uzeti u obzir prilikom identifikacije ruta za linearne objekte. Također se istražuje kako višekriterijski pristupi mogu poboljšati proces lociranja koridora za različite primjene poput planiranja zaštite okoliša, planiranja staza i praćenja prirodnih resursa. Kriteriji koji se uzimaju u obzir kod višekriterijske analize su dužina koridora, kvaliteta terena (topografske karakteristike), utjecaj na okoliš, troškovi izgradnje i održavanja i sigurnost. Dijkstrin algoritam koristi se više puta u pristupu kako bi se identificirali efikasni koridori; korištenje Dijkstrinog algoritma više puta s malim grafovima je brže nego korištenje istog algoritma jednom na velikom grafu što omogućuje brže identificiranje efikasnih koridora uz smanjenje gustoće grafa povezanosti u svakoj iteraciji algoritma. Kombinacija kriterija i korištenje Dijkstrinog algoritma omogućuju efikasno rješavanje problema lociranja koridora uzimajući u obzir različite aspekte. Ovaj pristup omogućuje identifikaciju optimalnih koridora koji zadovoljavaju postavljene ciljeve i kriterije lociranja koridora na temelju više kriterija istovremeno.

2.2. Strojno učenje

Strojno učenje općenito obuhvaća automatske računalne postupke temeljene na logičkim ili binarnim operacijama koji uče kako riješiti zadatak iz niza primjera [51]. Sustavi strojnog učenja su sposobni reprezentirati kompleksne probleme uz dovoljnu količinu podataka, što može zahtijevati značajne resurse. U prošlosti je cilj strojnog učenja bio generirati izraze za klasifikaciju dovoljno jednostavne da ih ljudi mogu razumjeti. No, danas se pokazalo da modeli mogu obavljati važne zadatke, iako nisu uvijek transparentni i lako razumljivi ljudima. Kao i kod statističkih pristupa, moguće je koristiti prethodno znanje tijekom razvoja modela, no rad sustava pretpostavlja operativnost bez intervencije ljudi. Strojno učenje istražuje metodologije za konstrukciju samoučećih računalnih modela koji automatski poboljšavaju svoje performanse kako akumuliraju "iskustvo" [52]. Naglasak je na razvoju algoritama i tehnika koji omogućuju računalima da nauče iz podataka, prilagode se promjenama te optimiziraju svoje ponašanje tijekom vremena. Ovaj proces omogućuje računalima da autonomno apsorbiraju informacije iz okoline, prilagode se novim izazovima i kontinuirano unaprjeđuju svoje sposobnosti. Strojno učenje također predstavlja bitan doprinos razumijevanju kako računala mogu evoluirati i prilagoditi se na način sličan ljudskom učenju.

Obično se dostupnost podataka smatra ključnom za izradu modela strojnog učenja. Podaci mogu biti različitih oblika, kao što su strukturirani, polustrukturirani, nestrukturirani, a tu se još uključuju i tzv. metadata podaci [53].

Što se tiče vrsta podataka korištenih za izradu modela strojnog učenja, u literaturi se spominju sljedeće vrste:

- Strukturirani podaci posjeduju dobro definiranu strukturu, pridržavaju se modela podataka prema standardnom redosljedju, što ih čini visoko organiziranima i lako dostupnima te se koriste od strane subjekta ili računalnog programa. U dobro definiranim shemama, poput relacijskih baza podataka, strukturirani podaci obično se pohranjuju u tabličnom formatu. Primjerice, imena, datumi, adrese, brojevi kreditnih kartica, informacije o dionicama, geolokacija itd. su primjeri strukturiranih podataka.
- Kod nestrukturiranih podataka ne postoji unaprijed definiran format ili organizacija,

što ih čini znatno težim za zahvatiti, procesirati i analizirati, uglavnom sadržavajući tekstualni i multimedijalni materijal. Primjeri nestrukturiranih podataka uključuju podatke senzora, e-poštu, dokumente obrade teksta, PDF datoteke, audio datoteke, videozapise, slike, prezentacije, web stranice i slično.

- Polustrukturirani podaci nisu pohranjeni u relacijskoj bazi podataka poput strukturiranih podataka navedenih gore, ali imaju određena organizacijska svojstva koja olakšavaju analizu. HTML, XML, JSON dokumenti, NoSQL baze podataka, itd., su neki od primjera takvih vrsta podataka.
- Metapodatak (*engl. metadata*) nije uobičajeni oblik podataka, već "podatak o podacima". Glavna razlika između običnih podataka i metapodataka jest da su podaci materijal koji može klasificirati, mjeriti ili dokumentirati. S druge strane, metapodaci opisuju relevantne informacije o podacima, pridajući im veći značaj za korisnike podataka. Osnovni primjer metapodataka za dokument može uključivati autora, veličinu datoteke, datum generiranja dokumenta, ključne riječi za definiranje dokumenta i slično.

Algoritmi strojnog učenja uglavnom se dijele u četiri kategorije: nadzirano učenje (*engl. Supervised learning*), nenadzirano učenje (*engl. Unsupervised learning*), polunadzirano učenje (*engl. Semi-supervised learning*) i podržano učenje (*engl. Reinforcement learning*) [54], kako je prikazano na Slici 2.8 [53]

Nadzirano učenje podrazumijeva osnovni cilj u području strojnog učenja, a to je stjecanje znanja o funkciji koja opisuje odnos između ulaznih i izlaznih podataka, temeljeno na uzorcima ulazno-izlaznih parova [55]. Ovaj pristup koristi labelirane podatke za treniranje i skup primjera za treniranje kako bi deducirao funkcionalni odnos. Nadzirano učenje provodi se kada su određeni ciljevi identificirani kao zadaci koji se trebaju postići iz određenog skupa ulaza, odnosno koristi pristup vođen zadacima. Najčešći zadaci nadziranog učenja su klasifikacija, koja razdvaja podatke, i regresija, koja se prilagođava podacima. Primjer nadziranog učenja jest predviđanje oznake klase ili sentimenta teksta, odnosno klasifikacija teksta.

Nenadzirano učenje u analizi neoznačenih skupova podataka provodi se bez potrebe za

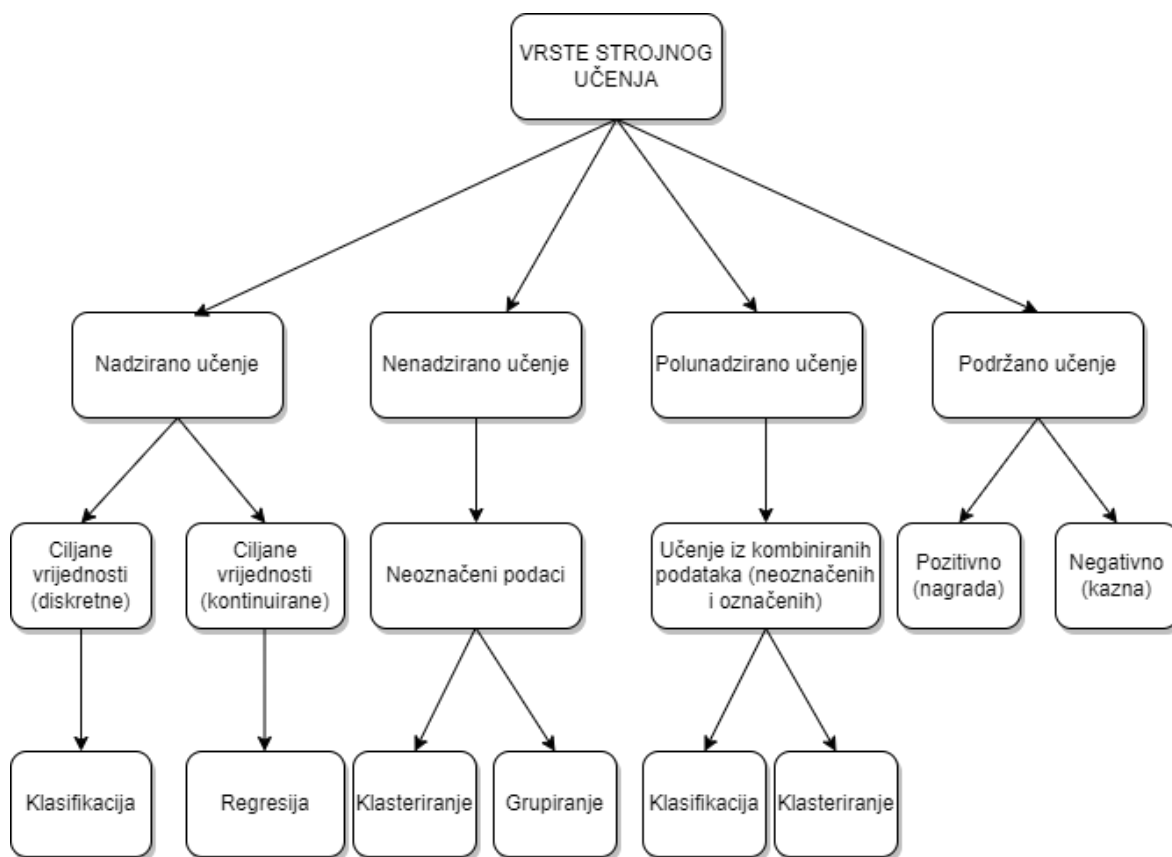
ljudskim posredovanjem, odnosno, to je proces vođen podacima. Široko se primjenjuje za izdvajanje generativnih značajki, prepoznavanje značajnih trendova i struktura, identifikaciju grupiranja u rezultatima te za istraživačke svrhe. Najčešći zadaci nenadziranog učenja obuhvaćaju klasteriranje, procjenu gustoće, učenje značajki, smanjenje dimenzionalnosti, pronalaženje pravila udruživanja, otkrivanje anomalija i slično.

Polunadzirano učenje može se opisati kao hibrid prethodno navedenih nadziranih i nenadziranih metoda jer radi istovremeno na labeliranim i nelabeliranim podacima [56]. Stoga se nalazi između paradigmi učenja bez nadzora i učenja s nadzorom. U stvarnom svijetu labelirani podaci mogu biti rijetki u različitim kontekstima, dok su neoznačeni podaci brojni, što čini polunadzirano učenje posebno korisnim. Konačni cilj modela polunadziranog učenja jest pružiti bolje rezultate predviđanja u usporedbi s onima dobivenima isključivo iz označenih podataka. Neka od područja primjene polunadziranog učenja obuhvaćaju strojno prevođenje, detekciju prijevara, označavanje podataka i klasifikaciju teksta.

Podržano učenje se ističe kao kategorija algoritama strojnog učenja osmišljena da omogućiti softverima i strojevima samostalno ocjenjivanje optimalnog ponašanja u određenom kontekstu ili okruženju, čime se poboljšava njihova učinkovitost [57]. Ovaj pristup temelji se na metodologiji vođenoj okolinom jer se učenje temelji na sustavu nagrada i kazni, s krajnjim ciljem iskorištavanja uvida dobivenih interakcijama s okolinom kako bi donosili odluke koje ili maksimiziraju nagrade ili minimiziraju rizik. Podržano učenje djeluje kao instrument za treniranje modela umjetne inteligencije usmjerenih na poboljšanje automatizacije ili optimizaciju operativne učinkovitosti kompleksnih sustava, kao što su robotika, zadaci autonomne vožnje, proizvodnja i logistika lanca opskrbe, dok njegova primjena nije poželjna za rješavanje osnovnih ili jednostavnih problema.

Neke od domene korištenja strojnog učenja su:

- Računalni vid: Prepoznavanje objekata, detekcija objekata i obrada objekata su pod-domeni u domeni računalnog vida.
- Predviđanje: Različite pod-domene ovdje čine klasifikacija, analiza i preporuka. Tekstualna klasifikacija, klasifikacija dokumenata, analiza slika, medicinska dijagnoza, predviđanje detekcije mreža i predviđanje napada na uslugu su uspješno implementi-



Slika 2.8. Grafikon vrsta strojnog učenja [53]

rani koristeći strojno učenje.

- Semantička analiza i obrada prirodnog jezika i pretraživanje informacija: Proces povezivanja sintaktičkih struktura između odlomaka, rečenica i riječi s razinom pisanja kao cjeline.

2.2.1. Klasifikacijska analiza

Klasifikacija se smatra nadziranom metodom učenja u području strojnog učenja. Rješava problem prediktivnog modeliranja gdje se za dani primjer predviđa oznaka klase [41]. Matematički, uključuje mapiranje funkcije (f) od ulaznih varijabli (X) do izlaznih varijabli (Y) koje predstavljaju cilj, oznaku ili kategorije. Ovaj proces može se primijeniti na strukturirane ili nestrukturirane podatke kako bi se predvidjela klasa danih podataka.

Binarna klasifikacija se odnosi na zadatke s dvije oznake klase poput istina i laž ili da i ne. U binarnoj klasifikaciji jedna klasa može predstavljati normalno stanje, dok druga označava abnormalno stanje. Na primjer, spam i nije spam u pružateljima usluga e-pošte

primjeri su binarne klasifikacije.

Višeklasna klasifikacija se tradicionalno se odnosi na zadatke s više od dvije oznake klase. Za razliku od binarne klasifikacije, višeklasna klasifikacija ne posjeduje koncept normalnih i abnormalnih ishoda. Umjesto toga, primjeri se klasificiraju kao pripadajući jednoj od nekoliko određenih klasa.

Klasifikacija s više labela: U strojnom učenju, klasifikacija s više labela je značajna kada je primjer povezan s nekoliko klasa ili oznaka. To je generalizacija višeklasne klasifikacije, uključujući hijerarhijski strukturirane klase. Svaki primjer istovremeno može pripadati više od jedne klase na svakoj hijerarhijskoj razini, kao što je vidljivo u višerazinskoj klasifikaciji teksta.

Neke od vrsta klasifikacijskih algoritama strojnog učenja su: *Naive Bayes*, *Linear Discriminant Analysis (LDA)*, *Logistic regression (LR)*, *K-nearest neighbors (KNN)*, *Support vector machine (SVM)*, *Decision tree (DT)*,

2.2.2. Regresijska analiza

Regresijska analiza obuhvaća nekoliko metoda strojnog učenja koje omogućuju predviđanje kontinuirane rezultatne varijable (y) na temelju vrijednosti jedne ili više prediktorskih varijabli (x). Glavna razlika između klasifikacije i regresije leži u njihovim ciljevima predviđanja: klasifikacija predviđa jasne oznake klasa, dok regresija omogućuje predviđanje kontinuirane količine.

Modeli regresije široko se primjenjuju u različitim područjima, uključujući financijsko prognoziranje, procjenu troškova, analizu trendova, marketing, procjenu vremenskih nizova, modeliranje odgovora na lijekove i mnoga druga područja. Linearna, polinomna, *lasso* i *ridge* regresija neki su od poznatih tipova regresijskih algoritama.

Jednostavna i višestruka linearna regresija spadaju među najčešće korištene tehnike modeliranja u strojnom učenju i dobro su poznate u analizi regresije. U ovim tehnikama, ovisna varijabla je kontinuirana, a nezavisna varijabla može biti kontinuirana ili diskretna. Oblik regresijske linije je linearan, što uspostavlja odnos između ovisne varijable (Y) i jedne ili više nezavisnih varijabli (X), često nazvane regresijskom linijom. Cilj linearne regresije je

stvaranje najbolje prilagođenog pravca. Karakterizirana je sljedećim jednadžbama:

$$y = ax + b \quad (2.17)$$

$$y = a + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad (2.18)$$

gdje a predstavlja presjek, b je nagib pravca, a e označava pogrešku; cilj je predvidjeti vrijednost ciljne varijable na temelju zadane prediktorske varijable. Jednadžba 2.17 odnosi se na jednostavnu linearnu regresiju, dok se jednadžba 2.18 odnosi na višestranu linearnu regresiju - proširenje koje omogućuje dva ili više prediktorskih varijabli za modeliranje odzivne varijable y linearno. Obrnuto, jednostavna linearna regresija, definirana u jednadžbi 2.17, ima samo jednu nezavisnu varijablu.

Polinomna regresija koristi se kada veza između nezavisne varijable x i ovisne varijable y nije linearna, već se temelji na n -tom polinomnom stupnju. Jednadžba za polinomnu regresiju dobiva se iz jednadžbe linearne regresije, i za polinomnu regresiju stupnja 1 definirana je kao:

$$y = b_0 + b_1x + b_2x^2 + b_3x^3 + \dots + b_nx^n + e \quad (2.19)$$

Ovdje je y predviđeni izlaz, b_0, b_1, \dots, b_n su regresijski koeficijenti, a x je nezavisna (ulazna) varijabla. Polinomna regresija posebno je korisna kada podaci nisu linearno distribuirani, već slijede polinom n -tog stupnja.

LASSO i Ridge regresija su tehnike koje se koriste za izgradnju modela učenja s velikim brojem značajki, sprječavanje pretreniranja i smanjenje složenosti modela. LASSO (engl. *Least Absolute Shrinkage and Selection Operator*) koristi L1 regularizaciju [58], kažnjavajući apsolutnu vrijednost magnituda koeficijenata (L1 kazna), postavljajući neke koeficijente na nulu. Cilj mu je pronaći podskup prediktora koji minimizira pogrešku predviđanja za kvantitativnu odzivnu varijablu. S druge strane, Ridge regresija koristi L2 regularizaciju, kažnjavajući kvadratnu magnitudu koeficijenata (L2 kazna). Za razliku od LASSO-a, Ridge regresija ne postavlja koeficijente na nulu. LASSO je koristan za dobivanje podskupa prediktora eliminiranjem manje važnih značajki, dok je Ridge regresija korisna kada skup podataka pokazuje multikolinearnost, tj. kada su prediktori međusobno korelirani.

2.2.3. Support Vector Machine - SVM

Support Vector Machine (SVM) [59] je nadzirani algoritam učenja koji se koristi za zadatke klasifikacije. Radi pronalženjem optimalne razdjelne hiperravnine koja maksimizira marginu između različitih klasa u ulaznom prostoru. SVM modeli su sposobni rukovati nelinearno odvojivim slučajevima mapiranjem ulaznih podataka u višedimenzionalni prostor značajki pomoću kernel funkcija, gdje linearno razdvajanje postaje moguće. Minimiziranjem strukturalnog rizika i VC (Vapnik-Chervonenkis) dimenzije [60], SVM modeli imaju za cilj postići dobru generalizaciju i robusnu izvedbu na dosad neviđenim podacima. Strukturalni rizik povezan je s sposobnošću generalizacije modela strojnog učenja, dok VC pruža mjeru kapaciteta ili složenosti klase hipoteza, što je skup svih mogućih funkcija koje algoritam učenja može odabrati kao rješenje. U kontekstu SVM-a, VC dimenzija pomaže karakterizirati kapacitet modela određenog izborom kernel funkcija i drugih parametara. Veća VC dimenzija implicira veći kapacitet modela za prilagođavanje složenim obrascima u podacima za treniranje, ali istovremeno povećava rizik od pretreniranja. U kontekstu SVM-a, odnosi se na ravnotežu između složenosti modela i sposobnosti da dobro generalizira na nove, neviđene podatke. Dodatno, SVM-ovi mogu podnijeti podatke sa šumom korištene za treniranje i učinkoviti su za zadatke prepoznavanja uzoraka i regresijske procjene, što ih čini svestranim i široko korištenim alatom za strojno učenje.

SVM modeli pronalaze primjene u raznim domenama i to zahvaljujući svojim sposobnostima rukovanjem s visokodimenzionalnim podacima i učinkovite klasifikacije složenih uzoraka [61]. Tako se SVM modeli intenzivno koriste u zadacima kao što su prepoznavanje lica [62, 63], detekcija predmeta [64, 65] i segmentacija slike [66]. Njihova sposobnost rukovanja visokodimenzionalnim podacima koji sadržavaju slike i učinkovitog klasificiranja nelinearnih uzoraka čini ih dobrim izborom kod zadataka koji uključuju obradu slika. U području obrade prirodnog jezika, SVM modeli su korišteni za zadatke poput analize osjećaja [67] i filtriranja neželjene pošte [68]. Također se ističe i mogućnost njihove primjene u bioinformatici što uključuje primjenu u predviđanju strukture proteina [69], analizu ekspresije gena [70] i otkrivanje lijekova [71]. SVM modeli svoju primjenu pronalaze i u financijama, konkretno u predviđanju kreditnog rizika [72] i predviđanju vrijednosti dionica [73].

Support Vector Regression - SVR

Za razliku od SVM koji rješava probleme klasifikacije, SVR modeli se bave problemima regresije [74]. SVR je također razvio Vapnik sa suradnicima kao nadogradnju na SVM [75]. Cilj SVM modela je pronaći hiperravninu koja maksimizira razmak između različitih klasa, istovremeno ispravno klasificirajući točke učenja, dok je cilj SVR modela kod problema regresije pronaći najuži omotač oko procijenjene funkcije, istovremeno minimalizirajući pogrešku predviđanja, koju čini udaljenost između predviđenih i željenih izlaznih rezultata. Što se tiče izračuna gubitaka, SVM koristi Funkciju gubitka zglobnice (engl. *Hinge Loss Function*) [76] za penaliziranje pogrešnih klasifikacija, dok SVR koristi konveksnu ϵ -insenzitivnu funkciju gubitka [77] kako bi penalizirao točke izvan omotača, dok one unutar omotača, bilo iznad ili ispod funkcije, nisu penalizirane. Na kraju, kod SVM-a se kreira granica odluke koja razdvaja različite klase u problemima klasifikacije, dok SVR stvara kontinuiranu, višedimenzionalnu funkciju koja procjenjuje ciljnu varijablu u problemima regresije.

Matematička formulacija linearnog SVR-a se izražava na sljedeći način. Ako postoji skup podataka za treniranje označen kao $(x_1, y_1), \dots, (x_i, y_i)$, gdje x_i predstavlja ulazne podatke, a y_i željeni izlaz, linearna funkcija f je napisana u obliku [78]:

$$y = f(x) = w \cdot x + b = w^T x + b \quad (2.20)$$

gdje $w \cdot x$ označava skalarni produkt ulaznih podataka x i vektora težina w . U SVR-u, aproksimacija funkcije f se izvodi pronalaskom ϵ -insenzitivnog omotača što je moguće ravnijim, što se formalno naziva plohatošću, odnosno traženjem što manje vrijednosti w .

Kako bi se omogućilo SVR-u rukovanje nelinearnim podacima, uvodi se kernel funkcija koja transformira izvorne ulazne podatke u prostor više dimenzija, poznat kao kernel prostor (engl. *kernel space*). Korištenje kernela je jedan od najčešćih pristupa u SVM-u (za regresiju i klasifikaciju) jer tada nema potrebe za rješavanjem hiperploha visokog reda u ulaznom prostoru, što je izrazito složeno u usporedbi s rješavanjem linearnog optimiranja u kernel prostoru.

2.2.4. Duboko učenje

Duboko učenje, kao podvrsta strojnog učenja, se odnosi na proces u kojem višeslojni modeli nastoje apstrahirati informacije iz podataka [79]. U analizi velikih skupova podataka, primjenom mehanizma širenja unatrag (poznatog i kao engl. *Backpropagation*), postoji mogućnost prilagodbe inicijalnih parametara računala kako bi se dobili reprezentativni podaci u trenutnim i budućim slojevima u odnosu na prethodne slojeve. Adekvatan broj preciznih transformacija može rezultirati usvajanjem izrazito složenih funkcija. Ključna karakteristika dubokog učenja leži u tome što težine i povezanosti pojedinih slojeva nisu unaprijed dizajnirane od strane stručnjaka; umjesto toga, one se prilagođavaju iz podataka prema prethodno definiranoj proceduri.

Proučavajući iz pojednostavljene perspektive, u umjetnoj inteligenciji se prepoznaju dvije glavne paradigme učenja: paradigma nadahnuta logikom i paradigma nadahnuta mozgom [80]. U pristupu nadahnutom logikom, ključna komponenta inteligencije je sekvencijalno zaključivanje, s fokusom na implementaciji procesa donošenja zaključaka u računalima. Ovaj pristup koristi pravila zaključivanja koja su ljudi osmislili, djelujući na simboličkim izrazima koji formalno predstavljaju znanje. U okviru ove paradigme, naglasak je na procesu sekvencijalnog zaključivanja, a struktura izraza ne sugerira unaprijed definiranu unutarnju strukturu; umjesto toga, odnosi između simbola predstavljaju značenje.

U paradigmi nadahutoj mozgom, pristup učenju iz podataka predstavlja suštinu inteligencije, s ciljem izvođenja učenja putem osmišljavanja ili razvoja pravila za izmjenu jakosti veza u simuliranim mrežama umjetnih neurona. Unutar ove paradigme, vanjski simboli korišteni za komunikaciju transformiraju se u vektore neuralne aktivnosti s razgranatom strukturom sličnosti. Ti vektori aktivnosti koriste se za modeliranje strukture koja se sastoji od nizova simbola na način da se uče odgovarajući vektori aktivnosti za svaki simbol. Ovaj proces uključuje učenje nelinearnih transformacija koje omogućuju popunjavanje vektora aktivnosti, čime se nadoknađuju nedostajući elementi niza simbola. Prvi primjer takvog pristupa predstavljen je u [81], gdje su autori predstavili *back-propagation* kao metodu učenja za neuronske mreže. Konkretna implementacija backprop mreže opisana je u [82], gdje su autori koristili mrežu za predviđanje riječi u rečenicama. Automatska generalizacija predstavlja


ključnu prednost korištenja vektora neuralne aktivnosti.

Neuronske mreže

Iako je temeljni princip rada neuronskih mreža bio poznat još od 80-ih godina 20. stoljeća, dubinsko istraživanje nad njima započinje tijekom početka 2000-ih. Ovaj zamah istraživanja potaknut je povećanjem snage hardvera, uključujući procesore i grafičke kartice, te širom dostupnosti obimnih skupova podataka putem Interneta [80]. Zajedno s razvitkom softvera kao što su Tensorflow [83], PyTorch [84], Torch [85], Caffe [86], Theano [87], omogućeno je treniranje složenih neuronskih mreža, fleksibilnost u građenju mreže i korištenje različitih modela neuronskih mreža.

Evolucija Umjetnih neuronskih mreža (engl. *Artificial Neural Networks - ANN*), poznatih i kao neuronske mreže, temelji se na nastojanju da se simulira biološki živčani sustav putem međusobnog povezivanja većeg broja jednostavnih elemenata, odnosno neurona. Takva kompleksna struktura posjeduje sposobnost samoorganizacije i učenja, no nazivanje ovog fenomena inteligencijom često izaziva rasprave [88]. Dok ljudski mozak sastoji se od približno sto milijardi neurona, rijetko koja neuronska mreža obuhvaća više od nekoliko tisuća neurona. Nadalje, neuronske mreže se uspoređuju s statističkim metodama koje su sposobne obraditi obimne količine podataka i predviđati trendove kretanja podataka u budućnosti, no to samo po sebi ne čini ih inteligentnima. Motivacija iza istraživanja neuronskih mreža proizlazi iz načina funkcioniranja ljudske inteligencije, koja se temelji na visokoparaleliziranim nelinearnim neuronima sposobnim učenja putem prilagodbe jačine međusobnih veza.

Na Slici 2.9 je prikazan model linearne regresije. Prikazan je primjer ulaznih podataka u



Slika 2.9. Model linearne regresije


model linearne regresije koji generalizira njihov trend u obliku pravca. Tako dobiven pravac

se uspoređuje s dostupnim testnim podacima čime se dobivaju informacije o kvaliteti takvog modela. Svaki neuron definiran je matematičkom funkcijom koja transformira ulaz u izlaz. Jednostavna jednoslojna neuronska mreža izračunava linearnu kombinaciju ulaza, na kojoj djeluje aktivacijska funkcija, rezultirajući u izlazu.

Neki od primjera aktivacijskih funkcija:

- Linearna: $a(x) = x$
- Hiperbolični tangens: $a(x) = \tanh(x)$
- Sigmoidna: $a(x) = (1 + e^{-x})^{-1}$
- Funkcija praga: $a(x) = 0$ za $x < 0$, inače 1
- Gaussova: $a(x) = e^{-\frac{x^2}{2}}$
- ReLu: $a(x) = 0$ za $x < 0$, inače x

Funkcija mapiranja, koja se označava kao Γ , svakom neuronu i dodjeljuje podskup $\Gamma(i) \subseteq V$ koji se sastoji od svih prethodnika tog neurona, pri čemu V predstavlja skup svih neurona [89]. Težinski koeficijent ω_{ij} predstavlja vezu između i -tog i j -tog neurona, dok je i -ti neuron karakteriziran koeficijentom praga ϑ_i . Težinski koeficijent ω_{ij} označava važnost pojedine veze u mreži, kako je prikazano na Slici 2.10.



Slika 2.10. Veza dvaju neurona


Vrijednost i -tog neurona x_i se izračunava kao:

$$x_i = f(\xi_i) \tag{2.21}$$

$$\xi_i = \vartheta_i + \sum_{j \in \Gamma_i} \omega_{ij} x_j \quad (2.22)$$

pri čemu je $f(\xi_i)$ aktivacijska funkcija, dok se ξ_i naziva potencijal i -tog neurona.


Upotreba neuronskih mreža na koristan način može postojati samo ako je mreža posložena na način da može prepoznati zadane uzorke. Zbog toga se mreže organiziraju u obliku slojeva [90]. Veze među slojevima se mogu organizirati kao *feed forward* u kojima informacija putuje samo u jednom smjeru od ulaznog prema izlaznom sloju neuronske mreže. Također, veze se mogu organizirati i kao *feedback* gdje se sloj može aktivirati više od jednom, odnosno, informacija može putovati u oba smjera među slojevima. Na Slici 2.11 je prikazan primjer troslojne *feedforward* neuronske mreže.



Slika 2.11. Troslojna *feedforward* neuronska mreža [89]

Kod *feedback* mreža, prethodni slojevi mogu dobiti informacije o pogreškama iz slojeva koji se nalaze ispred, to se može iskoristiti radi prilagođavanja modela da bi bolje naučio ono što se traži od mreže. Na Slici 2.12 je prikazan primjer *feedback* neuronske mreže.

Neuronska mreža koja ima jednostavnu strukturu može biti iskorištena za dobivanje relevantnih podataka. Takav jedan primjer je prikazan u [92], gdje je korištena jednostavna *feedforward* troslojna neuronska mreža, koristila se za prepoznavanje udaljenosti do naslaga *kuroko* minerala u Japanu. Skriveni sloj se sastoji od pet neurona, hiperbolični tangens je aktivacijska funkcija. Rendgenske snimke, koje sadrže podatke o postojanju minerala u zemlji, su ulaz u mrežu. Minerali koje rendgenska snimka otkrije, bez obzira na vrstu minerala,



Slika 2.12. Feedback neuronska mreža [91]

može dati indicaciju da se u blizini nalazi traženi mineral. Autori zaključuju da i ova mala i jednostavna neuronska mreža uspješno pronalazi nalazišta željenog minerala.

Nadalje, primjer jednostavne *feedback* mreže je prikazan u [93] gdje se troslojna mreža koristi za filtriranje seizmoloških podataka. Pošto čisti seizmološki podaci sadržavaju veliku količinu šuma, nisu prikladni za čitanje i potrebno je iskustvo da bi se seizmološki podaci pročitali uz zadovoljavajuću točnost. Kako navode autori, prikazana neuronska mreža smanjuje količinu šuma za 50% pa autori navode da ovakva mreža, iako jednostavna, može prepoznati i umanjiti više vrsta šuma (npr. izravni i refraktirani valovi, nasumični šum, odroni tla).

Razvoj neuronskih mreža nije samo bio usmjeren prema produblivanju mreže (povećanju broja slojeva) [94], već su tu bile uključene metode i procedure samog treninga i arhitekture koja se treba prilagoditi ulaznim podacima [95]. U tom pogledu je zanimljiv doprinos dan u [96] gdje autori proučavaju *Deep Belief Network* (DBN), vrstu nenadziranog algoritma učenja [97]. Empirijski su proučavali i istraživali način rada mreže te pokušali pronaći najbolju primjenu te zaključili da se rad s inicijalnim težinama koje teže lokalnom minimumu vrijednosti pokazao najbolji u smislu strategije treniranja.

Neuronska mreža mora prilagoditi vezu između neurona, odnosno, između ulaza i izlaza, da bi naučila raditi ono što joj je zadano. Taj proces se još naziva i treniranje neuronske mreže. Proces treniranja se sastoji od koraka u kojima se radi prilagodba varijednosti težina i praga neurona, kao i veza neurona s drugim neuronima. Tako se mreža prilagođava da na izlazu generira rezultate što bliže željenima za svaku ulaznu vrijednost. Koraci treniranja

neuronske mreže se još nazivaju i algoritam učenja [98]. Skup podataka po kojima mreža uči se dijeli u dva seta: za treniranje i testiranje, i to u takvom odnosu da podaci za treniranje čine 60-90% podataka, dok ostatak od 40-10% čine podaci za testiranje. Podaci za testiranje se stavljaju na ulaz tako da mreža primi dosad neviđene podatke; na osnovu toga se na izlazu dobivaju rezultati na osnovu kojih se procjenjuje prihvatljivost mreže.

Kod treniranja neuronskih mreža razlikuju se strategije testiranja. Nadzirano učenje (engl. *Supervised learning*) je strategija testiranja u kojem su dostupni podaci o željenom rezultatu na izlazu, uz dostupan ulazni set podataka. Tijekom testiranja, vrijednosti težina i praga neurona se prilagođavaju primjenom koraka treniranja mreže. Mreža se smatra treniranom u trenutku kada razlika između željenog i dobivenom rezultata dođe unutar prihvatljivog raspona vrijednosti

Za razliku od nadziranog učenja, kod nenadziranog učenja (engl. *Unsupervised learning*) ne postoji informacija o željenoj vrijednosti izlaza, mreža se prilikom učenja treba sama organizirati na način da identificira klasterne temeljeno na njihovim sličnostima. Postoji mogućnost da korisnik unaprijed specificira maksimalni broj klastera i time pomogne mreži u procesu klasteriranja.

Podržano učenje (engl. *Reinforcement learning*) se smatra varijacijom strategije nadziranog učenja [99]. Temelji se na kvalitativnim i kvantitativnim informacijama dobivenim od okoline na osnovu kojih se radi procjena performansi učenja i tako prilagođavaju vrijednosti pragova.

Izvanmrežno učenje (engl. *Offline learning, Batch learning*) predstavlja strategiju treniranja u kojoj se vrijednosti težina veza i pragova mijenjaju nakon završenog postupka treniranja za cijeli trening set.

Mrežno učenje (engl. *Online learning*), suprotno od izvanmrežnog treniranja, je strategija treniranja u kojoj se vrijednosti težina veza i pragova prilagođavaju nakon korištenja svakog uzorka za testiranje. Navedena strategija je posebno od koristi kod sustava čije se vrijednosti brzo mijenjaju što omogućuje da se određeni uzorak u sred postupka treniranja, može odbaciti.

U nekim slučajevima, količina ulaznih podataka za treniranje može biti nedovoljna za

postizanje željene preciznosti modela. U tim slučajevima, može se koristiti predtreniranje modela na nekom drugom skupu podataka, koji će služiti za generiranje slojeva detektora značajki. Nakon toga, detektori značajki se mogu fino podesiti na ulazne podatke specifične za zadanu primjenu. U krajnjem slučaju, moguće je generirati slojeve detektora značajki bez ikakvih podataka, slaganje autoenkoder (engl. *Autoencoder*) neuronske mreže [100]. U početnoj fazi, dva sloja detektora značajki se stvaraju tako da svaki sljedeći sloj rekonstruira onaj prethodni. Na taj se način stvaraju skriveni slojevi. Nakon što je stvorena arhitektura koja se sastoji od nekoliko istreniranih skrivenih slojeva, pokušava se predvidjeti značajka u zadnjem sloju. Greška se vraća natrag kako bi se podesili detektori značajki. U ovom kontekstu, značaj detektora značajki je važan jer omogućuju korištenje ulaznih podataka koji mogu biti količinski oskudni. Predtreniranje može generirati značajke koje nisu relevantne za konačnu klasifikaciju. No, uzimajući u obzir važnost ulaznih podataka, svako predtreniranje je korisno ako olakšava proces treniranja. Postupak predtreniranja je ključan za uklanjanje opće prihvaćene činjenice da su duboke mreže inherentno teške za treniranje. U kontekstu značaja dubine učenja, značajan je rad [101] koji postavlja pitanje je li jednostavno dodavanje slojeva dovoljno za postizanje bolje performanse mreže. Međutim, to odmah dovodi do problema nestajanja [102] ili eksplozije [103] gradijenata, koji ometaju konvergenciju mreže. Nakon rješavanja ovog problema, javlja se problem stagnacije ili degradacije točnosti treniranja, koji se javlja kada se jednostavno dodaju slojevi na mrežu [104]. To sugerira da optimizacija mreže prema željama korisnika nije jednostavan zadatak. Zbog toga, autori rada [101] se bave problemom degradacije i predstavljaju svoj *Deep residual learning framework*.

Neuronske mreže su našle svoju primjenu u širokom spektru zanimanja, uključujući i ona osjetljiva na pogreške, kao što su dijagnostika u medicini [105, 106], procjena kreditne sposobnosti [107], upravljanje automobilima [108] i drugo. Stoga je važno biti u mogućnosti procijeniti pouzdanost izlaza koje mreža generira za unesene ulaze. Postoje dvije razine pristupa validaciji mreže. Prva razina se fokusira na dodjeljivanje izlaznim podacima razine pouzdanosti. Ova tehnika omogućuje obradu velikog broja podataka, pri čemu se podaci s nižom razinom pouzdanosti mogu odbaciti ili obraditi ručno. Druga razina pristupa predstavlja garanciju da će mreža davati pouzdane podatke za bilo koji ulaz. Ova razina je puno

rigoroznija i teže ostvariva [109]. Budući da je funkcioniranje neuronskih mreža složeno i često teško intuitivno razumljivo, postavlja se pitanje kako bolje komunicirati o rizicima koji proizlaze iz korištenja takvih mreža. Kako neuronske mreže nisu programirane u uobičajenom smislu, pravila kojima se određuje njihovo ponašanje ne postoje, već rade po modelu naučenom iz dijela ulaznih podataka i pripadnih izlaznih podataka, tako da nije moguće predvidjeti koji će biti izlaz za većinu vrijednosti ulaza. Svrha evaluacije i verifikacije mreže je otkriti i locirati svaku slabost unutar samog sustava [110]. Ocjenjivanje sustava ima širi opseg nego što je bio tijekom generiranja mreže, kada je cilj bio optimizirati performanse. U ovoj fazi je potrebno ocijeniti jesu li zahtjevi, ciljevi i potrebe korisnika ispunjeni na osnovu više tehnika:

- Provjera faze treniranja: Radi se procjena načina treniranja mreže i ocjena radi li se o ispravnim ili neispravnim izlazima za određene ulaze.
- Odabir tehnike testiranja: Nedovoljna količina testnih podataka predstavlja glavni problem u evaluaciji mreže. Da bi se mreža mogla adekvatno procijeniti, potrebno je koristiti širok raspon podataka, uključujući i one koji su pogrešni ili su blizu granica prihvatljivog ponašanja. U slučaju zadataka prepoznavanja slika ili objekata na slikama, potrebno je testirati sposobnost mreže da identificira i prisutne i odsutne objekte. Stvarni podaci za testiranje trebaju se koristiti kada god je to moguće.
- Korištenje simulacija: Učinkovita metoda za evaluaciju mreže, uz uvjet da odražava okruženje u kojem će se mreža koristiti.
- Testiranje od strane stručnjaka: Iskorištavanje znanja i iskustva nekoga tko je iskusan u području mreža za davanje mišljenja o mreži.
- Testiranje od strane korisnika: Krajnji korisnici trebaju provjeriti odgovara li sustav standardima korištenja korisnika

U okviru evaluacije i verifikacije mreže potrebno je provesti i sljedeće korake:


- Provjera sigurnosti: Potrebno je detaljno provjeriti postoji li mogućnost da sustav, u slučaju pogrešnog izlaza, nekome naudi ili prouzroči štetu.

- Pronalaženje granica između prihvatljivog i neprihvatljivog ponašanja: koji je jako izazovan zadatak. Međutim, identificiranje takve granice, čak i ako je nejasna, može značajno povećati pouzdanost mreže. Općenito, određivanje granice uključuje evaluaciju širokog raspona testnih slučajeva i njihovo klasificiranje kao valjanih ili nevaljanih.
- Testiranje robusnosti: Namjerno ubacivanje pogrešnih provjera mreže, izostavljanje podataka, ubacivanje podataka koji ne pripadaju mogućem ulazu
- Testiranje na licu mjesta: Isprobati sustav na mjestu korištenja pri čemu na njim rade korisnici za koje se planira da rade na njemu. Ovo se preporučuje izvesti ako je moguće.

Rekurentne neuronske mreže

Neuronske mreže kod kojih se informacije prenose kroz vremenske korake se nazivaju Rekurentne neuronske mreže (engl. *Recurrent NN* - RNN) [111]. RNN pronalazi svoju primjenu u obradi teksta, prepoznavanju slika, detekciji lica, sustavima za pretvaranje govora u tekst... U vremenu t , čvorovi prime ulaznu informaciju od trenutnog čvora $x(t)$ i informaciju od skrivenog čvora $h(t - 1)$ od prethodnog stanja neuronske mreže. Izlaz, označen kao $y'(t)$ će biti generiran koristeći skriveno stanje trenutnog koraka, označenog kao $h(t)$. S pomoću rekurentnih veza, ulaz $x(t - 1)$ u vremenu $t - 1$ utječe na izlaz $y'(t)$ u vremenu t . Primjer rekurentne neuronske mreže u vremenskim koracima je prikazan na Slici 2.13

Slojevite rekurentne neuronske mreže (engl. *Layer Recurrent Neural Networks* - LRNN) su podvrsta RNN čiju je pojednostavljenu dvoslojnu verziju prvi predstavio Elman u [112]. Za razliku od RNN, LRNN uz povratne veze ima i povratne veze unutar svakog sloja. Tako će čvorovi u vremenu t primiti informaciju od trenutnog čvora $x(t)$, od skrivenog čvora $h(t - 1)$ od prethodnog stanja i od povratnih veza unutar samog sloja $h'(t - 1)$. Primjer korištenja LRNN je prikazan u [113] koji istražuje primjenu slojevite rekurentne neuronske mreže (LRNN) za predviđanje brzine vjetera i proizvodnje energije vjetroturbine na različitim lokacijama. Autori su zaključili da LRNN može precizno predviđati vjetrovitost i proizvodnju energije vjetroturbine, ovisno o kvaliteti ulaznih uzoraka podataka i arhitekturi modela. Također, zaključeno je da odabir odgovarajućeg broja skrivenih neurona u LRNN arhitekturi



Slika 2.13. Rekurentna mreža prikazana u vremenskim koracima

može biti ključan za postizanje optimalnih rezultata.

Levenberg-Marquardt (LM) algoritam je iterativna tehnika koja se koristi za pronalaženje minimuma funkcije koja je izražena kao zbroj kvadrata nelinearnih funkcija [114]. Ovaj algoritam je postao standardna tehnika za rješavanje problema nelinearne regresije. Koristi se u neuronskim mrežama za treniranje u problemima regresije. Algoritam optimizira težine mreže minimizacijom funkcije greške kroz iterativno prilagođavanje parametara [115].

2.2.5. GIS i duboko učenje

Geografski informacijski sustavi (GIS) su sustavi za prikupljanje, analizu, ispitivanje i pohranu prostornih podataka [116]. duboko učenje je grana umjetne inteligencije koja se temelji na algoritmima strojnog učenja s višestrukim slojevima neuronskih mreža, omogućujući sustavu da automatski uči složene obrasce i značajke iz podataka [79].

Integracija GIS-a i dubokog učenja predstavlja pristup koji omogućuje analizu prostornih podataka na novoj razini. Kombinacija GIS-a kao alata za analizu i prikaz prostornih podataka s dubokim učenjem kao načinom prepoznavanja složenih uzoraka i veza iz podataka otvara nove mogućnosti u razumijevanju i primjeni prostornih informacija.

Prikaz integracije GIS-a s umjetnom inteligencijom je prikazan u radu [117] koji se fokusira se modeliranje urbanog razvoja. Autori su primijenili neizraziti *c-means* algoritam [118] za stvaranje klastera koji predstavljaju razinu urbanizacije. Ovi klasteri omogućuju praće-

nje razvoja regije, prateći njezinu transformaciju od ruralnog prema urbanom području s povećanjem brojem stanovnika. Nakon dobivanja rezultata, autori su ih integrirali u GIS bazu podataka, koristeći GIS softver za vizualizaciju. Kako bi predvidjeli razvoj urbanizacije, autori su koristili neuronske mreže za analizu promjene u urbanoj strukturi susjednih područja. Proces stvaranja neuronske mreže uključivao je testiranje tri različite arhitekture. Neuronska mreža A imala je jedan skriveni sloj s 252 neurona i linearnu prijenosnu funkciju. Neuronska mreža B sastojala se od dva skrivena sloja s ukupno 488 neurona i kombinacijom linearnih i sigmoidnih prijenosnih funkcija. Treća arhitektura, neuronska mreža C, imala je dva skrivena sloja s ukupno 550 neurona i kombinacijom linearnih i sigmoidnih prijenosnih funkcija. Prema rezultatima, neuronska mreža C pokazala se najučinkovitijom arhitekturom, s MSE pogreškom od 0,005 nakon 1000 epoha i koeficijentom korelacije (r) od 0,91. Ovi rezultati nadmašili su performanse neuronskih mreža A i B, koje su imale veće MSE vrijednosti i niže koeficijente korelacije. Zaključak autora je da je neuronska mreža C najpogodnija za predviđanje i interpretaciju urbanih uzoraka rasta u gradskom području Atene. Autori su također zaključili da integracija GIS-a, neizrazite logike i neuronskih mreža, prema predloženoj metodologiji, uz potpune ulazne podatke, može pružiti precizne informacije o budućem urbanizacijskom razvoju.

Kia i suradnici [119] istraživali su primjenu kombinacije neuronskih mreža i GIS-a u razvoju modela za simulaciju poplava u područjima podložnim poplavama. Koristili su jednostavnu *feed-forward* neuronsku mrežu s sedam ulaznih parametara, što je rezultiralo ulaznom neuronskom mrežom od sedam čvorova. Iako je model bio jednostavan, zaključak je da u kombinaciji s GIS-om pruža dovoljnu preciznost da doprinese zaštiti od poplava, nadmašujući već postojeće sustave.

Cilj istraživanja [120] je razviti model za predviđanje osjetljivosti na klizišta koristeći kombinaciju GIS-a i neuronskih mreža. Autori su prikupili podatke iz različitih izvora, uključujući topografske karte, satelitske slike i geološke karte, kako bi stvorili geoprostornu bazu podataka faktora povezanih s klizištima. Za treniranje i evaluaciju modela, korišteni su prošli podaci o klizištima i GIS podaci o podložnosti klizištima. Koristeći MLP (višeslojnu perceptronsku mrežu - engl. *Multilayer Perceptron*) s tri sloja (ulazni, skriveni i izlazni), model

je konfiguriran sa 10 čvorova u ulaznom sloju, predstavljajući faktore povezane s klizištima. Izlazni sloj ima jedan čvor koji pruža informaciju o osjetljivosti na klizišta, dok se skriveni sloj sastoji od 15 čvorova s aktivacijskom funkcijom sigmoida. Korištena je povratna propagacija kako bi se prilagodile težine i osigurala sličnost između izračunatog i željenog izlaza. Rezultati modela pokazuju točnost predviđanja osjetljivosti na klizišta od 87,5%. Ključni čimbenici koji su pridonijeli podložnosti klizištima uključivali su nagib, orijentaciju nagiba i udaljenost od vodenih masa. Unatoč sveobuhvatnoj metodologiji koja koristi kombinaciju neuronskih mreža i GIS-a, istraživanje ukazuje na potrebu razmatranja dodatnih čimbenika koji nisu uzeti u obzir, poput seizmičke aktivnosti, svojstava tla i utjecaja čovjeka. Važno je napomenuti da je istraživanje provedeno samo na ograničenom području jednog okruga, što može ograničiti generalizaciju modela na druga područja. Također, istraživanje se oslanja na povijesne podatke za treniranje modela, a mogućnost pogrešaka postoji zbog promjena u uvjetima okoline tijekom vremena.

U radu [121] prikazana je još jedna kombinacija GIS-a s neuronskim mrežama, ovaj put primijenjena za predviđanje cestovnih prometnih nesreća. Autori su usporedili rezultate dobivene pomoću neuronskih mreža s onima dobivenim korištenjem viševarijantne analize te zaključili da su oba pristupa prikladna za rješavanje navedenog problema. Viševarijantna analiza je statistička tehnika koja istražuje odnose i interakcije među više varijabli istovremeno kako bi otkrila obrasce i ovisnosti u složenim skupovima podataka. Važno je napomenuti razliku između višekriterijske i viševarijantne analize. Višekriterijska analiza je tehnika donošenja odluka koja procjenjuje i rangira alternative na temelju više kriterija ili ciljeva, pomažući donositeljima odluka u složenim situacijama. S druge strane, viševarijantna analiza je statistička metoda koja istražuje odnose i obrasce između više varijabli istovremeno, s ciljem razumijevanja njihovih međuovisnosti i smanjenja dimenzionalnosti podataka. Iako je korišten MLP, radu nedostaje detaljnijih objašnjenja arhitekture same mreže, kao i metode računanja točnosti, osim što su autori naveli da iznosi 73,5%. Unatoč tome, ovaj rad predstavlja zanimljivu ideju, otvarajući još jednu perspektivu korištenja GIS-a i neuronskih mreža u analizi cestovnih prometnih nesreća.

U istraživanju prikazanom u [122], autori su primijenili Rekurentnu neuronsku mrežu za

predviđanje ozbiljnosti posljedica prometnih nesreća. Rekurentne neuronske mreže su vrsta neuronskih mreža koje koriste povratne veze, omogućujući pamćenje prethodnih stanja i pružajući sposobnost učenja dinamike sekvencijalnih podataka. Prema zaključku autora, Rekurentne neuronske mreže su se pokazale korisnima i postigle su najbolje rezultate u predviđanju ozbiljnosti posljedica prometnih nesreća.

Prethodna istraživanja jasno ukazuju na potencijale i koristi GIS-a u kombinaciji s neuronskim mrežama. Iako se često koriste jednostavne mreže s nekoliko slojeva, to ne ograničava njihovu sposobnost postizanja značajnih rezultata u svojim specifičnim primjenama.

Bi i suradnici [123] u svom istraživanju predstavljaju inovativan pristup razmatranju različitih sudionika u prometu unutar urbanih područja. Autori predstavljaju ujedinjeni model neuronske mreže s ciljem izračuna vremenski i energetske učinkovitih ruta unutar gradskih cestovnih mreža. Ova metodologija se razlikuje od prethodnih radova koji su koristili *feed-forward* neuronske mreže, budući da Bi i suradnici koriste *Random* neuronske mreže. *Random* neuronske mreže su stohastički modeli koji se sastoje od skupa neurona međusobno povezanih na nasumičan način. Neuroni u ovim mrežama imaju varijable stanja koje se mijenjaju tijekom vremena kao odgovor na ulazne signale dobivene od drugih neurona. Stanje svakog neurona se stohastički ažurira na temelju skupa prijelaznih vjerojatnosti, ovisno o stanju drugih neurona u mreži. Cestovna mreža se prikazuje grafički, gdje čvorovi predstavljaju lokacije, a veze predstavljaju cestovne segmente. Ova mreža koristi GIS podatke kako bi izračunala ekološki najpogodniju rutu za različite vrste vozila. Važno je napomenuti da različiti zahtjevi različitih korisnika ceste mogu utjecati na učinkovitost sustava. Stoga bi se eventualno poboljšanje moglo postići stvaranjem modela fokusiranog na određenu vrstu vozila, prilagođavajući se njihovim specifičnim zahtjevima. Autori zaključuju istraživanje pokazujući da njihova studija ima smisla, posebno s obzirom na ekološki aspekt. U Pekingu, njihov model je rezultirao smanjenjem prosječnog vremena putovanja za 20% i potrošnje energije za 10%.

U radu prikazanom u [124], koristi se kombinacija GIS-a i neuronskih mreža s ciljem poboljšanja cestovne sigurnosti. Neuronska mreža se koristi za izračunavanje predvidljivosti rizika, dok se GIS koristi za generiranje geoprostornih podataka. DEA (engl. *Data Envelop-*

ment Analysis) integrirana je s neuronskom mrežom, pri čemu je DEA korištena kao benchmarking mehanizam za procjenu učinkovitosti i razine rizika cestovnih segmenata. DEA, tehnika matematičke optimizacije često korištena u ekonomiji, definira se kao metoda koja mjeri relativnu učinkovitost jedinica odlučivanja uspoređujući njihove ulaze i izlaze. U kontekstu analize cestovne sigurnosti, DEA se koristi za izračunavanje razine rizika cestovnih segmenata na temelju broja nesreća i smrtnih slučajeva. Vrijednosti rizika dobivene iz DEA zatim se koriste kao ulaz u neuronski model koji se koristi za predviđanje i procjenu razine rizika cestovnih segmenata, uzimajući u obzir čimbenike kao što su brzina, protok i geometrijske karakteristike dizajna ceste. Ovaj inovativni pristup omogućuje precizniju procjenu rizika, pružajući donositeljima odluka vrijedne uvide u poboljšanje uvjeta sigurnosti na cestama. Iako se u samom radu ne navodi precizna vrsta neuronske mreže korištene u modelu, slike sugeriraju da je riječ o *feed-forward* mreži. Osim toga, prvi put se koristi DEA metoda čiji izlazi ulaze u neuronsku mrežu, a takav pristup evaluiran je i uspoređen s višestrukom linearnom regresijom, pri čemu je zabilježeno značajno smanjenje korijen srednje kvadratne pogreške s 1,08 na 0,62.

U radu [125] primijenjen je inovativan pristup tako što predstavljaju metodologiju koja uzima u obzir vizualni okoliš prilikom odabira biciklističke rute, koristeći neuronske mreže za dobivanje statistike o atributima izgrađenog okoliša. Podaci o izgrađenom okolišu, obrađeni neuronskim mrežama, postaju ključni ulaz u proces izračuna rute. Ovi podaci, uključujući impendanciju ceste, koriste se u izračunu preporučenih cesta na temelju minimalne impendancije rute. Impendancija se odnosi na faktor koji se koristi za određivanje optimalne biciklističke rute na temelju osobnih preferencija korisnika. Uključuje različite čimbenike poput brzine vožnje, udaljenosti, kvalitete urbanog okoliša i drugih kriterija. Kroz prilagođavanje impendancije prema preferencijama korisnika, sistem može preporučiti rute koje odgovaraju specifičnim potrebama biciklista. Autori su primijenili model *deeplabv3+* temeljen na Tensorflowu, koji uključuje modul za kodiranje i modul za dekodiranje, za obradu vizualnih atributa. Meng i Zheng su kao autori pokazali kako integracija vizualnih podataka može obogatiti proces odabira ruta, osobito u kontekstu biciklističkih staza.

Proučavajući prethodne radove, zaključuje se da integracija GIS-a i neuronskih mreža

pruža učinkovit alat za rješavanje složenih problema temeljenih na prostornim podacima. Raznovrsnost primjena ovog pristupa uključuje predviđanje klizišta, analizu prometnih nesreća, urbanističko modeliranje te analizu rizika od požara. Svaki od navedenih radova usredotočuje se na specifičan problem u kontekstu primjene GIS-a. Različite vrste neuronskih mreža, uključujući *feed-forward* mreže, rekurentne neuronske mreže (RNN) i *random* neuronske mreže, korištene su u istraživanjima. Podaci korišteni za treniranje i testiranje modela uključuju geoprostorne podatke, statističke podatke, povijesne podatke i druge relevantne informacije. Unatoč prednostima koje ova integracija nosi sa sobom, postoje izazovi i ograničenja koje nosi sa sobom. Izazovi uključuju potrebu za obimnim podacima za treniranje neuronskih mreža, pravilan odabir arhitekture mreže, obradu i čišćenje podataka, te ispravnu interpretaciju rezultata. Najznačajnije ograničenje leži u potrebi za velikom količinom podataka, što može predstavljati izazov u prikupljanju. Treniranje i korištenje neuronskih mreža može biti resursno zahtjevno, osobito na računalima s ograničenim resursima. Pretreniranje (engl. *Overfitting*), tj. prilagodba podacima za treniranje, također predstavlja problem koji zahtijeva pažljivo rukovanje kako bi se očuvala generalizacija na šire podatke. Dodatno, GIS podaci mogu biti zastarjeli ili nepouzdana, što može dovesti do netočnih zaključaka. Stoga, uprkos prednostima, važno je pažljivo upravljati ovom integracijom, uzimajući u obzir navedene izazove i ograničenja.

3. METODE ISTRAŽIVANJA

Metode istraživanja ovog doktorskog rada uključuju višekriterijsku GIS analizu, teoriju grafova i strojno učenje s posebnim naglaskom na neuronske mreže s ciljem optimizacije biciklističkih ruta. Kao prvi korak istraživanja prikupljeni su podaci svih puteva primjerenih za prolazak biciklom; to uključuje asfaltirane ceste i sve što je iz GIS-a moglo biti identificirano kao prikladno. S praktične perspektive, ovo istraživanje predstavlja korak prema novim pristupima planiranju i razvoju biciklističkih ruta, pružajući turistima priliku da istraže neotkrivene ljepote i prirodne resurse. Dodatno, istraživanje ima mogućnost potaknuti lokalne zajednice da iskoriste svoj turistički potencijal, otvarajući mogućnosti za ekonomski razvoj i očuvanje prirodnog okoliša. Kroz korištenje integriranih pristupa i naprednih tehnologija, ovo istraživanje ima potencijal transformirati način na koji se planiraju, razvijaju i promiču biciklističke rute, pridonoseći istovremeno održivom turizmu i lokalnom razvoju.

Cilj ovog rada je predložiti biciklističke rute temeljene na višekriterijskoj GIS analizi (MCDA-GIS - engl. *Multi-Criteria Decision Analysis*) u ruralnom području. Model odabira ruta primijenjen je na cestama Imotskog, malog grada u Dalmatinskoj zagori. Model je temeljen na višestrukim kriterijima koji obuhvaćaju kako rekreativne tako i sigurnosne aspekte. Svrha modela bila je povezati zanimljive točke u širem području grada biciklističkim rutama. Kriteriji koji su utjecali na odluku o najboljem putu odabrani su prema potrebama turista. Za izradu modela rute korišten je softver ArcGIS.

3.1. Ulazni podaci

Optimizacija modela u strojnom učenju zahtijeva temeljitu analizu i upotrebu kvalitetnih podataka radi postizanja optimalnih rezultata. Preciznost i kvaliteta podataka ključni su

čimbenici u generiranju robustnih modela.

U izradi modela korišten je softver ESRI ArcGIS Desktop 10,5. ArcGIS [126] je softverska platforma koja korisnicima omogućuje stvaranje, analizu, prikazivanje i upravljanje prostornim podacima. U sebi sadržava ekstenzije i alate i koje omogućuju korisnicima pristup i rad na geografskim podacima što uključuje kartografsko prikazivanje, analizu terena, prostornu analizu, planiranje i slično. U izradi modela su korišteni *3D Analyst*, *Spatial Analyst* i *Network Analyst* ekstenzije. *3D Analyst* [127] ekstenzija sadrži alate za stvaranje, vizualizaciju i analizu GIS podataka u trodimenzionalnom kontekstu. Koristi se za različite svrhe, uključujući vizualizaciju terena, analizu vidljivosti, modeliranje građevinskih struktura te proučavanje i oblikovanje terena za različite svrhe poput urbanog planiranja ili istraživanja podzemnih geoloških tijela. *Spatial Analyst* [128] ekstenzija sadrži alate za prostorno modeliranje i analizu. Alati ove ekstenzije se mogu koristiti za izvođenje prostornih analiza, uključujući stvaranje novih informacija iz postojećih podataka, pronalaženje optimalnih lokacija za različite svrhe te izvođenje analiza udaljenosti, putovanja i statističkih analiza na prostornim podacima. Osim toga, *Spatial Analyst* omogućuje interpolaciju podataka, filtriranje podataka te druge prostorne analize koje pomažu u rješavanju prostornih problema. Ekstenzija *Network Analyst* [129] omogućuje analizu i modeliranje transportnih mreža za rješavanje prostornih problema, uključujući pronalazak najkraćih puteva, identifikaciju optimalnih lokacija, analizu udaljenosti i putovanja, kao i optimizaciju rute i rasporeda vozila u svrhu poboljšanja učinkovitosti. Ekstenzija koja nije korištena za kreiranje modela, a smatra se važnom je *ArcScan* [130] ekstenzija koja sadrži alate koji omogućuju pretvaranje skeniranih slika u vektorske slojeve značajki, tj. vektorizaciju. Ova ekstenzija se često koristi za konvertiranje rasterne slike u vektorske slojeve radi integracije starih geografskih dokumenata u GIS. Tako daje mogućnost za pretvaranje dokumenata u digitalni oblik olakšavajući njihovu daljnju analizu i manipulaciju.

Sloj podloge za rad bio je TK25 topografska karta Državne geodetske uprave [131] u mjerilu 1:25000. Za prikupljanje podataka potrebnih za kreiranje modela korišteni su podaci o cestama, nagibu terena, vodenim površinama i lokacijama hitne pomoći. Topografske karte su georeferencirane u službenoj geografskoj projekciji Republike Hrvatske HTRS96/TM, a

s karata su korišteni slojevi: cesta i puteva; slojnica; vodenih tokova, rijeka i kanala, površina i izvora. Ovi slojevi su vektorizirani koristeći alate za automatsku i poluautomatsku vektorizaciju, te su im pridjeljeni atributni podaci.


Podaci o cestama, vodenim površinama i nagibu terena su izvorno skenirani, georeferencirani, vektorizirani i obogaćeni atributima. Nastali su kao rezultat obrade za potrebu prethodnih projekata.

Sloj podataka sa cestama u putevima je vektoriziran u obliku polilinija. Svaki segment ceste definiran je kao linija između dva raskrižja, odnosno, mjesta gdje se susreću više linija. Tablica atributa sadrži podatke o identifikaciji svakog segmenta, duljini te vrsti ceste kojoj segment pripada. Svaki segment klasificiran je u jednu od sedam vrsta cesta: autocesta, cesta za daljinski promet, glavna cesta, lokalna cesta, sporedna cesta, asfaltirana cesta i put, pri čemu su poredani od veće važnosti prema manjoj.

Što se tiče promatranih cesta na području grada Imotskog i okolnih općina, sloj cesta je skraćen tako da samo obuhvaća ceste tog područja. Tako se sada ceste sastoje od 268 segmenata čija je prosječna duljina 1556,06 m. Listovi TK25 topografske karte korišteni na ovom području su Imotski (4371-2-1-2), Vinjani (4371-2-2-1), Studenci (4417-4-3-3), Ričice (4417-4-3-4), Zagvozd (4317-2-1-1), Makarska (4317-2-1-3), Slivno (zapad) (4317-2-1-4) i Slivno (istok) (4317-2-2-3). Što se tiče vrsta ceste, na ovom području nisu prisutne autoceste ni ceste za daljinski promet, dok su ostale prethodno navedene vrste prisutne u tablici atributa. Na Slici 3.1 je prikazana TK25 topografska karta preklopljena sa slojem cesta na području Imotskog.

Da bi se dobile promatrane ceste na području Knina, sloj cesta je skraćen na 215 segmenata čija je prosječna duljina 1403 m. Listovi TK25 topografske karte korištene na području Knina su: Knin (4416-2-3-4), Polača (4416-2-4-3), Plavno (4416-2-3-2), Mokro Polje (4416-2-3-3), Oklaj (4416-4-1-1), Siverić (4416-4-1-2) i Štikovo (4416-4-2-1). Kad se promatraju dostupne vrste cesta na ovom području, nisu prisutne autoceste, ostale vrste cesta su navedene u tablici atributa.

Promatrane ceste na području Vrgorca se sastoje od 168 segmenata iz čega se da zaključiti da je to najmanje razgranato područje od promatranih. Prosječna duljina segmenata




Slika 3.1. TK25 i sloj cesta na području Imotskog

je 1937 m. Promatrani listovi TK25 topografske karte na ovom području su: Vrgorac (zapad) (4317-2-4-1), Vrgorac (istok) (4317-2-4-2), Slivno (zapad) (4317-2-1-4), Slivno (istok) (4317-2-2-3), Živogošće (4317-2-3-2), Opuzen (sjever) (4318-1-3-1), Trpanj (43187-2-4-3), Ploče (2317-2-4-4) i Opuzen (jug) (4318-1-3-3). Kao i kod Knina, od vrsta cesta jedino autocesta nije dostupna, ostale vrste cesta postoje u navedenom području.

Za izračun nagiba na pojedinom segmentu ceste u je potrebna informacija o reljefu. Tu informaciju sadrži sloj slojnica u obliku polilinja s vertikalnom rezolucijom 50 metara. Na osnovu tih podataka je rekonstruirana informacija o nagibu svakog segmenta na svim promatranim područjima. Nagib segmenta je izračunat temeljem početne i krajnje točke segmenta, što predstavlja pojednostavljenje, jer ne uzima u obzir moguće veće promjene nagiba unutar samog segmenta. Stoga će u idućoj fazi istraživanja modeliranje nagiba unutar segmenata biti prilagođeno na način da vodi računa o promjenama nagiba unutar samog segmenta. Slojnice su prikazane na Slici 3.2.


Korištenjem podataka koji sadrže slojnice o visini terena s karata, rekonstruirani su re-



Slika 3.2. Slojnice na području Imotskog

ljejni modeli promatranih područja pomoću alata *Create TIN* (Slika 3.3). Rekonstruiran je reljefni model područja pomoću mreže trokutastih neregularnih trokuta (engl. *Triangulated Irregular Network - TIN*), koristeći slojeve s podacima o visini dobivenim s topografske karte u mjerilu 1:25.000. TIN je vektorski podatak koji nastaje triangulacijom vrhova povezanih nizom bridova, stvarajući mrežu trokuta, s većom razlučivošću na dinamičnijim područjima. Važno je napomenuti da TIN model predstavlja trokutnu mrežu koja pomaže u preciznom modeliranju i analizi terena. Ovaj pristup omogućuje izračunavanje nagiba terena, što je ključno za planiranje biciklističkih ruta i prilagođavanje staza različitim preferencijama i sposobnostima biciklista.

TIN aproksimira površinu terena pomoću skupa trokutnih ploha. TIN modeli prikazuju ravne trokutne plohe kako bi se pojednostavnila interpolacija. Svaki trokut definiran je s tri brida, a svaki brid omeđen je s dva vrha. Vrhovi u TIN-ovima opisuju čvorove terenskih obilježja, poput vrhova, udubljenja ili prijelaza, dok bridovi prikazuju linearna terenska obilježja, poput usjeka, grebena ili vododerina. Većina postojećih metoda izgradnje TIN-



Slika 3.3. TIN (Triangulated Irregular Network) model reljefa

ova u osnovi je niz postupaka za odabir skupa točaka koje najbolje aproksimiraju površinu terena prema određenim kriterijima [132]. Kod izračuna TIN-a iz slojnica se koristila Delaunayeva triangulacija kao algoritam izračuna [133] koja najmanje kuteve svakog trokuta i time se izbjegavaju dugi i tanki trokuti; teži se trokutima što bliže jednakostraničnima.

Na Slici 3.3 se na jugoistočnom rubu Imotskog polja mogu vidjeti pojave artefakata do kojih dolazi zbog ruba područja koje TIN pokriva što dovodi do nepravilnosti u izračunu trokuta. Kako se navedeno područje nalazi izvan promatranog područja, tj. izvan dohvata točki interesa, artefakti nisu utjecali na konačan izračun nagiba. Manji artefakti nalaze se i na spojevima topografskih karata, međutim zbog svojih dimenzija nisu uticala na proračun. Zbog uočenih nedostataka korištenja TIN-a modela reljefa u idućoj fazi istraživanja se planira koristiti preciznije podatke dobivene LIDAR-om.

Koristeći alat *Slope* koji je dio *3D Analyst* ekstenzije je na osnovu TIN-a dobivena informacija o postotnom nagibu svakog segmenta ceste te je taj podatak pridodan ostalima u tablici atributa cesta.

Lokacije potoka na promatranim područjima su dobiveni spajajući slojeve polilinja koje sadržavaju potoke i rijeke na promatranom području. Takav novostvoreni sloj polilinja se sastoji od 41 segmenta prosječne duljine 1398 m. Izračun udaljenosti od centroida segmenta do potoka je izveden koristeći *The Closest Facility* alat koji omogućuje izračun najbrže ili najkraće putanje između točaka interesa, koje se nazivaju *facilities* (objekti) i lokacijama koje trebaju te usluge, poznatima kao *incidents* (incidenti). Ovaj alat može se koristiti za razne primjene, poput pronalaženja najbliže bolnice, vatrogasne postaje, ili trgovine određene lokacije, optimizaciju ruta dostave, hitne intervencije, i slično.

Prije upotrebe alata trebalo je pretvoriti sloj polilinja koji čini potoke i rijeke u točke. Za razliku od pretvaranja sloja cesta koji je razgranat i zbog čega je bilo dovoljno ceste aproksimirati centroidima, ovdje je svaka linija pretvorena u točku, rezultirajući slojem od 1744 točke. Ukupna duljina svih polilinja koje čine potoke iznosi 57339 m, što znači da svaka točka u prosjeku zamjenjuje poliliniu u duljini od 32,88 m. *The Closest Facility* na osnovu tih točaka izračunava najbližu točku potoka najbližem centroidu segmenta ceste. Što se tiče potoka na području Vrgorca, polilinije na tom području se sastoje od 213 segmenata prosječne duljine 1076 m. Suma duljina svih polilinja potoka iznosi 229260 m. Pretvaranje polilinja u točke je rezultiralo s 1977 točaka, time se dobiva da svaka točka prosječno zamjenjuje poliliniu u duljini 115,96 m. Na području Knina se potoci i rijeke sastoje od ukupno 90 segmenata prosječne duljine 2589 m. Polilinije su pretvorene u ukupno 1557 točaka pa se tako dobije da je svaka točka prosječno zamijenila poliliniu u duljini od 149,7 m.

Lokacija hitne pomoći u Imotskom je identificirana pomoću prethodnog znanja o lokaciji. Zajedno s informacijom o lokaciji, uz TK25 topografsku kartu u pozadini, stvoren je novi sloj koji sadržava točku s lokacijom hitne pomoći za područje Imotskog. Izračun udaljenosti do hitne pomoći je napravljen koristeći *The Closest Facility* alat iz *Network Analyst* ekstenzije. Radi jednostavnosti izračuna, svaki od segmenata mreže cesta je pretvoren u točku i to na sredini segmenta (centroid) koristeći *Feature Vertices to Points* alat. *The Closest Facility* alat vraća najbližu udaljenost u mreži cesta od početne do najbliže od završnih točaka. Lokacije hitne pomoći u Kninu i Vrgorcu je identificirana pomoću *Google Maps* servisa, lokacija je prepoznata na TK25 topografskoj karti i stvoreni su novi slojevi koji sadržavaju lokaciju

hitne pomoći na području Knina i Vrgorca,

Prije izračuna modela su podaci normalizirani [134]. Normalizacija podataka je postupak skaliranja vrijednosti atributa u skupu podataka na određeni raspon kako bi se osigurala usporedivost među atributima ili jednostavnije rukovanje podacima. Jedna od metoda normalizacije je standardizacija, koja se koristi kako bi se distribucija podataka pretvorila u standardnu normalnu distribuciju sa srednjom vrijednošću od 0 i standardnom devijacijom od 1.

U istraživanju je odabrana Min-max normalizacija kao metodologija normalizacije podataka [135]. Ova specifična normalizacijska tehnika je preferirana zbog svoje jednostavnosti i praktičnosti, budući da skalira vrijednosti atributa u rasponu [0,1]. Takva karakteristika odgovara zahtjevima istraživanja, pružajući jasno razumijevanje o skali vrijednosti. Nadalje, Min-max normalizacija zadržava relativne razlike između vrijednosti, što je ključno za analizu podataka u kontekstu istraživanja. Izraz za Min-max normalizaciju glasi:

$$X'_i = \frac{X_i - X_{i_{min}}}{X_{i_{max}} - X_{i_{min}}} \quad (3.1)$$

pri čemu X_i predstavlja i -ti podatak u setu podataka kriterija, $X_{i_{min}}$ je minimalna, a $X_{i_{max}}$ maksimalna vrijednost promatranog seta podataka pojedinog kriterija.

3.2. Višekriterijska GIS analiza

U inicijalnoj fazi ovog istraživanja, ključni alat za analizu cestovnih mreža je upravo GIS, koji omogućuje rad s različitim izvorima podataka. U tom kontekstu, GIS pruža podatke u obliku slojeva polilinja koji precizno predstavljaju mrežu cesta i puteva. Ova mreža je modelirana kao graf, gdje svaki segment ceste između raskrižja čini dio grafa, a raskrižja predstavljaju čvorove grafa. Svaki segment ceste definiran je raznim značajkama, uključujući duljinu i vrstu ceste. Nad ovako definiranim grafovima u GIS-u primijenjuje se višekriterijska analiza (MCDA-GIS - engl. *Multi-Criteria Decision Analysis*). Različiti kriteriji, poput nagiba terena, dostupnosti vode i udaljenosti do hitne pomoći, su uzeti u obzir. Numeričke vrijednosti pojedinih kriterija se dobivaju pomoću GIS-a, pri čemu je nagib pojedinog

segmenta izračunat iz 3D modela terena, a udaljenosti od značajki analizirane kroz točkaste slojeve. Odabir kriterija ovisi o vrsti bicikliranja, bilo amaterskom ili profesionalnom treniranju. Definiciju kriterija i ponderiranje se izvršava uz konzultaciju dostupne literature i ekspertnog znanja.

Izračun vrijednosti segmenata putem višekriterijske analize je jasan: zbroj ponderiranih značajki pojedinih segmenata čini težinu svakog segmenta. Nakon definiranja kriterija i pondera, mreža cesta na odabranom području je izolirana, a kao točke interesa su odabrana mjesta koja ruta treba obuhvatiti. Korištenjem tih kriterija i ponderiranja, pristupa se generiranju biciklističkih ruta koje prolaze kroz sve zadane točke interesa. Ključan alat za odabir optimalnih ruta između tih točaka je Dijkstra algoritam [46], koji se koristi za pronalaženje najkraćih, odnosno najpogodnijih ruta uzimajući u obzir definirane kriterije. Kroz primjenu Dijkstra algoritma, višekriterijska analiza odabire najpogodniji put između zadanih točaka interesa. Kako bi se ispitala kvaliteta novog modela rutiranja, uspoređuje se generirana ruta s onom koju stvaraju ljudski eksperti, a koja se koristi u praksi, te mjeri njihova sličnost. U sklopu istraživanja je provedeno istraživanje među ispitanicima vezani za biciklizam da bi se dobilo više informacija o njihovim preferencijama prilikom odabira biciklističke rute.

3.2.1. Provođenje istraživanja preferencija među biciklistima

Da bi se bolje razumjele preferencije biciklista prilikom odabira biciklističke rute, provedeno je istraživanje i to kombinirajući kvalitativni i kvantitativni pristup; to su pristupi koji se razlikuju po metodama prikupljanja i analize podataka, kao i po vrsti podataka kojima se bave.

Kvalitativno istraživanje fokusira se na razumijevanje ljudskog ponašanja, doživljaja, stavova ili kultura kroz detaljno opisivanje i analizu nebrojivih podataka. Primjeri metodologija kvalitativnog istraživanja uključuju intervjuiranje, promatranje, studije slučaja, i analizu teksta. Cilj je razumjeti dublje značenje, procese i kontekstualne aspekte vezane za istraživačko pitanje. Kvalitativno istraživanje omogućava fleksibilnost i dubinsko istraživanje kompleksnih fenomena, ali često ne omogućava generalizaciju nalaza na širu populaciju.

Kvantitativno istraživanje, s druge strane, koristi se za kvantificiranje problema kroz ge-

neriranje numeričkih podataka ili podataka koji se mogu pretvoriti u upotrebljive statistike. Ovaj pristup se oslanja na mjerenje, matematičku i statističku analizu kako bi se dokazale hipoteze ili procijenile varijable. Metode kvantitativnog istraživanja uključuju ankete, eksperimente, kvazi-eksperimente i longitudinalna istraživanja. Kvantitativno istraživanje omogućava testiranje teorija, predviđanje fenomena i generalizaciju rezultata na veće populacije, ali može biti ograničeno u razumijevanju dubine i konteksta istraživačkog problema.

U ovom istraživanju primjenjuje se kombinacija oba pristupa kako bi se dobila sveobuhvatna analiza preferencija biciklista.

Kvalitativni dio istraživanja

U kvalitativnom dijelu istraživanja provedeni su dubinski polustrukturirani intervjui s biciklističkim ekspertima. Odabrani su kontaktiranjem biciklističkih udruga i saveza koji su dali svoje preporuke za iskusne i relevantne sudionike. Preporučeni eksperti su kontaktirani e-mailom kojim im je objašnjena tema i svrha istraživanja te su zamoljeni za sudjelovanje. Od sedam kontaktiranih eksperata, šest ih je pristalo sudjelovati. Intervjui su provedeni putem telefona ili videopoziva.

Na početku intervjua sudionicima je dodatno pojašnjena svrha istraživanja te zatražen pristanak za snimanje intervjua. Prema vodiču za intervju, prvo su odgovarali na demografska pitanja i pitanja o dosadašnjem biciklističkom iskustvu, nakon čega su uslijedila pitanja koja se tiču svrhe korištenja bicikla, odvoženih ruta i kriterija za odabir istih. Prosječno trajanje intervjua je bilo 30 minuta.

Nakon provedenih intervjua napravljeni su transkripti prema snimljenim audio zapisima. Transkripti su analizirani uz pomoć programa Taguette [136], prema kodnom planu koji prati vodič za intervju.

Izabrani su citati koji najbolje reprezentiraju sličnost i varijacije među sudionicima, a dodatno su uređeni da bi bili jasniji za čitanje. Nakon citata u zagradama se nalazi brojčana oznaka ispitanika (npr. I3). Prikaz rezultata istraživanja organiziran je prema temama obrađenim u intervjuu.

Svih šest sudionika ove etape istraživanja su muškarci, koji navode da bicikliraju već

dugi niz godina te su aktivni u unaprjeđivanju biciklističkog iskustva. Ističu se kao eksperti u biciklizmu jer se među sugovornicima nalaze profesionalni licencirani treneri biciklizma, voditelji biciklističkog saveza, sudionici na sportskim biciklističkim događajima, znanstvenici koji se bave istraživanjima na području cikloturizma, članovi biciklističkih udruga, biciklistički aktivisti... Svi sugovornici su istaknuti pojedinci u svijetu bicikliranja.

“Udruga se uspjela probiti i doći na glas pa se sad članove aktivno poziva na sudjelovanje u javnim procesima. Sad kroz udrugu lobiramo svugdje gdje možemo kako bi osigurali bolje uvjete za bicikliste i općenito za biciklističku infrastrukturu.” (I2)

“Uvijek sam nekako težio otići na neku rutu kojom prije nisam prošao pa ju dokumentirati i tako s vremenom bildati neku bazu ruta. Onda sam se zainteresirao za OpenStreetMap pa još uvijek često znam tamo ucrtati ako nađem neki zgodan prolaz ili nešto slično” (I6)

“Imamo previše klubova u Hrvatskoj pa sam ja to krenuo okupljati i okrupnjavati; u upravi sam jednog kluba, član uprave u drugom, tajnik u jednom klubu i tajnik biciklističkog saveza i radim kao trener za jedan treći klub” (I1)

Svi sudionici navode da bicikliraju već dugi niz godina; uglavnom su počeli koristiti bicikl u djetinjstvu kao najdostupnije prijevozno sredstvo, a tijekom godina se korištenje nastavilo za različite svrhe. U razgovoru najviše ističu sljedeće svrhe korištenja bicikla:

- Gradski prijevoz - svi sudionici bicikl smatraju najjednostavnijim i najbržim sredstvom za gradsku vožnju, osobito kroz centre većih gradova. Navode kako biciklom ne upadaju u gužvu niti su ovisni o često nepovoljnom rasporedu gradskog prijevoza.

“Kad trebam nešto otići obaviti, otići s frendovima, nekom nešto odnijeti, sjednem na bicikl. To mi je najjednostavnije za bilo kakvo operativno kretanje po gradu jer ga je jednostavno ostaviti u blizini mjesta na koje trebam doći” (I1)

“Nikad nisam položio vozački zato što nije bilo potrebe. Bajk je odlično rješenje za transport po gradu i to mi je onda neko vrijeme koje provedem i vježbajući.” (I3)

“To su mi bile neke primarne stvari za korištenje bicikla - neovisnost o prometu, neovisnost o gužvama, mogućnost biranja puta, a uvijek si siguran da ćeš doći otprilike u isto vrijeme” (I2)

- Turističke svrhe - svi sudionici navode da vole koristiti bicikl na godišnjem odmoru te da su odvozili rute po više stotina (neki čak i tisuća) kilometara. Naglašavaju vlastitu znatiželju, tj, želju da obiđu neku lokaciju koju dosad nisu vidjeli, a najpoželjnije su lokacije koje su u prirodi. U ove svrhe se najčešće voze sami.

“Uvijek biram područja koja se isplati vidjeti, neke vidikovce, jezera, male gradove, dakle, pretežito udaljeno od grada i uživanje u prirodi, istraživanje, dolaženje u nove krajolike” (I2)

“Recimo, kad idemo na godišnji u Split, obično supruga i djeca idu autom, a ja bajkom, cestom kojom se smije.” (I3)

“Kad pogledam kartu, mogu vidjeti otprilike kakav je krajolik i što se tamo ima za vidjeti; ne idem uvijek u iste krajolike već u one atraktivne s dobro uređenim biciklističkim stazama.” (I5)

- Sport, rekreacija i utrke - bicikl smatraju jednostavnim, jeftinim i dostupnim načinom rekreacije i dovođenja u formu, a navode i da je lako uklopiv u svakodnevnu rutinu, tj. da nema potrebe izdvajati zasebno vrijeme za njega. Dio sudionika navodi i da su sudjelovali na određenim natjecanjima i utrkama, što smatraju dobrim iskustvom, korisnim za upoznavanje drugih biciklista i razvijanje volje i kondicije.

“Vodim rekreativnu trening grupu, zovem je r-grupa; r kao recovery za ozbiljne bicikliste koji su dan prije napravili brutalan trening i dođu na taj laganiji i r kao recruit za one koji dođu prvi put i još nisu sigurni hoće li nastaviti.” (I1)

“Nisam nikad bio biciklistički sportaš da bi trenirao u nekom klubu, ali jesam vozio rekreativne maratone, imam prilično iskustva u tim rekreativnim dugim utrkama.” (I4)

“Sve je više ljudi, više nastupa svake godine. Baš je jako popularan sport zato što je zapravo pristupačan. Samo trebamo kondicije do koje se može dovesti normalnom vožnjom bicikla. I ono malo volje da se to završi.” (I3)

Kad se sudionike pitalo kako odabiru rutu kojom će voziti, najčešće prvo navode sigurnost vožnje - odvojenost od automobilske prometa i uređenost biciklističkih staza te atraktivnost krajolika.

“Postoji puno kriterija, ali ja recimo veliki veliki naglasak stavljam na to da ima malo prometa. Znači to mi je recimo prvi, apsolutno glavni kriterij.” (I6)

“Količina prometa mi je jako presudna, da ne vozimo glavnim cestama. Okolina i panorama su sekundarne, prioritet broj 1 je sigurnost.” (I1)

“Na to koliko ću dugu rutu odabrati utječe nekakva okolina, kakva mi je panorama okolo, ima li okolo zelenila; ako ima, onda se lijepo vozim.” (I3)

Dodatno, kriteriji koji su im važni su i duljina i uspon te odabir kraćih i dužih, strmijih i manje strmih staza ovisi o iskustvu koje žele imati tokom vožnje, kao i o vremenu koje im je na raspolaganju. Važna im je i vrsta ceste kojom voze.

“Mene osobno dosta privlače brda i planine; cilj mi je popeti se na neku planinu i onda se spustiti s nje. To je meni privlačno, ali nekom može biti i suprotno, netko voli voziti uz more ili da mu je ravno.” (I2)

“Ja recimo makadam izbjegavam; volim ga, ali me često koštao gume i smanjuje trajanje komponenti.” (I3)

“Brdovit teren je naporan, to je za one u malo boljoj fizičkoj kondiciji; idealno mi je kad je ravnije s malo tih blagih uzbrdica.” (I5)

Nakon spontanog izjavljivanja o bitnim kriterijima odabira, sudionici su zamoljeni da prokomentiraju važnost svakog od kriterija odabira rute korištenih u dosadašnjem istraživanju: vrstu ceste, nagib staze, duljinu staze, blizinu pitke vode i blizinu hitne pomoći, te da ih rangiraju prema tome koliko su njima osobno važne.

Vrsta ceste - sudionicima generalno među važnijim kriterijima, zajedno s nagibom i duljinom. Ovaj kriterij često povezuju sa samom sigurnošću, tj. smatraju da vrsta ceste ujedno znači i prometnost iste; također, biraju vrstu ceste prema samoj opremi koja im je na raspolaganju.

“Vrsta ceste mi je bitna jer imam specifičan cestovni bicikl pa ne mogu baš ići na puno toga.” (I2)

“Ako pretpostavimo da vrsta ceste znači i prometnost, onda mi je ona definitivno na prvom mjestu” (I6)

Nagib staze - također među važnijim kriterijima; odabir nagiba ovisi o kondiciji u kojoj su sudionici u tom trenutku te je li im prioritet rekreacija ili čisto razgledavanje.

“A nagib, to ovisi kako sam raspoložen, ako sam malo slabije kondicije, onda me pustite da idem malo više ravno, ako sam u boljoj kondiciji ili se želim više rekreirati, onda odaberem one s malo većim nagibom.” (I5)

“Veći nagib je nama u rekreaciji pozitivna stvar; kod većeg nagiba samo treba prihvatiti da ga voziš polako i da će vrijeme proći.” (I4)

Duljina staze - kriterij koji je sudionicima izrazito važan u planiranju vremena putovanja, tj. kad sudionici moraju putovanje prilagoditi vremenu koje im je na raspolaganju.

“Duljina mora pasati; ako recimo imam 1 dan vremena, ne mogu htjeti na put od 500 kilometara, nego imam rutu od 30 kilometara.” (I4)

“Gledam kad planiram rutu da to bude neka normalna udaljenost, da mogu u pozivu napisati kome je namijenjena ruta.” (I1)

Blizina pitke vode - kriterij koji svi sudionici smještaju na predzadnje mjesto; važnije od hitne pomoći, ali značajno manje važno od vrste, nagiba i duljine. Potrebe za vodom uglavnom zadovoljavaju pomoću zaliha koje nose sa sobom ili nabavljanjem usput kod duljih tura.

“O pitkoj vodi uopće ne razmišljam; to je nešto što svaki biciklist nosi sa sobom i ne bi mi palo na pamet da bez nje negdje idem.” (I5)

“Uvijek nosim sa sobom puno vode, čak i 2 bidona ako je baš vruće, a uvijek naletiš i na neki kafić putem.” (I2)

Blizina hitne pomoći - kriterij koji sudionici jednoglasno proglašavaju najmanje važnim. Smatraju da sama blizina nema utjecaja na vožnju te da je to nešto što će im najrjeđe zatrebati.

“To ne umanjuje rizik, blizina hitne pomoći. Ako hoćeš biti siguran, ne izlazi iz kuće. Hitnu zovemo tamo gdje jesmo, ali ne idemo mimo glavnih prometnica” (I1)

“Hitna pomoć mi je većinu vremena potpuno nebitna, nikad mi nije pala na pamet kao kriterij.” (I6)

Na osnovu saznanja iz kvalitativnog dijela istraživanja složen je anketni upitnik za kvantitativni dio.

Kvantitativni dio istraživanja

U kvantitativnom dijelu istraživanja provedeno je anketno istraživanje na prigodnom uzorku od 98 biciklista. Istraživanje je provedeno metodom sniježne grude - svaki sudionik je zamoljen da anketu proslijedi svojim prijateljima i poznanicima za koje zna da redovito bicikliraju. Anketiranje je provedeno u online obliku te se sudionicima jamčila anonimnost, budući da nisu prikupljeni identificirajući podaci. Anketni upitnik se sastojao od ukupno 15 pitanja; 7 pitanja višestrukog izbora, 6 pitanja otvorenog tipa te dva pitanja prisilnog izbora, tj. rangiranja. Kako bi se izbjeglo slučajno previđanje nekih pitanja, a budući da se nije radilo o

osjetljivim ili stresnim temama, bilo je obvezno dati odgovor na sva pitanja kako bi se upitnik mogao završiti. Procijenjeno vrijeme ispunjavanja je bilo 3 minute, a budući da se provodilo u online obliku na osobnim računalima ili mobitelima, sudionici su ga mogli ispuniti u vrijeme koje im je najviše odgovaralo.

Pitanja koje sadržava upitnik su osmišljena tako da obuhvate razne aspekte biciklističkog iskustva, uključujući demografske podatke, učestalost i svrhe bicikliranja, te kriterije za odabir ruta. Na početku upitnika, od ispitanika se tražilo da se izjasne o svom rodu. Ovim pitanjem se željelo omogućiti analizu podataka prema rodu ispitanika. Zatim je bilo potrebno navesti dob ispitanika u godinama, čime se omogućilo razumijevanje dobne strukture sudionika istraživanja. Kako bi se saznalo više o sudjelovanju ispitanika u biciklističkim zajednicama, postavljeno je pitanje jesu li članovi neke biciklističke udruge ili kluba. Sljedeće pitanje odnosilo se na svrhe bicikliranja, gdje su ispitanici trebali označiti sve svrhe za koje bicikliraju. Učestalost bicikliranja ispitanika ispitana je pitanjem o tome koliko često bicikliraju. Također, prikupljeni su podaci o broju kilometara koje ispitanici prijeđu biciklom u uobičajenom radnom tjednu, kao i tijekom uobičajenog godišnjeg odmora. Najduža ruta koju su ispitanici prešli biciklom ispitana je pitanjem o broju kilometara te rute, s naglaskom na cjelokupnu planiranu rutu od točke A do točke B. Kako bi se razumjelo koje kriterije ispitanici smatraju najvažnijima prilikom odabira turističke rute, postavljeno je pitanje o najvažnijem kriteriju za odabir rute. Osim glavnog kriterija, ispitanici su trebali navesti dodatne kriterije koje uzimaju u obzir prilikom odabira rute za turističku vožnju. Zatim su ocjenjivali važnost različitih kriterija (duljina staze, nagib staze, vrsta ceste, blizina pitke vode i blizina hitne pomoći) prilikom odabira rute. Ispitanicima je također postavljeno pitanje da rangiraju navedene kriterije prema osobnoj važnosti, kao i prema tome koliko smatraju da su ti kriteriji važni drugim biciklistima. Interes za korištenje aplikacije koja bi predložila rutu uzevši u obzir navedene prioritete također je ispitano. Na kraju upitnika, ispitanici su trebali označiti izvore informacija koje koriste za informiranje o potencijalnim rutama, kao i alate koje koriste za planiranje rute kojom će voziti.

Pitanja poput članstva u biciklističkoj udruzi ili klubu te broja prijeđenih kilometara biciklom u uobičajenom radnom tjednu i tijekom uobičajenog godišnjeg odmora postavljena

su kako bi se potvrdila relevantnost sudionika istraživanja u kontekstu bicikliranja.

Rezultati provedene ankete su prikazani u potpoglavlju 4.1,

3.2.2. Modeliranje biciklističkih ruta koristeći višekriterijsku analizu

U skladu s istraživanjem [28], odabir biciklističkih ruta se temelji na ciljevima ugodnosti, sigurnosti i ležernosti. Ugodnost kao cilj podrazumijeva odabir najefikasnije biciklističke rute, primjerice, najkraćeg puta. Cilj sigurnosti usredotočen je na minimiziranje rizika od ozljeda. Konačno, cilj ležernosti povezan je s užicima koje pruža vožnja biciklom, primjerice, zanimljivim mjestima i panoramskim pogledima. Razmatraju se ovi kriteriji kako bi se oblikovao model odabira ruta za bicikliste u urbanom i prigradskom području. Model je primijenjen na prometnicama administrativnog područja grada Imotskog, a kriteriji se pažljivo odabiraju prema potrebama turista i biciklističkih entuzijasta. Cilj modela je uspostaviti sigurne i privlačne biciklističke rute koje povezuju značajne točke interesa u širem području grada. Za izradu ovog modela koristi se GIS softver, poput ArcGIS-a, kako bi se pružila preciznost i učinkovitost u planiranju biciklističkih ruta. Istraživanje naglašava važnost višekriterijske analize u planiranju biciklističkih ruta, što omogućuje zadovoljavanje različitih potreba korisnika, uključujući praktičnost, sigurnost i rekreaciju. Upravo takav pristup omogućuje optimizaciju biciklističkih iskustava, pridonoseći istovremeno smanjenju prometnih gužvi, poticanju zdravih životnih stilova te očuvanju okoliša.

Mreža cesta grada Imotskog poslužila je kao temelj za model odabira biciklističkih ruta. S obzirom da je biciklizam u ovom području uglavnom usmjeren prema turizmu, rekreacija je bila najvažniji cilj modela. Stoga je cilj bio stvoriti biciklističku rutu koja će povezivati značajne točke interesa u području Imotskog. Među svim značajnim točkama interesa u Imotskom, odabrano je devet:

- Modro i Crveno jezero
- Dva oka (jezero)
- Prološko blato
- Kip Tina Ujevića

- Perinuša (mlin na rijeci Vrljici)
- Panoramski pogled na Prološko blato
- Topana (Imotska tvrđava)
- Zelena katedrala

Uzimajući u obzir istraživanje [31] kriteriji odabrani za određivanje poželjnosti biciklističkih ruta su:

- Duljina segmenta ceste
- Vrsta ceste
- Nagib terena
- Udaljenost između hitne medicinske pomoći i segmenta ceste;
- Udaljenost između izvora pitke vode i segmenta ceste.

Topologija korištene mreže cesta sastojala se od segmenata i čvorova. Segment ceste povezuje dva čvora; to je dio ceste između dva raskrižja. Svih pet spomenutih kriterija korišteni za određivanje poželjnosti rute bili su dodijeljeni određenom segmentu ceste. Kriterij duljine segmenta ceste uzet je prilikom kreiranja modela uzimajući u obzir potrebu odabira najkraćeg puta. To znači da će se vjerojatnije odabrati kraći segment ceste kao najbolji. Vrsta ceste uzeta je kao kriterij za određivanje poželjnosti biciklističke rute iz sigurnosnih razloga. Budući da je infrastruktura cesta u području Imotskog nerazvijena, sigurnije je za bicikliste voziti se cestama više kategorije jer se održavaju u boljem stanju od cesta niže kategorije. Udaljenost do hitne medicinske pomoći također je sigurnosni kriterij. Stoga će model proizvesti putanje koje gravitiraju prema ustanovama hitne pomoći; u slučaju nesreće, udaljenost do hitne medicinske pomoći bit će svedena na minimum. Udaljenost između izvora pitke vode i segmenta ceste prije svega je kriterij orijentiran na ležernost, iako se može djelomično smatrati i sigurnosnim kriterijem. Budući da u nizinskom dijelu područja Imotskog postoji mnogo izvora pitke vode, može se koristiti kako bi se pružila bolja sigurnost i ugodnost pri vožnji bicikla.

Za izradu modela biciklističkih ruta koristila se ekstenzija *Network Analyst*, temeljena na skupu ulaznih podataka koji obuhvaćaju parametre i definirane točke zaustavljanja. Točke zaustavljanja su mjesta koja se moraju obavezno uključiti u rutu, dok parametri predstavljaju kriterije koji utječu na odabir staza. Proces je započeo stvaranjem mreže cesta unutar područja Imotskog. Nakon toga, provedena je normalizacija kriterija za odabir parametara. Točke interesa su integrirane kao točke zaustavljanja u GIS-u, dok su odabrani kriteriji uključeni kao parametri. Informacije o vrsti i duljini cesta preuzete su iz sloja s podacima o cestovnoj mreži. U svrhu određivanja udaljenosti do ustanova hitne medicinske pomoći koristio se alat *The Closest Facility* iz *Network Analyst* ekstenzije. Ovaj alat omogućio je izračun najkraćih udaljenosti između ustanova hitne pomoći i pojedinačnih cestovnih segmenata. Kao pripremni korak za primjenu ekstenzije, generirane su točke iz polilinija koje definiraju sloj cesta. Za određivanje najkraćih udaljenosti između cestovnih segmenata u području Imotskog i najbližih vodenih tokova također se koristio alat *The Closest Facility*. Kako je opisano u poglavlju 3.1, prije samog izračuna udaljenosti do hitne pomoći i najbližih vodenih tokova, bilo je neophodno polilinije hitne pomoći i tokova pretvoriti u skup točaka.

Za dobivanje informacija o nagibu terena za svaki cestovni segment koristio se model reljefa. Za izračun se primijenio alat za geoprocesiranje *Add surface information*. Ulazni podaci bili su TIN, dok je izlaz bio prosječni nagib svakog pojedinog cestovnog segmenta. Ovaj pristup omogućio je dobivanje detaljnih informacija o nagibu terena duž svakog segmenta ceste. Koristeći *Add surface information* ekstenziju, TIN model je djelovao kao izvor podataka, omogućujući mjerenje prosječnog postotnog nagiba za svaki pojedini cestovni segment. Ova informacija o nagibu ključna je za ocjenu staza i njihovo uklapanje u biciklistički model, posebno uzimajući u obzir različite razine iskustva biciklista.

Da bi se izračunala najpovoljnija ruta između dva ili više mjesta, korišten je Dijkstra algoritam. Dijkstra algoritam radi pretragu najkraćeg puta pretraživanjem po svim alternativama. Iako je ovaj pristup skup u smislu vremena i procesorske snage, budući da je prioritet modela točnost odabira željene rute, odlučeno je da se koristi takav model bez kompromisa po pitanju vremenskih zahtjeva. Kako se u konkretnom slučaju radi o mreži cesta u kojoj svaki segment ima vrijednost koji nastaje kao linearna kombinacija kriterija (ne samo du-

ljine koja je uobičajeno kriterij kod upotrebe Dijkstra algoritma), Dijkstra algoritam će kao povratnu informaciju davati najpogodniju rutu između dvije ili više točaka, ne najkraću kako je uobičajeno.

Podaci o kriterijima su prije uporabe morali biti normalizirani zbog različitih kriterija; kriteriji imaju različite raspone tako da bi, bez upotrebe normalizacije, utjecaj pojedinih kriterija bi bio neujednačen. Naprimjer, srednja aritmetička vrijednost segmenta ceste je 1406 m, a prosječni nagib 5,23%, dok je duljina u metrima, nagib se izražava kao omjer razlika visine i duljine segmenta ceste. Normalizacijom se podaci različite prirode svode na zajednički raspon kako je prikazano u poglavlju 3.1. Nakon završenog procesa normalizacije, sve vrijednosti svih kriterija će biti u rasponu između 0 i 1. Težina pojedinog cestovnog kriterija je izračunata zbrajanjem normaliziranog podatka svakog kriterija i to je korišteno kao ulaz u *Network analyst* ekstenziju. Na ovaj način je kreirana biciklistička staza koja ipak cilja na bicikliste početnike budući da je kod odabira sklonija ravnijim rutama. Upravo zbog toga je odlučeno da se kreira još jedan model koji će raditi odabir biciklističkih ruta, ali ovaj put za bicikliste profesionalce koji preferiraju rute koje su im izazovnije. Model biciklista amatera se dobiva zbrajanjem bez pondera za pojedine kriterije, dok je profesionalni model prilagođen na način da se ponderi kojima se množe težine pojedinih kriterija prilagođeni tako da preferiraju veće nagibe i udaljenosti, s naglaskom na nagibu koji je profesionalnim biciklistima važan što je potvrđeno literaturom i ispitivanjem pojašnjenom u potpoglavlju 3.2.1 i poglavlju 4.1. Tako je nagib množen s ponderom 2, dok su ostali kriteriji ostali na ponderu 1. Za potrebe izgradnje profesionalnog modela normalizirana vrijednost udaljenosti je invertirana tako da se preferiraju dulje staze:

$$X'_i = 1 - X_i \quad (3.2)$$


X'_i predstavlja novu vrijednost težine udaljenosti cestovnog segmenta, a X_i je stara udaljenost cestovnog segmenta; manju težinu će imati cestovni segmenti veće duljine. U Tablici 3.1 su prikazani korišteni ponderi za kriterije kod amaterskih i profesionalnih ruta, zvjezdicom je označen invertirani kriterij.

Svi normalizirani kriteriji se množe s pripadajućim ponderom, zbrajaju i tako se izraču-

Tablica 3.1. Pregled pondera za kriterije u višekriterijskoj analizi


Kriterij \ Vrsta	Nagib	Duljina segmenta	Vrste ceste	Ud. do hitne	Ud. do vodenog toka
Amaterska	1	1	1	1	1
Profesionalna	2	1*	1	1	1

nava ponderirana linearna kombinacija. Svaki segment ceste sadrži normalizirane vrijednosti kriterija, izračunom ponderirane linearne kombinacije se dobije težina svakog segmenta koja se upisuje u tablicu atributa polilinja cesta. Da bi se mogao iskoristiti *Network Analyst* za izračun rute, najprije je bilo potrebno stvoriti *Network Dataset* i uvesti u njega sloj polilinja cesta. U postavkama novostvorenog *Network Dataseta* je kao vrijednost težine postavljen stupac s težinom svakog segmenta i napravljen je *Build*. U *Network Analystu* je odabrana *New Route* opcija koja stvori novi sloj rute. U tom sloju su točke interesa dodane kao *Stops*. Dijalog s parametrima izračuna rute je prikazan na Slici 3.4.



Slika 3.4. Dijalog s parametrima Network Analysta

Postavljeno je da se raspored stajališta može mijenjati za pronalazak optimalne rute, kao impendancija je korištena vrijednost težine, a izlaz se dobiva u obliku sloja sa stvarnim mjerama. Primjer rute koja nastaje kao rezultat je prikazana na Slici 3.5.



Slika 3.5. Primjer rezultata korištenja Network Analysta za izračun rute

Crvenom bojom je označena izabrana ruta, ljubičasti krugovi su stajališta, brojevi unutar krugova raspored obilaska.

AHP izračun

Nastavno na potpoglavlje 2.1.1 u kojem je opisana AHP metoda i popratni izračuni, u ovom dijelu se prikazuje izračun konzistentnosti za kriterije koji su uzeti u obzir. Kod amaterske rute su svi kriteriji imali isti ponder, stoga je izračun konzistentnosti nepotreban. Kod profesionalne rute, nagib ima ponder od 2, dok drugi kriteriji imaju ponder 1. Iako ovakva podjela težine kriterija nije uobičajena, ona preslikava važnost kojeg nagib ima kod profesionalnog bicikliranja. Ovakva dodjela kriterija je bila polazna točka istraživanja, a u idućoj fazi istraživanja kriteriji će se prilagoditi u skladu s istraživanjem preferencija biciklista predstavljenim

u poglavlju 3.2.1.

Matrica s usporedbom svaki-sa-svakim prikazana u Tablici 3.2. Normalizirana tablica

Tablica 3.2. AHP: usporedba svaki-sa-svakim

Kriterij	Nagib	Vrsta	Duljina	Udalj. voda	Udalj. Hitna
Nagib	1	2	2	2	2
Vrsta	0,5	1	1	1	1
Duljina	0,5	1	1	1	1
Udalj. voda	0,5	1	1	1	1
Udalj. Hitna	0,5	1	1	1	1
Suma	3	6	6	6	6

usporedbe svaki-sa-svakim je prikazana u Tablici 3.3, zadnji stupac je aritmetička sredina normaliziranih vrijednosti za svaki kriterij što je težina pojedinog kriterija

Tablica 3.3. AHP: normalizirana tablica usporedbe svaki-sa-svakim

Kriterij	Nagib	Vrsta	Duljina	Udalj. voda	Udalj. Hitna	Težina
Nagib	0,33	0,33	0,33	0,33	0,33	0,33
Vrsta	0,17	0,17	0,17	0,17	0,17	0,17
Duljina	0,17	0,17	0,17	0,17	0,17	0,17
Udalj. voda	0,17	0,17	0,17	0,17	0,17	0,17
Udalj. Hitna	0,17	0,17	0,17	0,17	0,17	0,17

Da bi se izračunao indeks konzistentnosti, potrebno je pomnožiti nenormaliziranu tablicu svaki-sa-svakim (Tablica 3.2) s izračunatom težinom za taj kriterij čime se dobije Tablica 3.4.

Tablica 3.4. Pomoćna tablica za izračun indeksa konzistentnosti

	Nagib	Vrsta	Duljina	Udalj. voda	Udalj. Hitna	Zbroj	Težina kriterija	Zbroj/težina kriterija
Nagib	0,33	0,33	0,33	0,33	0,33	1,67	0,33	5,06
Vrsta	0,17	0,17	0,17	0,17	0,17	0,83	0,17	4,88
Duljina	0,17	0,17	0,17	0,17	0,17	0,83	0,17	4,88
Udalj. voda	0,17	0,17	0,17	0,17	0,17	0,83	0,17	4,88
Udalj. Hitna	0,17	0,17	0,17	0,17	0,17	0,83	0,17	4,88

Aritmetička sredina vrijednosti kvocijenta zbroja i težina kriterija (zadnji stupac Tablice 3.4) je λ_{max} , odnosno, svojstvena vrijednost matrice koja iznosi 4,92. Prema izrazu 2.4 se

konačno izračuna indeks konzistentnosti (CI) koji iznosi -0,02. Može se zaključiti da su kriteriji konzistentni pošto je apsolutna vrijednost manja od 0,1 [20].

Slijedi izračun omjera konzistentnosti (CR) koji se izračunava po izrazu:

$$CR = \frac{CI}{RI} \quad (3.3)$$

pri čemu CI predstavlja indeks konzistentnosti, RI je slučajni indeks (engl. *Random index*) koji se izračunava iz Tablice 3.5 prema broju kriterija [137, 138]:

Tablica 3.5. Slučajni indeksi (RI) za različite dimenzije tablice

Dimenzija	Slučajni indeks (RI)
1	0
2	0
3	0,5799
4	0,8921
5	1,1159
6	1,2358
7	1,3322
8	1,3952
9	1,4537
10	1,4882

Prema izrazu 3.3, računa se omjer konzistentnosti (CR) za 5 kriterija što daje vrijednost slučajnog indeksa (RI) od 1,1159. Omjer konzistentnosti (CR) računa kao kvocijent indeksa konzistentnosti (CI) i slučajnog indeksa (RI) što daje vrijednost od -0.018. Vrijednosti CR manja od 0.1 potvrđuje prihvatljivost rezultata usporedbe [138].

3.3. Primjena strojnog učenja

Nakon završetka višekriterijske analize, istraživanje se proširuje na primjenu metoda strojnog učenja i neuronskih mreža. Već postojeće biciklističke rute, formirane od strane stručnjaka, su korištene kao temeljni skup podataka za treniranje modela, odnosno *ground truth*. Segmenti koji su dijelovi *ground truth* ruta su labelirani 1, dok oni koji nisu dio izabrane rute su labelirani s 0. Tako labelirani podaci ulaze u model kao skup za treniranje. GIS služi

kao alat za generiranje ulaznih podataka o cestovnim segmentima, nakon čega se primjenom metoda strojnog učenja model trenira. Model strojnog učenja, odnosno neuronsku mrežu, se strukturira tako da kao izlaz daje mjeru prikladnosti svakog pojedinog segmenta ceste za biciklističke rute. Trenirani model strojnog učenja je kombiniran s tradicionalnim Dijkstra algoritmom, tvoreći hibridni model za rutiranje. Dijkstra algoritam koristi se za povezivanje točaka interesa i odabir ruta, gdje se težine svakog pojedinog segmenta koriste kao izlaz generiran istreniranim modelom strojnog učenja. Ovaj koncept se primjenjuje za rutiranje biciklističkih staza u ruralnim područjima, testirajući ga na različitim područjima s već definiranim biciklističkim stazama. Odvojeno se treniraju dva modela: jedan za manje zahtjevne bicikliste i drugi za one koji preferiraju izazovnije staze. Model je treniran na pojedinačnim stazama, kao i na cjelokupnom skupu staza, kako bi se usporedili rezultati. Osim toga, ispituju se različiti modeli strojnog učenja i različite vrste dubokih neuronskih mreža te se radi usporedba njihovih rezultate. Na kraju se izvodi verifikacija rezultata različitim pristupima (unakrsna provjera i usporedba s kartom intenziteta čime rezultati dobivaju na težini i potvrđuje se njihova relevantnost).

3.3.1. Modeliranje biciklističkih ruta koristeći hibridni model

Uz pristup koristeći višekriterijsku GIS analizu prikazanu u poglavlju 3.2.2, predstavljen je još jedan pristup u pokušaju pronalaska najpovoljnije biciklističke rute u ruralnom području, i to korištenjem strojnog učenja. Poučeni radom [139], odlučeno je da se rezultati dobiveni višekriterijskom GIS analizom koristeći ArcGIS-ov *Network analyst tool* usporede s rezultatima koje će dati razne arhitekture neuronske mreže. Za treniranje i testiranje neuronske mreže je korišten *nntool* koji je dio MATLAB-a.


Slično kao i kod višekriterijskog GIS pristupa odabiru biciklističke rute, koristi se neuronska mreža za kreiranje dva modela biciklističkih ruta: onih za bicikliste amatere i profesionalce. Nakon prikupljanja podataka za trening neuronske mreže, sljedeći korak je treniranje samog modela. Kao izvor podataka za treniranje modela se koriste postojeće biciklističke rute. Korišteni su podaci objavljeni na Web GIS portalima [140, 141] kao izvor podataka o postojećim rutama i to na području gradova Vrgorca i Knina zbog svoje sličnosti s Imotskim

u smještaju, nadmorskoj visini i reljefu. Za područje grada Vrgorca, korištena je staza "Tri polja" za trening podatke za amatersku rutu budući da je označena kao srednje ravna na Web GIS portalu. Staza je prikazana na Slici 3.6. Za trening podatke za profesionalnu rutu je korištena "Mate Svjetskoga" ruta, označena je kao strma na Web GIS portalu. Ruta je prikazana na Slici 3.7. Kad se promatra područje Knina, staza "Lopuška glavica" je korištena za trening amaterskog modela (Slika 3.8) jer je označena kao ravna na Web GIS portalu, dok je "Napoleonova staza" korištena kao izvor podataka za treniranje profesionalne rute, također je označena kao strma na Web GIS portalu (Slika 3.9).


U Tablici 3.6 su prikazani statistički podaci svake od staza.

Tablica 3.6. Podaci o stazama


Naziv staze	Vrsta	Grad	Duljina (m)	Br. segm.	Prosj. dulj. segmenta
Tri Polja	Amaterska	Vrgorac	42420	21	2020
Mate Svjetskoga	Profesionalna	Vrgorac	25021	17	1471
Lopuška Glavica	Amaterska	Knin	16542	19	870
Napoleonova staza	Profesionalna	Knin	36353	8	4544




Slika 3.6. Staza "Tri polja" Vrgorac



Slika 3.7. Staza "Mate Svjetskog" Vrgorac




Slika 3.8. Staza "Lopuška glavica" Knin




Slika 3.9. "Napoleonova staza" Knin.

Cestovna mreža uzeta u obzir na području Knina i Vrgorca je prikazana na Slikama 3.10 i 3.11.



Slika 3.10. Mreža cesta Knin



Slika 3.11. Mreža cesta Vrgorac

Uz pomoć navedene četiri staze, trenirana su četiri modela neuronskih mreža. Ulaz u neuronsku mrežu su cestovni segmenti. Segment je dio ceste između dva raskrižja. Ulazni podaci za svaki segment bili su isti kao u modelima višekriterijske analize - pet normaliziranih parametara. Kriterijima nije dodavana težina; ulazi u neuronsku mrežu su normalizirani podaci parametara. Na navedene ulazne podatke je dodan još stupac koji sadrži labele; on može sadržavati isključivo 0 i 1. Segmenti koji su dio ruta koje su korištene kao *ground truth* (navedene u Tablici 3.6) u stupcu koji sadržava labele imaju upisano 1, dok ostale imaju 0. Time su odvojeni segmenti koji su dio *ground truth* rute i oni koji nisu. Dio ulaznih podataka staze "Mate Svjetskog" Vrgorac je prikazan u Tablici 3.7. Broj segmenata korištenim kao ulaz u neuronsku mrežu su prikazani u Tablici 3.8.

Prikupljanje i labeliranje trening podataka je bilo dugotrajno - labele cestovnih segmenata su dodavane ručno.

Nakon treninga četiri modela neuronske mreže, dva u kninskom i dva u vrgoračkom području, modeli su iskorišteni na segmentima cesta na području Imotskog. Rezultat koji je

Tablica 3.7. Dio ulaznih podataka dobiveni od staze "Mate Svjetskog", Vrgorac


Vrsta	Duljina	Nagib	Hitna	Potok	Labela
0,5	0,022898618	0,164264783	0,006486832	0,059044866	1
0,75	0,012812021	0,256848577	0,008116696	0,066508047	0
0,5	0,007709606	0,022704964	0	0,056848575	0
0,75	0,009078104	0,024786148	0,003432783	0,060933842	0
0,5	0,301258319	0,131083082	0,057298834	0,119514926	1
0,75	0,001899572	0,476289886	0,147023827	0,226294335	0
0,5	0,100135036	0,139091959	0,023699006	0,085052155	0

Tablica 3.8. Broj segmenata po gradu

Grad	Broj segmenata
Vrgorac	168
Knin	215
Imotski	268

dala neuronska mreža sadržava informaciju koliko je određeni cestovni segment prikladan za biciklističku rutu. Prikladnost cestovnog segmenta za biciklističku rutu je izražen kao vrijednost u rasponu [0,1]. Vrijednost bliža 0 znači da je model neuronske mreže donio odluku da taj segment ceste nije prikladan za biciklističku rutu, dok vrijednost bliže 1 ima značenje da je segment ipak pogodniji za biciklističku rutu.


Izrađen je hibridni model koji kombinira Dijkstra algoritam s neuronskom mrežom kako bi se generirale optimizirane rute. Kako je već navedeno, neuronska mreža je pružila informacije o poželjnosti svakog segmenta ceste izraženo vrijednostima unutar raspona [0,1]. Te informacije korištene su kao težina za svaki segment ceste, a Dijkstra algoritam se koristio za povezivanje točaka interesa, uključujući informacije dobivene putem NN kako je pojašnjeno na dijagramu prikazanom na Slici 3.12. Na desnoj strani dijagrama može se vidjeti tijek odabira biciklističke staze pomoću neuronske mreže u usporedbi s koracima odabira biciklističke rute pomoću višekriterijske GIS analize. Prvi dio oba pristupa uključuje određivanje težina segmenata ceste. Uz GIS višekriterijsku analizu, to se provodi pomoću izraza koju određuje ekspert, dok su težine kod neuronske mreže generirane trenirajući mrežu na postojećim biciklističkim stazama. Svaki segment u stupcu "labela" nosi informaciju o tome je li taj segment dio postojeće biciklističke staze koja čini *ground truth* stazu. Sljedeći korak u oba pristupa je primjena Dijkstra algoritma na topologiju cestovne mreže.



Slika 3.12. Dijagram s objašnjenjem postupka izračuna rute.

Arhitektura neuronske mreže

S obzirom na organizaciju podataka o cestovnim segmentima, gdje su segmenti koji su međusobno povezani i smješteni jedan uz drugoga u tablici atributa, primjećuje se da ti segmenti također imaju prostornu povezanost na karti. Uvažavajući ovu blisku povezanost podataka, odlučeno je da se koristi implementacija slojevite rekurentne neuronske mreže. Ova odluka proizlazi iz potrebe za modeliranjem složenih veza među podacima o cestovnim segmentima, koji su ne samo susjedni u tablici, već i prostorno susjedni na karti.



Slika 3.13. Arhitektura slojevite rekurentne neuronske mreže

Arhitektura mreže sastojala se od pet slojeva kako je prikazano na Slici 3.13. Ulazni sloj imao je deset neurona, a izlazni sloj sastojao se od jednog neurona. U skrivenim slojevima, drugi sloj sadržavao je jedan neuron, dok su preostali skriveni slojevi imali po deset neurona. Ova konfiguracija neuronske mreže odabrana je kako bi se postigao kompromis između brzine treniranja i preciznosti. Primijećeno je da s povećanjem broja neurona vrijeme treniranja također raste, ali preciznost modela se značajno ne poboljšava. Kao funkcija treniranja korišten je Levenberg–Marquardt backpropagation [142], koji koristi Levenberg–Marquardt optimizaciju za ažuriranje težina i ažuriranje težina pristranosti. Unatoč većoj potrošnji memorije u odnosu na druge dostupne funkcije treniranja u `nnTool`, preporučuje se zbog brže izvedbe. Levenberg–Marquardt algoritam može izračunati Jacobianovu matricu pomoću aproksimacije koja je puno jednostavnija od izračuna Hessove matrice:

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (3.4)$$

gdje je x_{k+1} vrijednost varijable x u $k + 1$ iteraciji, x_k predstavlja vrijednost varijable x u k -toj iteraciji. J je Jacobianova matrica koja sadrži prve derivacije mrežnih pogrešaka koje se odnose na težine i pristranosti, e je vektor mrežnih pogrešaka, T označava transponiranje,

μ je faktor prigušenja koji se prilagođava pri svakoj iteraciji; smanjuje se nakon svakog uspješnog koraka i smanjuje ako bi to povećalo funkciju izvedbe, a I predstavlja jediničnu matricu.

U procesu treniranja korišten je silazni gradijent s momentom težine kao adaptivnom funkcijom učenja. Odabir stope učenja značajno utječe na performanse neuronske mreže. Ova stopa predstavlja numerički faktor koji određuje kako će se pogreška odraziti na težinske parametre modela. Adaptivne funkcije učenja mogu dinamički prilagoditi stopu učenja za sve težine unutar neuronske mreže, pri čemu momentum uzima u obzir promjenu težine iz prethodne iteracije kako bi izračunao težinu u trenutačnoj iteraciji. Kao funkcija performansi korištena je srednja kvadratna pogreška (engl. *Mean Square Error* - MSE).


Kao aktivacijska funkcija svakog neurona u ovoj mreži se koristi Hiperbolička tangensna sigmoidna funkcija (tansig) [143]:

$$a = f(n) = \frac{2}{(1 + e^{-2n})} - 1 \quad (3.5)$$

Aktivacijska funkcija je omeđena i kontinuirana što je čini kompatibilnom s *backprop* neuronskom mrežom. Iako slična tanges hiperboličnoj aktivacijskoj funkciji (tanh), tansig je ponešto strmiji u području oko 0 zbog čega brže reagira na male promjene ulaza, što može ubrzati proces učenja. Usporedba grafova tansig i tanh i njihova derivacija je prikazana na Slici 3.14.

Trening parametri su prikazani u Tablici 3.9.

Treniranje rekurentne neuronske mreže smatra se izazovnom zbog problema s eksplozijom gradijenta. To se događa kada se pogreške šire kroz vremenske korake. Razmatrajući ulaz koji je prošao kroz mrežu u vremenu t_1 i pogrešku koja se dogodila u vremenu t utjecaj ulaza u vremenu t_1 na izlaz u vremenu t eksplodirat će kako $t - t_1$ raste. Performansa neuronske mreže procijenjuje se korištenjem srednje kvadratne pogreške, koja predstavlja srednju vrijednost kvadriranog odstupanja između stvarne i procijenjene vrijednosti. MSE je izračunat korištenjem križne validacije, pri čemu je 70% podataka korišteno za treniranje, a po 15% za validaciju i testiranje.



Slika 3.14. Usporedba grafova i derivacija tansig i tanh aktivacijskih funkcija

Tablica 3.9. Parametri treninga neuronske mreže

Parametar	Opis	Vrijednost
epochs	maksimalan broj iteracija treninga	1000
time	maksimalno trajanje treninga u sekundama	∞
goal	cilj učinkovitosti u smislu funkcija učinkovitosti mreže	0
min_grad	minimalni gradijent učinkovitosti	10^{-7}
max_fail	maksimalan broj provjera validacije	6
mu	koristi se za trening s Levenberg–Marquardt funkcijom; što je veći—više težine se daje učenju silaznim gradijentom i smanjuje se veličina koraka	0,01
mu_dec	iznos smanjenja mu nakon neuspješnog koraka	0,1
mu_inc	iznos povećanja mu nakon uspješnog koraka	10
mu_max	maksimalni mu	10^9


4. REZULTATI I DISKUSIJA

U ovom poglavlju se razmatraju rezultati dobiveni kroz primjenu metodološkog pristupa za optimizaciju biciklističkih ruta u ruralnom području, koristeći višekriterijsku GIS analizu i kombinaciju tehnika strojnog učenja s Dijkstra algoritmom. Najprije su prezentirani rezultati dobiveni višekriterijskom GIS analizom, koji su verificirani korištenjem karte intenziteta (engl. *heatmap*). Nadalje, razmatraju se tri varijante hibridnog pristupa modeliranju biciklističkih ruta, gdje svaka podliježe procesu unakrsne verifikacije kako bi se potvrdila njihova pouzdanost. Konačno, uspoređuju se performanse hibridnog pristupa s rezultatima višekriterijske GIS analize, donoseći zaključak kako se tehnike strojnog učenja u kombinaciji s višekriterijskom GIS analizom mogu koristiti za kreiranje biciklističkih ruta koje uzimaju u obzir relevantne kriterije za različite vrste biciklista.


4.1. Rezultati kvantitativne analize istraživanja

Nastavno na potpoglavlje 3.2.1, u nastavku se donose rezultati kvantitativnog dijela istraživanja preferencija među biciklistima. Tako su opisani demografski podaci ispitanika i statistička analiza prikupljenih odgovora,

Od demografskih podataka prikupljeni su samo podaci o rodu i dobi sudionika. Sudjelovalo je ukupno 98 sudionika, od čega 79 muškaraca (80,6%), 18 žena (18,4%) te jedna osoba koja se nije željela izjasniti (1%) (Slika 4.1). Raspon godina sudionika kretao se između 24 i 66 godine, a prosječna dob je 42,9 godina ($M=42,9$, $SD=9,2$) (Slika 4.2).




Slika 4.1. Rod sudionika (%)



Slika 4.2. Dobna struktura sudionika


Anketnim pristupom se željelo steći uvid u navike bicikliranja sudionika te su im postavljena pitanja o članstvu u biciklističkim klubovima i udrugama, učestalosti bicikliranja, razlozima zbog kojih bicikliraju, prosječnoj kilometraži koju prijeđu u radnom tjednu i na godišnjem odmoru te o najdužoj ruti koju su ikad odvozili.

Više od trećine sudionika, njih 38,8% su članovi neke biciklističke udruge ili kluba, dok njih 61,2% navodi da nisu učlanjeni u takvu organizaciju (Slika 4.3).




Slika 4.3. Članstvo u biciklističkim udrugama/klubovima

Kad ih se pita o učestalosti korištenja bicikla, kao što je i očekivano, većina sudionika navodi da bicikl koristi svakodnevno (30,6%) ili nekoliko puta tjedno (49%). Ostali sudionici navode da bicikliraju jednom tjedno (7,1%), nekoliko puta mjesečno (10,2%), a najmanje sudionika biciklira jednom mjesečno ili rjeđe, njih 3,1% (Slika 4.4).



Slika 4.4. Učestalost bicikliranja

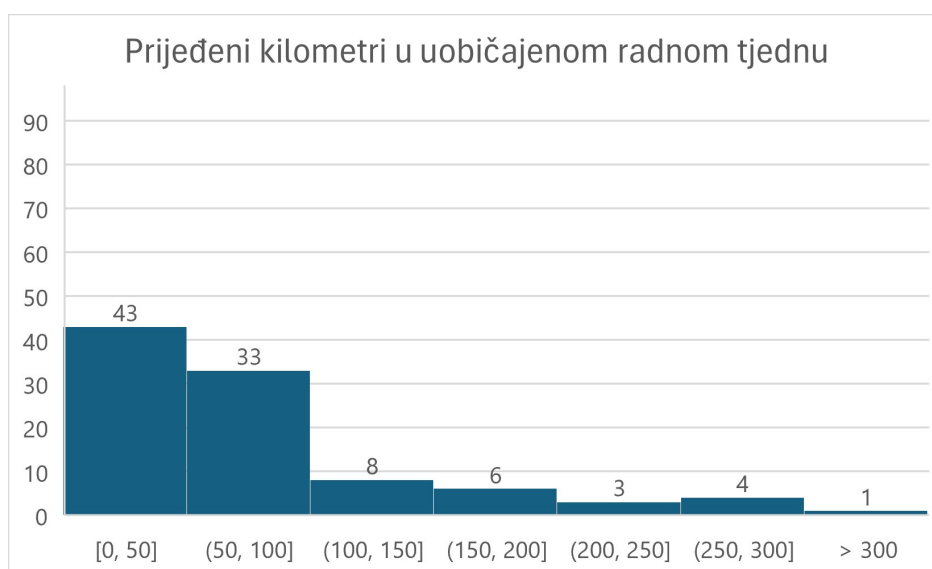
Kad ih se pita o svrhama u koje koriste prijevoz biciklom, gotovo svi sudionici, njih 95,9% navode sport i rekreaciju kao svrhu korištenja bicikla. Ostale svrhe su gradski prijevoz (72,4%), turizam (43,9%), a značajno najmanje ih bicikl koristi za natjecanja i utrke (23,5%) (Slika 4.5).



Slika 4.5. Svrha korištenja bicikla


Sljedeća pitanja su se odnosila na prosječnu kilometražu koju sudionici odvoze biciklom u dvije situacije: u uobičajenom radnom tjednu te na uobičajenom godišnjem odmoru.

U uobičajenom radnom tjednu sudionici navode biciklom prelaze između 0 i 400 kilometara, no, najčešće se radi o rutama do 100 kilometara. Prosječna kilometraža iznosi 88,36 kilometara ($M=88,36$, $SD=78,47$) (Slika 4.6).



Slika 4.6. Graf prijeđenih kilometara u uobičajenom radnom tjednu


Na uobičajenom godišnjem odmoru sudionici prelaze između 0 i 2000 kilometara te prosječna kilometraža iznosi 345,93 kilometra s izrazito velikom varijancom ($M=345,93$, $SD=361,6$) (Slika 4.7).



Slika 4.7. Graf prijedanih kilometara u uobičajenom godišnjem odmoru

T-testom za zavisne uzorke provjereno je postoji li statistički značajna razlika između prijedane kilometraže tijekom uobičajenog radnog tjedna i godišnjeg odmora te, kako je i očekivano, pronađeno je da sudionici statistički značajno više kilometara prelaze tijekom godišnjeg odmora ($t=-7,459$, $df=97$, $p<0,01$).


Najduža ruta koju su sudionici odvozili varira između 20 i 2000 kilometara, s prosječnom vrijednosti od 280,37 kilometara i visokim varijabilitetom ($M=280,37$, $SD=347,26$) (Slika 4.8).



Slika 4.8. Graf najduže prijedene rute

T-testom za nezavisne uzorke uspoređene su navedene kilometraže kod sudionika koji

bicikl koriste za turizam i onih koji ga koriste isključivo za druge svrhe. U prijedenoj kilometraži tijekom uobičajenog radnog tjedna nije pronađena značajna razlika ($M_1=96,63$, $M_2=81,78$, $t=0,925$, $df=96$, $p>0,05$), no značajne razlike su pronađene u druge dvije usporedbe. Sudionici koji bicikl koriste za turizam prelaze značajno više kilometara tijekom uobičajenog godišnjeg odmora ($M_1=435,58$, $M_2=274,54$, $df=96$, $t=2,22$, $p<0,05$) te su u prosjeku odvozili značajno dulju rutu ($M_1=379,37$, $M_2=201,54$, $df=96$, $t=2,578$, $p<0,05$) (Slika 4.9).




Slika 4.9. Usporedba prosječne prijeđene kilometraže kod sudionika koji koriste bicikl za turizam i onih koji ga ne koriste

Nakon danih informacija o iskustvu u bicikliranju, sudionici su pristupili glavnom dijelu anketnog istraživanja - pitanjima o kriterijima odabira biciklističke rute.

Kako bi se izbjeglo udešavanje sudionika na pojedini odgovor, prvo su im prikazana dva pitanja otvorenog tipa - “Kad birate rutu kojom ćete voziti u turističke svrhe, koji vam je (jedan) kriterij najvažniji za odabir rute?” i “Osim navedenog, koje još kriterije uzimate u obzir prilikom odabira rute za turističku vožnju? Molimo vas da navedete što je više moguće kriterija koji utječu na vaš odabir.”.

Kao značajno najvažniji kriteriji su se istakli atraktivnost rute, koju je kao najvažniju navelo 41,2% sudionika te sigurnost u vožnji, koje navodi 38,1% sudionika. Čak i sudionicima koji ih ne stavljaju na prvo mjesto po važnosti ovi kriteriji dosta znače - ukupno ih je spomenulo 88,7%, odnosno 73,2% svih ispitanih. Ostali važni kriteriji su kvaliteta staze, koja je

važna 43,3% sudionika, infrastruktura i sadržaji na ruti (36,1%) zahtjevnost same rute (34%) te prisutnost vode ili vodene površine (13,4%) (Slika 4.10).




Slika 4.10. Graf važnih kriterija pri odabiru biciklističke rute - spontano dosjećanje

Nakon što su spontano dali svoje odgovore, sudionici su trebali procijeniti važnost pojedinih kriterija odabira staze korištenih u ovom istraživanju - vrste ceste, nagiba staze, duljine staze, blizine pitke vode i blizine hitne pomoći. Važnost su procjenjivali ocjenama od 1 - uopće mi nije važno do 5 - izrazito mi je važno. Prosječne ocjene važnosti su međusobno uspoređene t-testom za zavisne uzorke, kako bi se utvrdila statistička značajnost razlike među njima

Kao značajno najvažniji kriterij ($t=7,05$, $df=97$, $p<0,01$) se istaknula vrsta ceste, s prosječnom ocjenom 4,38 (donekle mi je važno). Sljedeća dva najvažnija kriterija su nagib staze s prosječnom ocjenom 3,62 te duljina staze, s prosječnom ocjenom 3,50. Blizina pitke vode je procijenjena značajno manje važnom ($t=2,06$, $df=97$, $p<0,05$), s prosječnom ocjenom 3,15, dok je blizina hitne pomoći procijenjena značajno najmanje važnom ($t=7,38$, $df=97$, $p<0,01$), s prosječnom ocjenom 2,31. Na Slici 4.11 je prikazan grafički prikaz ocjene važnosti kriterija.

Nakon ocjene važnosti pojedinačnog kriterija, sudionici su navedenih pet kriterija morali rangirati međusobno po važnosti za odabir rute. Rangiranje je bilo prisilno, dakle, svakom



Slika 4.11. Graf ocjene važnosti pojedinog kriterija odabira staze

kriteriju se morao dodijeliti rang te nije bilo moguće dodijeliti isti rang više od jednog kriterija. Rangovi su bili postavljeni od 1 - najvažnije pri odabiru rute do 5 - najmanje važno pri odabiru rute, stoga u ovom dijelu manji rezultat znači veći važnost pri odabiru. T-testom za zavisne uzorke uspoređene su razlike među prosječnim rangovima, kako bi se utvrdila statistička značajnost razlike među njima.

Vrsta ceste je ponovno procijenjena značajno najvažnijom ($t=-2,439$, $df=97$, $p<0,05$), s prosječnim rangom 2,01. Na drugom mjestu po važnosti su duljina staze (prosječni rang 2,47) i nagib staze (prosječni rang 2,51). Blizina pitke vode je procijenjena značajno manje važnom od njih ($t=-6,77$, $df=97$, $p<0,01$) s prosječnim rangom 3,61, dok je blizina hitne pomoći ponovno procijenjena značajno najmanje važnom ($t=-5,66$, $df=97$, $p<0,01$) s prosječnim rangom 4,4. Navedeni rezultati su prikazani u Tablici 4.1

Tablica 4.1. Rangiranje kriterija pri odabiru rute - osobno

Kriterij	Prosječni rang
Vrsta ceste	2,01
Duljina staze	2,47
Nagib staze	2,51
Blizina pitke vode	3,61
Blizina hitne pomoći	4,4


Sudionike se također pitalo da procijene koliko je svaki od navedenih kriterija važan drugim biciklistima, također metodom prisilnog rangiranja. Kad su procjenjivali važnost

kriterija za druge, rezultati su se ponešto razlikovali - duljina, nagib i vrsta ceste su procijenjeni podjednako bitnima, s prosječnim rangovima 2,13, 2,35 i 2,60, dok je blizina pitke vode ponovno rangirana značajno niže ($t=-5,81$, $df=97$, $p<0,01$), s prosječnim rangom 3,7, a blizina hitne pomoći značajno najniže ($t=-3,98$, $df=97$, $p<0,01$), s prosječnim rangom 4,21 (Tablica 4.2).

Tablica 4.2. Rangiranje kriterija pri odabiru rute - drugi

Kriterij	Rang
Duljina staze	2,13
Nagib staze	2,35
Vrsta ceste	2,60
Blizina pitke vode	3,70
Blizina hitne pomoći	4,21

Kad se usporede prosječni rangovi koje su sudionici dodijelili navedenim kriterijima za sebe u odnosu na druge pomoću t-testa za zavisne uzorke, vidljiva je značajna razlika u dva kriterija. Procjenjuju da je vrsta ceste važnija njima nego drugima (2,01 nasuprot 2,60, $t=-4,6$, $df=97$, $p<0,01$), a da je duljina staze drugima važnija nego njima (2,47 nasuprot 2,13, $t=2,23$, $df=97$, $p<0,05$) (Slika 4.12).




Slika 4.12. Graf usporedbe osobnih i tuđih prioriteta pri odabiru rute

Za kraj ankete, sudionicima su postavljena pitanja o načinima na koje se informiraju o


rutama koje će voziti te alatima za planiranje koje koriste.

Najčešći izvor informacija o rutama je razgovor s prijateljima, koji koristi 78,4% sudionika, dok su na drugom mjestu specijalizirane biciklističke aplikacije, koje koristi njih 66%. Manje od polovice sudionika koristi društvene mreže (48,5%) ili specijalizirane forume (43,3%) kao izvore informacija. Manje od trećine (32%) informacije traži na web stranicama o putovanjima, a najmanje su popularne stranice turističke zajednice, koje koristi 23,7% sudionika (Slika 4.13).



Slika 4.13. Graf usporedbe izvora informiranja o biciklističkim rutama

Među alatima korištenima za planiranje rute najviše se ističu Googleovi servisi (Maps, Earth, StreetView) koje koristi 70,4% sudionika. Slijedi ga Strava, tj. karte intenziteta (engl. *heatmaps*), koje koristi 43,9% sudionika, dok Komoot koristi 39,8%. Manje popularni su OpenStreetMaps s 22,4% i RideWithGPS s 20,4%. Samo 4,1% ispitanih ne koristi nikakav alat za planiranje rute (Slika 4.14).



Slika 4.14. Grafički prikaz alata korištenih za planiranje rute

Unatoč korištenju većeg broja alata za planiranje, interes za novim alatima i dalje postoji. Više od tri četvrtine ispitanih (76,3%) je izrazilo interes za korištenjem nove aplikacije, koja bi u obzir uzela važnost koju oni pridaju pojedinom kriteriju i na temelju toga predložila rutu (Slika 4.15).




Slika 4.15. Graf interesa za korištenje nove aplikacije

Iz kvantitativnog i kvalitativnog dijela istraživanja se da zaključiti da su značajno najvažniji kriteriji vrsta ceste, duljina staze i nagib staze. Također, prema ispitanicima, udaljenost do pitke vode nije toliko važna radi pristupa pitke vode, koliko blizina pitke vode implicira lijep krajolik, Udaljenost do hitne pomoći je iskazan kao najmanje važan kriterij, no unatoč tome, dobiveni rezultati višekriterijske analize su verifikacijom pokazali kvalitetu dobivenih ruta.

4.2. Biciklističke rute generirane pomoću višekriterijske GIS analize

Početak analize i kreiranja modela biciklističkih staza započinje korištenjem višekriterijske GIS analize. U ovom pristupu su prvo izgrađeni modeli biciklističkih ruta temeljenih na GIS-u, nakon čega su korišteni za izračunavanje najbolje rute temeljene na analizi prostornih podataka. Odabrani su segmenti cesta koje će biciklisti koristiti te redoslijed stajališta kako bi

im se pružila najbolja ruta. Dobivena amaterska ruta je prikazana na Slici 4.16. Ruta počinje od Prološkog blata te nastavlja ravninskim dijelom Imotskog polja do Zelene katedrale, Dva oka i Perinuše. Iduće tri stanice su smještene u samom centru grada, kip Tina Ujevića, tvrđava Topana i Plavo jezero. Preko Crvenog jezera se dolazi do zadnje stanice koja je Panoramski pogled na Prološko blato.




Slika 4.16. Amaterska biciklasička ruta izabrana višekriterijskom GIS analizom

Drugi model je dizajniran kako bi generirao staze koje bi bile izazovnije; preferira dulje i strmije staze. Vrijednost nagiba normalizirane težine cestovnog segmenta invertirana je pomoću jednadžbe 3.2.

Rezultati profesionalnog modela prikazani su na Slici 4.17. Prva postaja je mlin Perinuša, nakon koje slijedi jezero Dva oka i Zelena katedrala, smještenim na području Imotskog polja s malim nagibom. Sljedeće postaje su Crveno jezero, Plavo jezero, tvrđava Imotski te kip Tina Ujevića. Odabrana ruta između prethodno navedenih postaja većinom prolazi strmim dijelom Imotskog. Sljedeće dvije postaje su panoramski pogled na Prološko blato, nakon čega slijedi Prološko blato. Odabir i raspored tih posljednjih dviju postaja također pokazuju

da se preferiraju strmije i duže rute.



Slika 4.17. Profesionalna biciklistička ruta izabrana višekriterijskom GIS analizom

Rezultati dobiveni višekriterijskom GIS analizom sami po sebi nemaju značaj ni težinu ako nisu verificirani. Tako je provedena verifikacija u odnosu na pouzdane izvore podataka, tj. *ground truth* kojeg sačinjavaju karte intenziteta. One nastaju prikupljajući podatke o bicikliranju od značajnog broja korisnika i time daju informaciju o poželjnosti pojedinog dijela ceste za bicikliranje. Takav pristup osigurava vjerodostojnost napravljene analize i potvrđuje realnu primjenjivost predloženih biciklističkih ruta.

4.2.1. Provjera rezultata višekriterijske GIS analize

Opisuje se postupak verifikacije rezultata dobivenih višekriterijskom GIS analizom kreiranjem biciklističke rute koja povezuje točke interesa na području Imotske krajine na temelju karte intenziteta dostupne na aplikaciji Strava [144]. Strava je popularna aplikacija za praćenje fizičkih aktivnosti kao što su trčanje, biciklizam i hodanje. Korisnici mogu pratiti svoje treninge, analizirati statistike poput udaljenosti, brzine i vremena aktivnosti te ih dijeliti s

drugima. Također omogućava postavljanje ciljeva i motiviranje korisnika kroz rang liste i segmente. Sakuplja informacije o aktivnostima i na osnovu toga generira karte intenziteta za aktivnosti.

Prema [145], podaci koje Strava skuplja i tako stvara karte intenziteta sadrži samo javne aktivnosti pri čemu vodi računa o postavkama privatnosti koje pojedini korisnici postavljaju na aplikaciji. Uz to, podaci prolaze kroz filtraciju tako da bi se isključili podaci koji su pogrešni (npr. vožnja nerealno visokom brzinom, mobilni uređaju koji ispravljaju GPS lokaciju). Nakon filtracije se podaci rasteriziraju koristeći Web Mercator Tile uslugu [146] koja se temelji na *Spherical/Web Mercator* projekciji (EPSG:3857) [147] i koristi se za prikaz geografskih podataka na web kartama. Ovaj sustav projicira Zemljinu površinu na ravninu koristeći Mercatorovu projekciju, što omogućuje prikaz geografskih podataka u obliku pločica (tiles) na web stranicama. Tileovi su kvadratni dijelovi karte koji se prikazuju na zadanom nivou zumiranja. Svaki tile ima svoje koordinate u *Spherical/Web Mercator* projekciji i definiranu razlučivost. Strava rasterizira podatke na 16. razini zooma, što svijet prikazuje u mreži od 216×216 pločica, od kojih se svaka sastoji od 256×256 piksela.

Podaci nakon toga prolaze kroz postupak normalizacije koja preslikava neobrađenu vrijednost heata za svaki piksel iz domene $[0, \infty)$ u ograničeni raspon $[0,1]$. Odabir normalizacije ima velik utjecaj na vizualni izgled karte intenziteta. Prikladna tehnika normalizacije je korištenje CDF-a (engl. *Cumulative Distribution Function* - kumulativna distribucijska funkcija). To znači da je normalizirana vrijednost određenog piksela postotak piksela s nižom vrijednosti topline, odnosno za svaki piksel u slici, izračunava se udio (ili postotak) piksela koji imaju manju vrijednost od trenutnog piksela. Na primjer, ako piksel ima veću vrijednost intenziteta od 70% ostalih piksela u slici, njegova normalizirana vrijednost će odražavati tu činjenicu, postavljajući ga u viši dio distribucije. Ovaj postupak osigurava da raspon intenziteta ili "toplina" piksela bude ravnomjerno raspoređen kroz cijelu sliku, čime se poboljšava kontrast i omogućava detaljniji prikaz različitih dijelova slike. Na taj način, svaki piksel dobiva novu vrijednost koja precizno odražava njegov relativni intenzitet u odnosu na ostatak slike, što rezultira vizualno uravnoteženijom i jasnijom slikom.

Precizan broj korisnika ili aktivnosti potreban za kreiranje karte intenziteta nije javno


dostupan od strane Strave. Međutim, indikativni podaci objavljeni u literaturi naglašavaju da je u 2023. godini više od 10 milijardi sportskih aktivnosti podijeljeno na Stravi, kako je istaknuto u članku objavljenom na [148]. Platforma Strava uključuje segmente ruta kreirane od strane korisnika, koji ne samo da pružaju informacije o mogućim rutama, već i omogućavaju drugim sportašima da isprobaju te rute i usporede svoje rezultate. Na primjer, segment Vinjani Donji - most Runović isproban je od strane 154 osobe u 1922 pokušaja, kako je prikazano na Slici 4.18. Ova informacija ukazuje na značajnu upotrebu aplikacije Strava na području Imotskog, sugerirajući relevantnost informacija koje Strava pruža.

☆ Vinjani donji - most Runović TT 4.57km

Ride Segment Donji Vinjani, Splitsko-dalmatinska županija, Croatia

Distance	Elevation Gain	Avg Grade	Lowest Elev	Highest Elev	Elev Difference
2.84mi	73ft	-0.1%	999ft	1,028ft	28ft

1,922 Attempts By 154 People



Slika 4.18. Segment Vinjani Donji - Most Runović na aplikaciji Strava

Aplikacija Strava nema mogućnost izvoza podataka u nijednom formatu, stoga je bilo potrebno napraviti sliku ekrana koja sadrži kartu intenziteta cesta područja Imotskog. Na Slici 4.19 je prikazana karta intenziteta biciklizma koje je korištena kao izvor podataka u ovom istraživanju. Svaki piksel pokriva područje od 11,15 m × 11,15 m.

Svjetlija boja predstavlja cestu koju su više koristili biciklisti korisnici aplikacije Strava. Budući da slika sadrži i druge lokacije (npr. jezera, rijeke), sliku je bilo potrebno maskirati tako da druge lokacije ne utječu na konačne rezultate. Time su se djelomično izgubile informacije o manje korištenim cestama. Maskiranje slike je napravljeno na temelju svjetline piksela, kao prag za zadržavanje piksela na slici je postavljen piksel koji označava vodenu površinu. Tako maskirana slika prebačena u crno-bijeli oblik je prikazana na Slici 4.20. His-




Slika 4.19. Stravina biciklistička karta intenziteta na području Imotskog

togram koji prikazuje frekvenciju vrijednosti piksela u koracima od 5 piksela je prikazan na Slici 4.21.




Slika 4.20. Obradena slika karte intenziteta biciklizma na području Imotskog

Svjetliji piksel označava češće korištenu cestu i tu je informaciju bilo potrebno dodijeliti sloju polilinija koji sadrži sve ceste u Imotskom. Prvi korak je bio uvesti Sliku 4.20 u ArcGIS softver u obliku rastera i georeferencirati je. Georeferenciranje je obavljeno koristeći polinomsku metodu na temelju 14 točaka. Idući korak je pretvaranje rastera u skup točaka koji sadrži informaciju o vrijednosti piksela za što je iskorišten alat *Raster to Points* što je




Slika 4.21. Histogram frekvencije piksela

prikazano na Slici 4.22 gdje se može vidjeti raspodjela piksela, tamnija boja točke predstavlja češće korištenu cestu. Time je generiran skup od 72611 točaka. Radi jednostavnosti računanja, svaki od segmenata iz sloja koji sadrži ceste je pretvoren u skup točaka koristeći *Feature Vertices to Points* s tim da je jedna točka predstavlja svaki segment, točka je locirana na sredini segmenta (centroid) kako je prikazano na Slici 4.23. Tako je dobiveno 268 točaka, svaka predstavlja jedan segment polilinije koja čini ceste.

Slika 4.22. Točke karte intenziteta nakon korištenja *Raster to points* alata


Korištena metoda za izračun poželjnosti svakog segmenta na temelju karte intenziteta se



Slika 4.23. Nakon korištenja *Feature Vertices to Points* alata na sredini svakog segmenta je točka koja predstavlja segment

temelji na pretrazi najsvjetlijeg piksela koji se nalazi u određenom radijusu oko centroida. Za izračun je iskorištena python skripta. Skripta traži najsvjetlije piksele u radijusu od 20 piksela, u metrima je to radijus od 230 metara što se činilo prikladno uzimajući u obzir razgranatost cestovne mreže. Maksimalna vrijednost piksela koja se nalazi u radijusu 230 m je pridijeljena svakom segmentu polilinja koja sadrži ceste. Iskorišten je *Network Analyst* dodatak i njegov *Create Route* alat za kreiranje rute na sličan način na koji je napravljena višekriterijska analiza, no sada se ruta kreira na temelju samo jednog kriterija – svjetline piksela. Svjetliji piksel predstavlja poželjniju stazu tako da je veća vrijednost piksela značila veću težinu segmenta. Pikseli su izravno mapirani u težine segmenata; težina pojedinog segmenta je bila jednaka najvećoj svjetlini piksela u radijusu od 230 m od centroida pojedinog segmenta. Na Slici 4.24 se može vidjeti primjer računanja težine segmenta na temelju karte intenziteta za jedan segment. Zeleni krug predstavlja centroid, crni krug predstavlja radijus od 230 metara oko centroida segmenta, unutar njega se traži maksimalna vrijednost topline i tako dobiva vrijednost težine segmenta. Kod računanja rute, kao stop točke (točke koje staza obvezno mora obići) su postavljene iste točke (točke interesa) kao i u višekriterijskoj analizi.

Rezultati preklapanja duljine i broja segmenata su prikazani u Tablici 4.3. Promatrano



Slika 4.24. Prikaz točki karte intenziteta jednog segmenta i radijusa 230 m oko centroida

je preklapanje ruta dobivenih višekriterijskom GIS analizom s rutama temeljenih na biciklističkim kartama intenziteta. Na Slici 4.25 je prikazan grafički prikaz preklapanja postotka duljine staze i postotka broja segmenata.


Tablica 4.3. Preklapanje duljine i broja segmenata za radijus 20 px (A - anaterska, P - profesionalna)

	Duljina			Broj segmenata		
	Preklapanje (m)	Ukupno (m)	% Preklapanja	Preklapanje	Ukupno	% Preklapanja
A	17818	35660	49,97%	16	22	72,73%
P	32937	39318	83,77%	21	25	84%

Na Slici 4.26 je prikazan primjer izračunate rute za radijus od 20 px (crvena boja) i preklapanje s profesionalnom rutom (crna boja).


Rezultati pokazuju značajno preklapanje ruta dobivenih podacima s kartama intenziteta s onima dobivenim višekriterijskom analizom. To potvrđuje značaj rezultata dobivenih višekriterijskom analizom i pokazuje relevantnost metode izračuna rute pomoću nje.

Iz rezultata možemo zaključiti da profesionalne rute imaju bolje preklapanje s rutom nastalom pomoću karte intenziteta, u usporedbi s amaterskom što je očekivano uzevši u obzir da Strava aplikaciju češće koriste biciklisti koji vode računa o fitnessu, imaju bolju kondiciju



Slika 4.25. Grafički prikaz preklapanja postotka duljine staze i postotka broja segmenata

i time ih možemo svrstati u profesionalne bicikliste.



Slika 4.26. Primjer preklapanja profesionalne staze radijusa preklapanja 20 px

4.3. Biciklističke rute generirane pomoću strojnog učenja i neuronskih mreža u hibridnom modelu

Hibridni model, čija je implementacija detaljno opisana u poglavlju 3.3.1, predstavlja integraciju različitih algoritama strojnog učenja i neuronskih mreža. Ovaj pristup predstavlja kombiniranje prednosti različitih modela kako bi se usporedila prediktivna mogućnost modela i generalizacija u rješavanju problema rutiranja. Konkretno, u ovom odjeljku se koriste SVM (engl. *Support Vector Machine*), FFNN (engl. *Feed Forward Neural Network*) i RNN (engl. *Recurrent neural network* - rekurentna neuronska mreža) kao dijelovi hibridnog modela čime se istražuje kako kombinacija funkcionira u zadacima rutiranja i to u zadacima rutiranja za biciklističke rute.

Polazeći od pretpostavke da je ljudsko iskustvo u definiranju biciklističkih ruta u Vrgorcu i Kninu slično, provjerena je konzistentnost rezultata modela strojnog i dubokog učenja izgrađenih na tim rutama pomoću međusobne unakrsne provjere. Konkretno, korišten je

vrgorački model kako bi se generirale rute na području Knina i uspoređene su s stvarnim, ljudski stvorenim rutama u kninskom području. Obrnuto, korišten je kninski model kako bi se stvorile rute na području Vrgorca i usporedili ih s stvarnim, ljudski stvorenim rutama u vrgoračkom području. Dobiveni rezultati pružili su informacije o reprezentativnosti modela strojnog i dubokog učenja.

GIS model temeljen na višekriterijskoj analizi se temeljio na točkama interesa koje su korištene kao stajališta u izračunu ruta. Stoga je bilo potrebno odabrati lokacije u Vrgorcu i Kninu koje će biti uključene u izračunate rute kao stajališta. Postojala je nesigurnost u vezi s time na koji način rasporediti točke. Oblik svih ruta prikazanih na web stranicama [140,141], koje su korištene kao izvor podataka, su cirkularne. Na temelju toga, odlučeno je da će se postaviti točke na rubnim dijelovima ruta pri čemu je cilj bio koristiti što manje točaka da bi se dobila ruta što sličnija stvarnoj. Sve rute, osim amaterske rute u Vrgorcu, trebale su tri točke kako bi se dobila ista ili slična ruta kao stvarna. Budući da su stvarne rute bile kružne, bila je potrebna dodatna točka kako bi se odredilo mjesto početka i završetka na istom mjestu. Vrgoračka amaterska ruta je zahtijevala jednu dodatnu točku zbog neobičnog oblika stvarne rute.

4.3.1. Korištenje rekurentne neuronske mreže za izračun staza

Kako je pojašnjeno u poglavlju 3.3.1, performansa neuronske mreže se procjenjuje korištenjem MSE izračunata unakrsnom validacijom. MSE za svaki model neuronske mreže je prikazan u Tablici 4.4.

Tablica 4.4. Srednja kvadratna pogreška (MSE) izračunata unakrsnom validacijom za modele slojevite rekurentne NN.


	Ruta	MSE
Knin	Amaterska	0,0298
	Profesionalna	0,0151
Vrgorac	Amaterska	0,0572
	Profesionalna	0,0809

Osim izračuna MSE, napravljena je evaluacija performansi generirane neuronske mreže usporedbom dvaju različitih modela.


Neuronska mreža korištena za generiranje rute je slojevita rekurentna neuronska mreža. Grafički prikaz postotka duljine generirane rute koja se preklapa sa stvarnom rutom dana u Tablici 4.5 je prikazana na Slici 4.27. Rezultati prikazani u Tablici 4.5 i na slikama 4.28, 4.29, 4.30 i 4.31 pokazuju da postoji značajna sličnost između ruta kojeg su proizveli različiti modeli. Ruta koju je odabrala neuronska mreža je prikazana s crvenom bojom, zajedno sa stajalištima, dok je do rute koji se ne preklapa označen crnom bojom. Za mjeru sličnosti su odabrane dvije veličine: broj segmenata koji se preklapaju i duljina segmenata koji se preklapaju. Vrgorački amaterski model korišten na kninskim cestama je proizveo identičnu rutu kao stvarna ruta (Slika 4.28). Profesionalni model na kninskim cestama je proizveo rutu koja se u 5 od 8 segmenata preklapa sa stvarnom i preklapanje duljine segmenata je 85% (Slika 4.29). U obrnutom smjeru, korištenje amaterskog modela treniranog na kninskim cestama na Vrgorcu je proizvelo rutu koja se preklapa sa stvarnom u 18 od 21 segmenata i u 78% duljine segmenata kako je prikazano na Slici 4.30. Profesionalni kninski model korišten na vrgoračkim cestama daje 75% preklapanja u duljini i u 14 od 17 segmenata sa stvarnom kninskom rutom (Slika 4.31). Iz podataka prikazanih u Tablici 4.5 se da zaključiti da modeli neuronske mreže trenirani na područjima Knina i Vrgorca dobro predstavljaju poželjnost biciklističkih ruta, posebno za amaterske rute.

Tablica 4.5. Rezultati verifikacije modela

Ruta		Duljina rute (preklapanje)	Broj segmenata u ruti (preklapanje)	Postotak duljine koja se preklapa	Postotak broja segmenata koji se preklapaju
Knin	Amaterska	16 542 m (16 542 m)	19 (19)	100%	100%
	Profesionalna	36 353 m (31 010 m)	8 (5)	85%	62,5%
Vrgorac	Amaterska	42 420 m (33 293 m)	21 (18)	78%	86%
	Profesionalna	25 021 m (19 766 m)	17 (14)	75%	82%




Slika 4.27. Rezultati verifikacije modela - postotak preklapanja duljine u kod unakrsne provjere.



Slika 4.28. LRNN - Vrgorački amaterski model na kninskim cestama

Verifikacija rezultata proširenjem ulaznih podataka

Ulazni podaci za ceste u Kninu su prošireni s obzirom na činjenicu da web stranica [140] sadržava označene biciklističke staze, pri čemu se četiri staze smatraju ravnim, a sedam strmima. S ciljem proširivanja opsega ulaznih podataka cesta Knina, odlučeno je da se uzmu



Slika 4.29. LRNN - Vrgorački profesionalni model na kninskim cestama

u obzir dodatne staze prilikom treniranja modela neuronske mreže, obzirom da je prethodni dio istraživanja obuhvaćao samo jednu stazu za profesionalne bicikliste i jednu za bicikliste amatere. U ovom dijelu istraživanja uzimaju se u obzir sve rute označene kao ravne koje su dostupne na web stranici, uz iznimku jedne od sedam strminskih staza zbog njezine značajne duljine (100 km), što bi rezultiralo preširokom mrežom cesta koja bi se morala uzeti u obzir da obuhvati segmente navedene staze.

Segmenti biciklističkih staza trebaju ući u set podataka za treniranje neuronske mreže, stoga je potrebno proširiti mrežu cesta koja ulazi u set podataka. Tako su poduzeti koraci proširivanja geografskog područja obuhvata cesta. U prethodnom dijelu istraživanja, model je bio treniran na 215 segmenata, dok nakon proširenja područja, model obuhvaća 777 segmenata. Na Slici 4.32 prikazan je opseg cesta za 215 i 777 segmenata, gdje su ceste obuhvaćene s 215 segmenata označene crnom bojom, dok je opseg 777 segmenata označen crvenom bojom.

Cilj je ponovno napraviti unakrsnu provjeru, trenirati model na cestama u Kninu i koristiti




Slika 4.30. LRNN - Kninski amaterski model na vrgoračkim cestama

ih na cestama u Vrgorcu, ali u ovom slučaju na više staza i širem obuhvatu mreže cesta. Ranije, 24 od 215 segmenata označeno je kao dio staze za amaterske rute, dok je 6 od 215 segmenata označeno kao dio staze za profesionalne rute, odnosno, da su ti označeni segmenti dio staze koja je temeljna istina kao ulazni podatak. Sada, uzimajući u obzir ukupno 10 ruta (4 amaterske i 6 profesionalnih), 66 od 777 segmenata označeno za amaterske rute, a 79 od 777 segmenata označeno je za profesionalne rute.

Tablica 4.6. Broj segmenata koji ulaze u mrežu kao dio odabrane staze.

	Amaterska	Profesionalna
Izvorno područje	24/215 11%	6/215 3%
Prošireno područje	66/777 9%	79/777 10%

Prvi korak bio je treniranje modela na 777 segmenata cesta u Kninu koristeći isti princip kao i prije – treniranje modela na slojevitoj rekurentnoj neuronskoj mreži pomoću nntool iz MATLAB-a. Model je zatim primijenjen na ceste u Vrgorcu koristeći istu metodu kao u pret-




Slika 4.31. LRNN - Kninski profesionalni model na vrgoračkim cestama

hodnom dijelu istraživanja. Točke interesa su postavljene na iste lokacije. Nakon treniranja modela, korišten smo ga na cestama u Vrgorcu pomoću Dijkstra algoritma. Proširenje opsega cesta i nove staze kao ulaz nisu donijeli nikakvo poboljšanje budući da su rezultirajuće ceste bile identične onima prikazanim na Slikama 4.30 i 4.31.

4.3.2. Korištenje SVM za izračun staza

Ovaj korak uključuje pristup prema izračunu poželjnosti svakog segmenta na području Vrgorca. Cilj je bio provjeriti mogućnost korištenja algoritma strojnog učenja SVM (engl. *Support Vector Machine*), odnosno, hoće li pristup u kojem se koristi SVM donijeti poboljšanja po pitanju točnosti. Kao *ground truth* staze su uzete na području Vrgorca i Knina prikazanim na web-stranicama [140, 141] koji se već prethodno izabrane od strane biciklista. Za potrebe treniranja modela korišten je *Regression Learner* alat koji je dio MATLAB-a. *Medium Gaussian SVM* je korišten pošto je on dao najbolje rezultate za MSE; za amaterske staze MSE je bio 0,0815, dok je za profesionalne iznosio 0,0778. Rezultati vezani za druge



Slika 4.32. Obuhvat cesta u Kninu za različit broj segmenata


SVM algoritme koje su bili na raspolaganju u korištenom alatu su prikazani u Tablici 4.7. Kao kernel funkcija je bila postavljena Gaussova, a vrijednosti *Box constraint*, *Kernel scale* i epsilon su postavljene na Auto. Model je treniran na 777 segmenata na kninskim cestama. Nakon treniranja modela, kao ulaz su korištene vrgoračke ceste i ponovo je korišten Dijkstra algoritam da poveže točke kako je već opisano u radu ranije.

Tablica 4.7. Usporedba MSE različitih SVM algoritama

Vrste	Amaterska	Profesionalna
Linear SVM	0,1018	0,0921
Quadratic SVM	0,0850	0,0887
Cubic SVM	0,1148	0,0817
Free Gaussian SVM	0,0876	0,0882
Medium Gaussian SVM	0,0815	0,0778
Coarse Gaussian SVM	0,1003	0,0913

Rezultati za amaterske staze trenirane na cestama Knina i korištene na cestama Vrgorca su sljedeći. Preklapanje iznosi 26 607 m od 42 420 m (63%) s *ground truth* rutom, što je lošije od rute dobivene slojevitom rekurentnom neuronskom mrežom (LR NN). Devet

cestovnih segmenata se ne preklapa, što je lošije od rute LR NN, gdje 3 segmenta nisu preklapala. Na Slici 4.33 prikazane su rute, crvenom bojom označena odabrana staza pomoću SVM-a, a crni segmenti označavaju segmente *ground truth* rute koji se ne preklapaju s rutama dobivenim pomoću SVM-a.




Slika 4.33. SVM amaterski model treniran na kninskim cestama, iskorišten u Vrgorcu

Sljede rezultati za profesionalne staze. Dio staze koji se preklapa iznosi 23 405 m od ukupno 25 021 m što čini 94% preklapanja - to je bolji rezultat nego onaj dobiven LR NN metodom koja se preklapa 15 968 m ili 64%. Kod SVM metode se preklapa 15 od 17 segmenata (88%), u usporedbi s LR NN je rezultat isto bolji pošto se tamo preklapa 14 od 17 segmenata (72%), kako je prikazano na Slici 4.34.

4.3.3. Korištenje *Feed Forward* NN za izračun staza

Sljedeći korak u istraživanju je kreiranje još jednog pristupa za izračun staza tako da se koristi jednostavna *Feed Forward* neuronska mreža (FFNN) umjesto dosad korištene slojevite rekurentne neuronske mreže (LR NN) i SVM algoritma. Jednostavna FFNN s jednim skrive-




Slika 4.34. SVM profesionalni model treniran na kninskim cestama, iskorišten u Vrgorcu

nim slojem je generirana u Kerasu [149]. Mreža je ponovo trenirana na kninskim cestovnim segmentima i to s 50 epoha i u veličinom *batcha* od 10. Ulazni i skriveni sloj imaju ReLU aktivacijsku funkciju, dok izlazni sloj ima sigmoidnu aktivacijsku funkciju.

Model je treniran na 777 segmenata na kninskim cestama s labeliranim segmentima na osnovu postojećih biciklističkih staza na web stranici [141]. Trenirani model je iskorišten na vrgoračkim cestama i na njegov izlaz je ponovo korišten Dijkstra algoritam čime su dobivene nove staze.

Za amaterske staze rezultati su kako slijedi. Neuronska mreža ima MSE od 0,032, 6 segmenata se ne preklapa s ukupnom duljinom od 9383 m što daje da se 71% od broja segmenata preklapa. Ukupna duljina rute je 42 420 m, što znači da se 33 037 ili 78% duljine preklapa. Izabrana ruta s dijelovima koji se ne preklapaju s *ground truth* stazom je prikazana na Slici 4.35. Rezultati su nešto lošiji nego oni dobiveni LR NN.

Isti postupak je ponovljen za profesionalne staze gdje je MSE bio 0,0125. Svi segmenti su se preklapali, što znači da je točnost 100%, odnosno, u potpunosti je isti kao *ground truth*



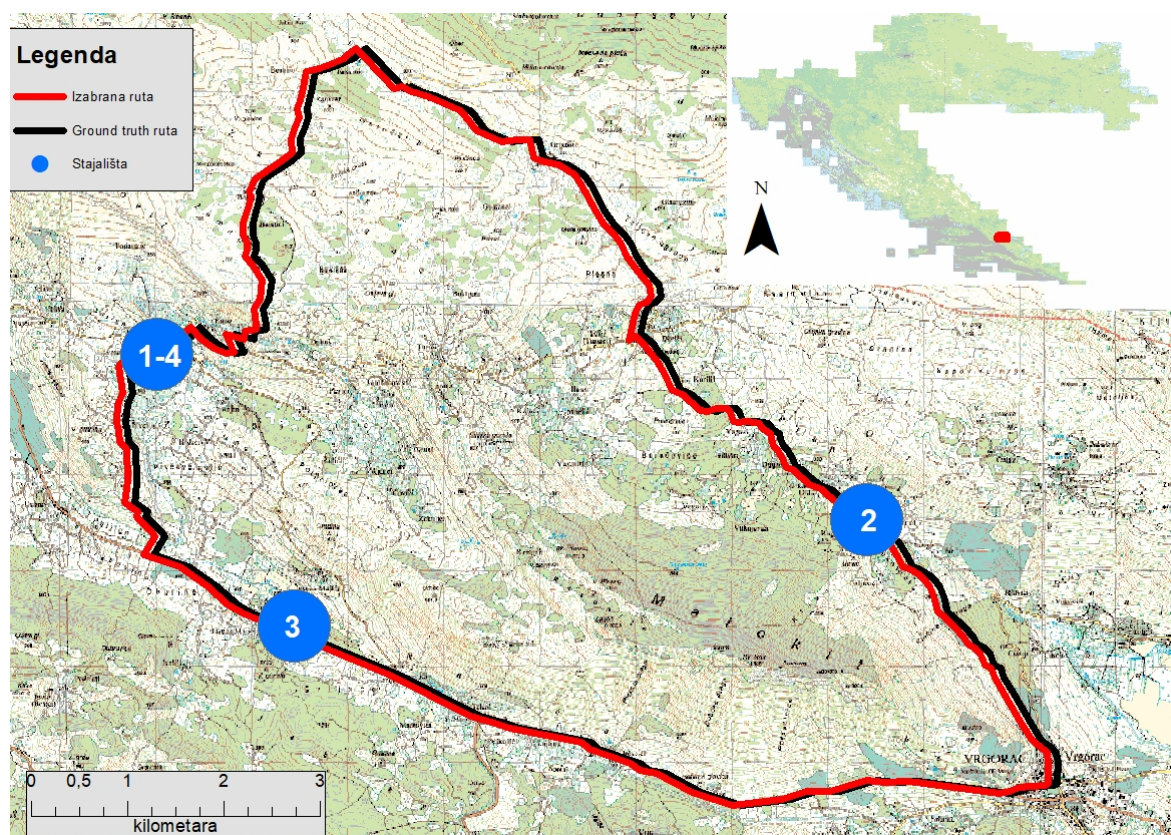
Slika 4.35. FFNN amaterski model treniran na kninskim cestama, iskorišten u Vrgorcu

staza. Ovi rezultati su bolji nego oni dobiveni preko LR NN i SVM (Slika 4.36).

4.3.4. Usporedba rezultata triju modela strojnog učenja

Nakon dobivanja amaterskih i profesionalnih ruta koristeći tri modela strojnog učenja, dobiveni rezultati su međusobno uspoređeni. Tako je u Tablici 4.8 prikazana usporedba svih rezultata dobivenih koristeći LR NN, SVM i FFNN.

Tablica usporedno prikazuje rezultate koje hibridna metoda daje kad je korištena u kombinaciji sa SVM algoritmom strojnog učenja i LR i FF neuronskim mrežama. Kad se gledaju preklapanja udaljenosti amaterskih staza, podjednako su točni LRNN i FFNN (78% ili 33293 i 33037 metara), dok SVM ima nešto lošiji rezultat od 63% ili 26607 metara. U profesionalnim stazama, postotna preklapanja su u potpunosti točna (100% ili svih 25021 m) kod FFNN, SVM ga prati s nekoliko postotaka nižim rezultatom (94% ili 23405 m), dok je LRNN dosta lošiji sa 75% ili 19766 metara preklapanja. Važna informacija je i broj i postotak preklapanja segmenata. Tako u amaterskom modelu se kao najbolja pokazuje LRNN sa 86% preklapanja



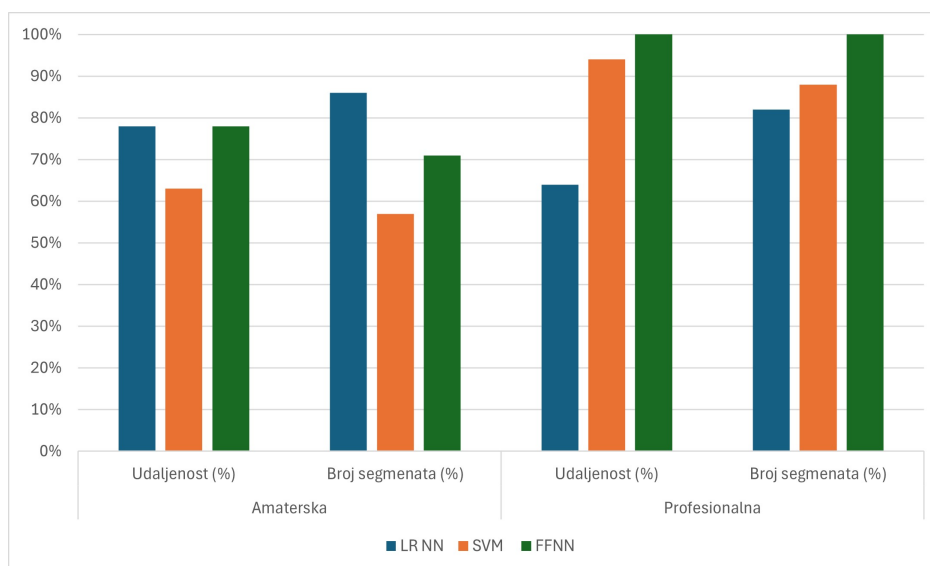
Slika 4.36. FFNN profesionalni model treniran na kninskim cestama, iskorišten u Vrgorcu

broja segmenata, odnosno 18 segmenata od ukupno 21. Sa 71% ili 15 segmenata koji se preklapaju je lošiji FFNN, dok je SVM jako loš s 12 segmenata ili 57% preklapanja. U profesionalnom modelu, najbolje preklapanje ima FFNN gdje se svih 17 segmenata preklapa. SVM je jako dobar s 15 segmenata (88%), dok značajno preklapanje ima i LRNN s 14 segmenata ili 82%. Grafički prikaz postotka preklapanja duljine i broja segmenata je prikazan na Slici 4.37.

Iz ovoga se da zaključiti da je, gledajući ukupan postotak, FFNN pokazala bolje preklapanje u profesionalnom modelu gdje je LRNN bio nešto lošije točnosti, no pokazuje bolju točnost kod amaterskim rutama. SVM pokazuje konkretnu točnost na profesionalnim stazama, unatoč tome što je algoritam dosta jednostavniji od NN, ipak je pokazao da može dobro generalizirati podatke za profesionalni model.

Tablica 4.8. Usporedba rezultata LR NN, SVM i FFNN

		Ground truth	LR NN (originalni i prošireni skup)	SVM (prošireni skup)	FF NN (prošireni skup)
Amaterska	m	42420	33293	26607	33037
	%	-	78	63	78
	Broj segmenata	21	18	12	15
	%	-	86	57	71
Profesionalna	m	25021	19766	23405	25021
	%	-	75	94	100
	Broj segmenata	17	14	15	17
	%	-	82	88	100




Slika 4.37. Grafički prikaz postotka preklapanja duljine i broja segmenata kod različitim pristupa hibridnom modelu

4.4. Usporedba korištenja višekriterijske GIS analize i hibridnog modela sa neuronskim mrežama

Nakon unakrsne provjere modela strojnog učenja i neuronskih mreža treniranih na područjima Vrgorca i Knina, kako je prikazano u odjeljku 4.3.1, korištene su za modeliranje biciklističkih ruta na području Imotskog. Uspoređene su rute na području Imotskog izračunate pomoću slojevitih rekurentnih neuronskih mreža s onima izračunatima korištenjem višekri-

terijskog GIS pristupa.

Neuronska mreža dobivena pomoću treniranja na području Vrgorca generirala je rutu prilagođenu amaterima dugu 35 660 m, od čega se 3788 m razlikuje od rute izračunate pomoću višekriterijske GIS analize. Ukupno, 89% rute izračunate pomoću neuronske mreže preklapa se s rutom izračunatom korištenjem višekriterijskog GIS pristupa. Ruta se sastojala od 29 segmenata, od kojih se 22 preklapalo s rutom izračunatom pomoću višekriterijskog pristupa. Na Slici 4.38 uspoređeni su rezultati proizvedeni pomoću neuronske mreže i oni proizvedeni pomoću višekriterijskog pristupa kada su poželjne ravne i kraće rute.




Slika 4.38. Usporedba - amaterska staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Vrgorcu

Ruta koju je generirala neuronska mreža s rekurentnim slojem prikazana je crvenom bojom. Ruta izračunata pomoću višekriterijske GIS analize, u dijelu u kojem se razlikovala od rute koju je generirala neuronska mreža, prikazana je crnom bojom. Redoslijed stajališta prema modelu neuronske mreže označen je bijelim brojevima, dok je redoslijed stajališta izračunat pomoću višekriterijske GIS analize označen crnim brojevima. Može se vidjeti da se rute preklapaju u većem dijelu cestovne mreže, ali redoslijed stajališta je različit. Razlika

u redoslijedu stajališta uzrokovana je razlikom u odabranoj ruti između Imotskog polja i središta grada. Ipak, može se zaključiti da su obje metode dale vrlo slične rezultate.

Profesionalna ruta odabrana pomoću neuronske mreže s rekurentnim slojem ima duljinu od 39 138 m i sastoji se od 25 segmenata. Dio rute, dug 7841 m i sastavljen od tri segmenta, nije isti kao ruta koju pruža višekriterijska GIS analiza. To znači da je preklapanje u duljini između dvije rute 80%, dok je preklapanje u broju segmenata je 88%.

Na Slici 4.39 prikazana je profesionalna ruta izračunata pomoću neuronske mreže s rekurentnim slojem. Potpuna usporedba ruta proizvedenih modelom temeljenim na višekriterijskoj GIS analizi i neuronskom mrežom treniranom na vrgoračkim i kninskim cestama prikazana je u Tablici 4.9, a grafički prikaz postotka preklapanja prikazan je na Slici 4.40.




Slika 4.39. Usporedba - profesionalna staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Vrgorcu

Sljedeći korak bio je provjeriti rezultate koje daju modeli trenirani na području Knina. Model koji je treniran za amaterske bicikliste generirao je identičnu rutu na području Imotskog kao i model treniran na području Vrgorca. Model treniran za bicikliste profesionalce generirao je rutu prikazanu na Slici 4.41, označenu crnom bojom.

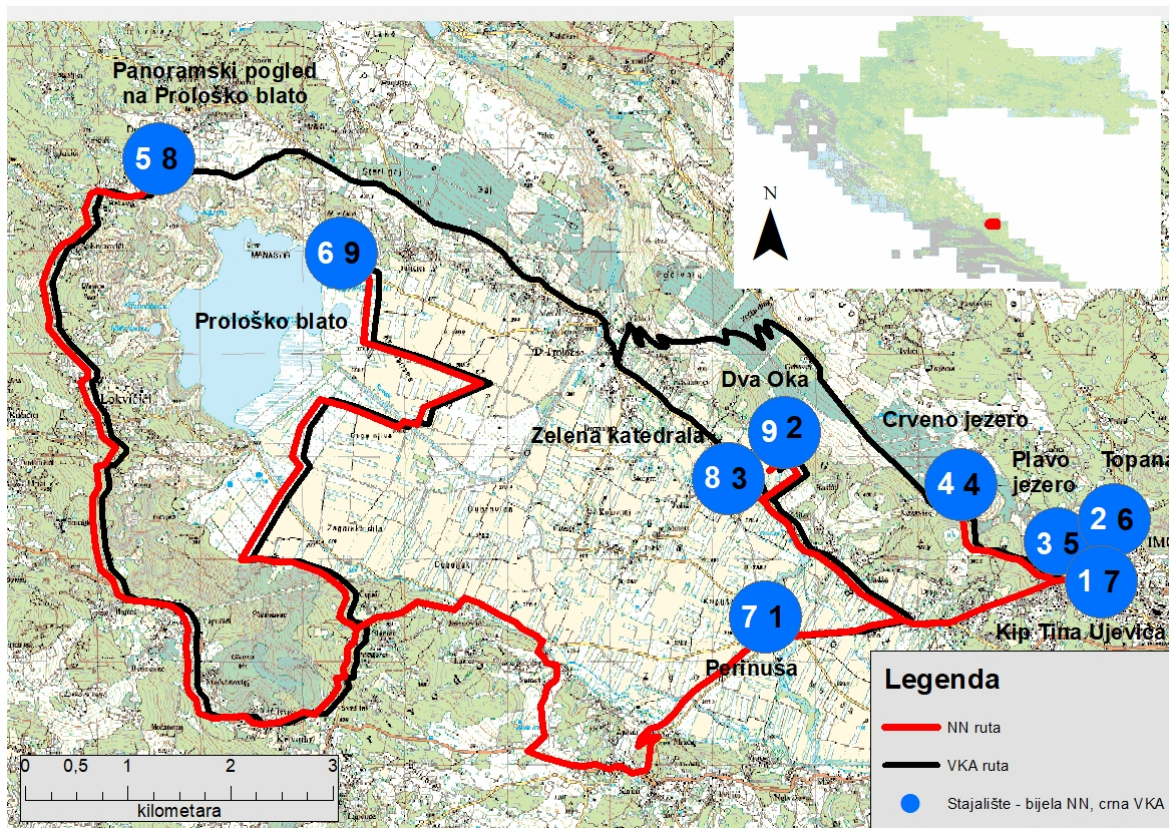
Tablica 4.9. Usporedba biciklističkih ruta u Imotskom dobivenih modelom višekriterijske GIS analize i neuronske mreže treniranom na području Vrgorca i Knina

Područje	Vrsta rute	Duljina rute (preklapanje)	Broj segmenata u ruti (preklapanje)	Postotak duljine koja se preklapa	Postotak broja segmenata koji se preklapaju
Vrgorac	Amaterska	35 660 m (31 782 m)	29 (22)	89%	76%
	Profesionalna	39 318 m (31 477 m)	25 (22)	80%	88%
Knin	Amaterska	35 660 m (35 660 m)	29 (29)	100%	100%
	Profesionalna	39 318 m (29 468 m)	25 (18)	75%	72%



Slika 4.40. Postotak preklapanja duljine između rezultata višekriterijske GIS analize i neuronske mreže trenirane na području Vrgorca i Knina za biciklističke rute u Imotskom

Prethodno je navedeno da je profesionalna ruta odabrana pomoću neuronske mreže s rekurentnim slojem duga 39 138 m i sastoji se od 25 segmenata. Dio rute, dug 9850 m i sastavljen od 7 segmenata, razlikuje se od rute koju generira višekriterijska GIS analiza. To znači da je preklapanje duljine između dvije rute 75%, dok je preklapanje segmenata 72%. Potpuna usporedba ruta proizvedenih višekriterijskih GIS modelom s rutama koji je proizvela neuronska mreža trenirana na cestama Knina prikazana je u Tablici 4.9, a grafički prikaz postotka preklapanja prikazan je na Slici 4.40.



Slika 4.41. Usporedba - profesionalna staza dobivena višekriterijskom GIS analizom i neuronskom mrežom treniranom u Kninu

Diskusija

Ovo istraživanje ima za cilj ispitati upotrebu višekriterijske GIS analize za kreiranje biciklističkih ruta u ruralnom području koje bi odražavale stvarne preferencije biciklista. Nadalje, korištene su metode strojnog učenja i neuronskih mreža za generiranje biciklističkih ruta kako bi se provjerila mogućnost prijenosa ljudske ekspertize u odabiru biciklističkih ruta s već utvrđenih ruta na nove.

Kad se gledaju ulazni podaci za kreiranje modela višekriterijske analize i kao ulaz u mrežu, jedan od glavnih ulaznih podataka je TIN model reljefa, rekonstruiran korištenjem slojeva s podacima o visini vertikalne razlučivosti od 50 m. Razlučivost modela nadmorske visine ovisila je o terenskoj strmosti, što znači da je viša razlučivost bila prisutna na mjestima gdje je površina varijabilnija.

Pri izračunu udaljenosti između svakog segmenta i jedinice hitne pomoći i izvora vode, odlučeno je da se segment smatra točkom smještenom u središtu segmenta, što je kompromis

između preciznosti i vremena izračuna. To je prvenstveno utjecalo na izračun udaljenosti do izvora vode. Vodeni tokovi korišteni u analizi su bili u obliku polilinja, pa je bilo potrebno pronaći najbliži segment vodenog toka svakom cestovnom segmentu. Korištenje svih točaka koje čine polilnije za predstavljanje segmenta učinilo bi izračun vremenski vrlo zahtjevnim.

Osim eksperimenta u kojem je ispitivana sposobnost dviju neuronskih mreža treniranih na različitim područjima za stvaranje dobrih biciklističkih ruta, uspoređene su rute stvorene tim modelima s onima stvorenima pomoću klasične GIS analize višekriterijskom analizom na području Imotskog. U GIS višekriterijskoj analizi, ključno pitanje bilo je jesu li odabrani kriteriji i dodijeljene težine vjerno odražavali faktore koji utječu na odluku biciklista pri odabiru biciklističke rute u stvarnim situacijama. Naglasak na važnosti nagiba rute rezultirao je dodjeljivanjem veće težine, budući da je smatran najvažnijim kriterij za odabir biciklističke rute, posebice među amaterskim biciklistima. Rute stvorene pomoću dva modela LR neuronskih mreža dobro su se poklapale s onima stvorenima pomoću višekriterijske GIS analize (najlošije preklapanje 75% duljine). Stoga se može zaključiti da su kriteriji za višekriterijsku GIS analizu dobro odabrani i da modeli nisu pretrenirani. Da je pretreniranje prisutno u ove dvije mreže, bile bi prekomjerno specijalizirane za svoje skupove podataka, što bi rezultiralo različitim predviđanjima na trećem skupu podataka, što nije bio slučaj.

Iako je podudaranje između višekriterijske GIS analize i neuronskih mreža bilo blisko, postoje i dalje manje razlike u odabranim rutama korištenjem različitih metodologija. Ove varijacije mogle su biti uzrokovane činjenicom da više kriterija utječe na odabir biciklističke rute nego što je razmatrano u ovom radu. Također, odabir kriterija i dodjela težina svakom kriteriju u višekriterijskoj GIS analizi imaju svojih nedostataka što je doprinijelo primijećenim razlikama.

Performanse neuronske mreže evaluirane su pomoću izračuna srednje kvadratne pogreške (MSE), primijenjenog na sve modele, pri čemu je model za profesionalnu stazu na području Vrgorca imao najveći MSE od 0,0809. Ako bi se izračunao RMSE (engl. *Root MSE*), koji je korijen iz MSE, to daje pogrešku u istoj skali kao i podaci. Za MSE od 0,0809, RMSE bi bio $\sqrt{0,0809} \approx 0,28$. Isto tako, za minimalnu vrijednost MSE od 0,0151, RMSE bi bio $\sqrt{0,0151} \approx 0,123$ bi značilo pogrešku od 0,123 u rasponu [0,1]. Uzimajući u obzir

relativnost vrijednosti MSE pri evaluaciji neuronskih mreža, provedena je evaluacija unakrsnom provjerom. Evaluacija je obavljena stvaranjem biciklističkih staza na području Knina pomoću modela za Vrgorac i obrnuto pri čemu se koristila LR NN. Takva evaluacija je pokazala visok postotak preklapanja između ruta stvorenih neuronskim mrežama i biciklističkih ruta koje već postoje na tom području. U nekim scenarijima, neuronska mreža je generirala potpuno iste rute koje već postoje na tom području, a najlošiji rezultat bio je preklapanje duljine od 75%. Na temelju toga se da zaključiti da neuronska mreža dobro obavlja zadatak i da trenirani modeli nisu pretrenirani. Nadalje, korištenje funkcije prilagodbenog učenja tijekom procesa treniranja neuronske mreže uključivalo je i funkciju učenja pristranosti, čime se spriječilo pretreniranje.

Može se primijetiti da su profesionalne rute nešto lošijih performansi za LRNN. Unakrsna verifikacija modela koristeći LRNN daje prosječnu točnost u udaljenosti za amatersku rutu od 89%, dok je za profesionalnu rutu prosječna točnost 80%. Ako se promatra postotak broja preklapajućih segmenata, prosječna točnost amaterske rute je 93%, a profesionalne 72,25%. No, korištenje SVM i FFNN je pokazalo bolju točnost kod profesionalnih ruta (SVM - duljina amaterska 63%, profesionalna 94%, FFNN duljina amaterska 78%, profesionalna 100%). Uzimajući u obzir navedena saznanja koja su detaljnije prikazana u potpoglavlju 4.3.4, postoji mogućnost korištenja kombinacije tako da se LRNN koristi za generiranje amaterskih ruta, a FFNN za profesionalne rute.

Usporedba korištenja hibridnog LRNN modela i višekriterijske GIS analize na području Imotskog je također pokazalo nešto lošiju performansu za profesionalne rute; prosječno 94,5% preklapanja udaljenosti i 88% preklapanja broja segmenata u amaterskim rutama prema 77,5% udaljenosti i 80% broja segmenata u profesionalnim rutama.

5. ZAKLJUČAK

Ovo istraživanje se bavi razvojem i evaluacijom metodološkog pristupa kreiranju biciklističkih ruta koristeći višekriterijsku GIS analizu (MCDA-GIS - engl. *Multi-Criteria Decision Analysis*) i integraciju algoritama strojnog i dubokog učenja s Dijkstra algoritmom (hibridni modeli). Posebna je pažnja dana ruralnim područjima pošto se motivacija istraživanja temelji na razvitku biciklizma i popratne infrastrukture kao turističke ponude u ruralnim područjima. Tako je temeljni cilj bio razviti i validirati model koji će omogućiti planiranje biciklističkih ruta koje su zanimljive, sigurne i prikladne korisnicima s različitom razinom iskustva.

Važan dio istraživanja čine korišteni podaci; rad tako prikazuje koji podaci su korišteni i kojom metodologijom su eventualno aproksimirani čime se nastojalo izgubiti što manje podataka, no istovremeno i uštedjeti vrijeme na nepotrebnim procesorskim računanjima. Važan dio je i opis ArcGIS softvera, pripadajućih ekstenzija i alata; programski paket se pokazao kao koristan i sveobuhvatan u prikazivanju i obradi podataka.

Sam početak istraživanja se temelji na višekriterijskoj GIS analizi gdje se uz kombinaciju provedenog kvantitativnog i kvalitativnog istraživanja provedenim među biciklističkim entuzijastima dobilo više informacija o preferencijama kod bicikliranja. U kvalitativnom dijelu su intervjuirani ispitanici od značaja i s velikim iskustvom u svijetu bicikliranja. Stečena znanja u kombinaciji s pregledom literature su iznjedrili potrebu za odvajanjem modela koji bi bili različiti za profesionalne bicikliste koji su fizički spremniji i kojima je izazov potreban da bi im iskustvo okoline bilo zanimljivo, dok je amaterskim biciklistima potrebno da dožive okolinu, a da se pritom ne preoptereće čime bi se poremetilo iskustvo. Pet kriterija koji su uzeti u obzir prilikom izračuna višekriterijske GIS analize su smatrani optimalnima stvarajući kompromis između unošenja količine informacija u modele i vremena potrebnog za obradu i skupljanje podataka. Tako se može zaključiti da su modeli iz izabranih kriterija

dobili dovoljno informacija koje su potrebni da bi radili sa zadovoljavajućom točnošću. Svakom kriteriju je bilo potrebno dati prikladan ponder kojom određeni kriterij utječe na konačni rezultat o prikladnosti dijela ceste, Kod amaterskog modela je bilo dovoljno da svaki od kriterija nosi istu težinu, dok je profesionalni model bilo potrebno pojačati da nagib ipak nosi težinu 2, vrijednost duljine je invertirana, dok su ostali kriteriji nosili težinu 1. Obzirom na pravila AHP-a, izračunat je koeficijent konzistentnosti čime je potvrđeno da su pridijeljene vrijednosti konzistentne.

Nastavak istraživanja se svodi na korištenje algoritama strojnog i dubokog učenja u kombinaciji s Dijkstra algoritmom čime je kreiran hibridni model. Algoritam strojnog učenja je treniran na cestama gradova koji se također nalaze u Dalmatinskoj zagori (Knin i Vrgorac), a na čijem području postoje definirane biciklističke rute. Te rute su zajedno s podacima vezanim za cestovne segmente uneseni kao ulazni podatak za treniranje modela. Kao neuronska mreža u hibridnom modelu su korištene slojevita rekurentna i *Feed Forward* neuronske mreže i *Support Vector Machine* algoritam strojnog učenja koji su na izlazu davali prikladnost svakog segmenta u rasponu od 0 do 1. Onda se postavio problem na koji način iskoristiti takve podatke, a da se pomoću njih može povezati ruta temeljena na generiranim podacima. Tu je iskorišten Dijkstra algoritam koji je spojio točke interesa preferirajući najpovoljnije segmente. Istrenirani modeli slojevite rekurentne mreže su pušteni na području Imotskog i uspoređeni s onima dobivenim višekriterijskom analizom i dobiveno je značajno preklapanjem dok su FFNN i SVM korišteni kod unakrsne provjere.

U sklopu ovog istraživanja, verifikacija razvijenih modela za optimizaciju biciklističkih ruta predstavlja ključni korak u verifikaciji metodologije i njenih rezultata. S obzirom na potencijalne izazove povezane s primjenjivosti modela u različitim geografskim i socio-ekonomskim kontekstima, posebna pažnja posvećena je detaljnoj verifikaciji dobivenih modela kroz implementaciju višeslojnih pristupa evaluaciji.

Jedan od pristupa koji je implementiran u ovom istraživanju jest unakrsna provjera, gdje su modeli razvijeni za područja Knina i Vrgorca isprobani međusobno. Konkretno, model razvijen za područje Knina testiran je na području Vrgorca i obrnuto, s ciljem evaluacije njihove primjenjivosti i učinkovitosti u različitim geografskim područjima. Rezultati unakrsne

provjere uspoređeni su s postojećim biciklističkim rutama na navedenim područjima, čime je omogućena direktna evaluacija točnosti generiranih modela. Analiza preklapanja između predloženih ruta i postojećih biciklističkih staza pokazala je značajno podudaranje, čime je dodatno potvrđena valjanost metodologije i izabranih ruta. Značajno preklapanje između modeliranih i postojećih ruta ukazuje na to da predloženi modeli dobro identificiraju ključne faktore koji utječu na odabir optimalnih biciklističkih ruta, kao što su sigurnost i zanimljivost ruta.

Ova verifikacijska metoda pruža dodatnu sigurnost u pogledu pouzdanosti i primjenjivosti razvijenih modela, ističući važnost kombiniranja različitih metoda evaluacije kako bi se osigurala sveobuhvatna verifikacija istraživačkih rezultata. Budući rad bi mogao uključivati proširenje ove metode verifikacije na veći broj područja te integraciju dodatnih parametara koji mogu utjecati na odabir i optimizaciju biciklističkih ruta, poput varijacija u klimatskim uvjetima i sezonskoj dostupnosti ruta.

Još jedan značajan pristup verifikaciji je prikazan u ovom radu i to korištenjem Stravinih karti intenziteta. Budući da Strava nije pružila mogućnost izvlačenja podataka izravno, izrađena je snimka zaslona, a zatim je provedena obrada te snimke. Metodologija u kojoj se traži najsvjetliji piksel u određenom radijusu od centroida semgneta se pokazao kao prikladan pošto je tom metodom dobivena ruta koja se značajno preklapa s ovom profesionalnom višekriterijskom stazom.

Iz istraživanja opisanog u doktorskoj disertaciji može se zaključiti da korištenje višekriterijske GIS analize i hibridni model koji nastaje kao kombinacija strojnog učenja i Dijkstra algoritma predstavljaju nov i učinkovit pristup za optimizaciju biciklističkih ruta, omogućujući modeliranje ruta koje zadovoljavaju različite kriterije uključujući korisnike različitog profila. Također, korištenje GIS-a kao alata za obradu, analizu i prikaz podataka omogućilo je reprezentaciju mreže cesta i puteva kroz graf, gdje svaki segment ceste između raskrižja čini dio grafa, a raskrižja predstavljaju čvorove grafa. Ovakva aproksimacija mreže cesta kroz segment je dovela do gubitka dijela informacija vezanih za mrežu cesta. No, uzimajući u obzir dobivene rezultate, nije bila od značajnog utjecaja na konačan izračun. Implementacija hibridnog modela, koji integrira Dijkstra algoritam i strojno učenje, pokazala se

efikasnom pri generiranju biciklističkih ruta. Ovi zaključci ukazuju na to da predloženi metodološki pristup može doprinijeti planiranju i razvoju biciklističkih ruta, potičući turizam i poboljšavajući kvalitetu biciklističkih iskustava u ruralnim područjima.

Budući rad na istraživanju je moguće usmjeriti prema potpunom izbacivanju Dijkstrinog algoritma kao sredine između vrijednosti segmenata i konačne rute. Cilj budućeg istraživanja bi bio koristiti metode strojnog ili dubokog učenja da bi se izravno dobila najprikladnija ruta koja povezuje točke interesa na određenom području. Svakako bi se model trebao isprobati na još kojem području s proširenim skupom kriterija koji mogu utjecati na odluku o stazi. Kriterijima bi se trebale dodijeliti težine koje su više u skladu s AHP metodom, s tim da težine dobivenim anketom mogu biti vodilja. Naime, trenutni model nagib segmenta računa pojednostavljeno, iz početne i krajnje točke segmenta, pa se planira u model uvesti detaljnije i vjernije modeliranje nagiba, koje bi vodilo računa o promjenama nagiba unutar samog segmenta. Također, trebao bi se iskoristiti drugačiji način aproksimacije cestovne mreže u segmente na način da budu prilagođene mjerilu i terenu na kojem se radi. Kao ulazni podaci bi se trebali koristiti precizniji LIDAR podaci umjesto vektoriziranih podataka koji su korišteni u ovom istraživanju. Također bi bilo zanimljivo povezati odluku o odabiru biciklističke rute s dinamičkim kriterijima kao što su vremenski uvjeti, uvjeti na cestama (radovi, gužve, nesreće) čime bi se doprinijelo relevantnosti kreiranih ruta.

Slijedom opisa istraživanja, dobivenih rezultata i verifikacije, doprinosi doktorske disertacije su sljedeći:

- Kreiran je model traženja najpovoljnije biciklističke rute između više točaka u ruralnim područjima, realiziran korištenjem MCDA-GIS i AHP metode te teorijom grafova
- Kreiran je model traženja najpovoljnije biciklističke rute između više točaka u ruralnim područjima realiziran korištenjem hibridne metode GIS analize i strojnog učenja

Doktorska disertacija ima i dodatne korisne rezultate istraživanja:

- Novo znanje o utjecaju izbora modela strojnog i dubokog učenja na točnost izbora najpovoljnije rute između dviju ili više točaka unutar cestovne mreže u ruralnim područjima

LITERATURA

- [1] A. Vujko, M. Dragosavac, N. Kisin i B. Maksimović, The influence of cyclo-tourism on health and economic destination development, *Facta Universitatis, Series: Physical Education and Sport*, 15, 1, 227–237, 2017.
- [2] K. A. Rus, Dezsi i O. R. Ciascai, Transformative experiences in cycling tourism: A conceptual framework, *Sustainability*, 15, 20, 15124, 2023.
- [3] A. Hull i C. O'Holleran, Bicycle infrastructure: can good design encourage cycling?, *Urban, Planning and Transport Research*, 2, 1, 369–406, siječanj 2014.
- [4] K.-T. Chang, Geographic information system, *International encyclopedia of geography: people, the earth, environment and technology*, 1–10, 2016.
- [5] T. G. Wade, J. D. Wickham, M. S. Nash, A. C. Neale, K. H. Riitters i K. B. Jones, A comparison of vector and raster GIS methods for calculating landscape metrics used in environmental assessments, *Photogrammetric Engineering & Remote Sensing*, 69, 12, 1399–1405, prosinac 2003.
- [6] J. R. Eastman, H. Jiang i J. Toledano, Multi-criteria and multi-objective decision making for land allocation using gis, 1998.
- [7] R. Greene, R. Devillers, J. E. Luther i B. G. Eddy, GIS-based multiple-criteria decision analysis, *Geography Compass*, 5, 6, 412–432, lipanj 2011.
- [8] J. Malczewski, On the use of weighted linear combination method in GIS: Common and best practice approaches, *Transactions in GIS*, 4, 1, 5–22, siječanj 2000.
- [9] K. P. Vadrevu, A. Eaturu i K. V. S. Badarinath, Fire risk evaluation using multicriteria analysis—a case study, *Environmental Monitoring and Assessment*, 166, 1–4, 223–239, svibanj 2009.
- [10] R. van Haaren i V. Fthenakis, GIS-based wind farm site selection using spatial multi-criteria analysis (SMCA): Evaluating the case for new york state, *Renewable and Sustainable Energy Reviews*, 15, 7, 3332–3340, rujan 2011.
- [11] M. M. Damoom, S. Hashim, M. S. Aljohani, M. A. Saleh i N. Xoubi, Potential areas for nuclear power plants siting in saudi arabia: GIS-based multi-criteria decision making analysis, *Progress in Nuclear Energy*, 110, 110–120, siječanj 2019.
- [12] D. Rincón, U. Khan i C. Armenakis, Flood risk mapping using GIS and multi-criteria analysis: A greater toronto area case study, *Geosciences*, 8, 8, 275, srpanj 2018.
- [13] L. Lin, Z. Wu i Q. Liang, Urban flood susceptibility analysis using a GIS-based multi-criteria analysis framework, *Natural Hazards*, 97, 2, 455–475, lipanj 2019.

- [14] L. Gigović, G. Jakovljević, D. Sekulović i M. Regodić, GIS multi-criteria analysis for identifying and mapping forest fire hazard: Nevesinje, bosnia and herzegovina, *Tehnicki vjesnik - Technical Gazette*, 25, 3, lipanj 2018.
- [15] M. Drabecki, E. Toczyłowski, K. Pieńkosz, G. Honisz i K. Kułak, Multi-criteria assignment problems for optimising the emergency medical services (EMS), considering non-homogeneous speciality of the emergency departments and EMS crews, *Scientific Reports*, 13, 1, svibanj 2023.
- [16] S. CHOOSUMRONG, V. RAGHAVAN i N. BOZON, Multi-criteria emergency route planning based on analytical hierarchy process and pgRouting, *GEOINFORMATICS*, 23, 4, 159–167, 2012.
- [17] T. Völkel i G. Weber, RouteCheckr, *Proceedings of the 10th international ACM SIGACCESS conference on Computers and accessibility*, ACM, listopad 2008.
- [18] M. Noureddine, i M. R. and, Route planning for hazardous materials transportation: Multi-criteria decision-making approach, *Decision Making: Applications in Management and Engineering*, 2, 1, 66–84, ožujak 2019.
- [19] X. Chen, H. Cai i T. Wolf, Multi-criteria routing in networks with path choices, *2015 IEEE 23rd International Conference on Network Protocols (ICNP)*, IEEE, studeni 2015.
- [20] T. L. Saaty, *The analytic hierarchy process : planning, priority setting, resource allocation*, McGraw-Hill International Book Co., New York; London, 1980.
- [21] A. H. Lee, W.-C. Chen i C.-J. Chang, A fuzzy AHP and BSC approach for evaluating performance of IT department in the manufacturing industry in taiwan, *Expert Systems with Applications*, 34, 1, 96–107, siječanj 2008.
- [22] M. Vahidnia, A. Alesheikh, A. Alimohammadi i A. Bassiri, Fuzzy analytical hierarchy process in gis application, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37, B2, 593–596, 2008.
- [23] S. Boroushaki i J. Malczewski, Implementing an extension of the analytical hierarchy process using ordered weighted averaging operators with fuzzy quantifiers in ArcGIS, *Computers & Geosciences*, 34, 4, 399–410, travanj 2008.
- [24] A. Rikalovic, I. Cosic i D. Lazarevic, Gis based multi-criteria analysis for industrial site selection, *Procedia Engineering*, 69, 1054–1063, 2014.
- [25] M. Sekulic, A. Siljeg, A. Mansourian, L. Watson i B. I. Cavric, Multi-criteria spatial-based modelling for optimal alignment of roadway by-passes in the tlokweng planning area, botswana, *Journal of Spatial Science*, 67, 2, 237–254, svibanj 2020.
- [26] M. Ghamgosar, M. Haghyghy, F. Mehrdoust, N. Arshad et al., Multicriteria decision making based on analytical hierarchy process (ahp) in gis for tourism, *Middle-East Journal of Scientific Research*, 10, 4, 501–507, 2011.
- [27] J. Ritchie, C. R. Goeldner i R. W. McIntosh, *Tourism: principles, practices, philosophies*, John Wiley & Son (New Jersey), 2003.

- [28] P. Chen, Q. Shen i S. Childress, A gps data-based analysis of built environment influences on bicyclist route preferences, *International Journal of Sustainable Transportation*, 12, 3, 218–231, srpanj 2017.
- [29] R. Pritchard, Y. Frøyen i B. Snizek, Bicycle level of service for route choice—a gis evaluation of four existing indicators with empirical data, *ISPRS International Journal of Geo-Information*, 8, 5, 214, svibanj 2019.
- [30] Z. Wang, S. Zlatanova, A. Moreno, P. van Oosterom i C. Toro, A data model for route planning in the case of forest fires, *Computers amp; Geosciences*, 68, 1–10, srpanj 2014.
- [31] Y. Huang i G. Ye, Selecting bicycle commuting routes using gis, *Berkeley Planning Journal*, 10, 1, srpanj 2012.
- [32] H. Deng, Multicriteria analysis with fuzzy pairwise comparison, *FUZZ-IEEE'99. 1999 IEEE International Fuzzy Systems. Conference Proceedings (Cat. No.99CH36315)*, IEEE, 1999.
- [33] L. Mikhailov i P. Tsvetinov, Evaluation of services using a fuzzy analytic hierarchy process, *Applied Soft Computing*, 5, 1, 23–33, prosinac 2004.
- [34] Y. C. Erensal, T. Öncan i M. L. Demircan, Determining key capabilities in technology management using fuzzy analytic hierarchy process: A case study of turkey, *Information Sciences*, 176, 18, 2755–2770, rujan 2006.
- [35] L. A. Zadeh, G. J. Klir i B. Yuan, *Fuzzy sets, fuzzy logic, and fuzzy systems: selected papers*, 6, World scientific, 1996.
- [36] H. S. Hansen, Gis-based multi-criteria analysis of wind farm development, *ScanGIS 2005: Proceedings of the 10th Scandinavian Research Conference on Geographical Information Science*, 75–87, Department of Planning and Environment, 2005.
- [37] D.-Y. Chang, Applications of the extent analysis method on fuzzy ahp, *European journal of operational research*, 95, 3, 649–655, 1996.
- [38] D. Latinopoulos i K. Kechagia, A gis-based multi-criteria evaluation for wind farm site selection. a regional scale application in greece, *Renewable Energy*, 78, 550–560, lipanj 2015.
- [39] A. T. Jebb, V. Ng i L. Tay, A review of key likert scale development advances: 1995–2019, *Frontiers in Psychology*, 12, svibanj 2021.
- [40] L.-X. Wang, *A course in fuzzy systems and control*, Prentice-Hall, Inc., 1996.
- [41] T. P. Hsu i Y. T. Lin, A model for planning a bicycle network with multi-criteria suitability evaluation using gis, *WIT Transactions on Ecology and The Environment*, RAV11, WIT Press, prosinac 2011.
- [42] A. Sadavare i R. Kulkarni, A review of application of graph theory for network, *International Journal of Computer Science and Information Technologies*, 3, 6, 5296–5300, 2012.

- [43] G. Valiente, *Algorithms on trees and graphs*, 112, Springer, 2002.
- [44] A. Majeed i I. Rauf, Graph theory: A comprehensive survey about graph theory applications in computer science and social networks, *Inventions*, 5, 1, 10, 2020.
- [45] K. R. Saoub, *A tour through graph theory*, CRC Press, 2017.
- [46] D. B. Johnson, A note on dijkstra's shortest path algorithm, *Journal of the ACM (JACM)*, 20, 3, 385–388, 1973.
- [47] A. Candra, M. A. Budiman i K. Hartanto, Dijkstra's and a-star in finding the shortest path: a tutorial, *2020 International Conference on Data Science, Artificial Intelligence, and Business Analytics (DATABIA)*, 28–32, 2020.
- [48] X. Wang, Y. Koç, S. Derrible, S. N. Ahmad, W. J. Pino i R. E. Kooij, Multi-criteria robustness analysis of metro networks, *Physica A: Statistical Mechanics and its Applications*, 474, 19–31, svibanj 2017.
- [49] Y. D. Rosita, E. E. Rosyida i M. A. Rudiyanto, Implementation of dijkstra algorithm and multi-criteria decision-making for optimal route distribution, *Procedia Computer Science*, 161, 378–385, 2019.
- [50] H. Aissi, S. Chakhar i V. Mousseau, Gis-based multicriteria evaluation approach for corridor siting, *Environment and Planning B: Planning and Design*, 39, 2, 287–307, travanj 2012.
- [51] D. Michie, D. J. Spiegelhalter i C. C. Taylor, *Machine learning, neural and statistical classification*, 1994.
- [52] T. M. Mitchell, *Machine learning*, 1, McGraw-hill New York, 1997.
- [53] I. H. Sarker, *Machine learning: Algorithms, real-world applications and research directions*, *SN Computer Science*, 2, 3, ožujak 2021.
- [54] M. Mohammed, M. B. Khan i E. B. M. Bashier, *Machine learning: algorithms and applications*, Crc Press, 2016.
- [55] J. Han, J. Pei i H. Tong, *Data mining: concepts and techniques*, Morgan kaufmann, 2022.
- [56] I. H. Sarker, A. Kayes, S. Badsha, H. Alqahtani, P. Watters i A. Ng, Cybersecurity data science: an overview from machine learning perspective, *Journal of Big data*, 7, 1–29, 2020.
- [57] L. P. Kaelbling, M. L. Littman i A. W. Moore, Reinforcement learning: A survey, *Journal of artificial intelligence research*, 4, 237–285, 1996.
- [58] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg et al., Scikit-learn: Machine learning in python, *the Journal of machine Learning research*, 12, 2825–2830, 2011.
- [59] C. Cortes i V. Vapnik, Support-vector networks, *Machine learning*, 20, 273–297, 1995.

- [60] Y. S. Abu-Mostafa, The vapnik-chervonenkis dimension: Information versus complexity in learning, *Neural Computation*, 1, 3, 312–317, 1989.
- [61] M. Stitson, J. Weston, A. Gammerman, V. Vovk i V. Vapnik, Theory of support vector machines, *University of London*, 117, 827, 188–191, 1996.
- [62] G. Guo, S. Z. Li i K. Chan, Face recognition by support vector machines, *Proceedings fourth IEEE international conference on automatic face and gesture recognition (cat. no. PR00580)*, 196–201, IEEE, 2000.
- [63] Y. Wang i Q. Wu, Research on face recognition technology based on pca and svm, *2022 7th International Conference on Big Data Analytics (ICBDA)*, 248–252, IEEE, 2022.
- [64] M. Pontil i A. Verri, Support vector machines for 3d object recognition, *IEEE transactions on pattern analysis and machine intelligence*, 20, 6, 637–646, 1998.
- [65] R. Kabir, Y. Watanobe, M. R. Islam, K. Naruse i M. M. Rahman, Unknown object detection using a one-class support vector machine for a cloud–robot system, *Sensors*, 22, 4, 1352, 2022.
- [66] M. Islam, A. Dinh, K. Wahid i P. Bhowmik, Detection of potato diseases using image segmentation and multiclass support vector machine, *2017 IEEE 30th canadian conference on electrical and computer engineering (CCECE)*, 1–4, IEEE, 2017.
- [67] T. Mullen i N. Collier, Sentiment analysis using support vector machines with diverse information sources, *Proceedings of the 2004 conference on empirical methods in natural language processing*, 412–418, 2004.
- [68] H. Drucker, D. Wu i V. N. Vapnik, Support vector machines for spam categorization, *IEEE Transactions on Neural networks*, 10, 5, 1048–1054, 1999.
- [69] A. K. Mandle, P. Jain i S. K. Shrivastava, Protein structure prediction using support vector machine, *International Journal on Soft Computing*, 3, 1, 67, 2012.
- [70] C. D. A. Vanitha, D. Devaraj i i. Venkatesulu, Gene expression data classification using support vector machine and mutual information-based gene selection, *procedia computer science*, 47, 13–21, 2015.
- [71] K. Heikamp i J. Bajorath, Support vector machines for drug discovery, *Expert opinion on drug discovery*, 9, 1, 93–104, 2014.
- [72] G. Wang i J. Ma, A hybrid ensemble approach for enterprise credit risk assessment based on support vector machine, *Expert Systems with Applications*, 39, 5, 5325–5331, 2012.
- [73] W. Fenghua, X. Jihong, H. Zhifang i G. Xu, Stock price prediction based on ssa and svm, *Procedia Computer Science*, 31, 625–631, 2014.
- [74] M. Awad, R. Khanna, M. Awad i R. Khanna, Support vector regression, *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67–80, 2015.

- [75] H. Drucker, C. J. Burges, L. Kaufman, A. Smola i V. Vapnik, Support vector regression machines, *Advances in neural information processing systems*, 9, 1996.
- [76] G. Xu, Z. Cao, B.-G. Hu i J. C. Principe, Robust support vector machines based on the rescaled hinge loss function, *Pattern Recognition*, 63, 139–148, 2017.
- [77] H. Tong i M. K. Ng, Calibration of ℓ_1 -insensitive loss in support vector machines regression, *Journal of the Franklin Institute*, 356, 4, 2111–2129, 2019.
- [78] F. Zhang i L. J. O’Donnell, Support vector regression, *Machine learning*, 123–140, Elsevier, 2020.
- [79] Y. LeCun, Y. Bengio i G. Hinton, Deep learning, *Nature*, 521, 7553, 436–444, svibanj 2015.
- [80] Y. Bengio, Y. Lecun i G. Hinton, Deep learning for ai, *Communications of the ACM*, 64, 7, 58–65, lipanj 2021.
- [81] D. E. Rumelhart, G. E. Hinton i R. J. Williams, Learning representations by back-propagating errors, *Nature*, 323, 6088, 533–536, listopad 1986.
- [82] Y. Bengio, R. Ducharme i P. Vincent, A neural probabilistic language model, *Advances in neural information processing systems*, 13, 2000.
- [83] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard et al., {TensorFlow}: a system for {Large-Scale} machine learning, *12th USENIX symposium on operating systems design and implementation (OSDI 16)*, 265–283, 2016.
- [84] A. Paszke, S. Gross, S. Chintala, G. Chanan, E. Yang, Z. DeVito, Z. Lin, A. Desmaison, L. Antiga i A. Lerer, Automatic differentiation in pytorch, 2017.
- [85] R. Collobert, K. Kavukcuoglu i C. Farabet, Torch7: A matlab-like environment for machine learning, *BigLearn, NIPS workshop*, CONF, 2011.
- [86] Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama i T. Darrell, Caffe: Convolutional architecture for fast feature embedding, *Proceedings of the 22nd ACM international conference on Multimedia*, 675–678, 2014.
- [87] J. Bergstra, O. Breuleux, F. Bastien, P. Lamblin, R. Pascanu, G. Desjardins, J. Turian, D. Warde-Farley i Y. Bengio, Theano: a cpu and gpu math expression compiler, *Proceedings of the Python for scientific computing conference (SciPy)*, 4, 1–7, Austin, TX, 2010.
- [88] W. S. Sarle, Neural networks and statistical models., *Proceedings of the 19th annual SAS users group international conference*, 13, 1994.
- [89] D. Svozil, V. Kvasnicka i J. Pospichal, Introduction to multi-layer feed-forward neural networks, *Chemometrics and intelligent laboratory systems*, 39, 1, 43–62, 1997.
- [90] B. Yegnanarayana, *Artificial neural networks*, PHI Learning Pvt. Ltd., 2009.
- [91] Neural Backpropagation — assignmentpoint.com, <https://assignmentpoint.com/neural-backpropagation/>, pristupljeno 3.6.2024.

- [92] D. A. Singer i R. Kouada, Application of a feedforward neural network in the search for kuroko deposits in the hokuroku district, japan, *Mathematical Geology*, 28, 1017–1023, 1996.
- [93] N. Djarfour, T. Aïfa, K. Baddari, A. Mihoubi i J. Ferahtia, Application of feedback connection artificial neural network to seismic data filtering, *Comptes Rendus Geoscience*, 340, 6, 335–344, 2008.
- [94] P. E. Utgoff i D. J. Straczuzi, Many-layered learning, *Neural computation*, 14, 10, 2497–2529, 2002.
- [95] X. Glorot, A. Bordes i Y. Bengio, Deep sparse rectifier neural networks, *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, 315–323, JMLR Workshop and Conference Proceedings, 2011.
- [96] Y. Bengio, P. Lamblin, D. Popovici i H. Larochelle, Greedy layer-wise training of deep networks, *Advances in neural information processing systems*, 19, 2006.
- [97] G. E. Hinton, S. Osindero i Y.-W. Teh, A fast learning algorithm for deep belief nets, *Neural computation*, 18, 7, 1527–1554, 2006.
- [98] I. N. Da Silva, D. Hernane Spatti, R. Andrade Flauzino, L. H. B. Liboni, S. F. dos Reis Alves, I. N. da Silva, D. Hernane Spatti, R. Andrade Flauzino, L. H. B. Liboni i S. F. dos Reis Alves, *Artificial neural network architectures and training processes*, Springer, 2017.
- [99] R. S. Sutton, A. G. Barto et al., *Introduction to reinforcement learning*, 135, MIT press Cambridge, 1998.
- [100] G. E. Hinton i R. R. Salakhutdinov, Reducing the dimensionality of data with neural networks, *science*, 313, 5786, 504–507, 2006.
- [101] K. He, X. Zhang, S. Ren i J. Sun, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770–778, 2016.
- [102] Y. Bengio, P. Simard i P. Frasconi, Learning long-term dependencies with gradient descent is difficult, *IEEE transactions on neural networks*, 5, 2, 157–166, 1994.
- [103] X. Glorot i Y. Bengio, Understanding the difficulty of training deep feedforward neural networks, *Proceedings of the thirteenth international conference on artificial intelligence and statistics*, 249–256, JMLR Workshop and Conference Proceedings, 2010.
- [104] K. He i J. Sun, Convolutional neural networks at constrained time cost, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 5353–5360, 2015.
- [105] W. G. Baxt, Use of an artificial neural network for the diagnosis of myocardial infarction, *Annals of internal medicine*, 115, 11, 843–848, 1991.
- [106] E. K. AbuSharekh, S. S. Abu-Naser et al., Diagnosis of hepatitis virus using artificial neural network, 2018.
- [107] W. Yotsawat, P. Wattuya i A. Srivihok, A novel method for credit scoring based on cost-sensitive neural network ensemble, *IEEE Access*, 9, 78521–78537, 2021.

- [108] W. Dangskul, K. Phattaravatin, K. Rattanaporn i Y. Kidjaidure, Real-time control using convolution neural network for self-driving cars, *2021 7th International Conference on Engineering, Applied Sciences and Technology (ICEAST)*, 125–128, IEEE, 2021.
- [109] C. M. Bishop, Novelty detection and neural network validation, *IEE Proceedings-Vision, Image and Signal processing*, 141, 4, 217–222, 1994.
- [110] G. E. Peterson, Foundation for neural network verification and validation, *Science of Artificial Neural Networks II*, 1966, 196–207, SPIE, 1993.
- [111] Z. C. Lipton, J. Berkowitz i C. Elkan, A critical review of recurrent neural networks for sequence learning, *arXiv preprint arXiv:1506.00019*, 2015.
- [112] J. L. Elman, Finding structure in time, *Cognitive Science*, 14, 2, 179–211, ožujak 1990.
- [113] D. D. Micu, L. Czumbil, G. Christoforidis i A. Ceclan, Layer recurrent neural network solution for an electromagnetic interference problem, *IEEE transactions on magnetics*, 47, 5, 1410–1413, 2011.
- [114] M. I. Lourakis et al., A brief description of the levenberg-marquardt algorithm implemented by levmar, *Foundation of Research and Technology*, 4, 1, 1–6, 2005.
- [115] M. Hagan i M. Menhaj, Training feedforward networks with the marquardt algorithm, *IEEE Transactions on Neural Networks*, 5, 6, 989–993, 1994.
- [116] W. F. Wieczorek i A. M. Delmerico, Geographic information systems, *Wiley Interdisciplinary Reviews: Computational Statistics*, 1, 2, 167–186, 2009.
- [117] G. Grekousis, P. Manetos i Y. N. Photis, Modeling urban evolution using neural networks, fuzzy logic and gis: The case of the athens metropolitan area, *Cities*, 30, 193–203, veljača 2013.
- [118] J. C. Bezdek, R. Ehrlich i W. Full, Fcm: The fuzzy c-means clustering algorithm, *Computers & geosciences*, 10, 2-3, 191–203, 1984.
- [119] M. B. Kia, S. Pirasteh, B. Pradhan, A. R. Mahmud, W. N. A. Sulaiman i A. Moradi, An artificial neural network model for flood simulation using gis: Johor river basin, malaysia, *Environmental Earth Sciences*, 67, 1, 251–264, prosinac 2011.
- [120] C. Samarasinghe, *Landslide susceptibility prediction based on GIS and Artificial Neural Network*, doktorska disertacija, 2021.
- [121] M. D. Luca, A comparison between prediction power of artificial neural networks and multivariate analysis in road safety management, *TRANSPORT*, 32, 4, 379–385, siječanj 2015.
- [122] M. Sameen i B. Pradhan, Severity prediction of traffic accidents with recurrent neural networks, *Applied Sciences*, 7, 6, 476, lipanj 2017.
- [123] H. Bi, W.-L. Shang, Y. Chen, K. Wang, Q. Yu i Y. Sui, Gis aided sustainable urban road management with a unifying queueing and neural network model, *Applied Energy*, 291, 116818, lipanj 2021.

- [124] S. Shah, T. Brijs, N. Ahmad, A. Pirdavani, Y. Shen i M. Basheer, Road safety risk evaluation using gis-based data envelopment analysis—artificial neural networks approach, *Applied Sciences*, 7, 9, 886, kolovoz 2017.
- [125] S. Meng i H. Zheng, A personalized bikeability-based cycling route recommendation method with machine learning, *International Journal of Applied Earth Observation and Geoinformation*, 121, 103373, srpanj 2023.
- [126] About ArcGIS | Mapping & Analytics Software and Services — esri.com, <https://www.esri.com/en-us/arcgis/about-arcgis/overview>, pristupljeno 19.3.2024.
- [127] What is the ArcGIS 3D Analyst extension?&x2014;ArcMap | Documentation — desktop.arcgis.com, <https://desktop.arcgis.com/en/arcmap/latest/extensions/3d-analyst/what-is-the-3d-analyst-extension-.htm>, pristupljeno 19.3.2024.
- [128] What is the ArcGIS Spatial Analyst extension?&x2014;ArcMap | Documentation — desktop.arcgis.com, <https://desktop.arcgis.com/en/arcmap/latest/extensions/spatial-analyst/what-is-the-spatial-analyst-extension.htm>, pristupljeno 19.3.2024.
- [129] What is the ArcGIS Network Analyst extension?&x2014;ArcMap | Documentation — desktop.arcgis.com, <https://desktop.arcgis.com/en/arcmap/latest/extensions/network-analyst/what-is-network-analyst-.htm>, pristupljeno 19.3.2024.
- [130] What is ArcScan?&x2014;ArcMap | Documentation — desktop.arcgis.com, <https://desktop.arcgis.com/en/arcmap/latest/extensions/arcscan/what-is-arcscan-.htm>, pristupljeno 19.3.2024.
- [131] Topografska karta 1:25 000 (TK25) — dgu.gov.hr, <https://dgu.gov.hr/proizvodi-i-usluge/sluzbene-drzavne-karte-i-ostale-karte/topografska-karta-1-25-000-tk25/176>, pristupljeno 28.5.2024.
- [132] J. LEE, Comparison of existing methods for building triangular irregular network, models of terrain from grid digital elevation models, *International journal of geographical information systems*, 5, 3, 267–285, siječanj 1991.
- [133] V. J. D. Tsai, Delaunay triangulations in tin creation: an overview and a linear-time algorithm, *International journal of geographical information systems*, 7, 6, 501–524, studeni 1993.
- [134] S. Patro i K. K. Sahu, Normalization: A preprocessing stage, *arXiv preprint arXiv:1503.06462*, 2015.
- [135] V. Gajera, R. Gupta, P. K. Jana et al., An effective multi-objective task scheduling algorithm using min-max normalization in cloud computing, *2016 2nd International Conference on Applied and Theoretical Computing and Communication Technology (iCATccT)*, 812–816, IEEE, 2016.
- [136] R. Rampin i V. Rampin, Taguette: open-source qualitative data analysis, *Journal of Open Source Software*, 6, 68, 3522, 2021.

- [137] B. L. Golden i Q. Wang, *An Alternate Measure of Consistency*, 68–81, Springer Berlin Heidelberg, 1989.
- [138] H. Taherdoost, Decision making using the analytic hierarchy process (ahp); a step by step approach, *International Journal of Economics and Management Systems*, 2, 2017.
- [139] J. Song i S. Quan, The bus line supporting system based on learning neural network model applied in gis, *Advances in Computer Science Research*, iccsae-15, Atlantis Press, 2016.
- [140] Dalmatia-bike, <http://www.dalmatia-bike.com>, pristupljeno: 30.5.2019.
- [141] Dalmacija-Šibenik, <http://www.bikeandhike.hr>, pristupljeno: 14.4.2020.
- [142] C. Lv, Y. Xing, J. Zhang, X. Na, Y. Li, T. Liu, D. Cao i F.-Y. Wang, Levenberg–marquardt backpropagation training of multilayer neural networks for state estimation of a safety-critical cyber-physical system, *IEEE Transactions on Industrial Informatics*, 14, 8, 3436–3446, 2017.
- [143] A. H. Namin, K. Leboeuf, R. Muscedere, H. Wu i M. Ahmadi, Efficient hardware implementation of the hyperbolic tangent sigmoid function, *2009 IEEE International Symposium on Circuits and Systems*, 2117–2120, IEEE, 2009.
- [144] Running App and Cycling App | Strava — [strava.com](https://www.strava.com/mobile), <https://www.strava.com/mobile>, pristupljeno 2.3.2024.
- [145] D. Robb, Building the Global Heatmap — [medium.com](https://medium.com/strava-engineering/the-global-heatmap-now-6x-hotter-23fc01d301de), <https://medium.com/strava-engineering/the-global-heatmap-now-6x-hotter-23fc01d301de>, pristupljeno 6.3.2024.
- [146] M. AG, Tiles à la Google Maps: Coordinates, Tile Bounds and Projection | MapTiler — [maptiler.org](http://www.maptiler.org/google-maps-coordinates-tile-bounds-projection/), <http://www.maptiler.org/google-maps-coordinates-tile-bounds-projection/>, pristupljeno 6.3.2024.
- [147] K. T. G. (<https://www.klokantech.com/>), WGS 84 / Pseudo-Mercator - Spherical Mercator, Google Maps, OpenStreetMap, Bing, ArcGIS, ESRI - EPSG:3857 — [epsg.io](https://epsg.io/3857), <https://epsg.io/3857>, pristupljeno 23.3.2024.
- [148] Strava or it Didn't Happen: What Year-End Data Says About Cyclists in 2023 — [bicycling.com](https://www.bicycling.com/news/a46275444/strava-or-it-didnt-happen-what-year-end-data-says-about-cyclists-in-2023/), <https://www.bicycling.com/news/a46275444/strava-or-it-didnt-happen-what-year-end-data-says-about-cyclists-in-2023/>, pristupljeno 23.3.2024.
- [149] N. Ketkar i N. Ketkar, Introduction to keras, *Deep learning with python: a hands-on introduction*, 97–111, 2017.

KRATICE

\tilde{A}	Trokutasta neizrazita matrica
<i>AHP</i>	Analitički hijerarhijski proces
<i>ANN</i>	Umjetne neuronske mreže (engl. <i>Artificial Neural Networks</i>)
<i>BFS</i>	Algoritam pretraživanja po širini (engl. <i>Breadth First Algoritm</i>)
<i>BLOS</i>	Razina usluga za bicikliste (engl. <i>Bicycle Level of Service</i>)
<i>CDF</i>	Kumulativna distribucijska funkcija (engl. <i>Cumulative Distribution Function</i>)
<i>CI</i>	Indeks konzistentnosti
C_λ	Čista (oštra) vrijednost
<i>DBN</i>	<i>Deep Belief Network</i>
<i>DEA</i>	<i>Data Envelopment Analysis</i>
<i>DFS</i>	Algoritam pretraživanja po dubini (engl. <i>Depth First Algoritm</i>)
<i>E</i>	Veze između čvorova (engl. <i>Edges</i>)
<i>EIA</i>	Procjena utjecaja na okoliš (engl. <i>Environmental Impact Assessment</i>)
<i>FAHP</i>	Neizrazita AHP (engl. <i>Fuzzy AHP</i>)
<i>FFNN</i>	<i>Feed Forward</i> neuronska mreža
<i>GIS</i>	Geografski informacijski sustavi
<i>GPS</i>	Globalni sustav pozicioniranja (engl. <i>Global Positioning System</i>)
<i>I</i>	Jedinična matrica

J	Jacobianova matrica
$LRNN$	<i>Layer Recurrent</i> neuronska mreža
$MCDA$	Analiza odlučivanja na temelju više kriterija (engl. <i>Multi-Criteria Decision Analysis</i>)
MCA	Višekriterijska analiza (engl. <i>Multi-Criteria Analysis</i>)
MSE	Srednja kvadratna pogreška (engl. <i>Mean Square Error</i>)
MLP	Višeslojni perceptron (engl. <i>Multilayer Perceptron</i>)
NN	Neuronske mreže (engl. <i>Neural Networks</i>)
P	Matrica performansi
R_i	Vrijednost i-tog kriterija
R_{min}	Minimalna vrijednost kriterija iz skupa
R_{max}	Maksimalna vrijednost kriterija iz skupa
RNN	<i>Recurrent</i> neuronske mreže
$RMSE$	Korijen srednje kvadratne pogreške (engl. <i>Root Mean Square Error</i>)
S	Mjera prikladnosti lokacije
SVM	Support Vector Machine
SVR	Support Vector Regression
TIN	Mreža neregularnih trokuta (engl. <i>Triangulated Irregular Network</i>)
V	Čvorovi (engl. <i>Vertices</i>)
VC	Vapnik-Chervonekis
w_i	Težina i-tog kriterija
WLC	Ponderirana linearna kombinacija (engl. <i>Weighted Linear Combination</i>)
Γ	Funkcija mapiranja
ϑ_i	Koeficijent praga neurona
λ_{max}	Najveća svojstvena vrijednost matrice
$\mu_a(x)$	Trokutasti neizraziti broj

ξ_i	Potencijal neurona
ω_{ij}	Težinski koeficijent veze neurona

Životopis

Jurica Đerek je rođen 3. srpnja 1993. u Splitu. Nakon završetka prirodoslovno-matematičke gimnazije dr. Mate Ujevića u Imotskom 2012. godine upisuje preddiplomski studij Elektrotehnike i informacijske tehnologije na Fakultetu elektrotehnike, strojarstva i brodogradnje u Splitu kojeg završava 2015. godine. Iste godine upisuje diplomski studij Elektronike i računalnog inženjerstva kojeg završava 2017. godine čime dobiva zvanje magistar inženjer elektronike i računalnog inženjerstva, Nakon završenog studija se zapošljava u kompaniji Ericsson Nikola Tesla d.d. gdje u Splitu i Zagrebu sudjeluje kao programer u razvoju softvera za radiokomunikaciju. Godine 2018. se zapošljava na Fakultetu elektrotehnike, strojarstva i brodogradnje, na Zavodu za elektroniku i računarstvo, Katedri za multimediju, obradu informacija i programiranje kao asistent. Iste godine upisuje i doktorski studij Elektrotehnike i informacijske tehnologije. Njegov istraživački interes je u polju programskih jezika, GIS-a i elektroakustike.

Autor je dva članka u znanstvenim časopisima (oba indeksirani u WoS-u) i pet članaka na znanstvenim skupovima. Živi u Imotskom, oženjen, otac jednog djeteta.

Curriculum Vitae

Jurica Đerek was born on July 3, 1993, in Split. After completing his secondary education at the Dr. Mate Ujević Natural Sciences and Mathematics High School in Imotski in 2012, he enrolled in the undergraduate program of Electrical Engineering and Information Technology at the Faculty of Electrical Engineering, Mechanical Engineering, and Naval Architecture in Split, which he completed in 2015. That same year, he started his graduate studies in Electronics and Computer Engineering, which he finished in 2017, earning the title of Master of Engineering in Electronics and Computer Engineering. After completing his studies, he was employed by Ericsson Nikola Tesla Inc., where he participated as a programmer in the development of software for radiocommunication in Split and Zagreb. In 2018, he took a position at the Faculty of Electrical Engineering, Mechanical Engineering, and Naval Architecture, in the Department of Electronics and Computing, Chair of Multimedia, Information Processing, and Programming as an assistant. That same year, he began his doctoral studies in Electrical Engineering and Information Technology. His research interest lies in the field of programming languages, GIS, and electroacoustics.

He is the author of two articles in scientific journals (both indexed in WoS) and five papers at scientific conferences. He lives in Imotski, is married, and is a father of one child.