Model izbora multimodalnoga putovanja temeljen na otkrivanju putničkih preferencija

Mandžuka, Bia

Doctoral thesis / Disertacija

2022

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Transport and Traffic Sciences / Sveučilište u Zagrebu, Fakultet prometnih znanosti**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:427405

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-04-24**

Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository

Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

Bia Mandžuka

MODEL IZBORA MULTIMODALNOGA PUTOVANJA TEMELJEN NA OTKRIVANJU PUTNIČKIH PREFERENCIJA

DOKTORSKI RAD

Zagreb, 2022.

Sveučilište u Zagrebu

FAKULTET PROMETNIH ZNANOSTI

Bia Mandžuka

MODEL IZBORA MULTIMODALNOGA PUTOVANJA TEMELJEN NA OTKRIVANJU PUTNIČKIH PREFERENCIJA

DOKTORSKI RAD

Mentori:
prof. dr. sc. Marinko Jurčević
doc. dr. sc. Krešimir Vidović

Zagreb, 2022.

University of Zagreb

FACULTY OF TRAFFIC AND TRANSPORT SCIENCES

Bia Mandžuka

MULTIMODAL TRAVEL CHOICE MODEL BASED ON DISCOVERING TRAVELLERS' PREFERENCES

DOCTORAL DISSERTATION

Supervisors:
Prof. Marinko Jurčević, Ph. D.
Asst. Prof. Krešimir Vidović, Ph. D.

Zagreb, 2022.

PODACI I INFORMACIJE O DOKTORANDU

1. Ime i prezime: **Bia Mandžuka, mag. ing. traff.**
2. Datum i mjesto rođenja: **16. lipnja 1989., Zagreb**
3. Naziv završenog fakulteta i godina diplomiranja: **Fakultet prometnih znanosti Sveučilišta u Zagrebu, 2013.**

INFORMACIJE O DOKTORSKOME RADU

1. Naziv doktorskoga studija: **Tehnološki sustavi u prometu i transportu**
2. Naslov doktorskoga rada: **Model izbora multimodalnoga putovanja temeljen na otkrivanju putničkih preferencija**
3. Fakultet na kojemu je doktorski rad branjen: **Fakultet prometnih znanosti Sveučilišta u Zagrebu**

POVJERENSTVA, OCJENA I OBRANA DOKTORSKOGA RADA

1. Datum prijave teme doktorskoga rada: 19.04.2021.
2. Prvi mentor: prof. dr. sc. Marinko Jurčević
3. Drugi mentor: doc. dr. sc. Krešimir Vidović
4. Povjerenstvo za ocjenu i obranu doktorskoga rada:
    1. izv. prof. dr. sc. Marko Ševrović, predsjednik
    2. prof. dr. sc. Marinko Jurčević, mentor, član
    3. doc. dr. sc. Krešimir Vidović, mentor, član
    4. prof. dr. sc. Zvonko Kavran, član
    5. prof. dr. sc. Goran Kos, vanjski član (Institut za turizam)
5. Datum obrane doktorskoga rada: 11.10.2022.
6. Lektor: Silvija Jurić, prof. hrvatskog jezika i književnosti

Informacije o mentorima

Životopis: **prof. dr. sc. Marinko Jurčević**

Marinko Jurčević rođen je 20. srpnja 1966. godine u Žepču, u Bosni i Hercegovini. Osnovnu školu završio je u Žepču, a srednju školu u Zenici. Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu diplomirao je 1995. godine. Na Ekonomskom fakultetu Sveučilišta u Zagrebu 1997. magistrirao je na dva poslijediplomska studija, specijalističkom, Upravljanje industrijskim i institucionalnim marketingom, i znanstvenom, Teorija i politika marketinga. Na istom je fakultetu i doktorirao 2000. godine. Ujedno je i apsolvent na poslijediplomskom studiju Filozofskog fakulteta Družbe Isusove gdje proučava komunikacijsko-medijske aspekte duhovnosti te marketing duhovnosti.

Radno je iskustvo stjecao obavljajući različite poslove: od rada u gospodarstvu (radeći kao rukovoditelj predstavništva te baveći se obradom tržišta) do rada u državnim tijelima uprave (Ministarstvo vanjskih poslova RH, Ministarstvo pomorstva, prometa i veza RH). Jedanaest godina radio je na HRT-u u Odjelu Marketinga HR-a, kao propagandist – realizator, baveći se medijskim oglašavanjem, organizacijom i provođenjem različitih medijskih kampanja. Stalni je sudski vještak za promet, tehniku i procjenu motornih vozila. Imenovan je prvim stalnim sudskim vještakom u Republici Hrvatskoj za marketing i medije. Od 2000. godine surađuje i izvodi nastavu na više visokoškolskih ustanova. Kao stručni suradnik/konzultant/edukator surađuje s više domaćih i međunarodnih poduzeća/organizacija iz profitnog i neprofitnog sektora. Kao vanjski savjetnik za politički marketing u PR agenciji bavio se profiliranjem nositelja kampanja te je radio kao savjetnik za strateški marketing kampanje. Član je i predsjednik više nadzornih i upravnih odbora različitih tvrtki i asocijacija. Od 2007. godine stalno je zaposlen na Fakultetu prometnih znanosti Sveučilišta u Zagrebu kao redoviti profesor u trajnom zvanju, gdje je voditelj Katedre za pravo i ekonomiku te nositelj i izvođač nastave na više kolegija preddiplomskog, diplomskog, postdiplomskog i doktorskog studija.

Objavio je značajan broj znanstvenih radova u zemlji i inozemstvu koji su objavljeni u međunarodnim referentnim časopisima ili su pak prezentirani na međunarodnim znanstvenim kongresima i savjetovanjima. Član je Znanstvenog vijeća za promet Hrvatske akademije znanosti i umjetnosti, Hrvatske komore prometnih inženjera, Družbe „Braća Hrvatskoga Zmaja“ te različitih strukovnih asocijacija.

Popis radova u području disertacije (CROSBI)

1. Mandžuka, B., Jurčević, M., Vidović, K., Vujić, M. Multimodal journey route selection as decision-making process. In: Lecture Notes in Networks and Systems. Cham: Springer International Publishing; 2022. p. 712–8.

2. Jurčević, M., Lulić, L., Mostarac, V. The digital transformation of Croatian economy compared with EU member states. Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues. 2020.;33(1):151-164.

3. Zavišić, Ž., Jurčević, M., Šipić, N. The impact of packaging design on functional fruit juice consumers' behaviour. Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues. 2019.;31(1):179-193.

4. Perkov, D., Jurčević, M. Features of impulse buying in Croatian retail. Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues. 2018.;31(2):349-360.

5. Jurčević, M., Bubalo, T., Mandžuka, B. Influence of costs on the optimization of transport routes. Ekonomski vjesnik: Review of Contemporary Entrepreneurship, Business, and Economic Issues. 2018.;31(1):65-73.

6. Mandžuka, B., Jurčević, M. The use of the extent of integrated marketing communications in the affirmation of ITS services. New solutions and innovations in logistics and transportation. Zagreb: Faculty of Transport and Traffic Sciences; 2017. p. 189-196.

Životopis: **doc. dr. sc. Krešimir Vidović**

Doc. dr. sc. Krešimir Vidović rođen je 7. listopada 1980. godine u Pakracu. Osnovnu i srednju školu (X. gimnazija – opći smjer) završio je u Zagrebu. Na Fakultetu prometnih znanosti Sveučilišta u Zagrebu završio je smjer Pošta i telekomunikacije te je diplomirao s izvrsnim uspjehom 2006. godine stekavši naziv diplomirani inženjer prometa. Na istom je fakultetu 2018. godine obranio doktorsku disertaciju Model procjene urbane mobilnosti zasnovan na zapisima o aktivnostima korisnika u javnim pokretnim komunikacijskim mrežama.

Dobitnik je Rektorove nagrade za rad „Model višekriterijskog odlučivanja pri izboru operatora mobilne telefonije u Republici Hrvatskoj". Od 2003. do 2006. godine bio je glavni urednik studentskog časopisa Fakulteta prometnih znanosti „PROM" te voditelj studentske međunarodne suradnje. Krajem studija započinje suradnički odnos na Institutu prometa i veza u Zagrebu gdje se zapošljava 2007. godine i radi do 2010. godine. Na poziciji stručnog suradnika radi na znanstveno-istraživačkim poslovima u prometu, bavi se prometnim planiranjem u studijama i projektima, radi na razvoju specijaliziranih računalnih aplikacija i primjeni u prometnom inženjerstvu.

Od 2010. godine zaposlen je kao domenski ekspert za područje inteligentnih transportnih sustava u kompaniji Ericsson Nikola Tesla. Zadužen je za projektiranje rješenja u domeni inteligentnih transportnih sustava, vodio je projekte financirane sredstvima EU-a u domeni transporta. Na razini grupacije Ericsson dio je globalnog ekspertnog tima za inteligentne transportne sustave. U suradnji s akademskim institucijama sudjeluje kao mentor u projektima Ljetnih kampova Ericsson Nikola Tesla. Kao gost predavač, vanjski suradnik, asistent, predavač sudjelovao je na više kolegija na Fakultetu prometnih znanosti (Inteligentni transportni sustavi II, Operacijska istraživanja, Rudarenje podataka, Telematika u prometu). Nastupno predavanje za naslovno nastavno zvanje predavača održao je 7. prosinca 2018. godine iz kolegija Računalna sigurnost na temu „Sigurnosne aplikacije u inteligentnim transportnim sustavima". U naslovno nastavno zvanje predavača iz područja tehničkih znanosti, polje Tehnologija prometa i transport izabran je 29. siječnja 2019. godine na period od pet godina. U zvanje znanstvenog suradnika u znanstvenom polju tehnologija prometa i transport izabran je 2020. godine, a u znanstveno-nastavno znanje docenta 2021. godine te zasniva radni odnos na Fakultetu prometnih znanosti.

Njegovo su uže područje interesa inteligentni transportni sustavi, primjena znanosti o podacima i primjena suvremenih komunikacijskih tehnologija u prometu i transportu. Objavio

je niz znanstvenih radova i aktivno sudjeluje u izradi stručnih projekata i programima popularizacije znanosti.

Popis radova u području disertacije (CROSBI)

1. Mandžuka, B., Jurčević, M., Vidović, K., Vujić, M. Multimodal journey route selection as decision-making process. In: Lecture Notes in Networks and Systems. Cham: Springer International Publishing; 2022. p. 712–8.

2. Mandžuka, B., Vidović, K., Vujić, M. The Importance of Open Data Accessibility For Multimodal Travel Improvement*. Interdisciplinary Description of Complex Systems [Internet]. 2022.

3. Vidović, K., Mandžuka, S., Šoštarić, M. National Access Point for Provision of EU-wide Multimodal Travel Information Services. In: Proceedings of 42nd International convention MIPRO 2019. Opatija; 2019.

4. Mandžuka, S., Vidović, K., Šoštarić, M. National Access Point for provision of Multimodal travel data. 28th Telecommunications Forum TELFOR 2020 [Internet]. Belgrade: IEEE; 2020. p. 4.

5. Vidović, K., Mandžuka, S., Šoštarić, M. Data Quality within National Access Point for Provision of Multimodal Travel Information within European Union. In: 61st International Symposium ELMAR [Internet]. Zadar, Croatia: Faculty of Electrical Engineering and Computing, Zagreb; 2019.

6. Vidović, K., Mandžuka, S., Šoštarić, M. Expert System for Urban Multimodal Mobility Estimation Based on Information from Public Mobile Network. In: Computational Science and Its Applications – ICCSA 2019 19th International Conference Saint Petersburg, Russia, July 1–4, 2019 Proceedings, Part II [Internet]. Saint Petersburg, Russia: Springer; 2019. p. 3–11.

7. Vidović, K., Šoštarić, M., Mandžuka, S., Kos, G. Model for Estimating Urban Mobility Based on the Records of User Activities in Public Mobile Networks. Sustainability [Internet]. 2020;12(3):838.

ZAHVALA

Zahvaljujem mentorima, profesoru dr. sc. Marinku Jurčeviću i docentu dr. sc. Krešimiru Vidoviću, koji su me pratili i savjetovali kroz cijeli postupak istraživanja i izrade doktorske disertacije te svojim znanjem, iskustvom, savjetima i idejama doprinijeli kvaliteti doktorske disertacije. Također bih htjela zahvaliti Povjerenstvu za ocjenu i obranu, predsjedniku izv. prof. dr. sc. Marku Ševroviću, prof. dr. sc. Zvonku Kavranu i vanjskom članu povjerenstva, prof. dr. sc. Goranu Kosu na konstruktivnim savjetima, te mentoru kroz studij, prof. dr. sc. Davoru Brčiću.

Dio istraživanja provedeno je za šire (urbano) područje Beča te ovom prilikom posebno zahvaljujem kolegama s Tehničkog sveučilišta u Beču (Technische Universität Wien - The Research Center of Transport Planning and Traffic Engineering).

Hvala i svima ostalima koji su mi bili podrška u ovom izazovnom, ali plodonosnom razdoblju.

SAŽETAK

Predmet znanstvenog istraživanja u okviru ovoga doktorskog rada jest definiranje metodologije otkrivanja putničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja putnika te razvoj modela za izbor multimodalnoga putovanja zasnovanog na putničkim preferencijama.

Cilj istraživanja bio je razviti model za izbor multimodalnoga putovanja zasnovan na putničkim preferencijama otkrivenim analizom prethodnih izbora te predložiti metodologiju otkrivanja putničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja putnika. Na osnovi provedene analize pojedinih metoda višekriterijske optimizacije (analiza prednosti i nedostataka) te provedenog testiranja na realnim primjerima, ustanovljeno je da je najprihvatljiviji model izbora multimodalnoga putovanja zasnovan na metodi težinskog zbroja (engl. *Weighted Sum Method* – WSM), koji uključuje i njezinu *fuzzy* inačicu. Ta metoda omogućuje dobro strukturiranje problema koji se razmatra; eksplicitno opisuje alternative, kriterije i njihove relativne rezultate i težine. Posebno je važno istaknuti da nije zahtjevna za donositelja odluke (putnik) te se jednostavno implementira. Osim toga, predložena je inovativna transformacija matematičkog modela metode težinskog umnoška (engl. *Weighted Product Method* – WPM) u model po strukturi veoma sličan WSM-u pa se i u tom slučaju mogu primjenjivati svi postupci kao i za WSM, a prije svega predložena metoda otkrivanja putničkih preferencija. Prednost primjene transformiranog WPM-a u odnosu na WSM jest u tome što nema potreba za prethodnom normalizacijom ulaznih podataka matrice alternativa.

U drugom dijelu istraživanja definirana je metodologija otkrivanja putničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja korisnika. Zasnovana je na dosadašnjem iskustvu iz sličnih istraživanja gdje vrijednosti kriterija odlučivanja, koje su otkrivene nakon završenih aktivnosti (putovanja), najtočnije opisuju putničke preferencije. Osim toga, utvrđeno je da je najbolje identificirati preferencije za svakog korisnika individualno, za razliku od pojedinih pristupa koji se temelje na preferencijama odgovarajuće populacije kojoj (po nekom principu) pripada korisnik. U ovom istraživanju predložen je pristup zasnovan na identifikaciji vrijednosti odgovarajućih kriterija za preferencije korištenjem postupka zasnovanog na tzv. inverznom modelu procesa odlučivanja. Matematički model inverznog procesa odlučivanja definiran je kao optimizacijska zadaća određivanja vektora težina kriterija preko minimizacije p-te norme

greške aproksimacije modela procesa odlučivanja. U slučaju izbora kvadratne norme, zadaća se svodi na klasičnu metodu najmanjih kvadrata greške u matričnom obliku. Kroz provedena testiranja i validaciju utvrđeni su veoma dobri rezultati provedenog postupka otkrivanja preferencija korisnika za multimodalna putovanja.

Ključne riječi: multimodalna putovanja, otkrivanje putničkih preferencija, višekriterijsko odlučivanje, metoda najmanjih kvadrata

EXTENDED SUMMARY

With economic globalization and continuous technological advances, human lives are changing dramatically. The lifestyle changes are particularly reflected in the population's different needs, demands, and new habits. The need for mobility is one of the requirements in this context, which poses a challenging and complex task for transport experts, urban planners, and other professionals. Sustainable mobility is one of the prerequisites for an efficient economy and society. Establishing sustainable mobility is complex because it requires rethinking at the individual level, i.e., at the level of the user - the passenger. The transition from individual transport to sustainable modes remains a complex behavioural process at the individual level and a challenge for society as a whole. Since passengers need to get from one place to another smoothly, quickly, and easily, it is necessary to provide a solution that can compete with the (still predominant) personal vehicle.

One of the potential opportunities for efficient and attractive public transport hides behind the concept of multimodal travel. The idea of multimodal travel is to connect the origin and the destination in a given time frame by combining available means of transport to reduce personal vehicle use. In this sense, multimodal trip planning is becoming more important and complex with the emergence of new mobility services (e.g., Mobility-as-a-Service - MaaS) and increasingly sophisticated passenger needs. The EU transport policy highlights the concept of door-to-door multimodal transport as one of the priority measures for alleviating traffic problems. The European Commission has developed a series of legislative and policy initiatives for better, adequate infrastructure and digital solutions to promote an integrated, multimodal, and sustainable transport system.

Available travel information can influence travellers' decisions to reach their destination as best as they can. Travellers need advanced information systems (tailored to them) that can

provide real-time information about the combined modes before and during the trip. Ad hoc trips (single, one-time trips) are also of great interest to researchers studying traveller mobility. Ad hoc trips are specific purpose trips where the traveller does not know the trip characteristics (such as possible routes, available modes and their combination, travel time, number of transfers, and waiting time when transferring) in advance.

Multimodal Journey Planners (MJPs) are a part of Intelligent Transport Systems (ITS) that provide a range of passenger transport services. The basic task of the system is to answer the user's question: "How do I get from place A to place B at a particular departure or arrival time, and under what conditions?" There are several active multimodal journey planner systems in the EU with different functionalities. Most of them include the basic functionalities (criteria for selecting a multimodal route). There is an obvious need for a user-friendly travel information platform. The modern user expects much more than just a route planning app, e.g., selecting a more environmentally friendly route, displaying the weather and road conditions during the journey, and specific personalized settings.

The existing MJPs are typically based on a solution that applies the shortest route and travel time criteria. The proposed travel scenarios (using only these two criteria) have proven inadequate. In recent years, special attention has been paid to understanding passenger behaviour, i.e., individual travel patterns, perceptions, and propensities toward multimodal mobility. Traveller behaviour should be perceived as a complex behaviour that involves individuals' perceptions, attitudes, opinions, feelings, beliefs, and intentions. It can be understood as a decision-making process based on accumulated experience and behaviour patterns developed during previous travels. Traveller behaviour can be represented by a "genome model," i.e., a complete set of all biological, motivational, cognitive, and situational information that drives the individual traveller's behaviour. Variability is another feature of passenger behaviour, especially in a dynamic urban environment. The complexity of building such models that enable personalized travel decisions is due to the diversity of traveller preferences.

This research aimed to develop an effective model for multimodal travel selection based on multicriteria decision methods. The analysis of the individual methods of multicriteria optimization (the analysis of advantages and disadvantages) and testing on real examples revealed that the model based on the Weighted Sum Method (WSM), including its fuzzy version, is most appropriate for multimodal travel choice. This method provides a good structuring of the observed problem by explicitly describing the alternatives, criteria, relative results, and weights. It is noteworthy that it does not impose any requirements on the decision

maker (passenger) and is easy to implement. Moreover, an innovative transformation of the Weighted Product Method (WPM) mathematical model into one very similar in structure to the WSM is proposed enabling the same application of procedures and a similar identification of passenger preferences as in the WSM. The advantage of the transformed WPM over the WSM is that the input data of the alternatives matrix do not need to be pre-normalized.

The second part of the research defines the methodology for identifying passengers' multimodal travel preferences based on the recorded selection of individual multimodal trips. Based on previous experience from similar research, the values of the decision criteria obtained after the completion of the activities (trips) most accurately describe travellers' preferences. In addition, it was found that it is best to identify the preferences of each user individually, as opposed to certain approaches based on the preferences of the user's population group (according to particular criteria). This study adopted an approach based on identifying the values of the criteria relating to particular preferences using a procedure based on the so-called inverse model of the decision-making process. The mathematical model of the inverse decision process is defined as the optimization task of determining the vector of criteria weights by minimizing the p-th norm of the approximation error of the decision model. When a quadratic norm is chosen, the problem reduces to the classical least squares error method in matrix form. The conducted tests and validation have returned very good results for the selected method of identifying passengers' multimodal travel preferences.

Keywords: multimodal travel, travellers' preferences discovering, multicriteria decision-making, least-square methods

Sadržaj

1. UVOD 1
1.1. Predmet istraživanja 1
1.2. Cilj, hipoteze i znanstveni doprinosi istraživanja 1
1.3. Pregled dosadašnjih istraživanja 2
1.4. Struktura disertacije 2
2. KONCEPT MULTIMODALNOGA PUTOVANJA 4
2.1. Održiva mobilnost 9
2.2. Pametna mobilnost 13
2.2.1. Mobilnost kao usluga 15
2.3. Multimodalna putovanja 19
2.3.1. Teorijski koncept 19
2.3.2. Segmenti multimodalnoga putovanja 20
3. PLANIRANJE MULTIMODALNOGA PUTOVANJA 23
3.1. Pregled relevantnih projekata u području multimodalnoga planiranja putovanja 23
3.2. Pregled i analiza multimodalnih putnih planera 26
3.2.1. Teoretski koncept multimodalnih putnih planera 26
3.2.2. Pregled i analiza multimodalnih putnih planera 29
3.3. Uloga i značaj otvorenih podataka kod multimodalnih putnih planera 37
3.4. Putničko ponašanje pri planiranju putovanja 40
3.5. Utjecaj naprednih sustava informiranja putnika na putnička ponašanja 41
4. IZBOR MULTIMODALNOGA PUTOVANJA KAO PROCES VIŠEKRITERIJSKOGA ODLUČIVANJA 43
4.1. Klasifikacija teorija odlučivanja 44
4.2. Značajke odlučivanja s obzirom na donositelja odluke 46
4.2.1. Odlučivanje eksperta 46
4.2.2. Odlučivanja neeksperta 49
4.3. Višekriterijsko odlučivanje 51
4.4. Pregled i analiza metoda višekriterijskoga odlučivanja 53
4.4.1. Metoda težinskoga zbroja (engl. *Weighted Sum Method* – WSM) 54
4.4.2. Metoda težinskoga umnoška (engl. *Weighted Product Method* – WPM) 55
4.4.3. Analitički hijerarhijski proces (engl. *Analytic Hierarchy Process* – AHP) 56

4.4.4. Tehnika za poredak preferencija po sličnosti s idealnim rješenjem 58
(engl. *Technique for Order Preference by Similarity to Ideal Solution* – TOPSIS) 58
4.4.5. ELECTRE (fr. *Elimination Et Choix Traduisant la Realité*, engl. *Elimination and Choice Expressing Reality*) 59
4.4.6. Ostale metode 59
4.5. Izbor užeg skupa prikladnih metoda višekriterijskoga odlučivanja za model izbora multimodalnoga putovanja 60
4.6. Kriteriji i preferencije putnika 61
5. METODE OTKRIVANJA PUTNIČKIH PREFERENCIJA 63
5.1. Otkrivanje korisničkih preferencija 63
5.1.1. Suradničko filtriranje 65
5.1.2. Sustavi temeljeni na znanju 66
5.1.3. Otkrivanje preferencija temeljeno na optimizacijama 67
5.2. Prijedlog modela otkrivanja putničkih preferencija 68
5.2.1. Inverzni model procesa odlučivanja 68
5.2.2. Primjeri 71
5.2.3. Proširenje modela otkrivanja 75
6. MODEL IZBORA MULTIMODALNOGA PUTOVANJA 76
6.1. Metoda težinskoga zbroja 77
6.2. Metoda težinskoga umnoška 78
6.3. Analitički hijerarhijski proces 80
6.4. *Fuzzy* model izbora multimodalnoga putovanja 81
6.4.1. *Fuzzy* WSM 82
6.4.2. *Fuzzy* AHP 84
6.5. Normalizacija 88
6.6. Zaključak 90
7. TESTIRANJE MODELA I VALIDACIJA 92
7.1. Metodologija rada 92
7.2. Rezultati testiranja modela 95
7.3. Validacija modela 97
7.4. Zaključak validacije 103
8. ZAKLJUČNA RAZMATRANJA 104
LITERATURA 106
POPIS SLIKA 117

POPIS TABLICA.....118
POPIS GRAFIKONA.....119
DODACI.....120
Dodatak 1 – Obrazac istraživanja preferencija putnika (Zagreb).....120
Dodatak 2 – Istraživanje preferencija putnika (Zagreb) – ulazni podaci.....124
Dodatak 3 – Istraživanje preferencija putnika (Zagreb) – omjer konzistentnosti.....125
Dodatak 4 – Istraživanje preferencija putnika (Zagreb) – rezultati odlučivanja.....126
Dodatak 5 – Obrazac istraživanja preferencija putnika (Beč).....127
Dodatak 6 – Istraživanje preferencija putnika (Beč) – ulazni podaci.....137
Dodatak 7 – Istraživanje preferencija putnika (Beč) – otkrivanje preferencija.....138
Dodatak 8 – Istraživanje preferencija putnika (Beč) – izračun vrijednosti alt.....140
Dodatak 9 – Istraživanje preferencija putnika (Beč) – rezultati testiranja.....145
Dodatak 10 – Istraživanje preferencija putnika (Beč) – validacija rezultata.....146

1. UVOD

1.1. Predmet istraživanja

Predmet znanstvenog istraživanja u okviru ovoga doktorskog rada jest definiranje metodologije otkrivanja putničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja putnika te razvoj modela za izbor multimodalnoga putovanja zasnovanog na putničkim preferencijama.

1.2. Cilj, hipoteze i znanstveni doprinosi istraživanja

Cilj istraživanja ove disertacije jest:

Razviti model za izbor multimodalnoga putovanja zasnovan na putničkim preferencijama otkrivenim analizom prethodnih izbora te predložiti metodologiju otkrivanja putničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja putnika.

Sukladno postavljenom cilju, znanstvene su hipoteze ove disertacije:

A. Na temelju zabilježenih izbora pojedinih multimodalnih putovanja korisnika moguće je izvesti zaključke o putničkim preferencijama tijekom odlučivanja.
B. Korištenjem postupka višekriterijskoga odlučivanja moguće je izraditi model izbora multimodalnoga putovanja zasnovan na putničkim preferencijama otkrivenim analizom prethodnih izbora.

Na temelju postavljenog cilja i hipoteza ostvareni su znanstveni doprinosi:

1. Definiranje metodologije otkrivanja korisničkih (putničkih) preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja korisnika.

2. Razvoj novog modela za izbor multimodalnoga putovanja zasnovanog na preferencijama korisnika (putnika) otkrivenih analizom prethodnih izbora.

1.3. Pregled dosadašnjih istraživanja

Detaljan pregled dosadašnjih istraživanja prikazan je u drugom, trećem, četvrtom i petom poglavlju ove disertacije. U drugom poglavlju objašnjeni su osnovni koncepti, pojmovi i suvremeni trendovi u području održive mobilnosti s posebnim naglaskom na organizaciju multimodalnih putovanja. Opisane su temeljne značajke koncepta *Mobilnost kao usluga* (engl. *Mobility-as-a-Service* – MaaS) kao integriranoga i inkluzivnoga koncepta mobilnosti. Objašnjen je teorijski koncept multimodalnih putovanja, kako u gradovima tako i u regionalnom i prekograničnom okviru.

U trećem poglavlju prikazan je problem planiranja multimodalnoga putovanja, gdje je istražena i analizirana relevantna znanstvena literatura u području multimodalnoga putnog planiranja, aktualni znanstveni i istraživačko-razvojni projekti te postojeći sustavi planiranja multimodalnih putovanja. Posebno su prikazani rezultati dosadašnjih istraživanja u području putničkog ponašanja pri planiranju multimodalnoga putovanja.

Za potrebe sagledavanja mogućnosti razvoja modela potpore planiranju zasnovanom na višekriterijskom odlučivanju, u četvrtom poglavlju analizirane su postojeće napredne metode višekriterijskoga odlučivanja prikladne za problem planiranja multimodalnoga putovanja.

U petom poglavlju objašnjena su teorijska počela ekonomskog koncepta otkrivanja preferencija kroz istoimenu teoriju (engl. *Revealed Preference Theory*) te su opisane metode otkrivanja koje su u dosadašnjoj upotrebi.

1.4. Struktura disertacije

U drugom poglavlju objašnjeni su koncepti multimodalnoga putovanja. Objašnjen je koncept urbanog ekosustava, kao i paradigma *Pametni grad*. Osim toga, ukazano je na značaj suvremenih koncepata urbane mobilnosti, osobito na značaj koncepta *Mobilnost kao usluga*.

Treće poglavlje opisuje temeljne značajke planiranja multimodalnoga putovanja iz perspektive krajnjeg korisnika – putnika. Dan je pregled relevantnih projekata u području multimodalnoga planiranja putovanja te pregled postojećih multimodalnih putnih planera s njihovim temeljnim značajkama. Opisane su značajke putničkog ponašanja pri planiranju

multimodalnoga putovanja. Osim toga, ukazano je na ulogu i značaj otvorenih podataka pri implementaciji multimodalnih putnih planera.

U četvrtom poglavlju razmatran je model izbora multimodalnoga putovanja kao proces višekriterijskoga odlučivanja. Dane su temeljne značajke teorije odlučivanja kroz opći model višekriterijskoga odlučivanja. Analizirane su pojedine metode višekriterijskoga odlučivanja te je odabran uži skup metoda koje su najprikladnije za primjenu pri izboru multimodalnoga putovanja. Sukladno tome, dan je opis odabranih metoda.

Peto je poglavlje posvećeno metodama otkrivanja putničkih preferencija. U prvom je dijelu opisano područje istraživanja krozprimjene u mikroekonomiji (e-trgovina, internetsko oglašavanje i prodaja). Istaknuta je postojeća spoznaja kako preferencije, koje su otkrivene nakon završenih (potrošačkih) aktivnosti, najtočnije opisuju potrošačko ponašanje, a shodno tome i pripadajuće preferencije. U drugom dijelu ovog poglavlja dan je i prijedlog novog modela otkrivanja putničkih preferencija za multimodalna putovanja zasnovan na inverznom modelu odlučivanja.

Modeli izbora multimodalnoga putovanja zasnovani na putničkim preferencijama objašnjeni su u šestom poglavlju. Na temelju nekoliko primjera ukazano je na mogućnosti primjene navedenih modela. Posebno je značajan doprinos ostvaren kroz novi izvod modela ponderiranog proizvoda, koji je posebno prikladan za optimizacijske metode otkrivanja putničkih preferencija. Na kraju je opisan i model izbora zasnovan na *fuzzy* teoriji, koji uspješno modelira nepreciznosti u iskazu krajnjih korisnika – putnika.

U sedmom poglavlju proveden je postupak testiranja i validacije. Za to je odabran slučaj korištenja pri izboru multimodalnoga putovanja na širem području Beča. Razlog je bio bogato razvijen multimodalni prijevozni sustav u Republici Austriji. Nakon odabira primjerenih scenarija multimodalnih putovanja, definiran je odgovarajući *online* obrazac (upitnik), koji je distribuiran krajnjim korisnicima. Za potrebe testiranja i validacije prikazana je odgovarajuća metodologija. Provedena validacija utvrdila je značajne prednosti korištenja predloženog modela izbora multimodalne rute putovanja, uzimajući u obzir i predloženu metodu otkrivanja korisničkih preferencija.

Osmo poglavlje u kontekstu dokazanih hipoteza te ostvarenog cilja i znanstvenog doprinosa, iznosi zaključna razmatranja i spoznaje nastale tijekom provedenog istraživanja. Završno su navedene smjernice za potencijalna buduća istraživanja i nadogradnje modela.

2. KONCEPT MULTIMODALNOGA PUTOVANJA

Procesom ekonomske globalizacije, urbanizacije te kontinuiranim napretkom tehnologije način života ljudi izrazito se mijenja. Projekcije pokazuju da će do 2050. godine 68 % svjetske populacije živjeti u urbanim sredinama [1]. Urbane aglomeracije su pokretač razvoja, centri povezivanja, inovativnosti i kreativnosti. Nadalje, to su centri rada i pružanja usluga za okolna područja te bitan element i faktor u ukupnom i teritorijalnom razvoju. Globalna urbanizacija započela je u dvadesetom stoljeću promjenama na ekonomskom i socijalnom planu.

Radi transformacije i uspostavljanja održivog razvoja na globalnoj razini, države članice Ujedinjenih naroda su 25. rujna 2015. usvojile „Agendu za održiv razvoj do 2030. godine“ (engl. *The 2030 Agenda for Sustainable Development* – Agenda 2030). Agenda 2030 opisuje transformativnu viziju te predstavlja zajednički nacrt za sadašnji i budući prosperitet, koji će se omogućiti putem 17 definiranih ciljeva održivog razvoja. U skladu s tim, ciljevi održivog razvoja univerzalni su i primjenjivi u svim zemljama i zajednicama. U njihovoj provedbi treba uzeti u obzir specifične okolnosti; razine razvoja, uvjete i prilike vezane za različite dijelove planeta. Ciljevi održivog razvoja (engl. *Sustainable Development Goal* – SDG) obuhvaćaju širok spektar izazova, poput iskorjenjivanja siromaštva i gladi, osiguranja zdravlja i dobrobiti, pristupačne i čiste energije, smanjenja nejednakosti, odgovora na klimatske promjene itd. Usto jedan od globalnih izazova današnjice jest učiniti gradove održivima, uključivima, integriranima i otpornima, što se posebno istaknulo neophodnim tijekom pandemije COVID-19. U tom smislu, u okviru Agende 2030, osobito je važan cilj uspostavljanja održivih gradova i zajednica po mjeri čovjeka (Slika 1.).

Osim osiguravanja pristupačnog, odgovarajućeg i sigurnog stanovanja, uključivosti i participacije u planiranju održivih urbanih sredina, posebno se, u nekoliko ciljeva i aktivnosti, ističe potreba za omogućavanjem sigurnog, pristupačnog i održivog prometnog sustava kao vrlo važne komponente održivoga urbanog ekosustava [2].

Slika 1. Dio skupine ciljeva u okviru Agende 2030 (prilagodio autor) [2]

U potrebi za mobilnošću još se uvijek oslanja na izbor osobnog automobila (osobito za kraća putovanja u urbanim sredinama). Prema posljednjem istraživanju Europskog udruženja proizvođača automobila (engl. *European Automobile Manufacturers' Association – ACEA*), na području Europske unije (ali i ostatka svijeta) još uvijek se bilježi trend rasta stupnja motorizacije. U 2020. godini vozni park (osobni automobili) u EU-u porastao je za 1,2 % u odnosu na 2019., s ukupno 246,3 milijuna automobila na cestama (Grafikon 1.). Europska unija broji 560 osobnih automobila i 81 gospodarsko vozilo na 1000 stanovnika. Luksemburg ima najveću gustoću automobila u EU-u (696 na 1000 stanovnika), slijedi ga Italija (666). U Latviji gotovo 43 % svih kućanstava ne posjeduje automobil, dok gotovo 32 % francuskih obitelji posjeduje dva osobna automobila [3].

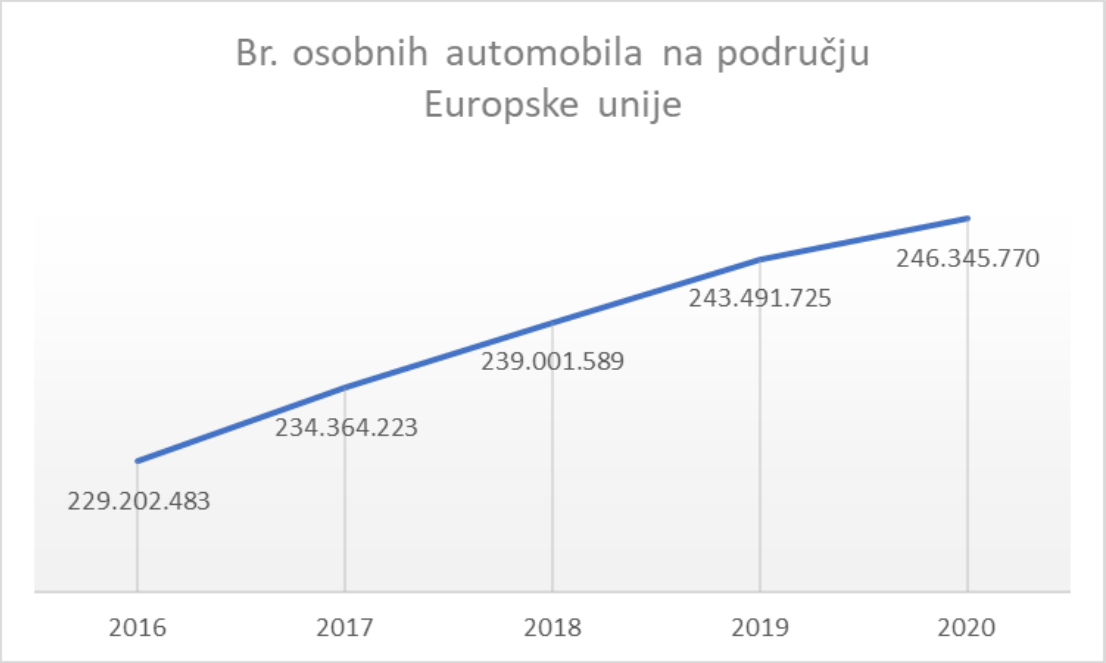

Grafikon 1. Trend porasta broja osobnih vozila na području Europske unije (prilagodio autor) [3]

Negativan utjecaj automobila ne završava samo na problemu ekološkog onečišćenja i buke. Naime, štetne emisije povezane s visokim stupnjem motorizacije povezane su s nizom drugih aspekata ekosustava; klimatskim promjenama, eutrofikacijom[1], smanjenom kvalitetom tla i vode.

[1] Eutrofikacija (eu- + -trofikacija), starenje vodenih sustava (npr. jezera). U prirodi taj proces traje tisućama godina dok se pod čovjekovim utjecajem skraćuje na samo nekoliko godina. U procesu eutrofikacije vodenih sustava intenzivno rastu alge, smanjuje se količina kisika i postupno izumiru životinjske vrste, a vodeni ekosustavi (obično jezera) mijenjaju boju u tamnozelenu i smeđu [139].

Negativni utjecaji visokog stupnja motorizacije najviše se osjećaju u gradovima. Sukladno tome, nužno je bilo osmisliti novu paradigmu, tj. održiv i integrirani koncept grada koji će eliminirati ili barem ublažiti negativne utjecaje na životnu sredinu. U tom smislu, koncept pametnoga grada (engl. *Smart City*) javlja se kao odgovor na brojne izazove s kojima se susreću urbane sredine – rastuću urbanizaciju i s njom povezane demografske promjene, klimatske promjene, onečišćenje okoliša itd. Neravnoteža u urbanoj sredini utječe i na ljudsko zdravlje, kvalitetu života te na druge žive organizme u ekosustavu. Unatoč brojnim znanstvenim naporima, strategijama, inicijativama u obliku mjera i poticanja svijesti ljudi, istraživanja ukazuju da se čovječanstvo još uvijek nije približilo *globalnoj održivosti* [4]–[6].

Općeprihvaćen cilj koncepta pametnoga grada jest poboljšati gospodarski rast i društveni razvoj kroz inovativnu, pametnu tehnologiju i snažnu suradnju ključnih dionika [7]. Danas postoji niz definicija i shvaćanja koncepta pametnoga grada, a u literaturi se često nailazi na pojmove poput „inteligentni grad“ i „digitalni grad“ koji predstavljaju konceptualne inačice. Zbog toga pojam „pametni grad“ još uvijek nema svoju službenu i jedinstvenu definiciju [4]. Radi usporedbe u nastavku teksta istaknute su četiri definicije pametnoga grada.

„Pametni grad je grad koji ima dugoročno dobre rezultate u gospodarstvu, ljudima, upravljanju, mobilnosti, okruženju i životu, izgrađen na pametnoj kombinaciji aktivnosti samoodlučnih, neovisnih i svjesnih građana.“ [8]

„Pametni grad je grad koji funkcionira na održiv i inteligentan način, integrirajući cjelokupnu infrastrukturu i usluge u kohezivnu cjelinu i koristeći inteligentne sustave za nadzor i kontrolu, kako bi se osigurala održivost i učinkovitost.“ [9]

„Grad je pametan kada ulaganja u ljudski i društveni kapital te tradicionalnu (promet) i modernu informacijsko komunikacijsku infrastrukturu potiču održivi gospodarski rast i visoku kvalitetu života, uz mudro upravljanje prirodnim resursima, kroz participativno upravljanje.“ [10]

„Grad koji povezuje fizičku infrastrukturu, IT infrastrukturu, društvenu infrastrukturu i poslovnu infrastrukturu kako bi se iskoristila kolektivna inteligencija grada.“ [11]

Definicija pametnoga grada, što je vidljivo u izdvojenim definicijama (ali i ostalim definicijama u literaturi), više nije ograničena samo na pojam i implementaciju *informacijsko-komunikacijskih tehnologija*. Pojašnjenje koncepta pametnoga grada proširilo se i na druge aspekte i pojmove poput gospodarskog rasta, razvoja društva, energetske učinkovitosti, bolje organizacije života, kolektivne participacije i inteligencije. U tom smislu, koncepcija se s

vremenom transformira, zauzima holistički pristup te je sve više usmjerena na potrebe ljudi, njihovu participaciju u kreiranju održive sredine i društvo u cjelini [4], [11].

Geneza pametnoga grada može se opisati kao nastavak i proširenje konceptualno analognih pojmova, poput: „digitalni grad“ (engl. *Digital city*), „zeleni grad“ (engl. *Green city*), i „grad znanja“ (engl. *Knowledge city*) [6].

Koncept pametnoga grada kontinuirano se razvija s razvojem tehnologije i potrebama društva. Implementacijom i povezivanjem naprednih informacijsko-komunikacijskih tehnologija, sve više gradova poprima karakteristike koncepta pametnoga grada. Paradigma pametnoga grada temelji se na integraciji i povezivanju pametnih usluga čineći grad umreženim u jednu cjelinu te pružajući razne mogućnosti radi poboljšanja kvalitete života. Ključne tehnologije za razvoj pametnih gradova su tehnologija *Interneta stvari* (engl. *Internet of Things* – IoT), koja predstavlja povezivanje uređaja ili objekata svakodnevne upotrebe na internet i/ili povezivanjem s drugim uređajem. Nadalje, tehnologije poput *velikih podataka* (engl. *Big Data* – BD), oblaka (engl. *Cloud*) te umjetne inteligencije (engl. *Artificial Intelligence* – AI) u narednom razdoblju imat će ključnu ulogu u razvoju i uspostavljanju pametnih gradova [12].

Jedna od ključnih komponenti pametnih gradova jest održivi promet/mobilnost koji, između ostalog, uključuje primjenu inteligentnih transportnih sustava (engl. *Intelligent Transport Systems* – ITS) čineći potpunu integraciju sustava urbane mobilnosti [13].

Pametni grad je najširi pojam, koji objedinjuje gotovo sve konceptualne inačice i pripadajuće karakteristike. Jedna od raširenijih verzija modela pametnoga grada temelji se na šest „pametnih“ dimenzija – *pametna ekonomija, pametna mobilnost, pametna okolina, pametni ljudi, pametno življenje i pametno upravljanje* (Slika 2.).

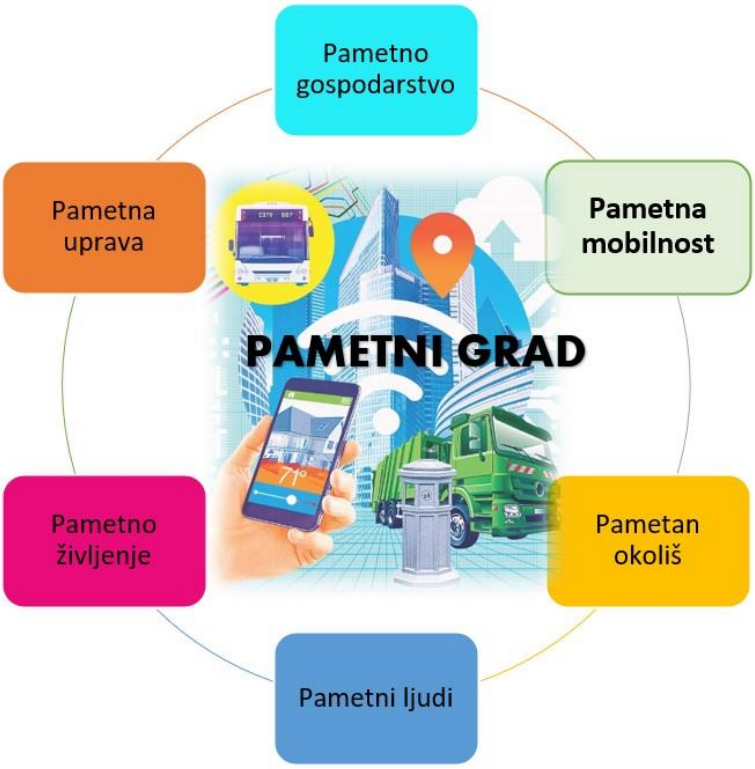

Slika 2. Komponente koncepta pametnoga grada (prilagodio autor) [7]

„Pametna mobilnost“ (engl. *Smart Mobility*) prožima svaku komponentu te je izrazito bitna za održivo funkcioniranje urbanih aglomeracija; za smanjenje prometnih zagušenja, onečišćenja okoliša, više dostupnih opcija „zelenih“ i pristupačnijih načina putovanja za sve skupine korisnika. Osim tih izazova, u konceptu „pametne mobilnosti“ često se spominje pojam „mobilnost usmjerena prema čovjeku“ (engl. *Human-centered mobility*) [14]. „Mobilnost usmjerena prema čovjeku“ pokriva potrebe suvremenog čovjeka kroz intuitivne, pametne usluge, i to od trenutka planiranja putovanja, kupnje karata do dostupnih i pravovremenih informacija tijekom putovanja.

2.1. Održiva mobilnost

Promicanje održive mobilnosti već je nekoliko godina prioritetna mjera Europske komisije. Cilj mjera i programa EU-a jest omogućiti svim stanovnicima nesmetanu mobilnost i pristup ključnim destinacijama i uslugama, povećavati sigurnost usluge, smanjiti štetne emisije i buku te poboljšati efikasnost i isplativost transportnog sustava u cjelini [15], [16].

S obzirom na to da se putnici trebaju kretati neometano, brzo i jednostavno s jednog mjesta na drugo, nužno je ponuditi rješenje koje će konkurirati osobnom automobilu (koji je još uvijek

dominantniji izbor). Cilj Europske unije (EU) za sektor prometa jest smanjiti emisiju stakleničkih plinova (engl. *Greenhouse Gas Emission* – GHG) za najmanje 60 % do 2050. godine [17]. EU i države članice postavile su kao cilj mobilnost koja teži održivosti i energetskoj učinkovitosti. Posljednjih nekoliko godina, potaknuto promocijom prometne politike EU-a, multimodalni putnički sustavi postaju jedan od imperativa u rješavanju problema mobilnosti [18].

Promjena u načinu i stilu života osobito se ogleda u drukčijim potrebama, zahtjevima i novim navikama. Neadekvatna prometna infrastruktura, manjak prostora namijenjen ljudima, smanjenje mobilnosti i pristupačnosti, povećanje zagušenja te negativni učinci na okoliš neki su od glavnih problema koji ukazuju na potrebu sustavnog pristupa u njihovu rješavanju. Gradovi s najuspješnijim prometnim strategijama prioritiziraju kretanje ljudi, dajući im pritom niz atraktivnih mogućnosti i načina u javnom prijevozu [16].

Mobilnost, odnosno *kretanje* ljudi potaknuto je radi pristupanja željenim destinacijama[2], koristeći različita prijevozna sredstva i načine putovanja unutar različitih vremenskih intervala [19]. Temeljna značajka svakodnevne mobilnosti (uključujući i svakodnevni odlazak na posao) danas nije isključivo vezana za prostor urbanih sredina, nego su sve više zastupljena i puno dulja putovanja (međugradska, regionalna pa i prekogranična). Kretanje putnika može se promatrati prema svrsi kretanja, vremenskoj distribuciji putovanja, odabiru načina putovanja, duljini kretanja i prostornim karakteristikama putovanja. Uz to, kretanja putnika mogu se promatrati na individualnoj razini (skup karakteristika na razini jednog putnika) te na razini skupine (populacije), uzevši pritom u obzir karakteristike promatrane skupine putnika (dob, zaposlenost itd.). Osim toga, kretanja se mogu podijeliti i prema tipovima putovanja, a to su *obligatorna* (kuća – posao – kuća) te *voluntarna putovanja* (kretanja tijekom slobodnog vremena, u skladu sa slobodnom voljom putnika) [19].

Najčešća putovanja vezana su za putovanje na posao, a nazivaju se pendularna putovanja (kuća – posao – kuća) te profesionalna putovanja u okviru posla i tijekom radnog vremena (npr. poslovna putovanja, sastanci, konferencije i ostala mjesta/aktivnosti u kontekstu obavljanja posla). Uz obligatorna putovanja, koja su najčešće vezana za posao/radno mjesto, ostala uobičajena kretanja vezana su za slobodno vrijeme i slobodnu volju (voluntarna putovanja), a u vidu odlazaka na mjesta rekreacije, kupovine, raznih manifestacija i događaja [19].

U tom su smislu danas posebno zastupljena turistička putovanja. Turistička putovanja se prije svega odvijaju na regionalnoj i prekograničnoj razini, a mogu biti vezana za rekreacijske

[2] Pristup robi, sadržaju ili uslugama te obavljanje aktivnosti koje stvaraju (ili ne stvaraju) ekonomsku vrijednost

lokacije (more, planine te ostale prirodne atrakcije), lokacije s povijesnim i kulturnim značajem (države, gradovi sa značajnim znamenitostima, povijesnim spomenicima i slično), manifestacije poput koncerata i festivala te danas iznimno zastupljene sportske događaje [19]. Putovanja vezana za radno mjesto najčešće su uhodana, isplanirana putovanja s dobro poznatim rutama, prijevoznim sredstvima (i njihovom kombinacijom). No, u promatranju kretanja putnika, značajna i od istraživačkog interesa su ***ad hoc*** **putovanja** (jednokratna, jedinstvena putovanja) [20]. *Ad hoc* putovanja su putovanja s određenom svrhom kretanja, gdje putnik nije unaprijed upoznat s karakteristikama putovanja (mogućim rutama, dostupnim izborom prijevoznih sredstava i njihovom kombinacijom, trajanjem putovanja, brojem presjedanja, vremenom čekanja na prijevozna sredstva itd.). Međutim, ponekad *ad hoc* putovanja mogu biti i obligatorna i voluntarna putovanja.

Tema održive mobilnosti aktualna je u europskom okruženju, što je vidljivo u znatnim ulaganjima financijskih sredstava EU-a [21]. Značajna prekretnica u pristupu prema sve učestalijim prometnim problemima započela je 2013. godine kreiranjem europskog koncepta planiranja prometa u urbanim sredinama, u formi „EU 2013 – Paket urbane mobilnosti“ (engl. *European Commission 2013 – Urban Mobility Package*). Na osnovi tog paketa određen je koncept za „Planove održive mobilnosti u gradovima – POMG“ (engl. *Sustainable Urban Mobility Plans* – SUMP). Plan održive mobilnosti u gradovima je strateški plan koji se nadovezuje na postojeću praksu u planiranju i uzima u obzir integracijske, participacijske i evaluacijske principe kako bi zadovoljio potrebe stanovnika gradova za mobilnošću (sada i u budućnosti) te osigurao bolju kvalitetu života u gradovima, ali i njihovu okruženju.

U skladu s ciljevima „Europskog zelenog dogovora“ (engl. *European Green Deal*), Europska komisija predložila je novu inicijativu urbane mobilnosti, tj. „Novi europski okvir urbane mobilnosti“ (engl. *The New European Urban Mobility Framework*). U inicijativi (Slika 3.) se posebno ističe prelazak na održivije načine putovanja (multimodalni prijevozni sustav) te podrška u vidu digitalnih rješenja. Osim toga, potiče se akceleracija i implementacija novih digitalnih rješenja kao podrške pri planiranju putovanja te zaštita osjetljivih putničkih podataka o mobilnosti [22].

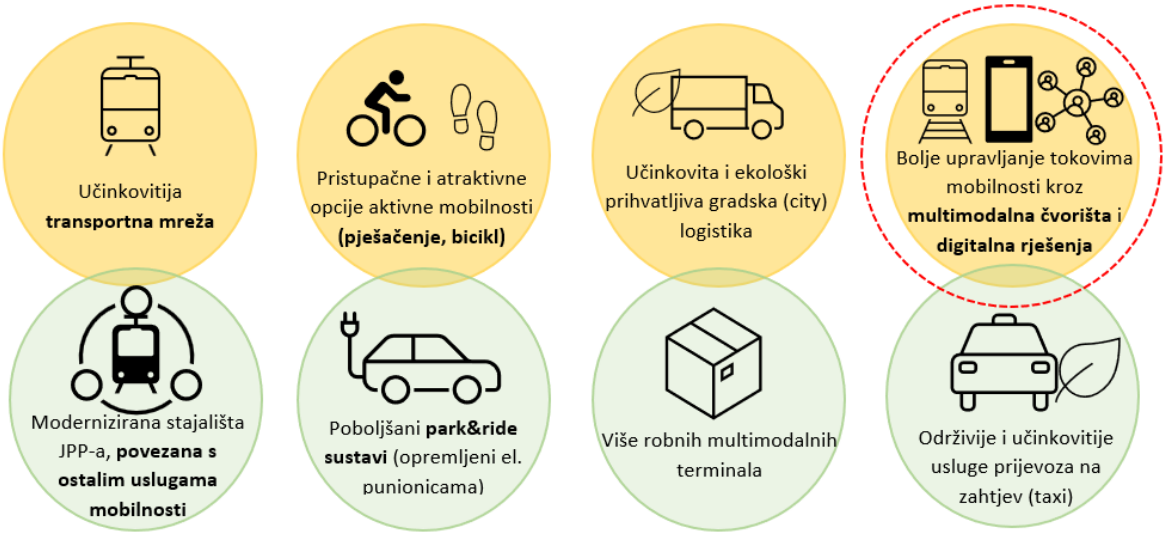

Slika 3. Smjernice i ciljevi inicijative

„Novi europski okvir urbane mobilnosti“ (prilagodio autor) [22]

Iz toga je vidljivo da je mobilnost ljudi, osobito danas, sveprisutna, intenzivna i dinamična. Uz to je jedna od najvažnijih komponenti u funkcioniranju životne sredine. U tom smislu, održiva mobilnost predstavlja izazovan i složen zadatak za prometne stručnjake, urbaniste i ostale eksperte te participaciju ostalih relevantnih dionika i građana.

2.2. Pametna mobilnost

Koncept *Pametna mobilnost* jedna je od temeljnih komponenti te je ključna u poticanju pomaka prema održivoj mobilnosti. Prema analizi literature u području pametne mobilnosti, glavni ciljevi podijeljeni su u četiri kategorije [9], [23]–[25]:

1. Smanjenje ekološkog onečišćenja i onečišćenja bukom
2. Smanjenje prometnih zagušenja
3. Povećanje sigurnosti prometa
4. Povećanje dostupnosti javnog prijevoza

Osim toga, uvođenjem naprednih rješenja u prometni sustav cilj je poboljšati učinkovitost postojeće infrastrukture i reducirati fizička proširenja koja privlače dodatan promet. U tom pogledu značajnu ulogu imaju inteligentni transportni sustavi koji predstavljaju holističku, upravljačku i informacijsko-komunikacijsku nadgradnju klasičnog sustava prometa i transporta, kojim se postiže znatno poboljšanje performansi, odvijanje prometa, učinkovitiji transport putnika i roba, poboljšanje sigurnosti u prometu, udobnost i zaštita putnika, manja onečišćenja okoliša itd. Danas je teško zamisliti fleksibilan i kvalitetan javni prijevoz bez primjene inteligentnih transportnih sustava (engl. *Intelligent Transport Systems* – ITS). Primjenom ITS usluga u gradskom prometu postiže se povećanje atraktivnosti, pouzdanosti, raspoloživosti i pristupačnosti [26].

Posljednjih nekoliko godina osobito su aktualni putnički informacijski sustavi (engl. *Traveler Informaton Systems* – TIS) kao podrška pri planiranju putovanja. Informiranje putnika (engl. *Traveller Information*) jedno je od funkcionalnih područja ITS-a. Navedeno područje obuhvaća statičke i dinamičke informacije o prometnoj mreži, usluge pretputnog i putnog informiranja te podršku službama koje obavljaju prikupljanje, pohranjivanje i upravljanje informacijama za planiranje transportnih aktivnosti. Usluge pretputnog informiranja (engl. *Pre-Trip Information*) značajne su za korisnike jer omogućuju kreiranje putovanja od kuće ili bilo koje druge lokacije gdje je omogućen pristup internetu, odnosno gdje su dostupne informacije o raspoloživim načinima prijevoza, vremenu ili troškovima putovanja. Osim pretputnih informacija, vrlo je važan pristup informacijama tijekom putovanja [26]. Putno informiranje (engl. O*n-Trip Information*) uključuje stvarnovremenske informacije o putovanju, procjeni vremena putovanja ovisno o postojećim uvjetima na prometnoj mreži, raspoloživosti parkirnih mjesta, prometnim nezgodama itd.

Napredni sustavi informiranja putnika (engl. *Advanced Traveler Information System* – ATIS) su sustavi koji služe kao podrška putniku u donošenju odluka prije i tijekom putovanja. Suvremeni sustavi ovog tipa prilagođavaju se potrebama korisnika. Prema [27], [28] predložen je okvir za treću (personaliziranu) generaciju sustava koji će služiti kao podrška pri multimodalnim putovanjima (u stvarnom vremenu).

Posebno su značajne **Integrirane multimodalne putne informacije** (engl. *Integrated Multimodal Travel Information* – IMTI) koje na integrirani način omogućavaju putnicima korištenje svih dostupnih načina putovanja [29]. U tom smislu, multimodalni putni planeri (engl. *Multimodal Journey Planners* – MJPs) temelje se na takvim informacijama i predstavljaju integraciju usluga te danas čine ključnu komponentu implementacije ITS-a. Oni pružaju opsežan spektar relevantnih informacija koje će pomoći korisniku pri planiranju putovanja *od vrata do vrata* [26], [30].

Uz prednosti koje pružaju napredne tehnologije i usluge u području ITS-a, još uvijek postoje barijere i izazovi koje je potrebno savladati radi uspostavljanja održivog i pametnog urbanog okruženja. Jedan od izazova kojem je potrebno sustavno pristupiti su – *korisnici* prometnog sustava. Naime, kvalitetna infrastrukturna rješenja, prijevozna sredstva, organizacija javnog prijevoza, kao i implementacija pametnih rješenja vezanih za mobilnost, nisu dovoljni kad je riječ o promjenama putničkih navika. U tom smislu, potrebno je utjecati na svijest korisnika; na prikladan način utjecati na percepciju o važnosti uspostavljanja pametne i održive mobilnosti te, isto tako, kontinuirano prikupljati korisničke zahtjeve i potrebe. Inkluzivnim pristupom moguće je kreirati sustav javnog prijevoza u skladu s potrebama korisnika (putnika). Uz to, znajući da pametni gradovi počivaju na velikim skupovima podataka, izuzetno je bitno zaštititi osjetljive podatke korisnika te spriječiti svaku njihovu zloupotrebu. Jedino je na taj način moguće steći povjerenje korisnika u pametne usluge mobilnosti te njihovo korištenje.

2.2.1. Mobilnost kao usluga

Transformacija urbanih aglomeracija potaknula je promjene u mobilnosti ljudi i njihovim putničkim navikama i preferencijama. Pri tradicionalnom pristupu predviđanju i planiranju prijevoznog sustava, najčešće se služilo tipičnim primjerom putovanja kuća – posao/škola – kuća. Suvremeni pristup planiranja mora uzeti u obzir širu i realniju sliku mobilnosti ljudi i njihovih putničkih obrazaca. Argument koji svjedoči tome u prilog jest činjenica da je mobilnost u dinamičnom i promjenjivom okruženju postala *nepredvidljiva*, a navike i potrebe ljudi – *sofisticiranije*.

Današnja se mobilnost može metaforički opisati kao „živi organizam“, gdje se korisnik – putnik – prilagođava novim okolnostima [31]. Radi optimizacije procesa vezanih za mobilnost ljudi, nužna su održiva i adaptabilna rješenja koja će, između ostalog, osigurati ekonomski prosperitet i socijalnu dobrobit, a s druge strane zaštititi okoliš i poboljšati kvalitetu života. U tom pogledu, koncept *Mobilnost kao usluga* (engl. *Mobility – as – a – Service* – MaaS) predstavlja novu paradigmu, koncept i prometno rješenje radi realizacije učinkovite mobilnosti ljudi, nudeći uslugu koja obuhvaća i kombinira više načina putovanja (javni prijevoz, dijeljeni prijevoz, sustav javnog iznajmljivanja bicikala, taksi) na jednoj platformi (mobilna aplikacija i *web*-sučelje). Osnivač i začetnik koncepta Sampo Hietanen (Finska) definirao je ovu uslugu kao model distribucije mobilnosti (engl. *Mobility distribution model*) koji pruža (ispostavlja) prijevoznu *uslugu* korisnicima putem jedne platforme/sučelja [32].

U znanstvenoj literaturi ističe se važnost integriranog i inkluzivnog koncepta koji obuhvaća skup dionika; MaaS operatere koji su posrednici između pružatelja usluga mobilnosti (ponuda) i MaaS korisnika (potražnja). Na Slici 4. pružatelji usluge mobilnosti objedinjuju prijevozne operatere. U ovom slučaju, misli se na javni prijevoz i usluge dijeljenja, no isto tako koncept može uključiti i privatni prijevoz (osobni automobil, bicikl i dr.). Pored javnog prijevoza, u ponudu su uključene usluge podrške mobilnosti, kao što su punionice električnih vozila, *park&ride* sustavi i dr. Kako bi se ostvarilo što bolje korisničko iskustvo, uključene su i napredne značajke poput interneta, multimedijalnih značajki itd. Temeljni segmenti MaaS platforme su multimodalni putni planer, informacije u stvarnom vremenu, funkcija rezervacije, plaćanja i izdavanja karata te korisnički profil. MaaS platforma integrira informiranje i planiranje te plaćanje i izdavanje karata radi što boljeg korisničkog iskustva.

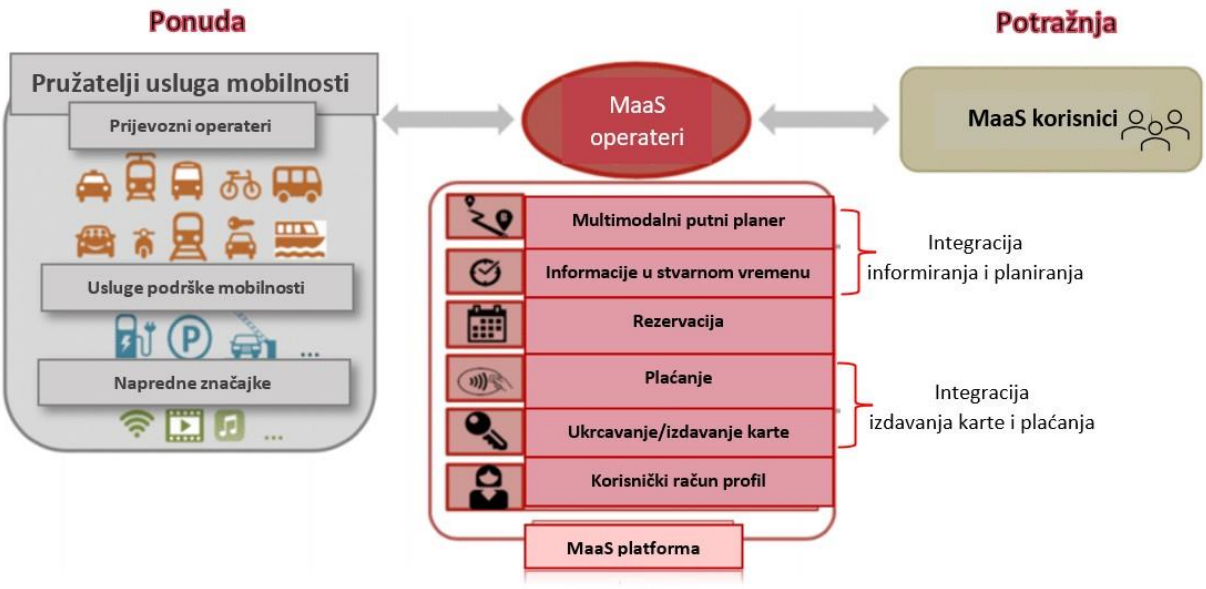

Slika 4. Koncept MaaS (prilagodio autor) [33]

Putem jedne digitalne platforme (mobilna aplikacija, *web*-sučelje) može se planirati multimodalno putovanje na temelju stvarnovremenskih putnih informacija (multimodalni putni planer) te rezervirati i platiti uslugu putem jedinstvene integrirane karte. U tom smislu trošak putovanja (prijevozne karte) više ne predstavlja jedan od ključnih kriterija u izboru **pojedinih** putovanja (rute) jer postoji jedinstvena, integrirana karta. Drugim riječima, uslugu je moguće platiti u obliku „paketa mobilnosti“ i „plaćanje po narudžbi“ (engl. *Pay-as-you-go*). „Paket mobilnosti“ predstavlja mjesečni (godišnji) pretplatni paket, a korisnici mogu izabrati tri vrste paketa: fiksni paket (fiskni broj korištenja), fleksibilni paket (prilagođavanje usluge u određenoj mjeri) te paket s neograničenim brojem korištenja.

Konačno, s obzirom na dinamičniji i složeniji dnevni raspored, putnici postaju sve zahtjevniji u potrebi za uslugama mobilnosti, kako bi smanjili vrijeme čekanja te, analogno tome, izabrali opciju putovanja najprikladniju njihovu rasporedu. Putničke informacije u stvarnom vremenu danas su dostupne putem više različitih sučelja. Google Maps pruža najviše informacija o javnom prijevozu, no ostale usluge na platformi (naplata, rezervacija, modalna integracija svih dostupnih načina putovanja) nisu u potpunosti integrirane ili uopće ne postoje. S obzirom na integrirane značajke, MaaS ima potencijal ponuditi kvalitetnije (olakšano) korisničko iskustvo [31]. U Tablici 1. je navedena taksonomija četiri razine integracije MaaS sustava, uključujući nultu razinu (bez integracije). Taksonomija razina integracije korisna je referenca u usporedbi trenutačnih MaaS koncepata [34].

Tablica 1. Taksonomija razina integracije MaaS koncepta (prilagodio autor)

Razina integracije	Opis integracije
Bez integracije	Pružaju se zasebne usluge za različita prijevozna sredstva. (npr. Hertz, Sixt)
Integracija informacija	Informacije se pružaju putem multimodalnoga putnog planera, koji može ili ne mora uključivati informacije o troškovima putovanja i pripadajućim rutama. Dodana vrijednost ove razine jest mogućnost izbora putovanja ovisno o dobu dana i kombinacije načina prijevoza. (npr. Google Maps)
Integracija pronalaženja ruta putovanja, rezervacija i plaćanja	Na ovoj razini integracije MaaS olakšano je pronalaženje ruta, rezerviranje i plaćanje pojedinačnih putovanja. Dodana vrijednost ove razine jest mogućnost odabira rute, rezervacije i plaćanja na „jednom mjestu“, tj. putem aplikacije s unaprijed izvršenom registracijom. (npr. Moovit, WienMobil)
Integracija prijevoznih usluga	Razina ne obuhvaća samo individualna putovanja već dnevne potrebe pojedinca, ali i članova obitelji, nudeći sveobuhvatne „pakete mobilnosti“. Dodana vrijednost treće razine integracije jest pokrivenost dnevnih zahtjeva i potreba za mobilnošću, što predstavlja alternativu (i konkurenciju) posjedovanju osobnog automobila. (npr. UbiGo, Whim)
Integracija društvenih ciljeva	Integracija društvenih ciljeva: smanjenje upotrebe osobnih automobila, promicanje održivosti urbanih sredina.

Izvor: [34]

Ono što je značajno za MaaS koncept jest to što je usmjeren na stvarne potrebe korisnika (engl. *User-oriented*). Korisnik (putnik) može se pridružiti platformi putem jednog, individualnog profila, no može, po potrebi, uključiti i cijelo kućanstvo (tzv. „obiteljski profil“). Dodana vrijednost samom konceptu je mogućnost personalizacija i korisničke prilagodbe (engl. *Customisation*) profila [35], što predstavlja korak dalje u odnosu na dosadašnja rješenja adaptivnih sustava planiranja putovanja. Personalizacija predstavlja modificiranje profila korisnika zasnovanog na podacima korisničkog ponašanja (prethodnog iskustva i izbora), a omogućuje učinkovitije ispunjenje zahtjeva i potreba korisnika. Na taj način MaaS usluga postaje atraktivnija i konkurentnija u odnosu na druge usluge te potencijalno konkurentna osobnom automobilu. Personalizirani korisnički profil može dati preporuke ruta (s odgovarajućom kombinacijom načina prijevoza) na temelju postavljenih preferencija (eksplicitnih iskaza) te zabilježenih putničkih obrazaca ponašanja (povijest putovanja – implicitnih iskaza). Kao dodatak, moguće je povezati profile društvenih mreža s MaaS profilom. S druge strane, korisnička prilagodba predstavlja ručno podešavanje i modifikaciju profila. Na taj se način povećava prilagodljivost, atraktivnost i kvaliteta usluge te lojalnost krajnjih korisnika prema davatelju usluge.

Konkretno, krajnji korisnici mogu, uz ponuđene opcije putovanja, kreirati svoje multimodalno putovanje i/ili kreirati svoj „paket mobilnosti“ koji će biti u skladu s njihovim aspiracijama i vizijom besprijekornog, neprekinutog putovanja (engl. *Seamless Journey*). Osim navedenih integriranih usluga, u pravilu, korisnicima su dostupne i usluge poput vremenske prognoze, sinkronizacije putovanja s osobnim kalendarom, izvješća o povijesti putovanja, pregleda računa te povratnih informacija.

2.3. Multimodalna putovanja

2.3.1. Teorijski koncept

Problematika uspostavljanja održive mobilnosti složena je jer se promjene u promišljanju i shvaćanju trebaju pokrenuti na individualnoj razini, odnosno na razini korisnika – putnika. Prijelaz s osobnog automobila na održive načine prijevoza još uvijek predstavlja složen bihevioralni proces na individualnoj razini, kao i društveni izazov općenito. Pored autonomije, udobnosti i društvenog statusa koje nudi posjedovanje i korištenje osobnog automobila, neophodno je uspostaviti i ponuditi koncept održivog putovanja (osobito u urbanim sredinama) koji će konkurirati osobnom automobilu.

Alternativa osobnom automobilu javni je prijevoz koji je racionalniji izbor, no niz je izazova s kojima se još uvijek suočava. S obzirom na to da je mreža javnog prijevoza fizički isprekidana i kruta, opsluživanje uslugom javnog prijevoza prostorno je ograničeno. Osim toga, podsustavi javnoga gradskog prijevoza najčešće operiraju neovisno i nesinkronizirano te u tom smislu otežavaju presjedanja putnika s jednog prijevoznog sredstva na drugo prijevozno sredstvo. Ti problemi značajno utječu na atraktivnost prijevozne usluge, osobito kod putnika koji **preferiraju neprekinuta putovanja** [19].

Jedna od potencijalnih mogućnosti učinkovitoga i atraktivnoga javnog prijevoza krije se pod pojmom i konceptom *multimodalna putovanja*. Pojavom novih usluga mobilnosti te sve zahtjevnijim potrebama putnika, planiranje multimodalnih putovanja postaje sve složenije. Ideja multimodalnoga putovanja jest povezati ishodište i odredište kombinacijom dostupnih načina putovanja u određenom vremenskom okviru radi smanjenja pojedinačnog korištenja automobila.

Prema Van Nesu i Bovyu [36], multimodalno putovanje definirano je kao kombinacija nekoliko načina putovanja između ishodišta i odredišta koje potencijalno može biti korisno za putnika te društvo u cjelini. Multimodalni koncept putovanja prema Bielli i koautorima definiran je malo šire [37], a predstavlja „kombinaciju načina prijevoza s glavnim komponentama – infrastrukturom, načinima putovanja i multimodalnim čvorištima koja predstavljaju točke transfera (presjedanja) s jednog načina putovanja na drugi“.

2.3.2. Segmenti multimodalnoga putovanja

Kod multimodalnih putovanja, kao što je prikazano na Slici 5., svaka ponuđena ruta sastoji se od dviju ili više dionica (engl. *Trip Legs*) s pripadajućim načinom putovanja. Dionica je određena mjestom ukrcaja putnika, trajanjem putovanja, uključujući vrijeme čekanja na presjedanje, te mjestom iskrcaja putnika (stajalište, terminal).

Prema definiciji [38], prijevozno sredstvo koje se upotrebljava tijekom najduže dionice, predstavlja *glavno prijevozno sredstvo* (engl. *Main Transport Mode/Primary Mode*) u multimodalnomu putovanju. Osim toga, najbrža prijevozna sredstva najčešće će pripadati najdužim dionicama, dok će za kraće dionice biti karakteristično pješačenje ili bicikl (npr. dionica do glavnog prijevoznog sredstva i dionica do odredišta).

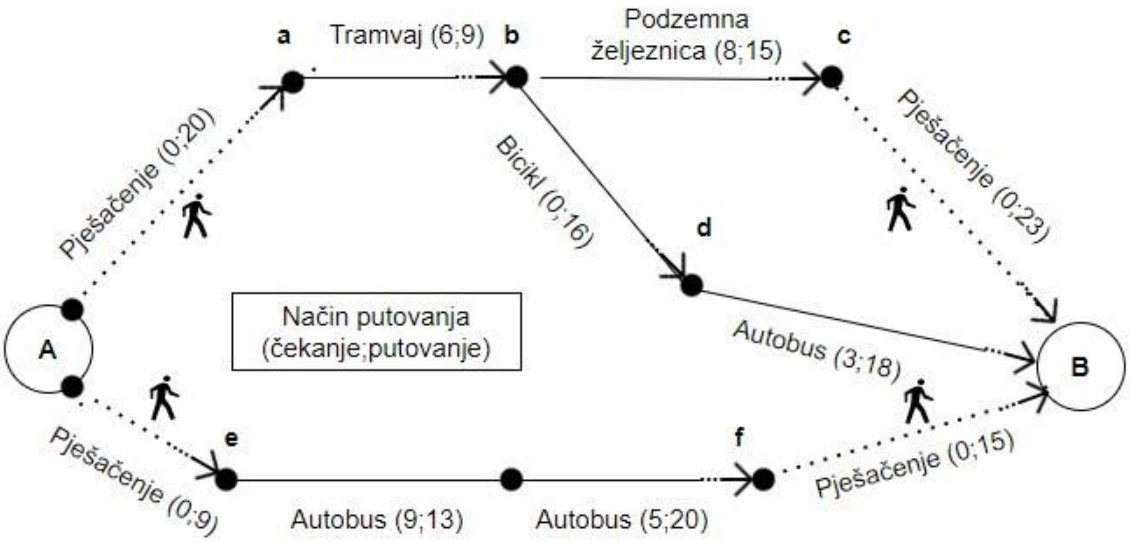

Slika 5. Koncept multimodalnoga putovanja (prilagodio autor) [39]

Pri multimodalnome putovanju kombiniraju se tzv. *privatni/osobni načini putovanja* [38]*:*

- **pješačenje, bicikl** (tzv. aktivni načini putovanja)
- osobni automobil

gdje pješačenje predstavlja sastavni dio multimodalnoga putovanja jer se gotovo uvijek odvija i upotrebljava kao način putovanja do prvog prijevoznog sredstva (engl. *first-mile*), pri presjedanju te putovanja do odredišta, tj. nakon izlaska iz zadnjeg prijevoznog sredstva do odredišta (engl. *last-mile*) (Slika 6.).

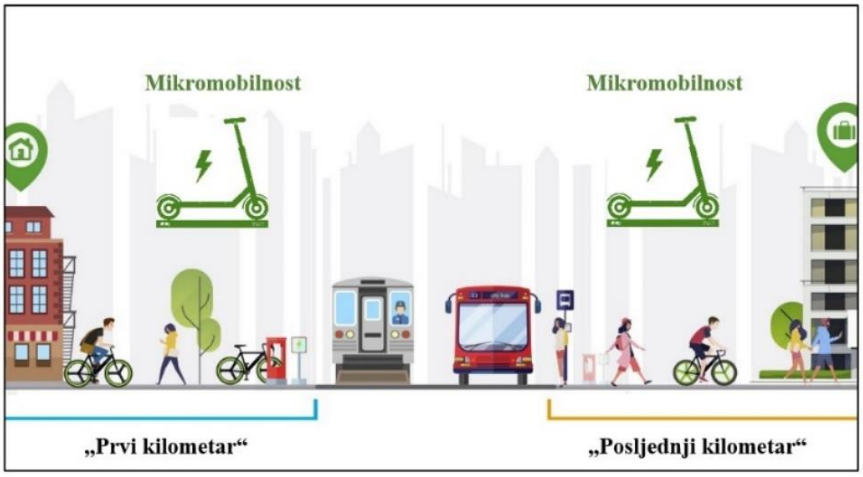

Slika 6. Prikaz opcija prvog i posljednjeg kilometra kod multimodalnoga putovanja (prilagodio autor) [40]

Dobra organizacija i pokrivenost prvog i posljednjeg kilometra, u vidu odgovarajuće infrastrukture za pješake i bicikliste[3], predstavlja izazov u postizanju održive mobilnosti. S jedne se strane izuzetni napori ulažu u poboljšanje javnog prijevoza, dok s druge strane postoji „problem prvog i posljednjeg kilometra“ koji kod velikog broja ljudi stvara otpor i animozitet pri izboru javnog prijevoza. Ako je prisutan nedostatak povezanosti do javnog prijevoza, putnici će se najčešće odlučiti za osobni automobil.

Radi postizanja povezanijega, a samim time i udobnijega multimodalnog putovanja, vrlo je bitno osigurati povezanost s pristupnim točkama javnog prijevoza. Pješačenje je tradicionalno najčešći izbor, osobito kod kraćih dionica prvog i posljednjeg kilometra. No, s obzirom na transformaciju i fizičku ekspanziju gradova, dionice prvog i zadnjeg kilometra postaju sve duže. U tom slučaju, mikromobilnost (npr. el. romobili) predstavlja prikladno rješenje problema „prvog i posljednjeg kilometra“.

Osim navedenih *privatnih/osobnih načina* putovanja, putnik tijekom gradskih, međugradskih, regionalnih i prekograničnih multimodalnih putovanja može kombinirati

[3] tradicionalni i najčešći načini putovanja na dionicama prvog i zadnjeg kilometra

različita prijevozna sredstva javnog prijevoza putnika (npr. tramvaj, autobus, željeznica, trajekt, zrakoplov).

Koncept multimodalnih putovanja *od vrata do vrata* jedna je od prioritetnih mjera koja se spominje u prometnoj politici EU-a koja može ublažiti prometne probleme. Europska komisija sastavila je niz zakonodavnih i političkih inicijativa koje se odnose na bolju, adekvatnu infrastrukturu i digitalna rješenja radi promicanja integriranoga, multimodalnoga te, u konačnici, održivoga prometnog sustava [41]. Tako je *multimodalnost* jedan od ključnih pojmova u okviru SUMP-a, kojemu je cilj poticati i omogućiti pristupačnost i praktičnost u kombiniranju i izmjeni održivih načina putovanja svim skupinama korisnika. Prijelaz prema ovom održivom konceptu putovanja smatra se velikim izazovom u narednim desetljećima, a sve kako bi se eliminirali ili barem ublažili negativni učinci koje trenutačno uzrokuje promet, naročito u urbanim sredinama [42], [43].

U skladu s tim, multimodalni koncept putovanja predstavlja odgovor koji vodi prema održivoj mobilnosti, a uključuje kontinuiranu povezanost duž cijelog putovanja (tzv. usluga *everywhere-to-everywhere*), uštedu vremena (omogućena jednostavna izmjena prijevoznih sredstava) te maksimalnu fleksibilnost kombiniranja načina putovanja.

3. PLANIRANJE MULTIMODALNOGA PUTOVANJA

U ovom poglavlju istražena je i analizirana relevantna znanstvena literatura u području multimodalnoga putnog planiranja, aktualni znanstveni i istraživačko-razvojni projekti te postojeći sustavi za planiranje multimodalnoga putovanja. Dostupne informacije o putovanju mogu itekako utjecati na odluke putnika koji žele doći na odredišta na najpovoljniji, tj. najprikladniji način. Putnicima su potrebni multimodalni informacijski sustavi prilagođeni njihovim potrebama, koji mogu pružiti informacije prije i za vrijeme putovanja s obzirom na kombinirani način prijevoza (prema preferencijama). Planeri putovanja ne bi se trebali smatrati samo alatima za pretraživanje podataka prije putovanja, nego bi trebali obuhvaćati i čitav proces putovanja, pružajući cjelovite i integrirane usluge putnicima. Putne informacije, osobito personalizirane, mogu utjecati na odluke putnika koji na svoja odredišta žele doći na najpovoljniji način te u konačnici na sveukupno zadovoljstvo uslugama javnog prijevoza [44]–[46].

3.1. Pregled relevantnih projekata u području multimodalnoga planiranja putovanja

Nekoliko je važnih projekata koji su pokrili područje istraživanja i razvoja multimodalnih personaliziranih usluga informiranja putnika. Projekt *WISETRIP* jedan je od prvih projekata EU-a gdje je pokrenuto istraživanje u području pružanja personaliziranih multimodalnih informacija, kao i popratnih naprednih tehnologija, a projekt *ENHANCED WISETRIP* nadogradnja je projekta s novim mogućnostima personalizacije, prilagodbe potrebama korisnika, integrirajući troškove i utjecaje na okoliš i omogućavajući upravljanje neočekivanim scenarijima tijekom multimodalnoga putovanja [47].

Nadalje, FP7 projekt *MyWay Personal Mobility* istraživao je, između ostalog, mogućnosti proširenja tradicionalnoga multimodalnoga putnog planera, i to u smjeru personalizacije usluge za krajnje korisnike. Pod pojmom *egocentric vision* razvio se napredniji pristup informiranja, nudeći rješenje najbliže osobnim potrebama i preferencijama korisnika [48].

EU projekt *SUPERHUB* bavi se izazovima pružanja rješenja koja se prilagođavaju potrebama mobilnosti ljudi. Razvijena je otvorena platforma usmjerena na krajnjeg korisnika (putnika) koji kombinira različite načine putovanja (u stvarnom vremenu). Platforma prikuplja podatke u stvarnom vremenu iz svih izvora prijevoza te na taj način pruža korisnicima širi

raspon mogućnosti, uključujući informacije o utjecajima na okoliš. Unutar projekta razvijen je i multimodalni putni planer orijentiran na krajnjeg korisnika i njegove potrebe [49].

Zahvaljujući naprednim tehnologijama i uslugama u okviru inteligentnih transportnih sustava, danas je dostupno sve više prometnih informacija u stvarnom vremenu. Shodno tome, neprihvatljivo je da putnici istražuju rute za svaku zemlju pojedinačno. Zbog toga je veoma bitno uspostaviti distribuirani sustav prekograničnih multimodalnih putnih planera.

U sklopu dunavskoga transnacionalnog programa (engl. *Danube Transnational Programme*), projekt *Linking Danube* imao je cilj provjeru inovativnog koncepta (engl. *Proof-of-Concept*) distribuiranih prekograničnih putnih planera koji pokrivaju urbana i ruralna područja. Linking Danube rješava problem pružanja prekograničnih informacija za putnike koji se koriste javnim prijevozom, osobito za prekogranična putovanja i ruralna područja. U skladu s tim, projekt je imao cilj poticati ekološki prihvatljive načine putovanja te uravnotežiti dostupnost u dunavskoj regiji. Projekt je poseban fokus usmjerio na manje dostupna područja u dunavskoj regiji povezivanjem alternativnih usluga javnog prijevoza te integriranjem podataka o prijevoznoj potražnji. U tom smislu, integriranje informacija o uslugama prijevoza jedan je od ključnih zadataka projekata. Jedan je od glavnih rezultata projekta koncept (usluga) Linking Danube za transnacionalne, multimodalne usluge planiranja putovanja. Usluga će se nadograđivati na već postojeće sustave te će funkcionirati na decentralizirani način (putem otvorenog API sučelja) (Slika 7.), kako bi se osigurala visoka kvaliteta podataka [50].

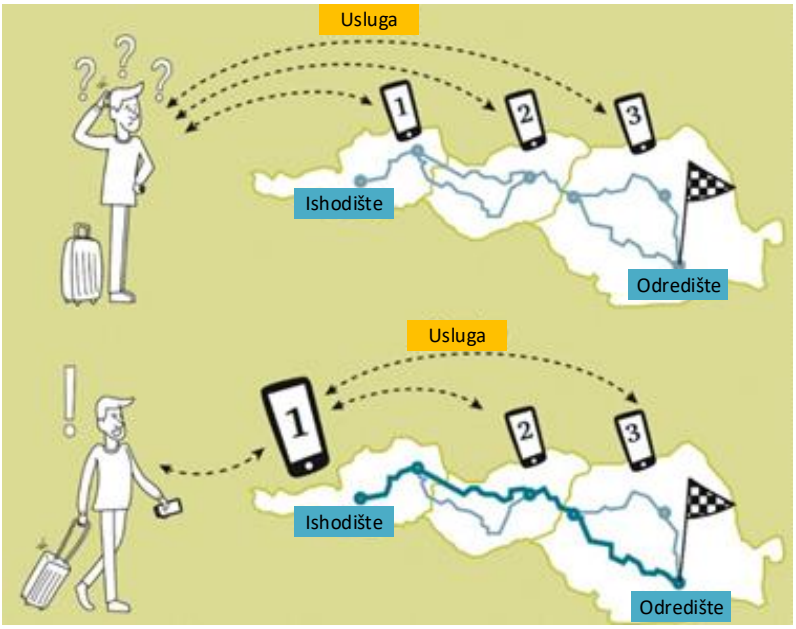

Slika 7. Metoda organiziranja prekograničnih multimodalnih putovanja (prilagodio autor) [50]

Aktualni projekt *Coordination mechanisms for multimodal cross-border traveller information network based on OJP for Danube Region* (OJP4DANUBE) nadogradnja je prethodnog projekta i proširenje na druge države, uključujući i Republiku Hrvatsku. Opći je cilj projekta uspostaviti ekološki prihvatljiv i siguran transportni sustav s dostupnošću urbanih i ruralnih područja. Konkretnije, cilj je uvesti mehanizme za bolju koordinaciju prijevoznika i pružatelja usluga putnih informacija kako bi integrirali svoje usluge planiranja putovanja. Osim toga, u okviru projektnih aktivnosti istražuje se mogućnost personaliziranog izbora prekograničnog putovanja, zasnovanog na distribuiranoj arhitekturi. Poseban naglasak usmjeren je na željezničke koridore te njihovo povezivanje s biciklističkim rutama u uslugu prekograničnog planiranja putovanja. Jedna od važnih projektnih aktivnosti jest i diseminacija rezultata projekta, odnosno odgovarajući prijenos znanja u zemlje zapadnog Balkana (Bosna i Hercegovina, Crna Gora, Srbija i Sjeverna Makedonija), kao i Moldaviju [51].

3.2. Pregled i analiza multimodalnih putnih planera

3.2.1. Teoretski koncept multimodalnih putnih planera

Multimodalni putni planeri predstavljaju dio ITS-a i nude niz usluga u domeni prijevoza putnika. Temeljna zadaća sustava jest odgovoriti na pitanje korisnika *Kako mogu doći iz mjesta A u mjesto B u određenom vremenu polaska/dolaska i pod kojim uvjetima?*. Sustav u principu sadržava putne i prometne informacije, kao što su: lokacije stajališta, polasci i dolasci prijevoznih sredstava (koji su integrirani u sustav, npr. tramvaj, metro, autobus itd.), mogućnosti kupnje karata, eventualne incidentne situacije, općenito o stanju u prometu itd. Za razliku od statičkih sustava informiranja, dinamički sustavi omogućuju pravovremenu odluku pri izboru načina i ruta putovanja [26], [30].

Prikladnu definiciju multimodalnih planera putovanja iznijeli su Gentile i Nökel [52], [53]: „Ovi sustavi putnicima pružaju najbolji plan puta prema nekoliko parametara koji karakteriziraju multimodalni putnički prijevoz. Multimodalni planeri putovanja pružaju bolju modalnu integraciju i veću održivost omogućujući putnicima da odaberu najprikladniju kombinaciju načina prijevoza za putovanje i mogli bi dovesti do veće upotrebe javnog prijevoza, vožnje biciklom ili pješačenja u urbanom okruženju.“

Niz je prednosti primjene multimodalnih putnih planera [54]; promiču održive načine putovanja, a sukladno tome utječu i na promjenu putničkih obrazaca putovanja te pridonose integraciji načina prijevoza u neprekinute lance putovanja. Moguće je na sveobuhvatan i jednostavan način informirati se i kombinirati načine putovanja (s naglaskom na održive) te javni prijevoz na taj način učiti atraktivnim i konkurentnim.

Multimodalne putne informacije pružaju dinamičke, stvarnovremenske informacije koje integriraju više načina dostupnoga javnog prijevoza (tramvaj, metro, autobus, vlak, pješačenje itd.). Korisnik, u tom pogledu, kreira sebi prilagođeno putovanje. Ranija istraživanja definirala su multimodalno informiranje u tri faze: informiranje prije putovanja, tijekom putovanja i nakon putovanja [26], [30]. Samim time, postoje različite fizičke lokacije na kojima se pojedinac može nalaziti kad donosi odluku o putovanju, a korištenjem multimodalnoga sustava informiranja, ovisno o informacijama, može promijeniti odluku, odnosno obrasce ponašanja tijekom putovanja.

Kad je riječ o urbanim sredinama, multimodalne informacije su vrlo značajne jer povećavaju udio korištenja javnog prijevoza te drugih „zdravih“ načina, kao što su pješačenje i biciklizam, mikromobilnost i dr. [30], [52], [53]. Multimodalne putne informacije promiču

mobilnost kod svih skupina korisnika, a posebice kod skupine korisnika s invaliditetom ili smanjenom pokretljivošću, dajući im informacije o objektima i podršku na prometnim čvorištima. Posebna vrsta korisnika multimodalnih putnih planera su turisti. Oni se mogu voditi dodatnim kriterijima odabira rute putovanja, koja, primjerice, može uključivati izbor rute koja uključuje različite atraktore (privlačna mjesta, POI i sl.). Sve to upućuje na široke mogućnosti izbora kriterija i njihov personalizirani karakter [30]. U skladu s tim, planeri omogućuju putnicima bolju informiranost pri izboru načina putovanja, dopuštajući izbor najprikladnije opcije za svoje potrebe te, u konačnici, omogućuju uspješan završetak putovanja.

Putni planeri nude mogućnost unimodalnoga i multimodalnoga planiranja putovanja (Slika 8.). U tom pogledu, unimodalni planeri generirat će višestruke opcije za biranu rutu, ali s jednim načinom javnog prijevoza, dok će kod multimodalnoga putovanja biti dostupne višestruke opcije ruta, gdje će svaka ruta sadržavati kombinaciju načina putovanja prema izabranim kriterijima.

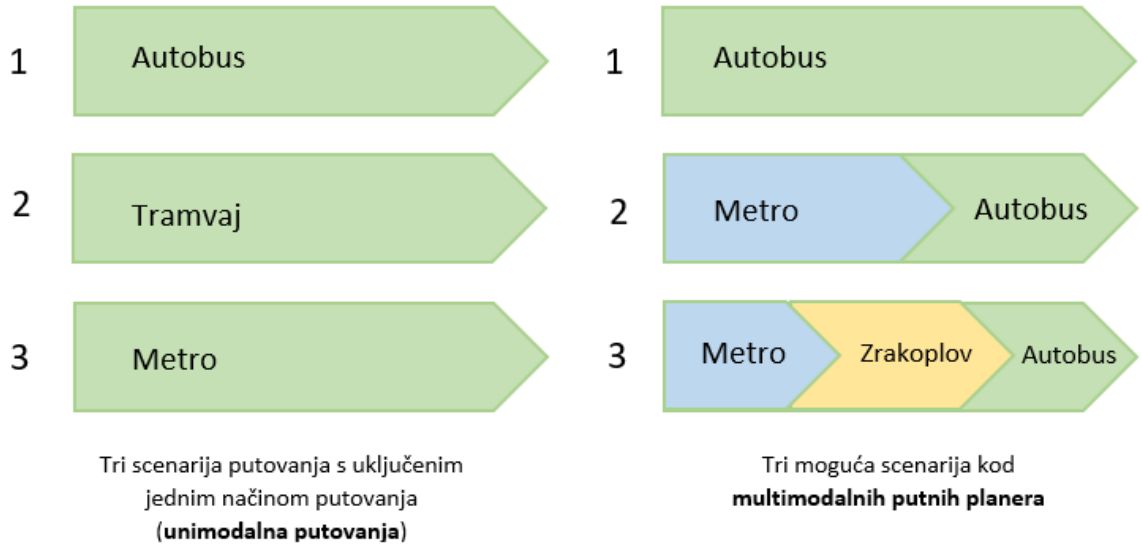

Slika 8. Konceptualna razlika ponuđenih opcija unimodalnih i multimodalnih putovanja (prilagodio autor) [39]

Pojedinačni informacijski sustavi potpore putnicima mogu se podijeliti na [27]:

- alate za usluge rutiranja
- planere putovanja
- savjetnike za putovanja.

Alati za usluge rutiranja pomažu putnicima tijekom putovanja slijediti zadanu rutu, dok planeri putovanja i savjetnici putovanja mogu pružiti skup rangiranih alternativa ruta generiranih prema skupu kriterija. Savjetnici za putovanja razlikuju se od planera putovanja uglavnom po tome što omogućuju interakciju s korisnikom radi predlaganja različitih preporuka o putovanju po mjeri putnika. Štoviše, planeri putovanja i savjetnici za putovanja mogu se podijeliti prema pristupu koji se upotrebljava za generiranje ruta [27]:

• **Temeljeni na pravilima** (engl. *Rule-based*), tj. odnose se na selektivni pristup u kojem se primjenjuje skup filtara koji mogu smanjiti skup izbora svih izvedivih putova kako bi se uklonili općenito neprihvaćeni putovi (npr. oni koji prelaze maksimalno vrijeme hodanja ili udaljenost, broj presjedanja, pristupačnost); takva pravila može definirati prijevoznik i/ili korisnik;

• **Temeljeni na prioritetu „subjektivnog" vremena putovanja** (engl. *Weighted Time-based*), tj. odnose se na rute koje uključuju analizu svih elemenata utrošenog vremena (kao što su pristup, čekanje, presjedanja i slično), s težinskim faktorima koje može definirati prijevoznik i/ili korisnik;

• **Temeljeni na korisnosti** (engl. *Utility-based*), temelje se na funkciji korisnosti rute koja se računa za svaku alternativu. Vrijednosti kriterija za pojedine atribute koji opisuju rutu, koje treba otkriti, mogu biti prosječne vrijednosti primijenjene na grupe korisnika (npr. mlađa populacija, umirovljenici i sl.) ili mogu biti pojedinačno prilagođeni na temelju osobnih putničkih preferencija (osobni preporučiteljski sustavi za putnike).

Upotreba informacijskih sustava potpore putnicima u stvarnim uvjetima ima čitav niz problema, [55] poput nepostojanje i neažurnost informacija za pojedina prijevozna sredstva (presjedanja, vrijeme čekanja), nedostatak integracije usluge planiranja i personalizacije, problemi pri presjedanju s jednog prijevoznog sredstva na drugo prijevozno sredstvo (osobito pri prelascima s podzemnih podsustava na površinske podsustave javnog prijevoza) itd. Važno je istaknuti da korist od multimodalnih putnih informacija i usluga za planiranje putovanja ima i šire gospodarstvo zemlje, u smislu pružanja novih poslovnih prilika za pružatelje usluga i otvaranja novih radnih mjesta u vrlo dinamičnom sektoru. Uvođenje novih sustava

informiranja i naplate prijevoza predstavlja važan korak prema kvalitetnijem transportnom sustavu.

3.2.2. Pregled i analiza multimodalnih putnih planera

Na području EU-a čitav je niz aktivnih multimodalnih putnih planera s različitim funkcionalnostima. Većina sadrži osnovne funkcije/kriterije za izbor multimodalne rute, a malo koji je u potpunosti korisnički orijentiran, tj. personaliziran [56]. S obzirom na značajke multimodalnoga koncepta putovanja, evidentna je potreba za *user-friendly*, korisnički orijentiranom platformom putnog informiranja.

Multimodalni putni planer jedna je od ključnih tema prometnih strategija EU-a, s ciljem realizacije održive urbane mobilnosti. S obzirom na veliki broj multimodalnih putnih planera (s različitim funkcionalnostima) na području Europske unije (urbanih i regionalnih), neophodno je dati pregled i ustanoviti koji je multimodalni putni planer najprikladniji, uzimajući pritom u obzir zahtjeve korisnika.

Za potrebe ovog istraživanja, pregled i analiza multimodalnih putnih planera napravljeni su na temelju postojećih istraživanja. U radovima [39], [52] ocijenjeni su, uspoređeni i rangirani multimodalni putni planeri te je na taj način prikazano stanje kvalitete usluge postojećih multimodalnih putnih planera na području EU-a.

Prema [52], dan je pregled europskih putnih planera na temelju predloženog okvira kriterija i potkriterija, uzevši u obzir perspektivu korisnika i njihovo zadovoljstvo uslugom. Istraživanje je obuhvatilo putne planere na području EU-a, koji se masovno rabe i koji su popularni među krajnjim korisnicima (putnicima). Definiran je okvir kriterija te su grupirani u četiri kategorije: usluga putnog planiranja, rezerviranje i naplata putovanja, tip obrađenih podataka i dodatne informacije.

Autori u radu [39], drukčijim pristupom vrednovanja analiziraju putne planere na području EU-a, a cilj istraživanja bio je identificirati postojeće aplikacije za planiranje putovanja, utvrditi značajke visoke razine usluge za svaki izabrani putni planer, ispitati upotrebljivost putnog planera, utvrditi konačnu kvalitetu usluge putnog informiranja te izdvojiti preporuke najbolje prakse. Odabrano je dvadeset aplikacija za planiranje putovanja koje su ocijenjene korištenjem metoda usporedne analize s naglaskom na tri kategorije kriterija: funkcionalnost, upotrebljivost i popularnost (iz perspektive korisnika). U nastavku su opisana četiri multimodalna putna planera koji su ostvarili visoke ocjene u spomenutim istraživanjima [39], [52]. Uz najbolje

ocijenjene multimodalne putne planere iz spomenutih istraživanja, opisana su još dva multimodalna putna planera koja se primjenjuju na području grada Beča i Helsinkija.

Multimodalnom putnom planeru DB Navigator (Slika 9.) dodijeljena je najviša ocjena prilikom vrednovanja od strane eksperata i korisnika [52]. Planer je primjenjiv za lokalni, regionalni i međugradski prijevoz na području Njemačke, ali i šire. Aplikacija objedinjuje željeznički, tramvajski i autobusni podsustav te nudi uslugu poput iznajmljivanja bicikala *Call-a-bike* (na stajalištima javnog prijevoza) te uslugu *shuttle*-prijevoza. Osim toga, nudi mogućnost rezervacije i kupnje karata te opciju pronalaženja najprikladnije karte za korisnika. Unutar aplikacije moguće je kreirati profil, označiti i pohraniti plan putovanja te primati odabrane obavijesti [57].

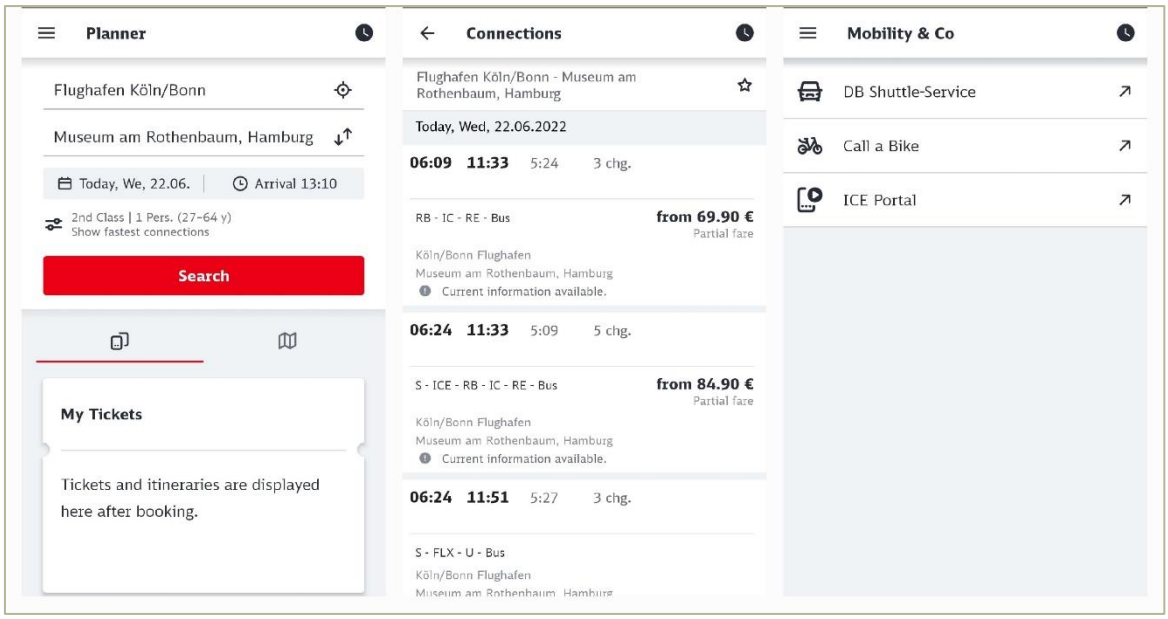

Slika 9. Prikaz sučelja multimodalnoga putnog planera DB Navigator [57]

Za urbano područje Budimpešte implementiran je **multimodalni putni planer BKK FUTÁR** [58] kojem je prema mišljenju eksperata [52] dodijeljena visoka evaluacijska ocjena. Planeru je moguće pristupiti putem *web*-sučelja te putem mobilne aplikacije (Slika 10.). Planer pruža širok spektar mogućnosti koje izravno utječu na korisnički doživljaj te kvalitetu putovanja (naročito pri multimodalnome putovanju). Planer obuhvaća sve prisutne načine javnog prijevoza na području Budimpešte (tramvaj, trolejbus, autobus, metro, bicikli, brodske linije). Sadržaj na karti je interaktivan (statičke i dinamičke informacije) te na taj način upotpunjuju *user-friendly* doživljaj. Personalizacija je prisutna u pogledu opcije izbora mjesta od interesnog značaja (npr. početna stanica javnog prijevoza za željeno odredište), kako bi joj se moglo brže pristupiti. Osim toga, integrirane su lokacije „MOL Bubi" bicikala za iznajmljivanje te lokacije automata za prodaju karata. Planer sadrži skup dinamičkih informacija (polasci, dolasci, čekanja) te je na taj način omogućeno planiranje putovanja u stvarnom vremenu. Planiranje putovanja prilagođeno je osobama s invaliditetom (npr. informacija o niskopodnim vozilima). U međuvremenu, u okviru koncepta MaaS, razvila se i postavljena je u funkciju **aplikacija BudapestGO** s dodatnim funkcionalnostima koje promiče MaaS koncept (Slika 10.). Planer se kontinuirano nadograđuje, a dugoročno se planira integracija dodatnih usluga prijevoza na području Budimpešte. U trenutačnoj verziji planera dostupna je kupnja karata, automatsko obnavljanje jedinstvene (mjesečne) prijevozne karte, kupnja pojedinačne karte, informacije o stanju u prometu, personalizacija u vidu *push* poruka, pojednostavljeno, *user-friendly* sučelje itd. U kreiranju funkcionalnosti planera posebna pozornost posvećena je zahtjevima slabovidnih osoba te osobama s invaliditetom.

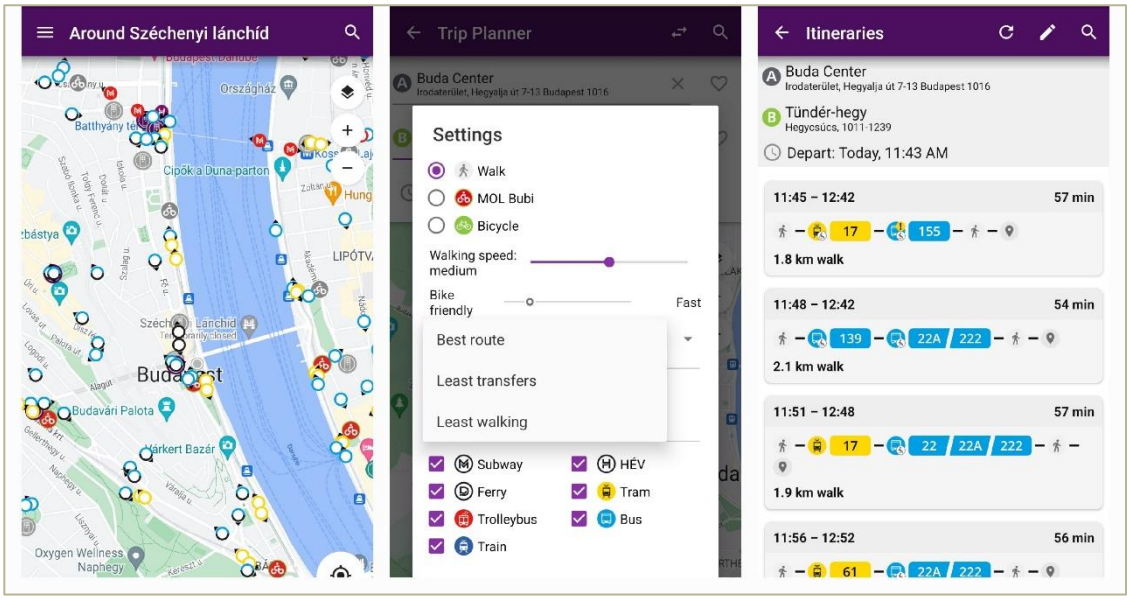

Slika 10. Prikaz sučelja multimodalnoga putnog planera BudapestGO [59]

Multimodalni putni planer Citymapper [60] opće je primjenjiv za niz europskih i američkih gradova (Slika 11.). Aplikacija pruža kreiranje multimodalnih putovanja uz spektar funkcija koje upotpunjuju doživljaj i zadovoljstvo krajnjom uslugom. Usluga pruža *step-by-step* upute tijekom putovanja, što je osobito bitno pri multimodalnim putovanjima zbog složenosti sustava (prijelaz na drugi način putovanja, čekanja itd.). Aplikacija daje prikaz vozarina za načine prijevoza, a u planiranje putovanja uključene su i platforme: Uber, Lyft, City Bike, GREEN Bike itd. Osim toga, aplikacija nudi mogućnost personalizacije korisničkog profila na principu pohranjivanja omiljenih ruta, stajališta itd. Pretplatiti se može na informacije za određeni način putovanja te je na taj način moguće primati informacije za odabrane stavke. Lokaciju je moguće dijeliti putem društvenih mreža te svojim izabranim proflilima/kontaktima. Multimodalni putni planer dostupan je i za područje Grada Zagreba.

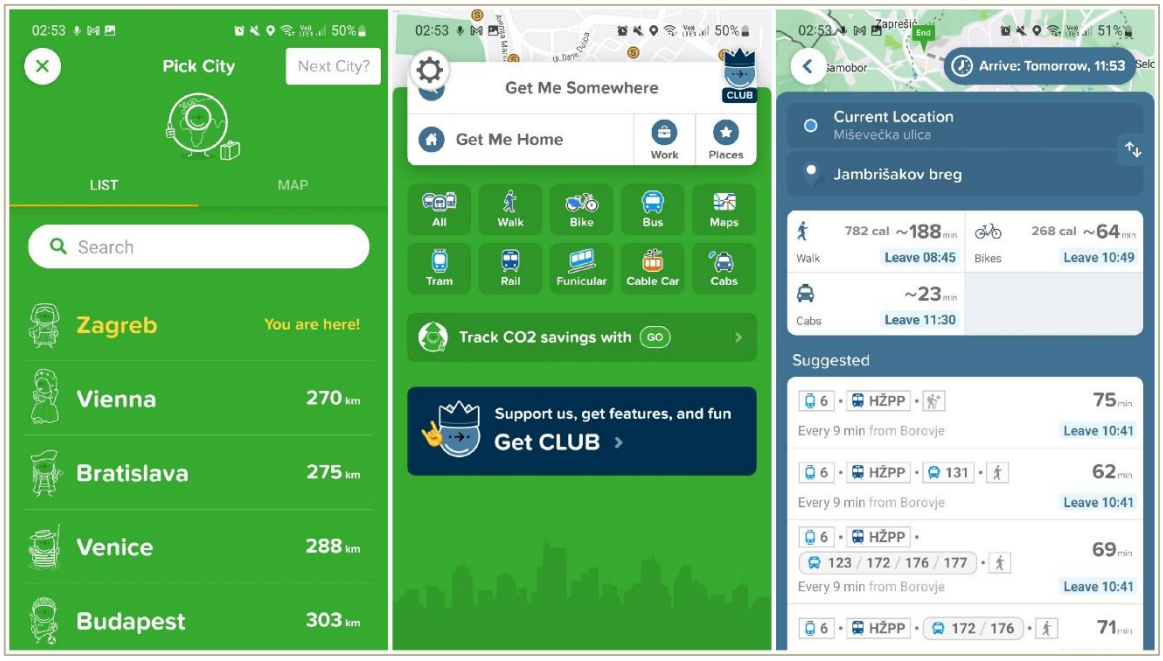

Slika 11. Prikaz sučelja multimodalnoga putnog planera Citymapper [61]

Usluga putnog planiranja TripGo [62] predstavlja uslugu podrške planiranja putovanja, a razvijena je unutar koncepta MaaS (Slika 12.). Planer je ocijenjen visokom ocjenom od strane eksperata [39], [52], a korištenje je rasprostranjeno i na području EU-a. Usluga nudi mogućnost multimodalnoga planiranja, i to kombiniranjem načina lokalnoga javnog prijevoza s osobnim automobilima i drugim načinima javnog prijevoza, poput taksija, sustava dijeljenja automobila, bicikala itd. Kao dodatnu, djelomično personaliziranu, funkcionalnost usluga nudi podsjetnik, tj. kreiranje dnevnog rasporeda aktivnosti povezanog s putovanjima predviđenim za taj dan te najprikladnije rute za korisnika. Osim toga, unutar aplikacije moguće je provjeriti vozne redove, notifikacije, odnosno upozorenja o događajima na ruti, trošak putovanja (vozarine, tarife) itd. TripGo pruža stvarnovremenske putne informacije kao što su: vrijeme polaska/dolaska prijevoznih sredstava, GPS lokacije prijevoznih sredstava itd. Usluga je dostupna na 200 lokacija širom svijeta, a vizija davatelja usluge jest daljnje proširenje ovog tipa podrške prije i tijekom putovanja.

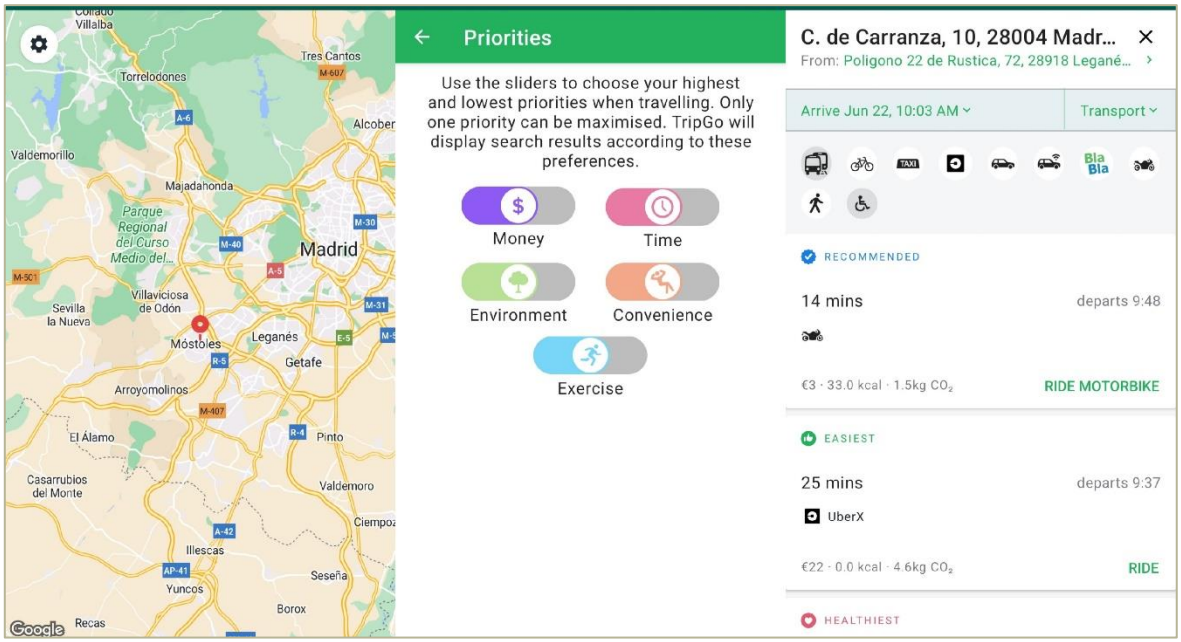

Slika 12. Prikaz sučelja multimodalnoga putnog planera TripGo [62]

Jedan od prioritetnih prometnih ciljeva grada Helsinkija (Finska) jest smanjiti stupanj motorizacije, tj. potaknuti prijelaz s osobnog automobila na sustave održivijeg načina putovanja. Kako bi se uopće potaknuo taj prijelaz, nužno je ponuditi dovoljno fleksibilnu, jednostavnu, brzu i cjenovno pristupačnu uslugu koja će konkurirati još uvijek dominantnijem načinu prijevoza – osobnom automobilu. Na području Helsinkija (Finska) dostupna je **aplikacija Whim** [63] koja predstavlja treću razinu integracije MaaS-a, ujedno i najvišu razinu dostupnih aplikacija (Slika 13.). Usluga je namijenjena već poprilično profiliranoj skupini korisnika koji inkliniraju multimodalnim putovanjima. Aplikacija pruža niz značajki i širok raspon dostupnih usluga mobilnosti – od javnog prijevoza (ponuda multimodalne mobilnosti je raznolika) do sustava dijeljenja bicikala, taksi-usluge, usluge dijeljenja automobila te konvencionalne usluge automobila za najam [64]. Za visoku razinu integracije i kolaboracije među dionicima, ključan korak bio je otvaranje i dijeljenje podataka između davatelja usluge prijevoza i ostalih uključenih aktera u proces pružanja usluge mobilnosti. Takvim otvorenim pristupom omogućena je i personalizacija usluge koja predstavlja dodanu vrijednost za krajnjeg korisnika. Whim aplikacija dostupna je još u Beču, Antwerpenu, Turku (Finska), Tokiju, na području Švicarske i u Birminghamu [65].

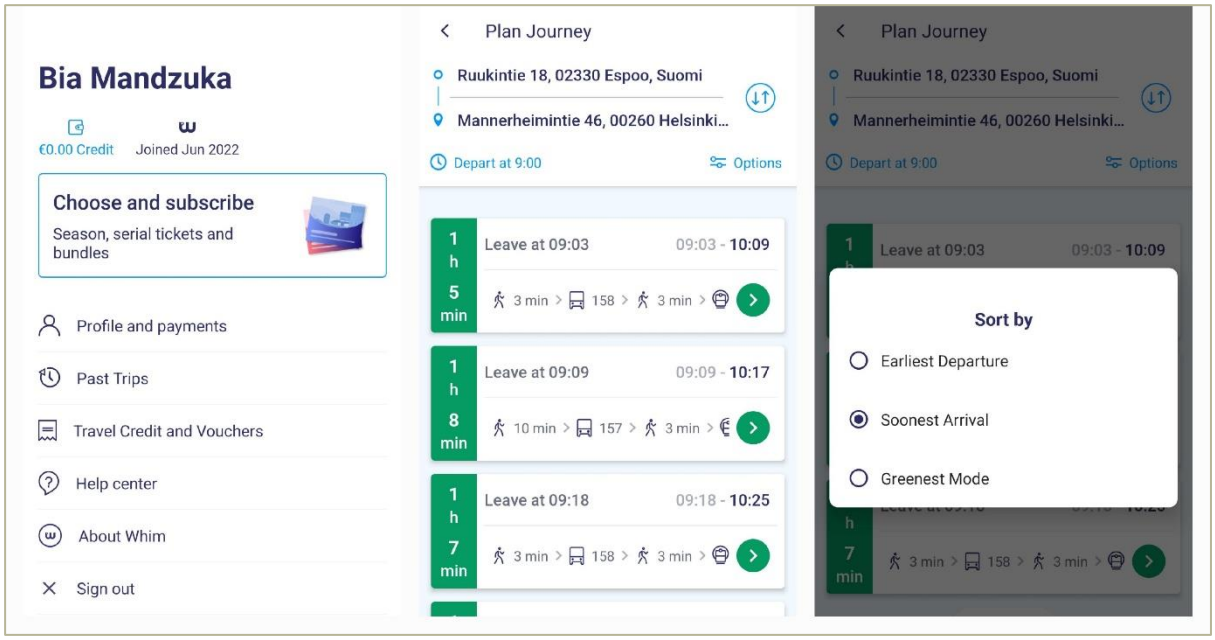

Slika 13. Prikaz sučelja multimodalnoga putnog planera Whim [66]

Na području grada Beča u funkciji je **multimodalni putni planer WienMobil**. Razvoj multimodalnoga putničkog informiranja na području Beča (Austrija) započeo je 2010. godine u sklopu Numo projekta te su na taj način postavljeni temelji za daljnje aktivnosti razvoja i implementacije. Pilot projekt Smile, u trajanju od tri godine (završno s 2015. godinom), povezao je dva glavna dionika za javni prijevoz – glavnog operatera javnog prijevoza (Wiener Linen) i nacionalnoga željezničkog operatera (ÖBB) [64]. To su bili ključni koraci za uspostavljanje sadašnje usluge mobilnosti pod nazivom WienMobil kojom upravlja WienerLinen. Aplikacija nudi svojim korisnicima informacije o svim prijevoznim sredstvima na području grada Beča putem multimodalnoga putnog planera, a odnedavno je dostupna i integrirana usluga električnih skutera i mopeda. Ono što je značajno za krajnje korisnike, a vezano je za zaštitu osobnih putničkih podataka, jest mogućnost odobrenja prikupljanja podataka GPS-a koji se pritom anonimiziraju. Aplikacija je ocijenjena drugom razinom integracije prema MaaS taksonomiji. Drugim riječima, za pojedine usluge mobilnosti informacije su dostupne na razini odabrane rute te se nudi mogućnost povezivanja putem poveznice prema partnerskim aplikacijama [64]. Na Slici 14. prikazano je sučelje WienMobil aplikacije.

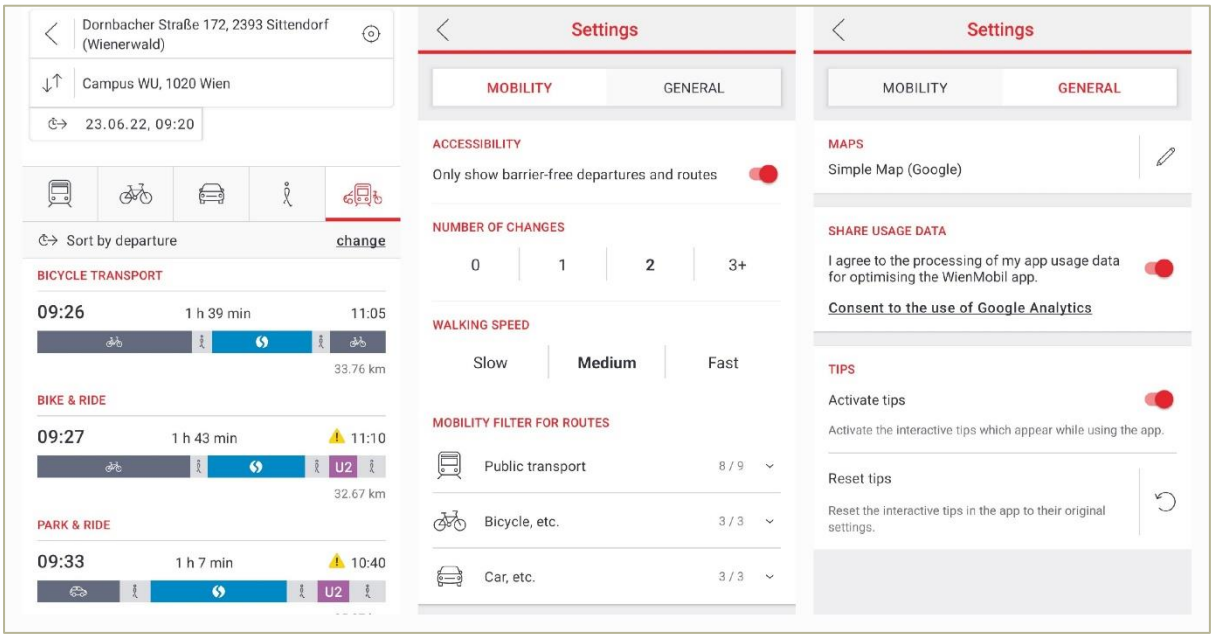

Slika 14. Prikaz sučelja multimodalnoga putnog planera WienMobil [67]

Primjer prekograničnog planiranja putovanja rješavan je u projektu Linking Danube. Rutiranje putovanja kreirano je putem otvorenih sučelja i usklađenih metapodataka. Različite se tehnike upotrebljavaju kad se optimiziraju kontinuirani itinereri kako bi se najbolje zadovoljila potražnja krajnjih korisnika. Proces planiranja putovanja podijeljen je u nekoliko faza planiranja (Slika 15.). Najprije aplikacija klijenta šalje *Zahtjev za putovanje* svom domicilnom sustavu, odnosno njegovu distribuiranom putnom planeru (engl. *Distributed Journey Planner* – DJP). DJP proslijedi *Zahtjev za planiranje putovanja* odgovarajućim sustavima u pojedinim državama (tzv. lokalni sustavi za rutiranje putovanja). Svaki lokalni sustav predlaže rutu (ili skup alternativa) za svoju državu te ih prosljeđuje sustavu države koja je pokrenula *Zahtjev za planiranje putovanja.* Taj sustav na kraju spaja sve pojedinačne rute (po državama) u jedinstvenu rutu, koju prosljeđuje korisniku koji je pokrenuo *Zahtjev za putovanje*.

Postoje neke pretpostavke za pristup distribuiranom planiranju putovanja [50], [68]:

- Sustav distribucije može podijeliti izvorni zadatak na odgovarajuće podzadaće.
- Distribucijski sustav zna od kojih se domicilnih sustava pojedinih država mogu očekivati rješenja za navedene podzadaće.
- Sustav distribucije poznaje točke razmjene (obično u blizini granica država) koje će povezati dijelove cjelokupnog putovanja.

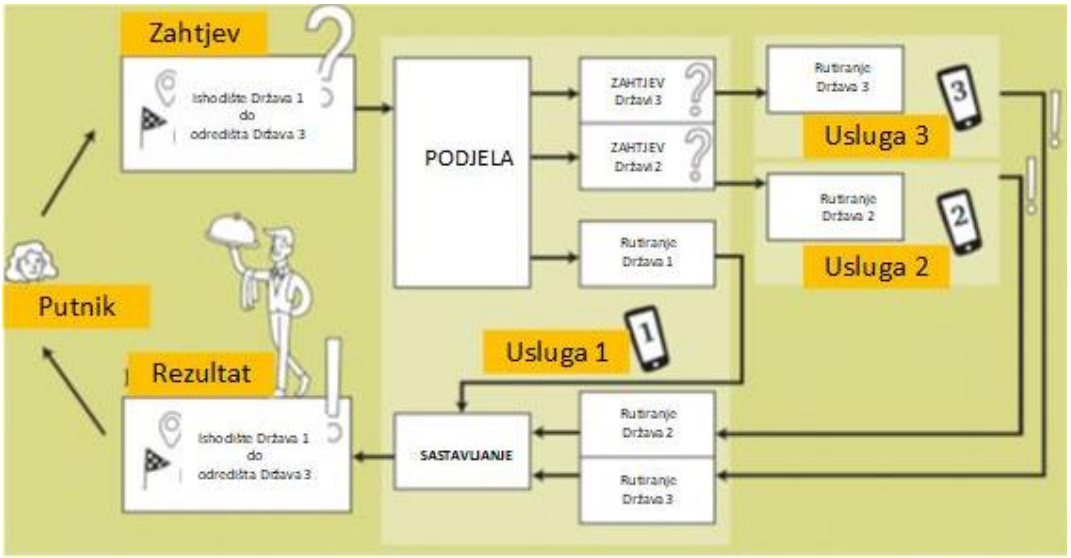

Slika 15. Planiranje putovanja korištenjem prekograničnoga multimodalnoga putnog planera (prilagodio autor) [50]

3.3. Uloga i značaj otvorenih podataka kod multimodalnih putnih planera

Otvoreni podaci (engl. *Open Data* – OD) mogu se opisati kao podaci koji su dostupni bez financijskih i pravnih ograničenja. Koncept otvorenih podataka snažno je povezan s inovacijom i transformacijom, osobito kad je riječ o integriranju otvorenih podataka u inovativna digitalna rješenja [69].

Otvorenost i dostupnost podataka jedan je od izazova u uspostavljanju održivih urbanih sredina i omogućavanju pametnih usluga. Kao što je spomenuto, paradigma pametnoga grada zasnovana je na ideji povezanoga, otvorenoga grada gdje su stanovnicima omogućene i transparentne brojne usluge i sadržaji. Jedan od ključnih čimbenika uspostavljanja pametnih gradova jest otvorenost podataka. Umreženo tkivo pametnoga grada generira veliku količinu podataka (engl. *Big Data* – BD) putem različitih privatnih i javnih izvora kao što su senzori, kamere, pokretne i nepokretne telekomunikacijske mreže, pametne prijevozne karte, društvene mreže i dr. [70]–[72]

Velika količina prometnih podataka prikuplja se u stvarnom vremenu te se prometni sektor transformira iz podatkovno oskudnog u podatkovno bogati sektor. Podaci o putovanjima u stvarnom vremenu danas mogu poslužiti prijevoznim operaterima, i to radi pružanja prijevozne usluge koja će pratiti potražnju i ostale potrebe putnika u spektru urbane mobilnosti [73]. Akteri koji su zaduženi za uspostavljanje i pružanje usluga mobilnosti, otvaranjem ključnih podataka mogu dobiti konkretnu sliku o korisnicima te bolje razumjeti njihove obrasce putničkog ponašanja, potrebe i aspiracije. Pristupom otvorenih i dijeljenih prometnih podataka, moguće je personalizirati usluge poput multimodalnih putnih planera, povećati pristupačnost usluge javnog prijevoza te poboljšati operativnu učinkovitost prometnog sustava u cjelini. Osim toga, otvaranje i dijeljenje prometnih podataka otvara niz novih mogućnosti u području inovacije usluga te novih poslovnih modela u području urbane mobilnosti.

Otvorenost podataka je ključna u omogućavanju kvalitetnoga multimodalnoga putnog informiranja. U dokumentima EU-a identificirano je šest glavnih vrsta problema kvalitete podataka, poput nedostatka cjelovitosti podataka, nedostatka istinitosti (ondje gdje podaci ne odražavaju „istinito“ stanje), nedostatka preciznosti (gdje podaci o lokacijama ili vremenskim okvirima nisu dovoljno detaljni da bi se pružile korisne informacije) itd. Jedan od izazova odnosi se i na dostupnost podataka i/ili informacija [74].

Bez otvorenosti i dostupnosti prometnih podataka, sustavi multimodalnoga putnog planiranja ne mogu biti u potpunosti korisni, a samim time i atraktivni za krajnjeg korisnika – putnika. Prema direktivama EU-a, svaka država članica uspostavlja nacionalnu pristupnu točku

(engl. *National Access Point* – NAP) koja će predstavljati jedinstvenu pristupnu točku za pristup putnim podacima (statičkim i u stvarnom vremenu) različitih načina prijevoza [74]. Nacionalna pristupna točka za multimodalne informacije (engl. *National Access Point for Multimodal Information* – NAPMM) definira se kao digitalno sučelje gdje su statički podaci o putovanju i povijesni prometni podaci, zajedno s odgovarajućim metapodacima, dostupni za ponovnu upotrebu ili gdje su izvori i metapodaci tih podataka dostupni za ponovnu upotrebu. NAPMM pokriva različite načine prijevoza, kao što su cestovni, zračni, željeznički, prijevoz vodnim putem, vožnja biciklom i hodanje.

Delegirana uredba 2017/1926 [75] definira da se multimodalne putničke usluge informiranja temelje na statičnim i dinamičnim podacima o putovanju i prometu, pri čemu *dinamični podaci o putovanjima i prometu* označavaju podatke koji se odnose na različite načine prijevoza koji se često redovito mijenjaju (npr. smetnje i kašnjenja). Takvi podaci omogućuju krajnjim korisnicima donošenje dobro informiranih odluka o putovanju. Druga vrsta podataka su *statični podaci o putovanju i prometu,* koji označavaju podatke koji se odnose na različite načine prijevoza koji se uopće ne mijenjaju ili se ne mijenjaju često. Takvi podaci potrebni su za informiranje i planiranje putovanja – prije putovanja. Na Slici 16. prikazani su korisnici Nacionalne pristupne točke. U tom smislu, korisnike predstavljaju bilo koji javni ili privatni subjekt koji upotrebljavaju Nacionalnu pristupnu točku, kao što su tijela nadležna za promet, prijevoznici, pružatelji informacija o putovanjima, proizvođači digitalnih zemljopisnih karata, pružatelji usluga prijevoza na zahtjev i upravitelji infrastrukture. S druge strane, postoje i krajnji korisnici, odnosno bilo koja fizička ili pravna osoba koja ima pristup informacijama o putovanjima [76], [77].

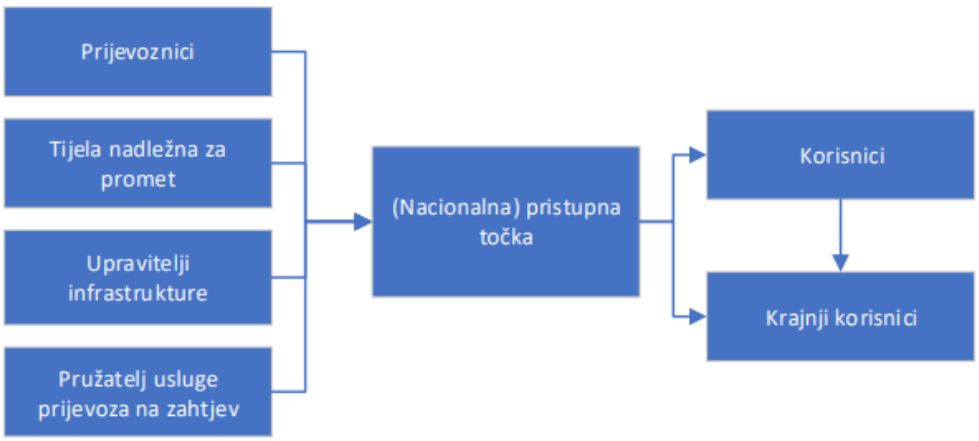

Slika 16. Dionici nacionalne pristupne točke [77]

Pristup prometnim podacima i podacima o putovanju još uvijek izaziva podijeljena mišljenja te postoje određeni problemi i barijere u kontekstu realizacije otvorenog pristupa. S jedne strane, prisutan je problem etičnosti prikupljanja i korištenja putničkih podataka. Naime, putnički podaci ujedno su i osobni podaci te su kao takvi označeni kao osjetljiva skupina podataka. Prema GDPR-u, osobni podaci su specifični dijelovi informacije o osobi koja se putem njih može identificirati, kao što su ime i lokacija. Na području Republike Hrvatske ne postoje iskustva anonimizacije [78] osobnih (putničkih) podataka, a shodno tome ni pripadajuća tehnologija. Osim toga, potrebno je podignuti svijest i potaknuti transparentnu komunikaciju o važnosti korištenja otvorenih podataka među svim dionicima prometnog sustava.

U podizanju svijesti o važnosti i interdisciplinarnoj komunikaciji te jačanju znanstvene izvrsnosti i inovacijskog kapaciteta u području otvorenih podataka, značajnu ulogu ima aktualni projekt Obzor 2020 *Twinning Open Data Operational* (TODO 2019-2022). Projekt je, između ostalog, usmjeren na uspostavljanje okruženja za istraživanje otvorenih podataka koje će olakšati i potaknuti interdisciplinarna multidomenska istraživanja otvorenih podataka unutar Sveučilišta u Zagrebu (pet sastavnica) i izvan njega, Tehnološkog sveučilišta Delft (Nizozemska) i Egejskog sveučilišta (Grčka), koji su među najistaknutijim svjetskim istraživačkim centrima za otvorene podatke [79].

Otvaranje i dijeljenje podataka o putovanju (i ostalih povezanih podataka) radi povećanja personalizacije i dostupnosti, može povećati kvalitetu prijevozne usluge i zadovoljstvo krajnjih korisnika – putnika [80]. Suprotno tome, ako se osobni podaci koriste na način koji narušava povjerenje, to može stvoriti tzv. problem *data wastelands* gdje se podaci ne prikupljaju ili ne upotrebljavaju, ograničavajući potencijal prometnog sustava [73], [81]. Sukladno tome, potrebno je identificirati što korisnici očekuju od novih usluga mobilnosti (npr. multimodalni putni planeri) i načina prikupljanja (otkrivanja), korištenja i dijeljenja podataka o njima (putovanjima, putničkim obrascima, preferencijama).

Osim toga, postoje i određene tehničke barijere poput interoperabilnosti i međusobne kompatibilnosti putnih planera (ako je riječ o prekograničnim putovanjima). Zato je potrebno upotrebljavati usklađeni niz interoperabilnih formata za razmjenu podataka [76].

3.4. Putničko ponašanje pri planiranju putovanja

Kako bi se planirala, organizirala i ispostavila kvalitetna multimodalna prijevozna usluga, u obzir treba uzeti stvarne potrebe krajnjeg korisnika – putnika. Pri izboru multimodalnih ruta putovanja, putnici najčešće biraju rutu uzimajući u obzir kriterije poput ukupnog vremena putovanja, broja presjedanja, ukupnog vremena čekanja, mogućih kašnjenja (pouzdanost) te troška putovanja, koji ujedno opisuju kvalitetu prijevozne usluge te utječu na ukupno iskustvo (multimodalnoga) putovanja (engl. *Travel Experience*) [82]–[84].

Suvremeni korisnik danas očekuje puno više od aplikacije planiranja putovanja, primjerice, izbor plana putovanja koji je ekološki prihvatljiviji, koji prikazuje vremenske uvjete tijekom putovanja, stanje prometnica, pa sve do konkretnih, personaliziranih postavki [85].

Ponašanje putnika pri planiranju putovanja u, za to predviđenim, aplikacijama i *web*-sučeljima (naročito kod multimodalnoga putovanja) može se promatrati kroz tri aspekta [86]:

1. *Ponašanje pri pretraživanju*. Predstavlja ono što korisnici traže i ponašanje povezano s tim (npr. vrsta putovanja koja se pretražuje i prostorno-vremenski aspekti povezani s planiranjem putovanja).
2. *Ponašanje pri sortiranju/filtriranju preferencija*. Predstavlja ponašanje koje uključuje sortiranje/filtriranje određenih preferencija (npr. ekološki prihvatljivi načini prijevoza, trošak putovanja, gdje korisničko filtriranje daje jasan uvid u važnost kriterija, koji u konačnici generiraju putovanje/rutu prema očekivanjima korisnika).
3. *Ponašanje pri selekciji rute*. Izbor rute (plana putovanja) zasnovane na uključenim preferencijama.

Aktivnosti, a samim time i korisnički zahtjevi povezani s multimodalnim putovanjima često se dijele na dvije faze, prije putovanja i tijekom putovanja, a naknadno je dodana i treća faza – nakon putovanja (engl. *Post-trip Planning*), kojoj je cilj zaokružiti krajnju uslugu te ju na taj način učiniti kompletnom [87]. U tom smislu, kreiranje multimodalnoga plana putovanja, koji je zasnovan na preferencijama korisnika, ima potencijala povećati pouzdanost, odnosno atraktivnost javnog prijevoza iz perspektive krajnjeg korisnika – putnika.

3.5. Utjecaj naprednih sustava informiranja putnika na putnička ponašanja

Osim uvođenja naprednih tehničkih značajki, razvijanju personaliziranih multimodalnih putnih planera treba prethoditi identifikacija profila korisnika, njihovih stavova, motivacije, sustava vrijednosti i osobnih preferencija. Kroz prizmu psihologije i ostalih društvenih znanosti potrebno je razumjeti potencijalnog korisnika, odnosno njegovo *ponašanje u putovanju* (engl. *Travel Behaviour*). Prema [88] treba se koncentrirati na pitanje *Na koji način stavovi o takvom načinu putovanja te osobne preferencije utječu na korištenje naprednih sustava multimodalnoga informiranja?*. Ne manje važno, sklonost tehnologiji ili averzija može biti presudna za usvajanje i buduću upotrebu naprednog sustava informiranja.

Rezultati istraživanja [89] o preferencijama korištenja naprednoga multimodalnog sustava informiranja ukazuju da korisnici koji su skloniji korištenju tehnologije, tzv. *tehnofili* (engl. *Technophiles*), pozitivno reagiraju te pridaju veću važnost postojanju te kvaliteti naprednog sustava informiranja. Uzorak je uključio širok spektar ispitanika različitih karakteristika koje se odnose na njihove putne navike (preferencije pri izboru rute), demografske podatke, lokacije mjesta stanovanja i posla, značajke koje opisuju putovanje od kuće do posla te navike korištenja raspoloživih putnih informacija. Nadalje, rezultati istraživanja pokazali su da postoje određeni čimbenici koji su značajni prilikom odluke o korištenju multimodalnih putnih planera kao potpore korisnicima pri izboru multimodalnoga načina putovanja. To su, očekivano, snalaženje u samoj aplikaciji, tj. koliko je ona *user-friendly* za krajnjeg korisnika, ukupno vrijeme putovanja (na osnovi generirane multimodalne kombinacije) te ukupni trošak putovanja.

Ljudsko ponašanje je složeno te bi tehnološka rješenja trebala pratiti tu karakteristiku, ponuditi personaliziranu uslugu koja će pratiti ritam i dinamiku životnog stila korisnika. Kad je riječ o sustavu multimodalnoga planiranja, tada ključnu ulogu ima – informacija. Ako ona dolazi u pravom trenutku te ako je uvjerljiva i prilagođena korisniku – tada je i relevantna. Jedino tada ona može prouzročiti promjene u dosada uhodanim putnim navikama te generalno percepciji i prihvaćanju multimodalnoga putovanja.

Cilj istraživačkog projekta „Optimod'Lyon“ [90] bio je analizirati učinak multimodalnoga informiranja u stvarnom vremenu na ponašanje ispitanika prije i tijekom putovanja, tj. njihovo putno (multimodalno) ponašanje. Uzorak istraživanja [90] dizajniran je na temelju spola, dobi, stupnja obrazovanja, interesa, razine primanja, prisutnosti djece u kućanstvu, ustaljenih obrazaca putovanja (vrijeme putovanja, broj putovanja, korišteni načini prijevoza, ishodište i odredište putovanja). Uzorak je dizajniran da uključuje različite profile korisnika kako bi se bolje testirala sva moguća ponašanja i reakcije na upotrebu aplikacije. Specijalizirana agencija

izabrala je pedeset sudionika slijedeći definirani plan uzorkovanja. Istraživanje provedeno na uzorku slijedilo je kvalitativno-kvantitativni pristup zasnovan na dva alata – *web*-upitniku i fokus-skupini – koji su trebali funkcionirati na integrirani način. Rezultati su pokazali da nije bilo ograničenja u korištenju „Optimod'Lyona", sve dok su sudionici bili upoznati s radom aplikacije.

Uzorak koji uključuje ljude različite dobi, obrazovanja i profesije pokazao je kako se upotreba tehnologije u velikoj mjeri ogleda kroz socio-ekonomske karakteristike, što pokazuje široki prodor informacijsko-komunikacijskih tehnologija alata na tržište. Zapravo, porast popularnosti mobilnih uređaja i sveprisutna mreža transformiraju način života, primjerice, tijekom izvanrednih situacija mobilne aplikacije i društvene mreže imaju bolji učinak od tradicionalnih sustava pružanja informacija [87]. Razvoj napredne usluge putnog informiranja, koja je pritom korisnički orijentirana, zasigurno može potaknuti prekretnicu u promjeni ustaljenih obrazaca ponašanja prije i tijekom putovanja (osobito multimodalnih), potičući korištenje i kombinaciju održivih načina prijevoza.

Personalizacija usluge multimodalnoga putnog planiranja predstavlja način pomoću kojeg je moguće zadovoljenje potreba/želja krajnjeg korisnika, a najčešće se postiže na temelju prethodnog ponašanja korisnika tijekom korištenja usluge. U tom pogledu, društvene mreže mogu imati značajnu ulogu, npr. kod povratne informacije i profiliranja korisnika i njihovih individualnih preferencija.

4. IZBOR MULTIMODALNOGA PUTOVANJA KAO PROCES VIŠEKRITERIJSKOGA ODLUČIVANJA

Odlučivanje (engl. *Decision-making*) je sastavni dio svakodnevnih ljudskih aktivnosti. Teorija odlučivanja predstavlja zasebnu znanstvenu disciplinu i ima značajnu ulogu u područjima koja istražuju i objašnjavaju ljudsko ponašanje, kao npr. psihologija, sociologija, filozofija, ekonomija, antropologija itd. U literaturi koja obrađuje područje teorije odlučivanja nailazi se na velik broj definicija koje opisuju proces odlučivanja.

Odluke donosimo svakodnevno, kako privatno, tako i poslovno. Za odlučivanje je temeljni preduvjet da postoji više mogućih odluka, koje nazivamo inačicama ili alternativama. Osim toga, posebno je potrebno naznačiti distinkciju između dva oblika donošenja odluka: eksperata u nekoj domeni i neeksperata (običnih ljudi u svakodnevnom životu). U nastavku je dân pregled uobičajenih definicija odlučivanja.

> Odlučivanje bi se moglo definirati kao izabiranje smjera odnosno načina djelovanja između više inačica [91], [92].

> Odlučivanje je proces stvaranja i procjenjivanja inačica, kao i proces izbora između više inačica [92], [93].

> Odlučivanje je proces identifikacije skupine mogućih inačica i izbor najpovoljnije od njih [92].

> Odlučivanje je proces rješavanja problema. Analogno tome, onaj tko odlučuje, mora uvidjeti problem. S obzirom na sposobnost odlučivanja, donositelji odluka mogu pripadati ovim tipovima ljudi: a) tip koji „ne zna da ne zna“, b) tip koji „zna da ne zna“, c) tip koji „ne zna da zna“ i d) tip koji „zna da zna“ [92], [94].

4.1. Klasifikacija teorija odlučivanja

Postoji nekoliko klasifikacija teorija odlučivanja (Slika 17.), no najšire prihvaćena je podjela, i to na normativne teorije odlučivanja, deskriptivne i preskriptivne teorije odlučivanja [92], [95].

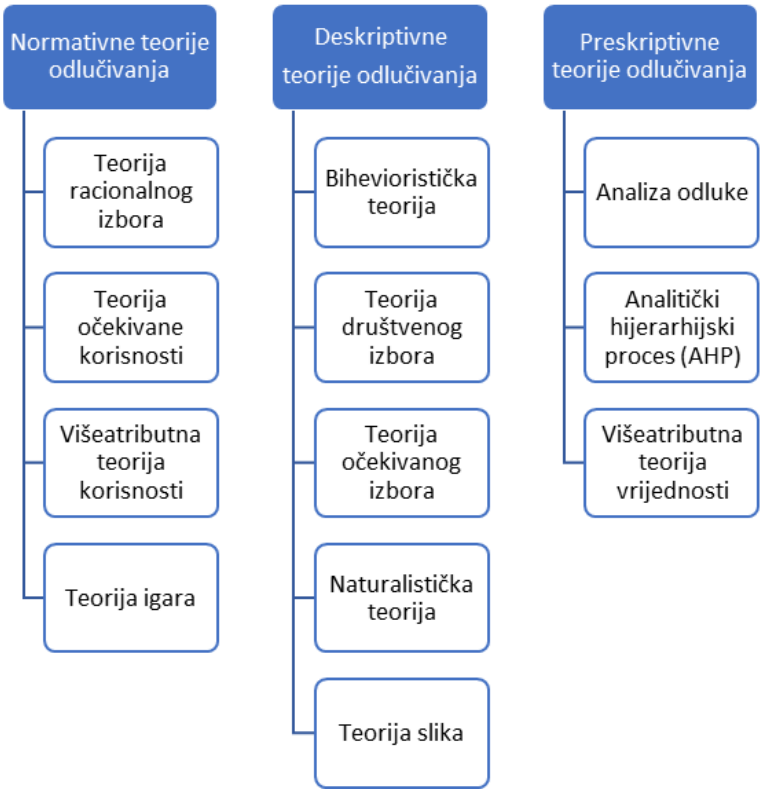

Slika 17. Klasifikacija teorija odlučivanja (prilagodio autor) [92]

Normativne teorije odlučivanja zasnovane su na pitanjima: *Kako bi ljudi trebali donositi odluke i prema kojim standardima (u teoriji)?* Normativni pristup naziva se još *racionalni model odlučivanja*, a temelji se na ovim pretpostavkama [92], [96]:

- donositelj odluke jasno razumije prirodu problema i definira svoje ciljeve u skladu s tim
- moguća je opsežna analiza i identifikacija svih mogućih alternativa rješenja problema te utvrđivanje njihovih posljedica
- svaka inačica se može objektivno procijeniti u odnosu na vjerojatnost postizanja željenih ciljeva, a odabire se ona koja može ostvariti ciljeve
- moguće je kontinuirano pratiti posljedice implementacije izabrane inačice te utvrditi uspjeh odabranog pravca djelovanja.

Ovaj pristup ne uzima u obzir kognitivna, psihološka te ostala ograničenja donositelja odluke. Normativni pristup temelji se na aksiomima racionalnosti, definiranim postupcima, standardima i proceduri, a prikladan je za rješavanje rutinskih problema sa savršenom točnošću. Ciljevi normativnih teorija odlučivanja su maksimizacija, optimizacija i konzistentnost odlučivanja, neovisno o ograničenjima donositelja odluke [92].

Pri donošenju odluka čovjek se susreće s raznim ograničenjima. Neka od tih ograničenja su kognitivne i psihološke prirode. Pojam „ograničena racionalnost“ (engl. *Bounded Rationality*) spominje se i jedna je od glavnih tema u literaturi o deskriptivnoj teoriji odlučivanja. Herbert Simon je zagovarao tzv. *bihevioralni realizam*, odnosno kako ljudi stvarno donose odluke, a ne kako bi ih trebali donositi. Uveo je pojam *ograničena racionalnost,* koji se isprva spominjao u području ekonomskih znanosti, no kasnije je koncept preuzet i primijenjen na druge društvene discipline. Simonova je nakana bila da se pretpostavka o idealnom *homo economicusu* zamijeni konceptom *aktera* koji je ograničenoga racionalnog ponašanja s obzirom na okruženje u kojemu se nalazi (kognitivna, mentalna, emotivna ograničenja, dostupnost informacija itd.) [97]. U fokusu proučavanja bio je pojedinac pa se ova teorija još naziva i *teorija individualnog odlučivanja*. Deskriptivna teorija odlučivanja bavi se pitanjem i opisuje na koji način ljudi donose odluke. U fokusu istraživanja jest proces donošenja odluke, tj. ponašanje prilikom donošenja odluke. Ovaj pristup u svom opisu uključuje ljudsku komponentu te svoje uporište pronalazi u kognitivnoj i bihevioralnoj psihologiji, sociologiji, ekonomiji i dr. Operativni naglasak je na sprečavanju sustavnih pogrešaka u ljudskom zaključivanju i odlučivanju [92].

Prema [95] ljudi su često nedosljedni i pristrani u donošenju odluke te postoji divergencija između savršeno racionalnog i stvarnog ponašanja. Preskriptivna teorija odlučivanja zasniva se na pitanju: kako pomoći čovjeku da što bolje donese odluku. Uz logička pravila i utvrđene procedure, nužno je *humanizirati* proces donošenja odluke, prihvatiti devijacije normativnosti te uključiti stvarno ponašanje donositelja odluke. Kako bi se razvio preskriptivni model odlučivanja, potrebno je utvrditi raskorak između idealnog normativnog i deskriptivnog modela odlučivanja. Preskriptivni model odlučivanja usmjerava aktera tijekom donošenja odluke i to prema normativnim načelima uzimajući pritom u obzir kognitivne karakteristike [92].

4.2. Značajke odlučivanja s obzirom na donositelja odluke

Procedura, tj. proces donošenja odluke razlikuje se s obzirom na *aktera* koji donosi odluku. U tom smislu, za potrebe ovog istraživanja, opisat će se proces (faze) odlučivanja iz perspektive eksperta te neeksperta.

Odlučivanje eksperata provodi se kao sustavni, znanstveno vođeni proces temeljen na dokazima koji obuhvaća standardizirane faze [92], [98]. U tom pogledu, ekspert ili grupa eksperata donosi odluku temeljenu na ekspertizi o konkretnom problemu odlučivanja (kod prijedloga projektnih rješenja i sl.).

Odlučivanje neeksperta svodi se na donošenje svakodnevnih odluka, najčešće temeljeno na heuristikama.

4.2.1. Odlučivanje eksperta

Odlučivanje eksperta karakterizirano je strogo definiranim fazama ovog procesa. U znanstvenoj literaturi postoje brojne klasifikacije faza procesa odlučivanja eksperta (grupe eksperata). Autori koji se bave izučavanjem i određivanjem broja faza u procesu odlučivanja ističu razlike koje se mogu, između ostalog, grupirati ovako [92]:

- Shvaćaju proces odlučivanja u užem ili širem smislu, tj. završava li proces donošenja odluke fazom donošenja odluke ili se proces promatra i nakon donošenja odluke, provođenja, a u smislu kontrole.
- Fazu „Priprema odluke“ posebno ističu te ju proširuju jednom ili u više potfaza.

Skupina autora [92], [94], [99] koji zagovaraju proces odlučivanja u užem smislu, u pravilu zagovaraju dvije osnovne faze – fazu pripreme odluke i fazu provođenja odluke. Proces donošenja odluke u užem smislu sastoji se od dvije osnovne faze: priprema odluke i provođenje odluke, kad ovakav proces ujedno i završava.

Autori [92] koji zagovaraju proces donošenja odluke u širem smislu, smatraju da taj ciklus treba pratiti i nakon donošenja odluke, u vidu provođenja odluke koja je donijeta te kontrole provođenja odluke. Osim toga, pored faze donošenje odluke, koja se smatra najbitnijom, vrlo je važna faza priprema odluke koja je, u širem smislu, proširena na pet potfaza: 1) identifikacija problema, 2) definiranje zadataka, 3) snimanje i analiza postojećeg stanja, 4) traženja inačica rješenja problema, 5) vrednovanje inačica rješenja problema.

Zaključno, proces donošenja odluke, u skladu s tim, treba promatrati kao *integralni proces* (u najširem smislu), koji obuhvaća osam temeljnih faza (Slika 18.): 1) identifikacija problema,

2) definiranje zadataka, 3) snimanje i analiza postojećeg stanja, 4) traženja inačica rješenja problema, 5) vrednovanje inačica rješenja problema, 6) donošenje odluke, 7) provođenje odluke i 8) kontrola provođenja odluke. U nastavku je opis svake faze pojedinačno [92].

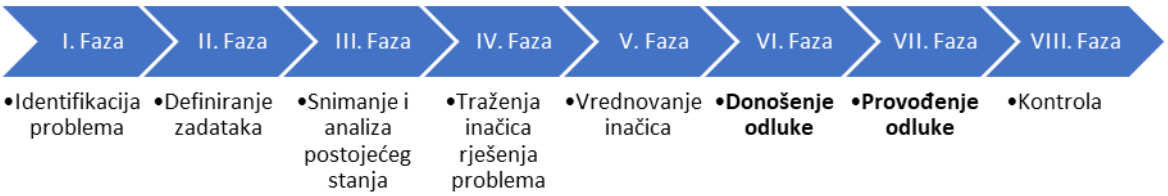

Slika 18. Proces donošenja odluke u širem smislu [92]

1. **Faza – Identifikacija problema** predstavlja prvi korak procesa donošenja odluke. To je korak otkrivanja problema, tj. dijagnosticiranje problema, a predstavlja vrlo važan korak jer o njemu ovisi uspjeh cjelokupnog procesa odlučivanja.
2. **Faza – Definiranje zadatka** predstavlja sljedeći korak kojim se utvrđuje što se želi postići. Ova faza je također bitna jer određuje kvalitetu i smjer kretanja procesa odlučivanja.
3. **Faza – Snimanje i analiza postojećeg stanja obuhvaća** pregled i utvrđivanje svih resursa koje donositelj odluke ima na raspolaganju pri rješavanju problema odlučivanja. Drugim riječima, u ovoj se fazi utvrđuju ograničenja koja donositelj odluke treba uzeti u obzir prilikom donošenja odluke. Na taj način skraćuje se vrijeme odlučivanja i troškovi.
4. **Faza – Traženja inačica** je faza koja je ujedno i prva „prava“ faza odlučivanja, dok su prethodne faze svojevrsna priprema odluke. Tijekom ove kreativne faze razvijaju se potencijalna rješenja problema odlučivanja. U ovoj fazi savjetuje se odrediti optimalan raspon inačica rješenja problema. Ukoliko se definira širi skup inačica, utoliko je veća vjerojatnost izbora najboljeg rješenja. S druge strane, takav pristup može rezultirati povećanim troškovima u fazi vrednovanja te dužim vremenom odlučivanja. U takvom slučaju, predlaže se otkloniti ekstremne inačice rješenja problema.
5. **Faza – Vrednovanje inačica** može se izvesti u pojednostavljenom obliku popisa prednosti i nedostataka za svaku inačicu pojedinačno pa sve do složenijih metoda višekriterijskoga odlučivanja. Faza vrednovanja također je faza pripreme odluke, a putem koje se, kao što sam naziv kaže, evoluiraju (ocjenjuju) inačice. Vrednovanje se

izvodi kvantitativnom i kvalitativnom analizom. Kvantitativna analiza je egzaktna, prikazana brojevima te samim time mjerljiva. Kvalitativna analiza obuhvaća čimbenike koje kvantitativna analiza ne može matematičkim jezikom iskazati i izmjeriti, no izuzetno je bitna jer, u konačnici, može imati snažan učinak na krajnji rezultat izbora alternativa.

6. **Faza – Donošenje odluke** ključna je faza integralnog procesa odlučivanja koja slijedi nakon prethodnih pet faza zaduženih za pripremu odluke. Donošenje odluke predstavlja izbor najprikladnije inačice temeljene na odlukama u fazi vrednovanja inačica.
7. **Faza – Provođenje odluke** predstavlja smisao cijelog procesa odlučivanja. U ovoj se fazi ostvaruju ciljevi koji su se postavili na samom početku procesa donošenja odluke.
8. **Faza – Kontrola** je posljednja faza u integralnom procesu odlučivanja te je izrazito važna za cjelokupni proces odlučivanja; fazom kontrole provjerava se je li odluka uopće provedena, na koji način je provedena te postoje li neke nepredviđene situacije nakon provođenja odluke.

4.2.2. Odlučivanja neeksperta

Ovaj je proces značajno jednostavniji od prethodnoga procesa te nema tako strogo definirane faze donošenja odluke. Ljudi svakodnevno donose razne odluke, kako privatne tako i poslovne. Neke od tih odluka su automatske, poput zaustavljanja automobila na semaforiziranom raskrižju, jutarnjega ustajanja i dr. Osim automatskih odluka, donose se i poluatomatske odluke, a odnose se na odluke koje uključuju varijabilni element, npr. odabir odjeće za posao, odabir obroka, prijevoznoga sredstva do određene lokacije i dr. Povrh toga, postoje i dobro promišljene odluke, kao što su kupnja kuće, automobila, turističke lokacije itd.

Iz toga je vidljivo da je proces donošenja odluke često vrlo specifičan, s obzirom na odluku koja se donosi. Neke su odluke jednostavne, programirane i rješavaju se u nekoliko koraka (faza), no neke su složenije te zahtijevaju složeniji pristup. Na Slici 19. prikazan je proces donošenja odluka u užem smislu iz perspektive neeksperta. Proces započinje fazom *izazova* potaknuto potrebom za donošenjem odluke. Druga faza obuhvaća proces zahvata u raspoložive izvore informacija. U ovom pogledu, izvori informacija mogu biti temeljeni na vlastitom iskustvu (heuristike), iskustvu drugih, elektronički izvor informacija (više ili niže složenosti).

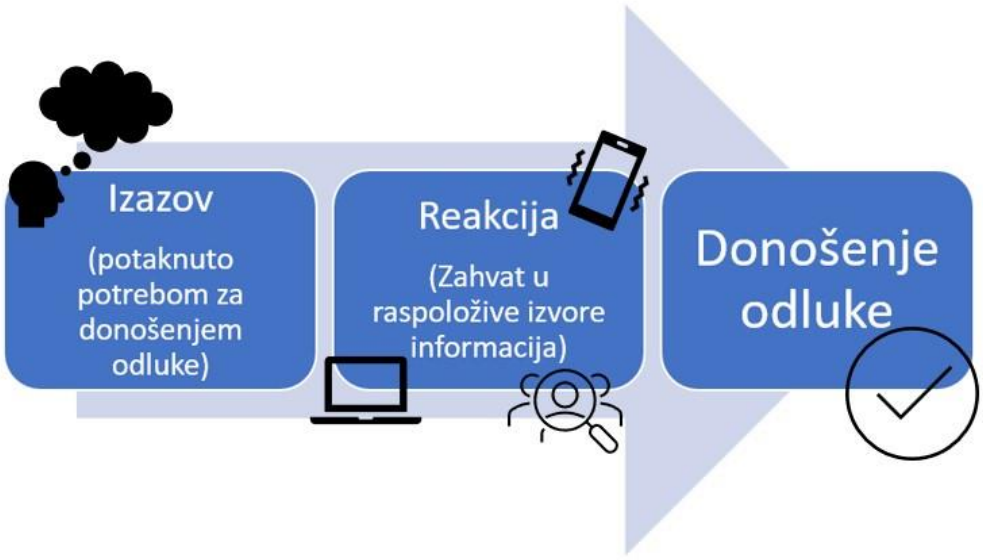

Slika 19. Faze donošenja odluka neeksperta (izradio autor)

Navedene faze (karakteristične za neeksperta) mogu se primijeniti i na primjeru izbora multimodalnoga putovanja. U ovom radu u fokusu je čovjek koji se suočava s problemom izbora multimodalnoga putovanja. On nije idealno racionalno biće, već je obilježen svojim prethodnim putovanjima; iskustvima, doživljajima, emocijama itd. Na temelju svojega putničkog *genoma* koji predstavlja zapis svega navedenog, donijet će odluku, tj. izbor multimodalnoga putovanja [100]. Prema [95], izbor između alternativa, tj. donošenje odluke čin je kompromisa između različitih *ja* unutar *donositelja odluke*.

Potreba za izborom (odlukom) multimodalne rute predstavlja izazov kojem slijedi reakcija, tj. potreba za informiranjem, kako bi se donijela što prikladnija odluka. Neekspert poseže za dostupnim izvorima informiranja. U ovom pogledu to može biti osobno iskustvo (heuristike), iskustvo drugih te elektronički izvori informiranja. Neekspert može posegnuti za jednostavnijim elektroničkim izvorima informiranja, u obliku statičkih podataka – voznih redova te složenijih izvora informacija u obliku usluge multimodalnih putnih planera. Nakon zahvaćanja/prikupljanja potrebnih informacija (npr. izbor predložene rute), vezano za problem odlučivanja (izbor rute), neekspert donosi odluku.

S obzirom na velik (prisutan) broj mogućnosti i kombinacija načina putovanja, izbor najprikladnije opcije multimodalnoga putovanja predstavlja problem odlučivanja iz perspektive donosioca odluke – putnika. Iz toga je vidljivo da se izbor multimodalnoga putovanja može promatrati kao proces donošenja odluke, zasnovan na prethodno prikupljenim doživljajima, iskustvima, razvijenim obrascima putničkog ponašanja te preferencijama [101].

U fazi odabira odluke ljudi zapravo teže donošenju zadovoljavajuće, dovoljno dobre odluke, a ne „najbolje odluke“. Zadovoljavajuća odluka određena je razinom aspiracije donositelja odluke, tj. skupom minimalnih zahtjeva koje postavlja donositelj odluke. Drugim riječima, donositelj odluke izabire alternativu koja zadovoljava zadanu. Simon je upotrijebio koncept zadovoljavajuće odluke kako bi opisao ponašanje pojedinca kad se ne može donijeti optimalna odluka.

Prema [102] ljudsko donošenje odluka snažno je subjektivno (pristrano) zbog nesvjesnih kognitivnih procesa, koji u pojedinim scenarijima donose dobre izbore, a u pojedinima dovode do iracionalnih izbora. Strah od gubitka i neuspjeha na ljudske odluke utječe više nego očekivanje dobiti i uspjeha izabranom odlukom.

Teorija *uokvirenja* (engl. *Framing Theory*) naznačuje da ljudi odlučuju o izborima odluka na temelju njihove pozitivne ili negativne konotacije, odnosno ovisno o tome hoće li izborom odluke nastupiti dobitak ili gubitak. Osim toga, ljudi su pristrani prema opcijama kojih se lakše prisjetiti ili ih je lakše zamisliti. Iz toga se može zaključiti da su naše buduće odluke

determinirane prošlim izborima, tj. pristrane su jer su donošene na temelju nekog prošlog iskustva, nečega što smo doživjeli i čiji nam je ishod poznat. Uz pristranost, emocije su ključni čimbenik pri donošenju odluka. Bez neke vrste emocionalne podloge (reakcije), teško je donositi odluke [103].

U nastavku teksta ove disertacije upotrebljavat će se riječ alternativa umjesto riječi inačica jer to bolje odgovara predmetu istraživanja i u tom smislu je uobičajeno u stručnoj i znanstvenoj literaturi.

4.3. Višekriterijsko odlučivanje

Višekriterijsko odlučivanje (engl. *Multiple Criteria Decision Making* – MCDM) jedno je od važnijih područja operacijskih istraživanja. Bavi se rangiranjem različitih alternativa, od najboljih do najgorih, koje se temelji na korištenju više različitih kriterija. Također, može postojati veći broj međusobno suprotnih kriterija. Problem se svodi na određivanje skupa alternativa. Proces odlučivanja predstavlja optimizaciju funkcije cilja na skupu mogućih rješenja te se ta rješenja procjenjuju, uspoređuju i rangiraju [104], [105].

Složenost procesa odlučivanja očituje se u sljedećem [106]:

- postojanje više kriterija
- konfliktnost kriterija
- vrednovanje odluka je podložno subjektivnom stavu donositelja odluke
- donositelj odluke često ne može lako usporediti dvije moguće odluke, odnosno odlučiti koje rješenje zapravo preferira
- skup mogućih odluka, kao i važnosti kriterija rijetko su fiksni te se mogu mijenjati u realnom vremenu.

U procesu donošenja odluka moguće je nekoliko pristupa, pa se mogu promatrati sljedeći problemi [106]:

- odabir jedne alternative
- svrstavanje alternativa u određene grupe s obzirom na kriterije
- rangiranje alternativa od najbolje do najlošije
- opis alternativa s obzirom na razinu zadovoljenja kriterija.

Kod višekriterijskoga odlučivanja skup dopustivih rješenja je diskretan, konačan te je unaprijed poznat. Višekriterijska optimizacija definirana je matematičkim modelom u kojemu dopustiva rješenja nisu unaprijed poznata te ih može biti konačan ili beskonačan broj [106]. Optimizacija u tom smislu uključuje funkcije ograničenja, koje mogu biti varijable (npr. pozitivnost rješenja), ali i neka procesna ili strukturna ograničenja. Optimizacije se dalje dijele na linearne i nelinearne te očekuje li se rješenje na skupu realnih brojeva, cjelobrojno i dr.

Kriteriji predstavljaju jednu od značajki atributa koji su zastupljeni u alternativama odluka. Njihove vrijednosti (težine) su mjera njihove važnosti. Kako je prethodno rečeno, općenito se dijele na tipove: „korist“ i „trošak“. To je posebno važno u postupku normalizacije vrijednosti atributa, što je prikazano u nastavku na konkretnim primjerima. Kriteriji mogu biti kvantitativni i kvalitativni. Kvantitativni kriteriji imaju odgovarajuću vrijednost, koja ovisi o konkretnoj zadaći. Ti se kriteriji mogu podijeliti na: kriterije koristi (engl. *benefit*) (pozitivno doprinose vrijednosti alternative) i kriterije troškova (engl. *cost*) (negativno doprinose vrijednosti alternative). U složenim zadaćama odlučivanja kriteriji mogu sadržavati i potkriterije. U tom slučaju mora biti jasno definirana hijerarhija odnosa između kriterija i potkriterija. Tipičan primjer za to je metoda *Analitičkoga hijerarhijskog procesa* (engl. *Analytic Hierarchy Process* – AHP) [104]–[106].

Formalni model odnosa kriterija i alternativa kod višekriterijskoga odlučivanja prikazan je strukturom [104]:

Alternativa	Kriteriji					
	W_{C1}	W_{C2}	...	$W_{C\,j}$	...	$W_{C\,k}$
Alt_1	a_{11}	a_{12}	...	a_{1j}	...	a_{1k}
Alt_2	a_{21}	a_{22}	...	a_{2j}	...	a_{2k}
	...	...	...	...	...	...
Alt_i	a_{i1}	a_{i2}	...	$\mathbf{a_{ij}}$	...	a_{ik}
	...	...	...	...	...	...
Alt_m	a_{m1}	a_{m2}	...	a_{mj}	...	a_{mk}

(4.1.)

Model se sastoji od:

- m alternativa: Alt_i, i = 1, 2, ..., m
- alternativa je definirana svojim atributima: $Alt_i = (a_{i1}, a_{i2}, ..., a_{ik})$

– k kriterija: W_{Cj}, j =1, 2, ..., k koji su povezani s odgovarajućim atributima alternativa
– a_{ij} = vrijednost atributa alternative Alt_i po kriteriju W_{Cj}

U skladu s tim u nastavku su prikazani općeniti koraci u rješavanju definiranoga problema višekriterijskoga odlučivanja (Slika 20.) [107]:

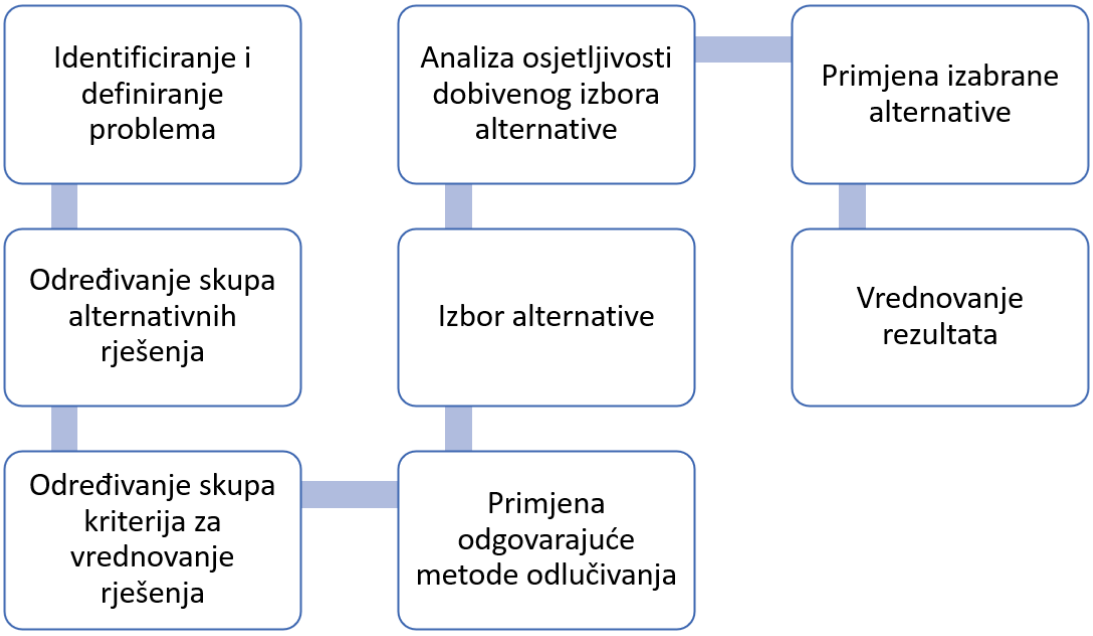

Slika 20. Općeniti koraci u rješavanju definiranoga problema višekriterijskoga odlučivanja (izradio autor)

4.4. Pregled i analiza metoda višekriterijskoga odlučivanja

Ovaj pregled metoda višekriterijskoga odlučivanja izrađen je za potrebe analize mogućnosti primjene pri izboru multimodalnoga putovanja s obzirom na to da se izbor rute multimodalnoga putovanja može shvatiti kao proces odlučivanja. Sukladno tome, analizirane su postojeće metode višekriterijskoga odlučivanja koje su prikladne za problem koji je predmet ovog istraživanja. Identifikacija i izbor metode nije nimalo lak zadatak te se također smatra višekriterijskim problemom. Velik broj znanstvene i stručne literature nudi primjere komparativne analize višekriterijskih metoda općenito ili za potrebe nekog područja primjene. Na temelju tih analiza razvijene su i mnoge smjernice koje mogu pomoći u odabiru prikladne metode. U evaluacijskim analizama višekriterijskih metoda često je dominantan kriterij kompatibilnost s područjem primjene. Nažalost, takve analize nisu rađene za problem kojim se bavi ovo istraživanje. Izbor najprikladnije metode veoma je bitan jer, u protivnom, pogrešan izbor metode može biti neprikladan za uporabu te nije u skladu s domenom problema. Pri

odabiru najprikladnijih metoda važan kriterij jest to da budući korisnik nije ekspert u ovoj domeni te u tom slučaju i metoda mora biti sa što manje zahtjeva donositelja odluke, koje mogu ispuniti samo eksperti (npr. složenost zadavanja preferencija kroz odgovarajuće kriterije koji su značajni za izbor multimodalnoga putovanja). Osim toga, važan element izbora modela je i jednostavnost buduće implementacije te odgovarajuća jednostavnost operativne upotrebe kod korisnika (putnika). Na osnovi analize postojećih preporučiteljskih sustava, neophodno je bilo odabrati metodu koja treba biti tolerantna na neodređenosti i nepreciznosti u iskazivanju preferencija, tj. treba dobro oponašati čovjekov način zaključivanja s nepreciznostima u iskazu.

Na osnovi uvida u slične komparativne analize metoda višekriterijskoga odlučivanja (međutim, za druga područja primjene) napravljen je prikaz prednosti i nedostataka. Neke od najčešće korištenih metoda koje bi se mogle primijeniti i u ovom području su [107], [108]:

4.4.1. Metoda težinskoga zbroja (engl. *Weighted Sum Method* – WSM)

To je najpoznatija i matematički jednostavna metoda višekriterijske analize. Zbog svoje jednostavnosti metoda je prikladna za različite zadaće, a prije svega za jednodimenzionalne probleme. Međutim, različitim postupcima normalizacije, ova se metoda može primijeniti i za višedimenzionalne probleme [109].

Matematički model izračuna vrijednosti optimalne alternative određuje se modelom:

$$A_{opt} = \underbrace{max}_{i} \sum_{j=1}^{n} a_{ij} w_j \qquad i = 1,2,3, \dots, m \tag{4.1}$$

gdje je:

a_{ij} – vrijednost j-tog atributa za i-tu alternativu

w_j – vrijednost kriterija za j-ti atribut

max – operacija izbora alternative s najvećom vrijednosti (A_{opt})

Prednosti:

- WSM omogućuje dobro strukturiranje problema koji se razmatra, eksplicitno opisuje alternative, kriterije i njihove relativne rezultate i težine.
- Nije zahtjevna za donositelja odluke.
- Jednostavne je implementacije.
- Prikaz vrijednosti kriterija i cjelokupni izračun relativno je jasan i razumljiv.

- Primjena postupka uključenja neodređenosti i nepreciznosti pri iskazivanju preferencija (npr. postupkom fazifikacije) veoma je jednostavna.

Nedostaci:

- Glavni nedostatak, koji se često navodi, jest taj da je namijenjena prije svega za jednodimenzionalne probleme. Primjerenim postupcima normalizacije vrijednosti atributa alternativa taj se nedostatak može izbjeći.
- Dodjela vrijednosti kriterija (težine kriterija) kod kompleksnih je problema veoma zahtjevna.
- Zbrajanje doprinosa pojedinih atributa može biti točno ako su atributi aditivni, što u nekim slučajevima može biti nerealno. Odgovarajućim odabirom reprezentativnih atributa, taj se problem može izbjeći.

4.4.2. Metoda težinskoga umnoška (engl. *Weighted Product Method* – WPM)

Ova je metoda vrlo slična metodi težinskog zbroja, no glavna je razlika što se u ovoj metodi uspoređuju parovi alternativa te se umjesto zbrajanja rabi operacija množenja. Svaka vrijednost atributa alternative uspoređuje se s odgovarajućim atributom drugih alternativa te se taj omjer podiže na potenciju jednaku vrijednosti odgovarajućeg kriterija. Na kraju se svi navedeni doprinosi množe [108], [109].
Rangiranje odnosa pojedinih alternativa određuje se izrazom:

$$R(A_K/A_L) = \prod_{j=1}^{n} (a_{Kj}/a_{Lj})^{w_j} \tag{4.2}$$

gdje je:

a_{Kj} – vrijednost j-tog atributa za K-tu alternativu
a_{Lj} – vrijednost j-tog atributa za L-tu alternativu
w_j – vrijednost kriterija za j-ti atribut

Na ovaj način model direktno postaje bezdimenzionalan te je metodu moguće rabiti i kod jednodimenzionalnih i višedimenzionalnih problema odlučivanja bez potrebe za normalizacijom vrijednosti atributa alternativa.

Prednosti:

- Metoda je izvorno bezdimenzionalna te nema potrebe za normalizacijom.
- Uključenja neodređenosti i nepreciznosti pri iskazivanju preferencija (npr. postupkom fazifikacije) relativno je jednostavno.

Nedostaci:

- Umjesto vrijednosti pojedinih alternativa metoda daje vrijednost odnosa alternativa.
- Složeniji izračun vrijednosti kriterija (težina) korištenjem različitih postojećih postupaka otkrivanja preferencija korisnika. U okviru ovog istraživanja razvijen je jedan modificirani matematički model težinskog umnoška koji eliminira ovaj problem.

4.4.3. Analitički hijerarhijski proces (engl. *Analytic Hierarchy Process* – AHP)

Analitički hijerarhijski proces jedna je od najpoznatijih metoda. Utemeljio ju je Thomas L. Saaty. Analitički hijerarhijski proces vrlo je zastupljena metoda, posebno namijenjena rješavanju složenih problema s mnogo kriterija i velikim brojem alternativa. To je najraširenija metoda za složene investicijske projekte. Proistekla je iz potrebe da se u slučaju velikog broja kriterija i alternativa ponudi pristup zasnovan na analizi njihovih međusobnih odnosa, a ne pojedinačnog definiranja vrijednosti kriterija. U tom smislu konstruira se odgovarajuća hijerarhija odnosa. Osim toga, ova metoda omogućuje rad i s kvantitativnim i kvalitativnim pokazateljima (npr. ocjena nekog svojstva alternativa). Mada je načelno ova metoda namijenjena za ekspertsku primjenu, uzeta je u obzir zato da se prikaže problematičnost njezine uporabe zbog dobro poznatog problema (čak i kod eksperata) testiranja konzistentnosti [104], [108], [109].

Postupak izračuna ima četiri temeljna koraka [110]:

1. Razvije se hijerarhijski model problema odlučivanja s ciljem postavljenim na vrhu, kriterijima i potkriterijima na nižim razinama te alternativama na dnu modela.
2. Na svakoj razini hijerarhijske strukture u parovima se međusobno uspoređuju elementi te strukture, pri čemu se preferencije donositelja odluke izražavaju uz pomoć Saatyjeve skale relativne važnosti koja ima pet stupnjeva i četiri međustupnja lingvistički opisanih intenziteta i odgovarajuće numeričke vrijednosti u rasponu od 1 do 9. (Tablica 2.)

Tablica 2. Saatyjeva skala relativne važnosti

Intenzitet važnosti	Definicija	Objašnjenje
1	Jednako važno	Dva kriterija ili alternative jednako doprinose cilju
3	Umjereno važnije	Na temelju iskustva i procjena daje se umjerena prednost jednom kriteriju ili jednoj alternativi u odnosu na drugi kriterij ili drugu alternativu
5	Strogo važnije	Na temelju iskustva i procjena strogo se favorizira jedan kriterij ili alternativa u odnosu na druge
7	Vrlo stroga, dokazana važnost	Jedan kriterij ili alternativa izrazito se favorizira u odnosu na druge; njegova dominacija dokazuje se u praksi
9	Ekstremna važnost	Dokazi na temelju kojih se favorizira jedan kriterij ili alternativa u odnosu na druge potvrđeni su s najvećom uvjerljivošću
2, 4, 6, 8		Međuvrijednosti

Izvor: [92]

3. Iz procjena relativnih važnosti elemenata odgovarajuće razine hijerarhijske strukture problema, pomoću matematičkog modela izračunavaju se lokalni prioriteti (težine) kriterija, potkriterija i alternativa, koji se zatim sintetiziraju u ukupne prioritete alternativa. Ukupni prioritet pojedine alternative izračunava se tako da se zbroje njezini lokalni prioriteti ponderirani s težinama elemenata više razine.
4. Provodi se analiza osjetljivosti.

Prednosti:

- Donositelj odluke uključen je u sve faze strukturiranja problema.
- Problem je organiziran u hijerarhijsku strukturu koja pomaže u provjeri inkonzistencije (nedosljednosti).
- Pogodna je za skupno odlučivanje.
- Primjena metode povećava znanje o problemu odlučivanja.
- Rezultati ne sadržavaju samo rang-ljestvicu alternativa nego i informacije o težinskim koeficijentima kriterija u odnosu na cilj – što omogućuje kvalitetnu postoptimalnu analizu.
- Uključenja neodređenosti i nepreciznosti pri iskazivanju preferencija (npr. postupkom fazifikacije) relativno su jednostavna.

Nedostaci:

- Namijenjena je prije svega stručnjacima, teško je razumljiva običnim korisnicima.
- Postizanje prihvatljivog omjera konzistencije i za stručnjake domene može biti teško.
- Velik je broj potrebnih komparacija u parovima kod složenijih problema.
- Problematična je implementacija kod preporučiteljskih sustava.
- Subjektivna evaluacija.

4.4.4. Tehnika za poredak preferencija po sličnosti s idealnim rješenjem (engl. *Technique for Order Preference by Similarity to Ideal Solution* – TOPSIS)

Ova metoda temelji se na konceptu koji izabire alternativu koja bi trebala imati najmanju „geometrijsku“ udaljenost od pozitivnog idealnog rješenja i najveću „geometrijsku“ udaljenost od negativnoga idealnog rješenja [108], [109].

Prednosti:

- Minimalan subjektivni unos podataka, podržavanje rada s velikim brojem alternativa i kriterija, olakšan unos podataka i smanjeno vrijeme donošenja odluke.
- Metoda ima racionalnu i razumljivu logiku, a koncept je u prilično jednostavnom matematičkom obliku.
- Donošenje odluka je jednostavno koristeći kriterije i troškova i koristi.
- Proces izračuna je relativno jednostavan u usporedbi s drugim metodama iste namjene.

Nedostaci:

- Dopušteni su samo neovisni kriteriji.
- Za ocjenu kriterija potrebna je normalizacija.
- Kriteriji su monotono padajuće ili rastuće prirode.
- Problematična je implementacija kod preporučiteljskih sustava.

4.4.5. ELECTRE (fr. *Elimination Et Choix Traduisant la Realité*, engl. *Elimination and Choice Expressing Reality*)

Ova je metoda predstavnik tzv. nekompenzacijskih metoda višekriterijskoga odlučivanja, što implicira da ne postoji kompenzacija između doprinosa kriterija tipa „troškovi“ i „koristi“ u ocjeni vrijednosti pojedine alternative. U tom je smislu temeljna odrednica ove metode razvoj modela međusobnih odnosa alternativa, a u smislu dominantnosti jedne alternative nad drugom alternativom [104], [109].

Prednosti:

- Uzima u obzir neodređenosti i nepreciznosti.

Nedostaci:

- Zahtijeva puno vremena za provedbu procedure odlučivanja.
- Proces zaključivanja i ishod teško je objasniti neekspertima.
- Snage i slabosti alternativa ne mogu se izravno identificirati.
- Zahtijeva veliku količinu polaznih podataka koji opisuju problem odlučivanja.

4.4.6. Ostale metode

Ostale metode, kao što su [104], [109], [111]:

- Multi-Attribute Value Theory (MAVT)
- PROMETHEE (Preference Ranking Organization METHod for the Enrichment of Evaluations)
- VIšekriterijumsko KOmpromisno Rangiranje (VIKOR)
- i dr.

Po svojoj namjeni, složenosti i prihvatljivosti za upotrebu od strane neeksperata ne mogu se primijeniti u slučaju izbora multimodalne rute putovanja.

4.5. Izbor užeg skupa prikladnih metoda višekriterijskoga odlučivanja za model izbora multimodalnoga putovanja

Pri odabiru najprikladnije metode važan je kriterij koji osigurava široke mogućnosti uključenja preferencija korisnika pri odabiru multimodalnoga putovanja. Ona treba biti što prikladnija za realnu primjenu u okviru postojećih tehnoloških mogućnosti, što uključuje odgovarajuću jednostavnost operativne uporabe. Isto tako, odabrana metoda treba biti tolerantna na neodređenosti i nepreciznosti pri iskazivanju preferencija (dobro oponašati ljudski način zaključivanja s nepreciznostima u iskazu).

Na osnovi analize šireg skupa metoda (prednosti/nedostaci) provedene u prethodnom poglavlju te uzimajući u obzir značajke problema izbora multimodalnoga putovanja, u uži izbor odabrane su:

a) Metoda težinskog zbroja (engl. *Weighted Sum Method* – WSM)
b) Metoda težinskog umnoška (engl. *Weighted Product Method* – WPM)
c) Analitički hijerarhijski proces (engl. *Analytic Hierarchy Process* – AHP).

U nastavku istraživanja obavljeno je testiranje tih metoda na odabranim slučajevima izbora multimodalnoga putovanja (Poglavlje 6). Osim toga, analizirana je i mogućnost primjene postupaka fazifikacije na izabranim metodama.

4.6. Kriteriji i preferencije putnika

Uzimajući u obzir percepciju putnika, a samim time i njegove „bihevioralne“ komponente, očigledno je da jedno putovanje neće imati jednaku vrijednost za svakog putnika. Ono se temelji na individualnoj percepciji putnika, njegovim preferencijama, navedenim socio-demografskim karakteristikama te spletu atributa putovanja i njihovoj kombinaciji za vrijeme trajanja cijelog putovanja. Ti se kriteriji mogu podijeliti na:

- Kriterij uključenja/isključenja (npr. izbjegavanje podzemne željeznice, dijela grada i sl.)
- Kvantitativni (npr. vrijeme putovanja, broj presjedanja, vrijeme pješačenja i dr.)
- Kvalitativni (npr. stanje zagušenja kapaciteta u prijevoznom sredstvu i dr.)
- Suvremeni (npr. ekološki kriterij u smislu izbora prijevoznih sredstava s manjim utjecajem onečišćenja na okoliš).

Iz perspektive putnika, ukupno vrijeme putovanja predstavlja jedan od ključnih kriterija u izboru rute multimodalnoga putovanja. Kod tako složenoga prijevoznog sustava, koji obuhvaća više načina putovanja, ukupno vrijeme putovanja uključuje vremena putovanja u prijevoznom sredstvu i izvan prijevoznog sredstva (vrijeme pješačenja, vrijeme čekanja). Tradicionalni pristup planiranja i upravljanja prijevoznog sustava uzima u obzir stvarno vrijeme putovanja te promatra vrijednost vremena putovanja (engl. *Value of Travel Time* – VTT) isključivo kroz prizmu novčane vrijednosti i to na razini cjelokupne populacije putnika[4]. Istraživanja su pokazala da ljudi drukčije percipiraju stvarno vrijeme putovanja, i to zbog niza unutarnjih i vanjskih čimbenika [112], [113]. Vanjski se čimbenici odnose na prometnu infrastrukturu, karakteristike prijevoznih sredstava i vršne sate (engl. *Peak-hours*), dok se unutarnji čimbenici odnose na percepciju pojedinca koja se temelji na socioekonomskim i psihološkim značajkama (kognitivne i emocionalne značajke) pojedinca te prethodnim iskustvima putovanja. Primjerice, ako se putnik nalazi na stajalištu javnog prijevoza bez sadržaja, u vidu klupa, nadstrešnica te sučelja za putno informiranje, tada percipirano vrijeme čekanja može biti čak dvostruko duže od stvarnog vremena čekanja [114]. Osim toga, na vrijeme čekanja mogu utjecati vanjski čimbenici poput vremenskih uvjeta, okruženja te unutarnjih, kao što su stres i anksioznost potaknuti čekanjem i neizvjesnošću [115].

Mjesta presjedanja izuzetno su bitna za prijevozni sustav jer omogućavaju multimodalno funkcioniranje prometne mreže [116]. No, iz perspektive putničkog iskustva predstavljaju

[4] Studije uzimaju u obzir standardne ulazne parametre poput socioekonomskih karakteristika putnika [112]

neuralgične točke putovanja, osobito ako se mijenja platforma stajališta javnog prijevoza (engl. *Public Transport Interchange*), prijevozno sredstvo (npr. vlak – autobus) i ako uključuje dodatno pješačenje i čekanje. Zbog toga se iskustvo presjedanja (engl. *Transfer Experience*) proučava kao zasebno područje putničkog ponašanja i ukupnog iskustva putovanja. U literaturi je identificiran niz čimbenika koji utječu na putničku percepciju presjedanja, a samim time i vremena izdvojenog za tu aktivnost [116], [117]:

- *Broj presjedanja.* To je jedan od najneugodnijih elemenata multimodalnoga putovanja. Istraživanja su pokazala da putnici najčešće biraju i dulju rutu (prostorno, vremenski) kako bi izbjegli veliki broj presjedanja.
- *Vrijeme pješačenja i vrijeme čekanja na presjedanje.* Ova vremena u korelaciji su s voznim redom, pouzdanošću i kapacitetom usluge javnog prijevoza.
- *Udobnost.* Povezana s estetikom, ergonomijom, dostupnošću, čistoćom mjesta presjedanja.
- *Sigurnost i zaštita putnika (na mjestima presjedanja).* Implementiran videonadzor i odgovarajuća rasvjeta jer se na taj način pojačava osjećaj sigurnosti i putnicima ulijeva povjerenje, što značajno utječe na smanjenje stresa i anksioznosti prilikom čekanja prijevoznog sredstva.
- *Dostupnost putnih informacija u stvarnom vremenu.* U izravnoj je vezi s percepcijom vremena pješačenja i čekanja zbog navedenih razloga.

Vremena putovanja (ukupno vrijeme putovanja, vrijeme pješačenja i dr.) također su veoma važni elementi iz perspektive izbora odgovarajuće rute putovanja. To je individualna karakteristika putnika. Tako, primjerice, odnos prema vremenu pješačenja neki korisnici (prije svega mlađa populacija) doživljavaju kao „korist“ (fitness, zdravi život, rekreacija i sl.), dok neki to doživljavaju kao otegotnu okolnost („trošak“). To se prije svega odnosi na starije putnike [116]–[118].

5. METODE OTKRIVANJA PUTNIČKIH PREFERENCIJA

Identificiranje (otkrivanje) i prikupljanje podataka o kretanjima putnika, navikama, sklonostima i putničkim obrascima sastavni je korak u planiranju atraktivnoga i održivoga javnog prijevoza putnika. Identificiranje preferencija putnika zasniva se na ekonomskom principu „izrečenih" (engl. *Stated Preferences* – SP) i „otkrivenih preferencija" (engl. *Revealed Preferences* – RP). Temeljna ideja izrečenih i otkrivenih preferencija u mikroekonomiji jest saznati (otkriti) što potrošači preferiraju, kako bi se pojasnilo određeno potrošačko ponašanje te ponudila usluga/proizvod u skladu s potrebama i afinitetima potrošača [119].

5.1. Otkrivanje korisničkih preferencija

Prethodna iskustva otkrivanja korisničkih preferencija u suvremenim oblicima trgovine (e-trgovina i sl.) može se primijeniti i pri utvrđivanju preferencija korisnika (putnika) sustava javnog prijevoza. Teoriju otkrivenih preferencije (engl. *Revealed Preference Theory*) uveo je američki ekonomist Paul Samuelson, smatrajući da iza svakog izbora potrošača postoji skup preferencija koji se može otkriti upravo na temelju tog izbora u kupovini [104]. Otkrivanje korisničkih preferencija (engl. *Discovering User Preferences*) posebno je područje istraživanja i primjene u mikroekonomiji (e-trgovina, internetsko oglašavanje i prodaja). Ekonomisti smatraju [105] da preferencije koje su otkrivene nakon završenih aktivnosti, najprihvatljivije opisuju potrošačko ponašanje, a shodno tome i pripadajuće preferencije.

Izrečene preferencije su one do kojih se došlo na eksplicitan način, anketama, raznim upitnicima, intervjuima itd. Nedostatak eksplicitno izrečenih preferencija jest to što vjerojatno neće prikazati i predvidjeti stvarno ponašanje putnika jer se ispitivanja temelje na izboru alternativa za fiktivni scenarij putovanja. Osim klasičnih metoda koje istražuju sklonosti na razini opće populacije, a koje ne ispituju preferencije na stvarnim, opipljivim situacijama, primjenjuju se metode poput tzv. *On-the-Spot* [120]. Upitnik se ispunjava u stvarnom okruženju, koje putniku omogućava da zamisli ponuđeni scenarij putovanja te izabere alternativu koja je najbliža njegovim sklonostima, za razliku od konvencionalnih anketa koje se provode u kućanstvu te su procjene često drugačije od stvarnih preferencija. Osim prikupljanja i identificiranja preferencija eksplicitnim putem, preferencije je moguće otkriti iz stvarnih događaja (obavljena putovanja koja su zapisana u sustavima).

Danas je više nego ikad potrebna personalizirana podrška u izboru usluga i proizvoda, sukladno aspiracijama i potrebama. Prema [121], [122] personalizacija se upotrebljava radi

prilagođavanja informacija specifičnim potrebama i preferencijama korisnika, a naglasak je na invidualizaciji. U ispostavljanju personalizirane usluge/proizvoda te u interakciji s krajnjim korisnikom, značajnu ulogu imaju preporučiteljski sustavi (engl. *Recommender Systems* – RS), koji su posebno istraživačko područje računalnih znanosti, marketinga, e-trgovine itd.

Personalizirani sustavi preporuka, prema tehnologijama otkrivanja preferencija, mogu se podijeliti u ove kategorije [123], [124]:

- Tradicionalne metode
    - Metode temeljene na suradnji (engl. *Collaborative Filtering – CF*)
    - Metode temeljene na sadržaju objekta (engl. *Model-based*)
    - Metode temeljene na znanju (engl. *Knowledge-based*)
- Nove metode
    - Metode temeljene na osobnosti (engl. *Personality-based*)
    - Metode temeljene na kontekstu (engl. *Context-based*)
    - Metode temeljene na oznakama (engl. *Tag-based*).

Istraživanja u području preporučiteljskih sustava eksponencijalno rastu razvojem interneta, odnosno razvojem e-trgovine. Kako bi pružio preporuku sukladnu preferencijama krajnjeg korisnika, preporučiteljski sustav zahtijeva informacije o preferencijama korisnika, i to na dva načina: na *eksplicitan način* (putem postavljenih upita, ocjena usluge/proizvoda) te na *implicitan način*, tj. praćenjem ponašanja korisnika, odnosno otkrivanjem i bilježenjem preferencija [125]. U ovom pogledu, korisnički je profil ključni element ovakvih sustava jer bilježi preferencije, interese te ostale relevantne atribute tijekom interakcije s korisnikom, a koji se s vremenom (i interakcijom) nadograđuje [122]. Sve se više preporučiteljskih sustava približava stvarnim potrebama korisnika te na taj način pruža personalizirano iskustvo [126]. Ovo je osobito važno pri planiranju putovanja. Nedostatak postojećih multimodalnih planera očituje se u ograničenim mogućnostima personalizacije [127], [128]. U tom smislu, potrebno je utvrditi prikladnu metodologiju koja će otkrivati stvarne aspiracije i potrebe putnika te ih usmjeriti na stavke koje su prikladne za njih.

Nekoliko je najčešćih nedostataka personaliziranih sustava [123]:

- Novi korisnici (engl. *New users*) – nedostatak znanja o njima
- Problem hladnog starta (engl. *Cold start*) – premalo ulaznih podataka (npr. ocjena) od strane korisnika (na početku rada)
- Korisnici koji nemaju sličnosti niti s jednim korisnikom (engl. *Black sheep*)
- Povjerenje u predložene preporuke – preporuke korisnika s učestalom interakcijom (podatkovno bogatim korisničkim profilom) često mogu „nadglasati" preporuke korisnika s oskudnim korisničkim profilom. U tom slučaju predlaže se distribucija prioriteta za korisnike.
- Skalabilnost – porastom broja korisnika i objekata potrebno je više resursa za obradu informacija i predlaganje preporuka. U tom smislu, uključuju se razni filteri i fizička poboljšanja sustava kako sustav ne bi bio preopterećen.
- Privatnost – kad je u pitanju personalizacija, tad se radi o velikim skupinama osjetljivih, osobnih podataka (npr. demografski podaci, geografski podaci – trenutna lokacija). U skladu s tim, e-trgovine (ili bilo koji drugi davatelj usluge) dužan je ponuditi zaštitu i privatnost osobnih podataka, korištenjem posebnih algoritama i programa namijenjenih za tu svrhu.

U nastavku su opisane metode koje su u dosadašnjoj upotrebi pri otkrivanju preferencija.

5.1.1. Suradničko filtriranje

Suradničko filtriranje (engl. *Collaborative Filtering* – CF) jedna je od najraširenijih metoda koju primjenjuju preporučiteljski sustavi. Preporučiteljski sustav koji je zasnovan na ovoj metodi, generira preporuke na bazi grupe korisnika sa sličnim prethodnim izborima, tj. sustav može preporučiti stavku korisniku A na temelju sličnog interesa korisnika B (Slika 21.). Ako dva korisnika imaju slične ili iste izbore (ocjene), onda ih u sustavu vežu i iste preferencije. Na taj način dva korisnika grade grupu ili tzv. susjedstvo (engl. *Nearest-neighbor)* [123], [129]. Metoda prikuplja preferencije na dva načina – implicitno i eksplicitno. Eksplicitno prikupljanje podataka zahtijeva od korisnika da ocijeni objekt (najčešće putem klizne ljestvice ocjena), pretražuje (kao oblik interakcije sa sustavom), rangira skup objekata (od najboljeg do najlošijeg), napravi izbor između dva objekta, stvori popis rangiranjem objekata itd. Kad je riječ o implicitnom prikupljanju preferencija, tada sustav prati ponašanje korisnika, promatra

izbor objekata te ono što korisnik pregledava (npr. u e-trgovini), analizira vrijeme pregledavanja itd. Ova metoda ima i neke nedostatke. Jedan od nedostataka personalizacije jest problem hladnog starta (engl. *Cold start*). Naime, kod novog korisnika, sustav nema dovoljno podataka (dodijeljene ocjene) za prikladnu i točnu preporuku. Isto tako, preporučiteljski sustav neće biti od koristi te će ostati izvan funkcije ako mu ne bude rasla baza podataka (ocjena) korisničkih profila. Pristup suradničkoga filtriranja najrasprostranjeniji je u e-trgovini. Korisnici (potrošači) u e-trgovini tako mogu ocjenjivati knjige, filmove, glazbu itd.

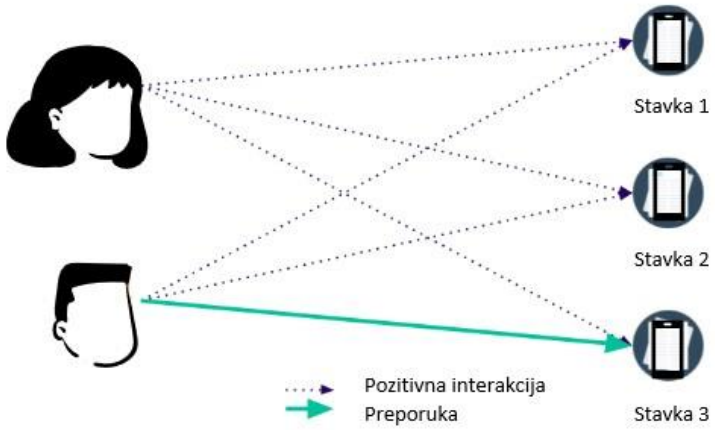

Slika 21. Suradničko filtriranje – način rada (prilagodio autor) [130]

5.1.2. Sustavi temeljeni na znanju

Sustavi preporuka temeljeni na znanju (engl. *Knowledge-based Recommenders*) posebna su kategorija preporučiteljskih sustava, a zasnovani su na eksplicitnim podacima korisnika (preferencije). Za razliku od preporučiteljskih sustava zasnovanih na suradničkom filtriranju, gdje se preporuke temelje na osnovi prethodno dodijeljenih ocjena, ovi sustavi daju preporuku na osnovi specifičnih upita (postavlja ih korisnik) i dubokog poznavanja ponuđenih stavki. Duboko znanje (engl. *Semantic knowledge*) o stavkama detaljno opisuje objekte te na taj način može dati prikladniju preporuku. Preporuka temeljena na usvojenom znanju oslanja se na sljedeće pozadinske podatke:

(a) skup pravila (ograničenja) kod problema izbora u određenoj domeni (npr. izbor multimodalnoga putovanja),
(b) metrike koje su vezane za odgovarajuće sličnosti među vrstama izbora i
(c) skup stavki vezanih za određenu domenu [131].

Ovisno o zadanim zahtjevima korisnika, pravila (uključujući i ograničenja) opisuju koje stavke treba preporučiti. Ograničenja mogu biti, primjerice, problem pristupa određenom prijevoznom sredstvu (osobe s invaliditetom).

Korisnik (npr. putnik) artikulira svoje zahtjeve (preferencije) u smislu specifikacija svojstava konkretnog problema izbora (npr. izbor rute multimodalnoga putovanja), koja trebaju biti dobro predstavljene u smislu pravila, uključujući ograničenja. Ograničenja mogu biti predstavljena isključivo korisničkim zahtjevima. Primjer takvog ograničenja je nepoželjnost upotrebe nekih prijevoznih sredstava (npr. podzemna željeznica i sl.) Označava činjenicu da korisnika prvenstveno zanimaju izbori alternativa putovanja koje ne uključuju to prijevozno sredstvo.

Cijela procedura zasniva se na pozadinskim podacima o korisniku, koji uključuju relacije pridruženja između korisnikovih ograničenja i mogućih izbora. Nakon svakog korištenja preporučiteljski sustav nadograđuje pozadinske podatke (sustav koji uči).

5.1.3. Otkrivanje preferencija temeljeno na optimizacijama

Jedan od popularnih algoritama preporuka je pristup baziran na modelu koji optimizira određeni cilj za poboljšanje davanja preporuke. Ovi modeli preporuka najčešće se bave jednim ciljem, kao što je minimiziranje pogrešaka predviđanja korisnikovih želja/preferencija (npr. kroz postupke otkrivanja preferencija korisnika) ili, primjerice, maksimiziranje kvalitete rangiranja preporuka [132]. Posljednjih godina javlja se potražnja za višeciljnim sustavima preporuka u kojima se razmatraju višestruki ciljevi i preporuke se mogu optimizirati višeciljnom optimizacijom [133]. Na primjer, model preporuke može se izgraditi optimizacijom više podataka, uključujući točnost, kvalitetu i raznolikost preporuka. Posebno su značajni modeli koji rabe kombinacije optimizacijskih algoritama te metode identifikacije zasnovane na različitim metodama najmanjih kvadrata za sustave preporuka.

U ovom istraživanju rabila se prilagođena optimizacijska metoda identifikacije statičkog sustava (inverzni model odlučivanja) koristeći eksplicitne povratne informacije od korisnika (putnika).

5.2. Prijedlog modela otkrivanja putničkih preferencija

U prethodnom poglavlju o otkrivanju korisničkih preferencija ukazano je na postojanje direktne veze između izbora krajnjeg korisnika (kupca, putnika i sl.) i odgovarajućeg skupa njegovih preferencija za konkretnu aktivnost. Osim toga, u dosadašnjim istraživanjima uočeno je da preferencije koje su otkrivene nakon završenih aktivnosti, najtočnije opisuju korisnikovo ponašanje. Zaključeno je da je odgovarajuće preferencije (iskazane, na primjer, preko numeričkih vrijednosti pripadajućih kriterija) najbolje identificirati za svakog korisnika individualno, za razliku od pojedinih pristupa koji se temelje na preferencijama odgovarajuće populacije, kojoj (po nekom principu) pripada korisnik. U ovom istraživanju predložen je pristup zasnovan na identifikaciji vrijednosti odgovarajućih kriterija za preferencije korištenjem postupka zasnovanog na tzv. inverznom modelu procesa odlučivanja.

5.2.1. Inverzni model procesa odlučivanja

Opći matematički model procesa odlučivanja može se opisati na sljedeći način:

> Zadan je (konačan) skup alternativa odluke Alt = {Alt_i za i = 1, 2, 3, ... , n} i skup od m težina kriterija odlučivanja W_C = {W_{Ci} za i = 1, 2, 3, ... , m}. Osim toga, poznat je doprinos a_{ij} (za i = 1, 2, 3, ... , n; j = 1, 2, 3, ... , m) svake alternative u odnosu na svaki kriterij. Zadaća je odrediti optimalnu alternativu Alt_k s najvećom vrijednosti, koja se još naziva i korisnost (engl. *Utility*) alternative.

U tom slučaju, inverzni model procesa odlučivanja opisuje se na sljedeći način:

> Na određen prikladan način rangiran (ocijenjen) je skup alternativa odluke Alt = {Alt_i za i = 1, 2, 3, ... , n} i poznat je doprinos a_{ij} (za i = 1, 2, 3, ... , n; j = 1, 2, 3, ... , m) svake alternative u odnosu na svaki kriterij. Zadaća je odrediti (procijeniti) vrijednosti težina m kriterija odlučivanja označenih kao W_{C1}, W_{C2}, W_{C3}, ... , W_{Cm}. Kako u općem slučaju ne postoji jedinstveno rješenje ovog problema, mogu se primijeniti različite metode optimalne procjene.

Primjena inverznog modela procesa odlučivanja sporadično je istraživana u svijetu, a u gornjem obliku definirana je u [134] na sljedeći način:

> Problem inverznog modela procesa odlučivanja (označen kao tip 1) jest taj da se na osnovi zadanog vektora težina za skup alternativa procijeni vektor težina za kriterije.

Neka je u općem slučaju matematički model procesa odlučivanja definiran kao zadaća određivanja elementa s najvećom vrijednosti iz vektora alternativa:

$$Alt(k) = \max_{Alt}(Alt = A * Wc) \tag{5.1.}$$

gdje je:

A – matrica doprinosa svake alternative u odnosu na svaki kriterij
Wc – vektor težina kriterija
Alt – vektor vrijednosti korisnosti svake alternative
Alt(k)- element iz vektora Alt s najvećom vrijednosti.

Matematički model inverznog procesa odlučivanja definiran je kao optimizacijska zadaća određivanja vektora težina kriterija preko minimizacije p-te norme greške aproksimacije modela procesa odlučivanja (5.1.):

$$\min_{Wc} \|Alt - A * Wc\|^p \tag{5.2.}$$

uz ograničenja na uvjete normalizacije i nenegativnosti elemenata vektora težina kriterija:

$$\begin{aligned} \sum_{j=1}^{m} Wc_j &= 1 \\ Wc &\geq 0 \end{aligned} \tag{5.3.}$$

U ovom slučaju vektor vrijednosti korisnosti svake od alternativa (Alt) određuje se na osnovi procjene ispitanika nekom metodom rangiranja.

Najčešće se upotrebljava kvadratna norma i u tom slučaju to je zadaća metode najmanjih kvadrata za određivanje približnog rješenja linearnog sustava jednadžbi uz dodatna ograničenja uvjeta normalizacije i nenegativnosti rješenja.

Za slučaj korištenja kvadratne norme, optimizacijska funkcija opisana u (5.2.) može se prikazati u matričnom obliku:

$$\mathrm{J} = \|Alt - A * Wc\|^2 = (Alt - A * Wc)^T (Alt - A * Wc) \tag{5.4.}$$

Odgovarajućim matričnim izračunom dobiva se konačno rješenje:

$$\mathrm{J} = Wc^T * Q * Wc - 2x^T * d + r \tag{5.5.}$$

gdje je:

$$Q = A^T * A \qquad d = A^T * Alt \qquad r = Alt^T * Alt$$

Pri uporabi ovog pristupa preporučuje se uzeti više slučajeva odabira multimodalne rute (različiti scenariji izbora multimodalne rute) jer se na taj način povećava točnost procjene preferencija korisnika izražena preko odgovarajućeg vektora težina kriterija. Na primjer, u slučaju korištenja tri različita scenarija izbora multimodalne rute vrijedi:

$$Alt = \begin{bmatrix} Alt_1 \\ Alt_2 \\ Alt_3 \end{bmatrix} \quad A = \begin{bmatrix} A_1 \\ A_2 \\ A_3 \end{bmatrix}$$

gdje je:

Alt_i – procjena vektora vrijednosti alternativa u i-tom scenariju izbora

A_i – matrica alternativa u i-tom scenariju izbora

Pod pretpostavkom da ispitanik ne mijenja svoje preferencije, na ovakav „integralni“ način dobiva se njihova točnija procjena.

5.2.2. Primjeri

Kao primjer određivanja preferencija za multimodalna putovanja iskoristit će se rezultati istraživanja putničkih preferencija za Zagreb (Dodatak 1).

Model alternativa putovanja:

	T_{ukup}[min]	Br.prel.	$T_{pješ}$[min]
A1	67,00	2	8,00
A2	70,00	3	5,00
A3	67,00	2	23,00

Korištenjem linearne normalizacije (Min-Max) definirane sljedećim izračunavanjem:

„Korist“ (Benefit)	$r_{ij}^{L} = 1 - \frac{x_j^{max} - x_{ij}}{x_j^{max} - x_j^{min}}$
„Troškovi“ (Cost)	$r_{ij}^{L} = 1 - \frac{x_{ij} - x_j^{min}}{x_j^{max} - x_j^{min}}$

dobije se sljedeći normalizirani model matrice alternativa:

	T_{ukup}	Br.prel.	$T_{pješ}$
A1	1	1	0,833333
A2	0	0	1
A3	1	1	0

Slučaj ispitanika A1.4 (Zagreb)

Ocjena alternativa dobivena je tako što je korisnik predložene alternative ocijenio skalom ocjena od 1 do 9. U tablici su navedene normalizirane vrijednosti alternativa:

Alt	Ocjena	Težine alternativa (norm) T_A
A1	7	0,50
A2	2	0,14
A3	5	0,36
Zbroj	14	

Za izračun težina kriterija $W_C = (\ W_{C1}\ W_{C2}\ W_{C3})^T$ korištena je navedena metoda najmanjih kvadrata prikazana optimizacijskom funkcijom u izmijenjenom obliku:

$$\min_{W_C}\{(Alt_1\ * W_C - T_{A1})^2 + (Alt_2\ * W_C - T_{A2})^2 + (Alt_3\ * W_C - T_{A3})^2\} \qquad (5.6.)$$

gdje je Alt_i i-ti redak matrice doprinosa alternativa.

Optimizacija (5.6) provodi se uz ograničenja:

$$Wc\ >=\ 0$$
$$W_{C1}\ +\ W_{C2}\ +\ W_{C3} = 1$$

Grafički prikaz optimizacijske funkcije prikazan je na slici:

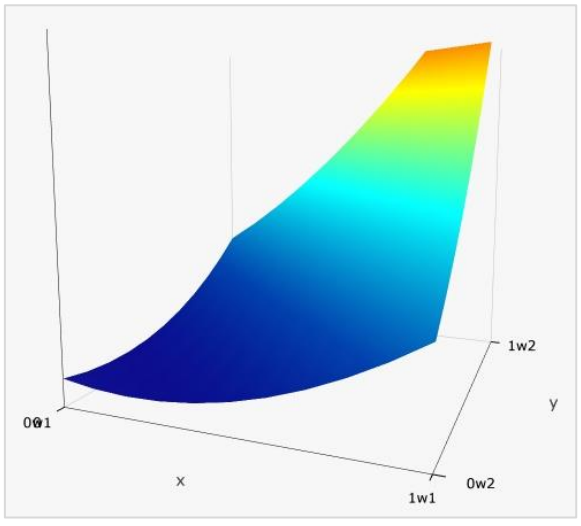

Slika 22. Grafički prikaz optimizacijske funkcije ispitanika A1.4

Kao rezultat optimizacije dobivene su ove vrijednosti vektora težina kriterija:

W_C
0,287
0,287
0,426

Na osnovi tih vrijednosti vektora težina kriterija izračunate su vrijednosti alternativa:

A1	0,927
A2	0,426
A3	0,574

što odgovara izboru ispitanika.

Slučaj ispitanika A1.8 (Zagreb)

Ocjena alternativa ispitanika i pripadna normalizacija:

Alt	Ocjena	Težine alternativa (norm) T_A
A1	9	0,45
A2	7	0,35
A3	4	0,20
Zbroj	20	

Grafički prikaz optimizacijske funkcije prikazan je na slici:

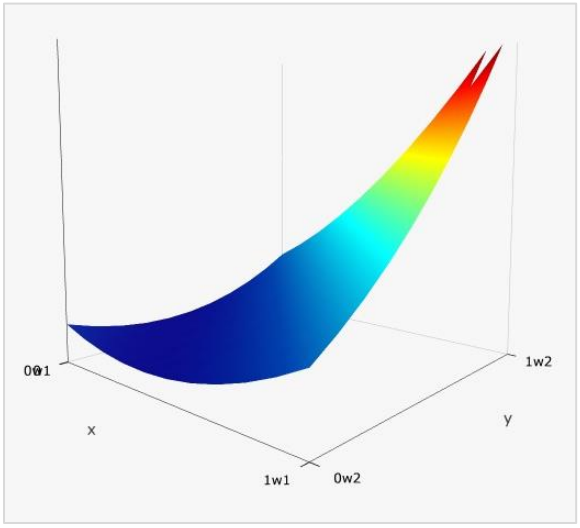

Slika 23. Grafički prikaz optimizacijske funkcije ispitanika A1.8

Kao rezultat optimizacije dobivene su ove vrijednosti vektora težina kriterija:

W_C
0,194
0,194
0,612

Na osnovi tih vrijednosti vektora težina kriterija izračunate su vrijednosti alternativa:

A1	0,898
A2	0,612
A3	0,388

što odgovara izboru ispitanika.

Slučaj ispitanika A1.10 (Zagreb)

Ocjena alternativa ispitanika i pripadna normalizacija:

Alt	Ocjena	Težine alternativa (norm) T_A
A1	8	0,44
A2	7	0,39
A3	3	0,17
Zbroj	18	

Grafički prikaz optimizacijske funkcije prikazan je na slici:

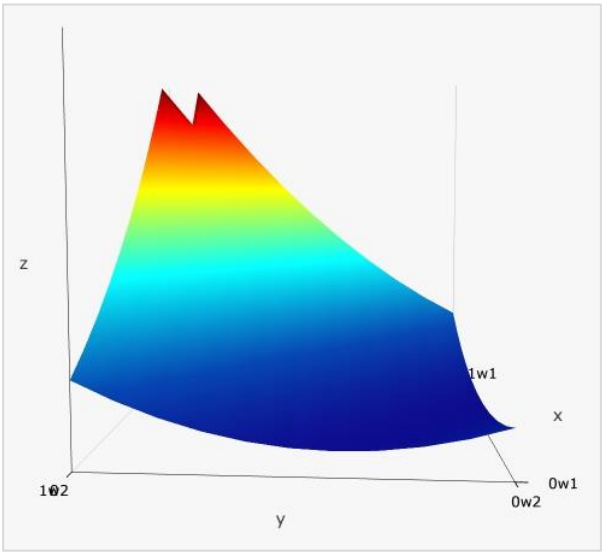

Slika 24. Grafički prikaz optimizacijske funkcije ispitanika A1.10

Kao rezultat optimizacije dobivene su ove vrijednosti vektora težina kriterija:

W_C
0,176
0,176
0,648

Na osnovi tih vrijednosti vektora težina kriterija izračunate su vrijednosti alternativa:

A1	0,890
A2	0,648
A3	0,352

što odgovara izboru ispitanika.

Rezultati otkrivanja korisničkih preferencija opisanom metodom dani su u Dodatku 4.

5.2.3. Proširenje modela otkrivanja

U slučaju da se od ispitanika traži da dodatno i sâm iskaže osobne težine kriterija, funkcija optimizacije otkrivanja preferencija može se proširiti na sljedeći način:

$$J = \lambda\|Alt - A * Wc\|^2 + (1-\lambda)\|Wc - Wc_0\|^2 \qquad (5.7.)$$
$$\lambda \in [0,1]$$

gdje je Wc_0 iskaz ispitanika za težine kriterija, a λ je koeficijent odmjeravanja u rasponu od 0 do 1. U tom slučaju kao integralna ocjena težina kriterija uzima se ona koja minimizira funkciju optimizacije uzimajući u obzir i koeficijent odmjeravanja λ.

6. MODEL IZBORA MULTIMODALNOGA PUTOVANJA

U poglavlju 4. prikazano je kako se izbor multimodalnoga putovanja može opisati kao poseban slučaj višekriterijskoga odlučivanja. Provedena je odgovarajuća analiza prihvatljivosti pojedinih naprednih metoda višekriterijskoga odlučivanja za korištenje pri izboru multimodalnoga putovanja. U tom smislu, izrađena je odgovarajuća analiza postojećih naprednih metoda višekriterijskoga odlučivanja, i to iz skupa metoda koje se temelje na preferencijama kriterija. Na osnovi svega odabranog, kroz analizu prednosti i nedostataka, za nastavak istraživanja odabrane su ove metode višekriterijskoga odlučivanja:

- Metoda težinskog zbroja (engl. *Weighted Sum Method* – WSM)
- Metoda težinskog umnoška (engl. *Weighted Product Method* – WPM)
- Analitički hijerarhijski proces (engl. *Analytic Hierarchy Process* – AHP).

Za potrebe analize, budući da metode trebaju biti tolerantne na neodređenosti i nepreciznosti, istražene su i mogućnosti navedenih metoda primjenom *fuzzy* pristupa. Na kraju ovog poglavlja posebno je ukazano na značaj neophodne normalizacije ulaznih podataka. Prikazane su neke najznačajnije metode normalizacije te su opisane njihove značajke.

6.1. Metoda težinskoga zbroja

Metoda težinskoga zbroja je najpoznatija i (matematički) najjednostavnija metoda višekriterijske analize. Na primjer, ako problem odlučivanja ima *m* alternativnih rješenja koja se ocjenjuju prema *n* kriterija te ako se pretpostavi da svi kriteriji maksimiziraju korisnost alternative, tada se matematički model odlučivanja može iskazati u obliku:

$$A_{opt} = \underbrace{max}_{i} \sum_{j=1}^{n} a_{ij} w_j \qquad i = 1,2,3, \dots, m \tag{6.1}$$

Primjer (Zagreb)

Kriteriji	TT	BrP	TP
Težine	0,5	0,4	0,1
Alt_1	67	2	8
Alt_2	70	3	5
Alt_3	67	2	23

a) Pješačenje „korist“

	Normalizacija (min-max)			Vrijed. Alter.	Red. Alt.
Alt_1	1	1	0,1667	0,92	**2**
Alt_2	0	0	0	0,00	**3**
Alt_3	1	1	1	1,00	**1**

b) Pješačenje „trošak“

	Normalizacija (min-max)			Vrijed. Alter.	Red. Alt.
Alt_1	1	1	0,8333	0,98	**1**
Alt_2	0	0	1	0,10	**3**
Alt_3	1	1	0	0,90	**2**

6.2. Metoda težinskoga umnoška

Metoda težinskoga umnoška slična je metodi težinskoga zbroja. Glavna je razlika u tome što se u matematičkome modelu svaka alternativa uspoređuje s drugima te se upotrebljava množenje (umjesto zbrajanja). Ova usporedba (u obliku omjera) obavlja se za svaki kriterij i svaki omjer se podiže na potenciju ekvivalentnu relativnoj težini odgovarajućega kriterija. Na ovaj je način eksplicitno zastupljena normalizacija te nema potrebe za uobičajenim postupcima normalizacije. Na taj način omogućuje se primjena kako u jednodimenzionalnim tako i u višedimenzionalnim problemima odlučivanja. Rangiranje odnosa pojedinih alternativa određuje se izrazom (6.2.):

$$R(A_K/A_L) = \prod_{j=1}^{n} (a_{Kj}/a_{Lj})^{w_j} \qquad (6.2)$$

gdje je n broj kriterija, a_{ij} je stvarna vrijednost i-te alternative u smislu j-tog kriterija, a w_j je težina važnosti j-tog kriterija. Vrijednost R može biti:

$$\begin{aligned} R > 1 \quad &\rightarrow \quad A_K > A_L \\ R = 1 \quad &\rightarrow \quad A_K = A_L \\ R < 1 \quad &\rightarrow \quad A_L > A_K \end{aligned}$$

Primjer (Zagreb)

Vrijednost parametara multimodalnoga putovanja za tri alternative:

Kriteriji	TT	BrP	TP
Težine	0,4	0,5	0,1
Alt_1	67	2	8
Alt_2	70	3	5
Alt_3	67	2	23

a) Pješačenje „korist“

Odnosi alternativa		Redoslijed. Alt.	
Alt1/Alt2	0,77	A1	**2**
Alt1/Alt3	1,11	A2	**1**
Alt2/Alt3	1,07	A3	**3**
A2>A1>A3			

b) Pješačenje „trošak“

	Odnosi alternativa	Redoslijed. Alt.	
Alt1/Alt2	0,8409	A1	**3**
Alt1/Alt3	0,8998	A2	**1**
Alt2/Alt3	1,0700	A3	**2**
A2>A3>A1			

Jedan od nedostataka navedenog modela (posebno pri korištenju metode otkrivanja preferencija predložene u ovom istraživanju) jest vrlo složena nelinearna matematička forma modela. Međutim, ova forma može se značajno pojednostaviti njezinim logaritmiranjem.

$$R^*[log(A_K/A_L)] = \sum_{j=1}^{n} w_j log(a_{Kj}/a_{Lj}) \tag{6.3}$$

Vrijednost R^* može biti:

$$\begin{aligned} R > 0 \quad &\rightarrow \quad A_K > A_L \\ R = 0 \quad &\rightarrow \quad A_K = A_L \\ R < 0 \quad &\rightarrow \quad A_L > A_K \end{aligned}$$

U ovom slučaju dobiva se linearna ovisnost o vrijednosti kriterija (težina) te je model sličan po strukturi metode težinskog zbroja (WSM). Elementi matrice alternativa su sada vrijednosti logaritma odgovarajućih kvocijenata izvornog modela. U tom se slučaju veoma jednostavno može primijeniti postupak otkrivanja opisan u poglavlju 5.2.

Tijekom rada na istraživanju pri izradi ove disertacije nije pronađen nijedan znanstveni izvor, koji je pokazao linearizirani matematički model za WPM u obliku kako je definiran u (6.3.).

6.3. Analitički hijerarhijski proces

Za potrebe ove analize provedeno je ispitivanje korisnika za scenarij izbora multimodalne rute u Zagrebu. Ispitni obrazac je prikazan u Dodatku 1, a dobiveni ulazni podaci za analizu dani su u Dodatku 2. Sukladno AHP metodi, od ispitanika se tražilo da usporede kriterije po Saatijevoj skali, što je i pokazano u Dodatku 3, zajedno s vrijednostima omjera konzistentnosti. Nakon toga provedeno je izračunavanje vrijednosti kriterija te ocjena konzistentnosti dobivenih rezultata. Sukladno prethodnom opisu, testiranje konzistentnosti nije zadovoljilo u najvećem broju ispitanika. To je i prikazano na Grafikonu 2., gdje se vidi da omjer konzistentnosti u najvećem broju slučajeva ima veliko prekoračenje (preporučena granica je 10 %).

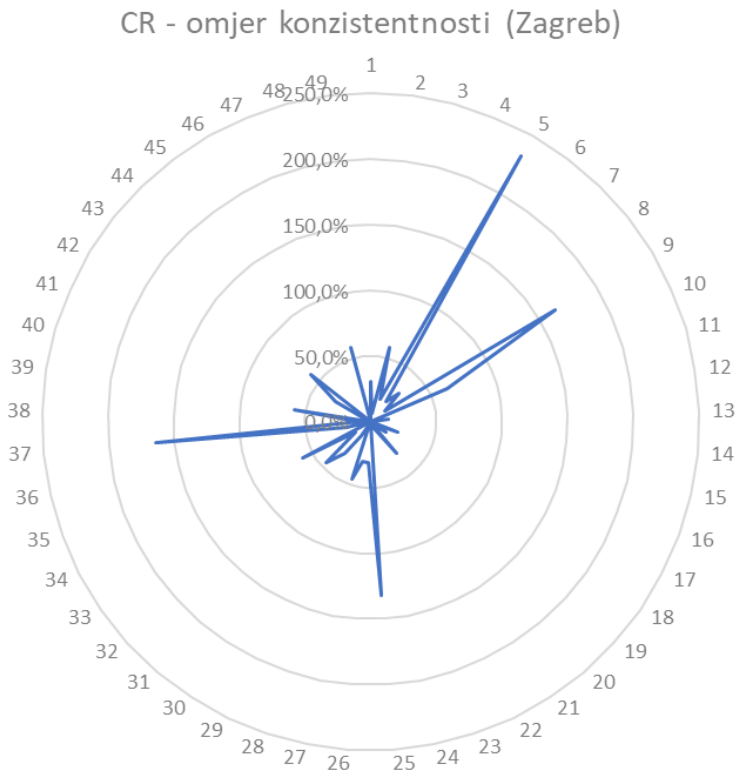

Grafikon 2. Testiranje uvjeta konzistentnosti primijenjene AHP metode

Uzimajući u obzir dobivene rezultate omjera konzistentnosti (kao i potvrde ovih problema iz literature [92], [135], [136]), može se pokazati da AHP metoda nije prikladna za uporabu u slučaju kad su korisnici neeksperti. Osim toga, navedene prednosti ove metode (veliki broj kriterija i alternativa i njihova složenog međuodnosa) ovdje i ne dolaze u obzir, jer uobičajena je preporuka da ne bude više od 4 – 5 kriterija i više od tri alternative.

U slučaju kad su alternative definirane kvantitativno (što je slučaj pri izboru multimodalne rute), AHP postupkom se na osnovi odnosa kriterija definira matrica kriterija, koja služi za izračunavanje pripadnih vrijednosti kriterija, kako je to prikazano na Slici 25. Nakon toga se klasičnim WSM postupkom određuju vrijednosti alternativa, odnosno njihov redoslijed (rang). Zbog toga nema potrebe za otkrivanjem preferencija putnika u obliku matrice odnosa kriterija, nego direktno, u obliku iznosa težinskih vrijednosti kriterija, kako je i pokazano u poglavlju 5.2.

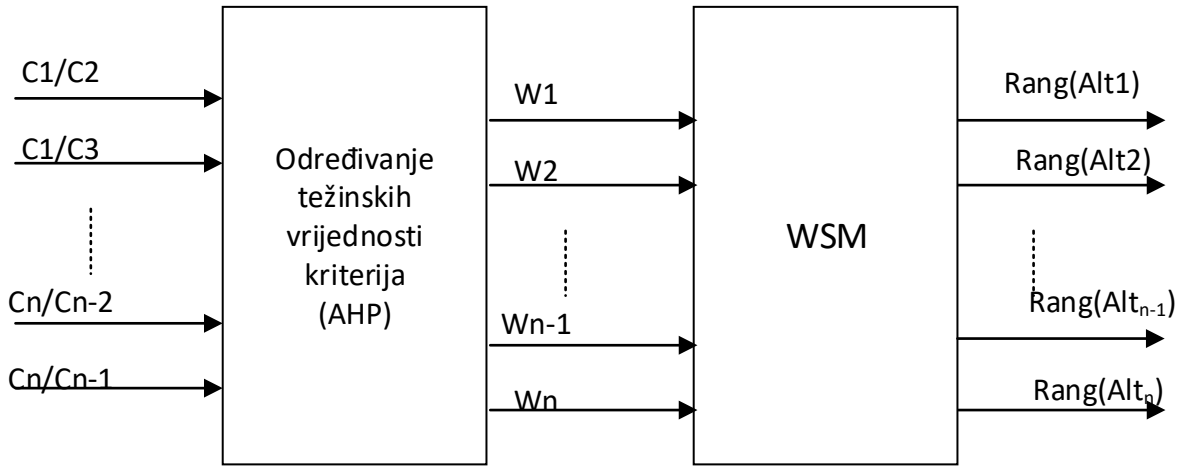

Slika 25. Struktura AHP modela kod kvantitativno definiranih elemenata matrice alternativa (izradio autor)

6.4. *Fuzzy* model izbora multimodalnoga putovanja

Već je u uvodu ovog poglavlja rečeno o važnosti izbora metode koja treba biti tolerantna na neodređenosti i nepreciznosti u iskazivanju preferencija, tj. treba dobro oponašati čovjekov način zaključivanja (s nepreciznostima u iskazu). U tom se smislu nameću modeli koji rabe neizrazitu logiku (engl. *Fuzzy logic*), odnosno pristup preko odgovarajućih funkcija pripadnosti. Kod ovog pristupa kriteriji nisu kvantificirani jedinstvenom numeričkom vrijednosti (engl. *Crisp value*), nego odgovarajućom funkcijom pripadnosti. U slučaju izbora trokutaste funkcije pripadnosti za vrijednost k-tog kriterija to se može iskazati trojkom:

$$w_k \quad \rightarrow \quad (w_{kl}, w_{km}, w_{ku})$$

Gdje w_{kl} definira donju granicu, w_{km} sredinu, a w_{ku} gornju granicu trokutaste funkcije pripadnosti. Na tako definiranim težinskim vrijednostima provodi se normalizacija tako da je zbroj odgovarajućih vrijednosti pojedinih elemenata trojki svih kriterija jednak jedan.

Teoretski se može uzeti u obzir da i elementi matrice alternativa također budu opisane kao neizraziti (engl. *Fuzzy*) brojevi (što bi dobro opisivalo slučaj kad pojedini element nije „izrazita“ vrijednost (engl. *Crisp value*) (npr. ukupno vrijeme putovanja može se prikazati također u obliku *fuzzy* trojke)).

Kao rezultat jednostavnih aritmetičkih operacija množenja i zbrajanja na *fuzzy* brojevima, dobiva se vrijednost alternative također kao *fuzzy* broj. U tom se slučaju provodi postupak rangiranja *fuzzy* brojeva. Prva metoda je utvrđivanje dominantnosti jednog *fuzzy* broja nad drugim kad se gledaju njihovi odsječci iznad npr. 0.9 vrijednosti odgovarajućih trokutastih funkcija pripadnosti. Druga metoda je zasnovana na rangiranju korištenjem agregacijske funkcije:

$$t_R = \frac{1}{3}\frac{r_{\mathrm{u}}^2 - r_{\mathrm{l}}^2 + r_{\mathrm{m}}r_{\mathrm{u}} - r_{\mathrm{l}}r_{\mathrm{m}}}{r_{\mathrm{u}} - r_{\mathrm{l}}}. \tag{6.4}$$

gdje r_l definira donju granicu, r_m sredinu, a r_u gornju granicu trokutaste funkcije pripadnosti. U sljedećih nekoliko primjera pokazana je karakteristična uporaba *fuzzy* pristupa za WSM i AHP. Kako je prethodno pokazano, jednostavnom transformacijom (6.3), WPM model se može transformirati u formu matematičkog modela WSM te se može primijeniti *fuzzy* pristup kao za WSM.

6.4.1. *Fuzzy* WSM

Primjer (Zagreb, prema podacima matrice alternativa za WSM):
Neka su kriteriji opisani *fuzzy* brojevima:

Kriteriji	L	M	U
TT	7	8	9
P	8	8	8
TP	3	5	6

Nakon postupka normalizacije dobivaju se ove vrijednosti kriterija:

	Normalizacija		
Kriteriji	L	M	U
TT	0,30	0,38	0,50
P	0,35	0,38	0,44
TP	0,13	0,24	0,33

a) Pješačenje „korist“:

Konačni rezultati su prikazani u tablici:

Vrijednost alternative	L	M	U	Rang (metoda odsječka)	Rang (težište)
A1	1,9	2,2	2,4	**2**	2,17 **(2)**
A2	1,8	2,0	2,3	**3**	2,03 **(3)**
A3	2,8	3,0	3,3	**1**	3,03 **(1)**

Prikaz funkcija pripadnosti alternativa dan je na Grafikonu 3. Vidljivo je da je dominantna alternativa A3, a najlošija alternativa A2.

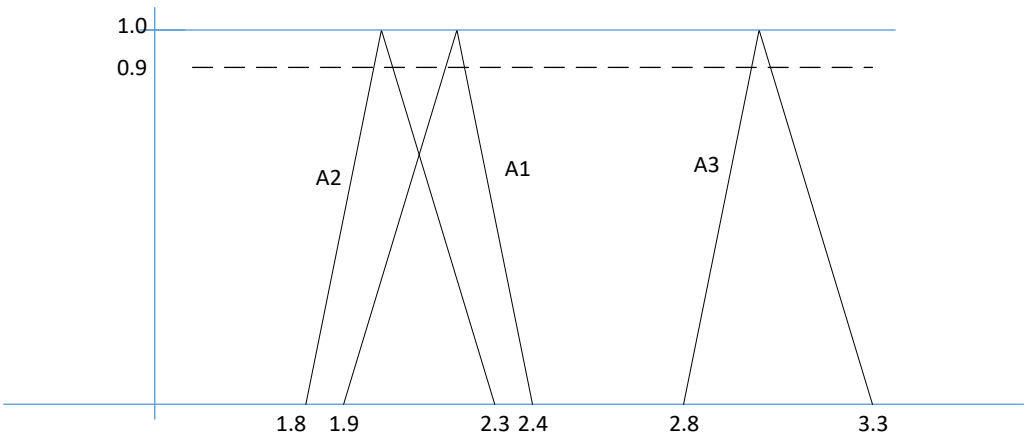

Grafikon 3. Prikaz alternativa za slučaj pješačenja („korist“)

b) Pješačenje „trošak“

Konačni rezultati prikazani su u tablici:

	L	M	U	Rang (metoda odsječak)	Rang (težište)
A1	3,62	3,83	4,11	**1**	3,85 **(1)**
A2	1,78	2,00	2,28	**3**	2,02 **(3)**
A3	2,78	3,00	3,28	**2**	3,02 **(2)**

Prikaz funkcija pripadnosti alternativa dan je na Grafikonu 4. Vidljivo je da je dominantna alternativa A1, a najlošija alternativa A2.

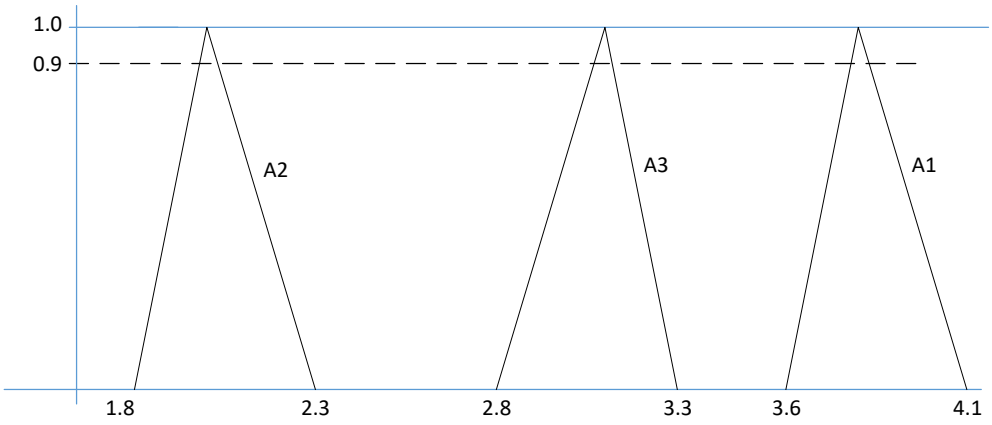

Grafikon 4. Prikaz alternativa za slučaj pješačenja („trošak“)

6.4.2. Fuzzy AHP

Slično kao kod opisa primjene *fuzzy* pristupa za vrijednosti kriterija, isti se pristup može primijeniti i na poznatu Saatijevu skalu relativnih važnosti. U sljedećoj tablici prikazane su vrijednosti Saatyjeve skale relativne važnosti kriterija s pridruženim parametrima pridružene trokutaste funkcije pripadnosti.

Tablica 3. Saatyjeva skala relativne važnosti s pridruženim parametrima pridružene trokutaste funkcije pripadnosti

1	Jednako važno	(1, 1, 1)
3	Umjereno važnije	(2, 3, 4)
5	Strogo važnije	(4, 5, 6)
7	Vrlo stroga, dokazana važnost	(6, 7, 8)
9	Ekstremna važnost	(9, 9, 9)
2, 4, 6, 8	Međuvrijednosti	(1, 2, 3), (3, 4, 5), (5, 6, 7), (7, 8, 9)
1/3, 1/5, 1/7, 1/9	Inverzne vrijednosti	(1,1,1), (1/4,1/3,1/2), (1/6,1/5,1/4), (1/8,1/7,1/6), (1/9,1/9,1/9) (1/3,1/2,1), (1/5,1/4,1/3), (1/7,1/6,1/5), (1/9,1/8,1/7)

Izvor: [137]

Nakon što se odrede *fuzzy* vrijednosti prema Saatijevoj skali, računaju se geometrijske težine (m_{i1}, m_{i2} i m_{i3}) za određivanje *fuzzy* vrijednosti kriterija (v_{i1}, v_{i2}, v_{i3}), što odgovara donjoj, srednjoj i gornjoj *fuzzy* vrijednosti kriterija:

$$m_{i1} = \left(\prod_{j=1}^{n} \widetilde{w}_{ij1}\right)^{\frac{1}{n}}, m_{i2} = \left(\prod_{j=1}^{n} \widetilde{w}_{ij2}\right)^{\frac{1}{n}}, m_{i3} = \left(\prod_{j=1}^{n} \widetilde{w}_{ij3}\right)^{\frac{1}{n}} \quad (6.5)$$

$$i = 1,2,..n$$

gdje je:

$$\widetilde{w}_{i,j} = \left(w_{ij1}, w_{ij2}, w_{ij3}\right)$$

$$\tilde{m}_i = (m_{i1}, m_{i2}, m_{i3})$$

Donja, srednja i gornja *fuzzy* vrijednosti kriterija su:

$$v_{i1} = \frac{m_{i1}}{m_{i1} + \sum_{j=1, j\neq i}^{n} m_{j3}}$$

$$v_{i2} = \frac{m_{i2}}{m_{i2} + \sum_{j=1, j\neq i}^{n} m_{j2}} \qquad (6.6)$$

$$v_{i3} = \frac{m_{i3}}{m_{i3} + \sum_{j=1, j\neq i}^{n} m_{j1}}$$

$$i = 1,2, \dots n,$$

Na taj je način izračunata *fuzzy* vrijednost kriterija definirana kao trojka:

$$\tilde{v}_i = (v_{i1}, v_{i2}, v_{i3}), i = 1, \dots, n$$

Za izračun *crisp* vrijednosti ranga može se primijeniti izraz (6.4).

Primjer (Zagreb):

Kriteriji	C1 TT	C2 BrP	C3 TP
Alt_1	67	2	8
Alt_2	70	3	5
Alt_3	67	2	23

Odnosi kriterija (prema Saatijevoj skali) definirani su *fuzzy* brojevima:

C1/C2 = (1, 2, 3)
C3/C1 = (1, 2, 3)
C3/C2 = (2, 3, 4)

Kriterij vrijeme pješačenja ima najveću težinsku vrijednost, a nakon njega slijedi kriterij vremena putovanja.

Matrica usporedbe parova s neizrazitim vrijednostima je:

Kriteriji	C1			C2			C3		
C1	1,000	1,000	1,000	1,000	2,000	3,000	0,333	0,500	1,000
C2	0,333	0,500	1,000	1,000	1,000	1,000	0,250	0,333	0,500
C3	1,000	2,000	3,000	2,000	3,000	4,000	1,000	1,000	1,000

Nakon što su dodijeljene vrijednosti odnosa kriterija koristeći Saatijevu skalu, izračunava se *fuzzy* geometrijska težina svakog kriterija, sukladno modelu (6.5). Nakon toga se izračunavaju težinske vrijednosti kriterija, koje se potom normaliziraju.

Težinske jedinstvene numeričke vrijednosti kriterija i njihove normalizirane vrijednost kriterija su:

Kriteriji	w_i	w_i(norm)
C1	0,351	**0,308**
C2	0,197	**0,173**
C3	0,592	**0,519**
ZBROJ	1,140	

Konačni su rezultati računani za dva slučaja vrednovanja pješačenje:

Pješačenje „korist“

	Normalizacija (min-max)			Vrijed. Alter.	Rang Alt.
Alt_1	1	1	0,17	**0,31**	2
Alt_2	0	0	0	**0,17**	3
Alt_3	1	1	1	**0,52**	1

Pješačenje „trošak“

	Normalizacija (min-max)			Vrijed. Alter.	Red. Alt.
Alt_1	1	1	0,8333	**0,91**	1
Alt_2	0	0	1	**0,52**	2
Alt_3	1	1	0	**0,48**	3

6.5. Normalizacija

U većini modela višekriterijskoga odlučivanja neophodno je provesti proceduru normalizacije ulaznih podataka jer se na taj način ostvaruje uvjet bezdimenzionalnosti elemenata matrice alternativa [92], [104]. Time se omogućuje primjena, kako u jednodimenzionalnim tako i u višedimenzionalnim problemima odlučivanja. Postoji više metoda normalizacije, od kojih svaka ima neke prednosti i neke nedostatke. Za potrebe ove analize odabrana su tri (najčešća) modela.

a) Jednostavna normalizacija

Normalizirane vrijednosti određuju se na sljedeći način:

$$r_{ij}^{S} = \frac{x_{ij}}{x_j^+}, x_{ij} > 0 \qquad \text{Korist}$$
$$r_{ij}^{S} = \frac{x_j^-}{x_{ij}}, x_{ij} > 0 \qquad \text{Trošak} \tag{6.7}$$

gdje je:

$$x_j^+ = max_i x_{ij} \; ; \; x_j^- = min_i x_{ij}$$

b) Linearna normalizacija (min-max)

$$r_{ij}^{L} = 1 - \frac{x_j^+ - x_{ij}}{x_j^+ - x_j^-} \qquad \text{Korist}$$
$$r_{ij}^{L} = 1 - \frac{x_{ij} - x_j^-}{x_j^+ - x_j^-} \qquad \text{Trošak} \tag{6.8}$$

c) Vektorska normalizacija

$$r_{ij}^{V} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^{m} x_{ij}^2}}$$
$$r_{ij}^{V} = \frac{1}{x_{ij}} \Big/ \sqrt{\sum_{i=1}^{m} \left(\frac{1}{x_{ij}}\right)^2}, x_{ij} > 0 \tag{6.9}$$

Temeljna svojstva ovih normalizacija (Domena, Linearnost transformacije, Pozitivna afina transformacija) prikazana su u Tablici 4. [138]

Tablica 4. Svojstva normalizacije

		Jednostavna	Linearna (min-max)	Vektorska
Domena	$x_{min} > 0$, $y_{min} > 0$	$(0 < r_{min}, 1]$	[0,1]	$(0 < r_{min}, r_{max} < 1)$
Linearnost transformacije	$y_{ij} = ax_{ij}$, $a > 0 \Rightarrow r(y_{ij}) = r(x_{ij})$	**DA**	**DA**	**DA**
Pozitivna afina transformacija	$y_{ij} = ax_{ij} + b$, $a > 0, b \neq 0 \Rightarrow r(y_{ij}) = r(x_{ij})$	**NE**	**DA**	**NE**

Izvor: [138]

Dokazi:

a) Linearnost transformacije:

Jednostavna normalizacija:

$$r(y_{ij}) = y_{ij}/y_j^+ = ax_{ij}/ax_j^+ = x_{ij}/x_j^+ = r(x_{ij}), y_j^+ = \max_j y_{ij}$$

Linearna (min-max) normalizacija:

$$r(y_{ij}) = 1 - (y_j^+ - y_{ij})/(y_j^+ - y_j^-) = 1 - (ax_j^+ - ax_{ij})/(ax_j^+ - ax_j^-) =$$
$$= 1 - (x_j^+ - x_{ij})/(x_j^+ - x_j^-) = r(x_{ij}),\ y_j^- = \min_j y_{ij}$$

Vektorska normalizacija:

$$r(y_{ij}) = y_{ij}/\sqrt{\sum_{i=1}^m y_{ij}^2} = ax_{ij}/\sqrt{a^2\sum_{i=1}^m x_{ij}^2} = x_{ij}/\sqrt{\sum_{i=1}^m x_{ij}^2} = r(x_{ij})$$

b) Pozitivna afina transformacija:

Jednostavna normalizacija:

$$r(y_{ij}) = y_{ij}/y_j^+ = (ax_{ij} + b)/(ax_j^+ + b) \neq x_{ij}/x_j^+ = r(x_{ij})$$

Linearna (min-max) normalizacija:

$$r(y_{ij}) = 1 - (y_j^+ - y_{ij})/(y_j^+ - y_j^-) =$$
$$= 1 - \left((ax_j^+ + b) - (ax_{ij} + b)\right) / \left((ax_j^+ + b) - (ax_j^- + b)\right) =$$
$$= 1 - (x_j^+ - x_{ij})/(x_j^+ - x_j^-) = r(x_{ij})$$

Vektorska normalizacija:

$$r(y_{ij}) = y_{ij}/\sqrt{\sum_{i=1}^m y_{ij}^2} = (ax_{ij} + b)/\sqrt{\sum_{i=1}^m (ax_{ij} + b)^2} \neq x_{ij}/\sqrt{\sum_{i=1}^m x_{ij}^2} = r(x_{ij})$$

Kao najprihvatljivija metoda normalizacije ističe se linearna (min-max) normalizacija jer zadovoljava svojstvo pozitivne afine transformacije. To svojstvo je važno jer kroz ostvarene transformacije ulaznih podataka ostaje sačuvana njihova linearna funkcijska ovisnost.

6.6. Zaključak

Provedenom analizom (prednosti/nedostaci) te prikazanim primjerima uporabe pojedinih metoda višekriterijske optimizacije ustanovljeno je da najviše prednosti ima metoda težinskog zbroja (WSM), uključujući njezinu *fuzzy* inačicu. Naime, izrazom (6.3) je pokazano da se model WPM može vrlo jednostavno transformirati u strukturu sličnu WSM-u pa se i u tom slučaju mogu primjenjivati svi postupci kao i za WSM, a prije svega predložena metoda otkrivanja putničkih preferencija. Metoda AHP je pokazala značajan nedostatak za korektnu uporabu zbog problema primjene teorijske nekonzistentnosti u pokazanim primjerima za neeksperte. Osim toga, pokazalo se (Slika 26.) da kod kvantitativno definiranih elemenata matrice alternativa, ako se upotrebljava predložena metoda otkrivanja putničkih preferencija multimodalnoga putovanja, nema potrebe otkrivati odnose kriterija. Naime, sama metoda otkrivanja putničkih preferencija već daje vrijednosti kriterija.

Primjena *fuzzy* pristupa potpuno je opravdana jer na veoma učinkovit način uzima u obzir neodređenosti i nepreciznosti pri iskazivanju preferencija, tj. veoma dobro oponaša čovjekov način zaključivanja (s nepreciznostima u iskazu).

Kao metoda normalizacije ulaznih podataka odabrana je linearna (min-max) normalizacija, čije su prednosti opisane u prethodnom poglavlju. Osim toga, važno je istaknuti da ona generira najveći raspon transformiranih podataka, što je povoljno svojstvo kod većine identifikacijskih metoda.

7. TESTIRANJE MODELA I VALIDACIJA

Za potrebe testiranja i validacije modela izbora multimodalne rute odabran je primjer putovanja na širem području Beča, a razlog je tomu vrlo dobro razvijen multimodalni sustav javnog prijevoza u Austriji. Kontaktirano je s više kolega s institucija vezanih za istraživanje i razvoj javnog prijevoza za pomoć u provedbi ispitivanja korisnika multimodalnoga sustava javnog prijevoza:

- Technische Universität Wien (Research Center of Transport Planning and Traffic Engineering)
- University of Applied Sciences Technikum Wien
- Austrian Institute of Technology (Integrated Digital Urban Planning).

Nakon odabira primjerenih scenarija multimodalnoga putovanja, definiran je odgovarajući *online* obrazac (Dodatak 5). Proslijeđen je odgovarajućim kanalima koje posjeduju navedene institucije (direktno, Facebook i dr.) prema krajnjim korisnicima (putnicima) javnog prijevoza na širem području Beča. Nakon završetka odabran je reprezentativni uzorak za provedbu testiranja modela i odgovarajuću validaciju. Ulazni podaci provedenog istraživanja dani su u Dodatku 6.

7.1. Metodologija rada

Za potrebe testiranja rabi se uobičajena metodologija za ocjenu primijenjenog modela u teoriji odlučivanja. Tu se ocjenjuje točnost redoslijeda alternativa, kao temeljni podatak izbora. Pritom se samo ocjenjivanje provodi davanjem kaznenih bodova u slučaju kad se ti redoslijedi razlikuju.

Za potrebe validacije modela razvijena je odgovarajuća metodologija, prikazana na Slikama 26. i 27. Nakon odabira reprezentativnog uzorka (odstranjeni su nepotpuno popunjeni obrasci, nekonzistentno popunjeni i dr.), predviđena je odgovarajuća predobrada, koja obuhvaća proceduru normalizacije pojedinih ulaznih podataka (modeli za scenarije S1, S2, S3 uzimajući u obzir izbor korisnika u vezi s doživljajem pješačenja), ocjene pojedinih kriterija od strane korisnika, korisnikova ocjena vektora vrijednosti alternativa (Vr. Alt.-ocjena).

U prvoj fazi predviđen je odgovarajući izračun vektora vrijednosti alternativa prema ocjeni kriterija korisnika. Taj je vektor označen kao: (Vr.alt.-kriter.). Nakon toga na osnovi predloženog modela otkrivanja preferencija korisnika (u ovom slučaju to su vektori vrijednosti kriterija), provodi se postupak koristeći model koji je opisan u potpoglavlju 5.2. Na osnovi tako

dobivenih vektora otkrivenih vrijednosti kriterija (pojedinog korisnika), provodi se izračun vektora vrijednosti alternativa za pojedine scenarije multimodalnoga putovanja (Vr.alt.-otkriv.).

U ovom pristupu polazi se od činjenice da korisnikov izbor alternativa multimodalnih ruta putovanja dosljedno sadrži (implicitno) i njegove odgovarajuće preferencije (vektor vrijednosti kriterija). U tom se smislu kao referentni vektor uzima upravo korisnikov izbor alternativa multimodalnih ruta putovanja (proveden odgovarajućim ocjenjivanjem ponuđenih opcija). Na osnovi toga provodi se kvalitativna ocjena dobivenih rezultata usporedbom referentnog vektora (Vr. Alt.-ocjena) s vektorima (Vr.alt.-kriter.) i (Vr.alt.-otkriv.).

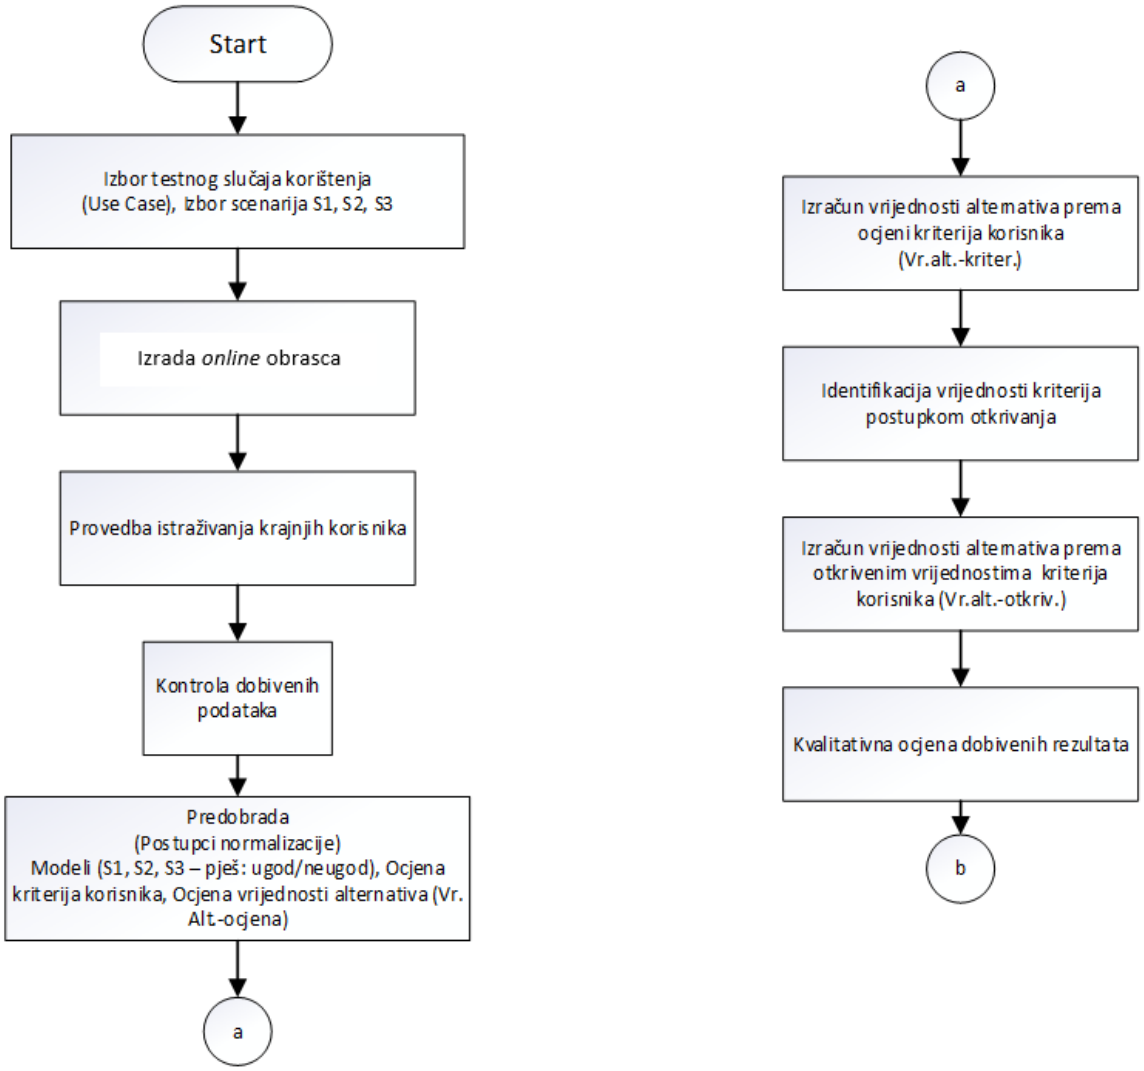

Slika 26. Metodologija testiranja i validacije (dijagram toka, prvi dio)

Sljedeći je korak detaljna numerička analiza dobivenih rezultata. Kao prvo, provodi se izračun grešaka izračunatih vrijednosti alternativa (Vr.alt.-kriter. i Vr.alt.-otkriv.) u odnosu na normaliziranu ocjenu od strane korisnika (vektor Vr. Alt.-ocjena). Zbog karaktera greške uzima se njezin apsolutni iznos. Računa se i **srednjak apsolutnih vrijednosti** grešaka za sva tri scenarija (za svakoga korisnika). Kao direktna mjera kvalitete postupka otkrivanja preferencija izračunava se odnos srednjaka tih grešaka za vrijednosti vektora alternativa Vr.alt.-kriter. i Vr.alt.-otkriv.

Zbog potrebe za kvalitetnijim uvidom u dobivene rezultate provodi se odgovarajuća vizualizacija dobivenih rezultata. Na osnovi svega navedenog, na kraju se donose i zaključci vezani za opisani postupak testiranja i validacije.

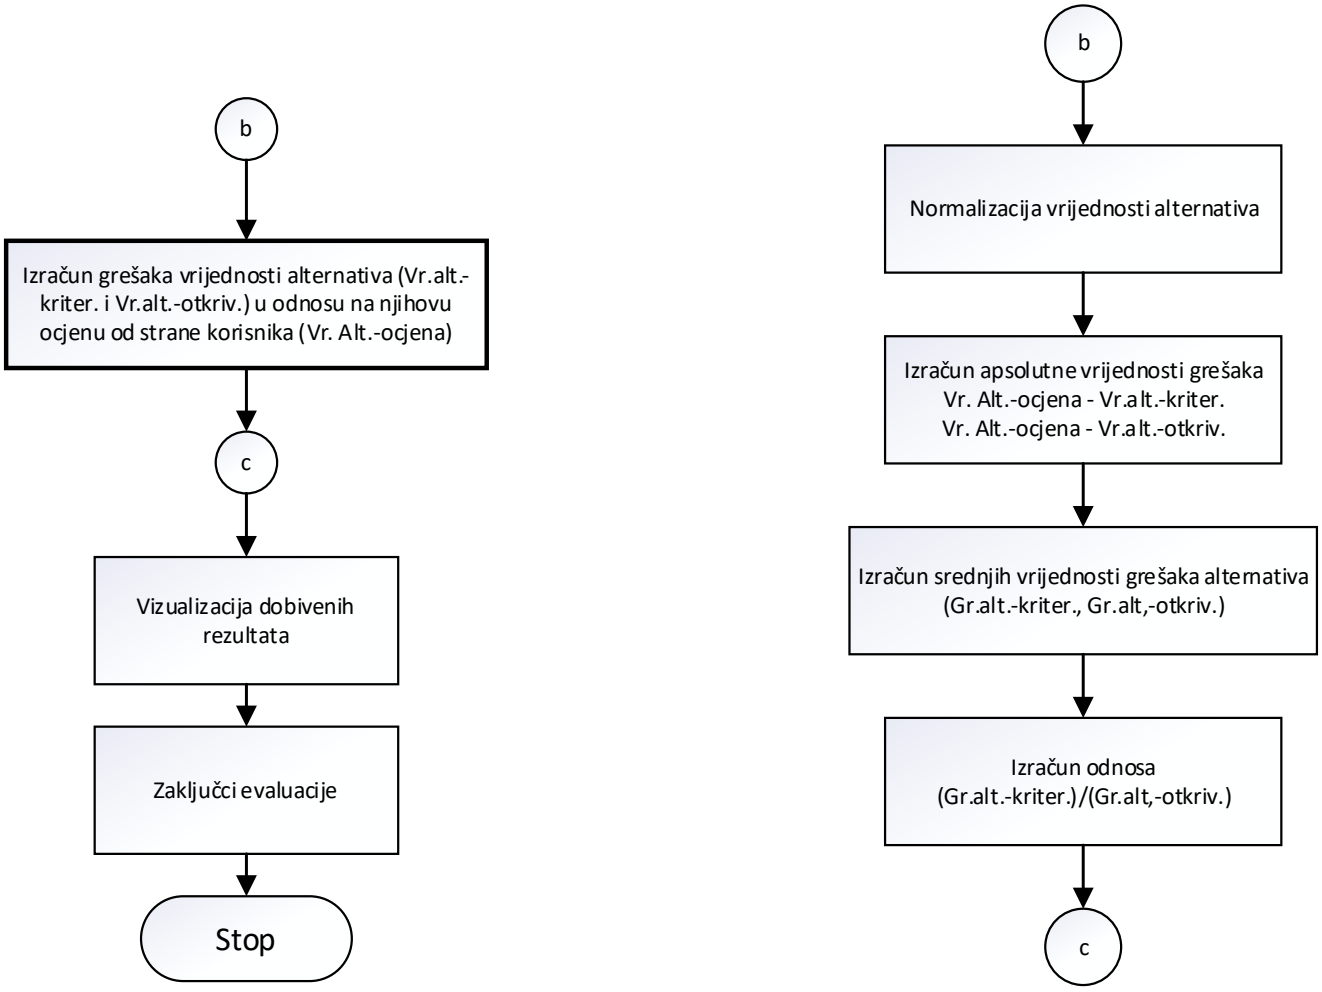

Slika 27. Metodologija testiranja i validacije (dijagram toka, drugi dio)

7.2. Rezultati testiranja modela

U ovom se testiranju uzima u obzir da je redoslijed alternativa dan od strane korisnika (vektor Vr. Alt.-ocjena) referentan. Testiranje modela izbora multimodalne rute provodi se tako da se uspoređuju rezultati redoslijeda alternativa za vektore *Vr.alt.-kriter*. i *Vr.alt.-otkriv*. u odnosu na redoslijed alternativa dân od strane korisnika (vektor Vr. Alt.-ocjena). Provodi se dodjeljivanjem kaznenih bodova postupku izbora izračunantih po vrijednostima kriterija ocijenjenih od korisnika (vektor *Vr.alt.-kriter*.) i postupku izbora izračunatih po vrijednostima kriterija korisnika otkrivenih predloženim postupkom otkrivanja korisničkih preferencija. Rezultati otkrivanja preferencija dani su u Dodatku 7. Izračun vrijednosti alternativa dan je u Dodatku 8. Ocjenjivanje se provodi za sva tri scenarija.

Kazneni bodovi dodjeljuju se na ovaj način:

3 kaznena boda

- ako najbolja odabrana alternativa (vektor Vr. Alt.-ocjena) bude na trećem mjestu (vektori Vr.alt.-kriter. i Vr.alt.-otkriv.)

2 kaznena boda

- ako najbolja odabrana alternativa (vektor Vr. Alt.-ocjena) bude na drugom mjestu (vektori Vr.alt.-kriter. i Vr.alt.-otkriv.)

1 kazneni bod

- ako druga najbolja odabrana alternativa (vektor Vr. Alt.-ocjena) bude na trećem mjestu (vektori Vr.alt.-kriter. i Vr.alt.-otkriv.).

Kazneni bodovi se zbrajaju za svakog korisnika za sve scenarije, gdje je minimalni zbroj nula (redoslijedi alternativa se u potpunosti poklapaju), a maksimalni zbroj je devet (u sva tri scenarija najbolja je alternativa bila na trećem mjestu). Rezultati testiranja dati su u Dodatku 9.

Na Grafikonu 5. prikazani su rezultati opisanog postupka kao zbroj kaznenih bodova (za sva tri scenarija) za svakog korisnika za oba modela izbora multimodalne rute. Iz grafičkog je prikaza vidljivo da je kod svih korisnika broj kaznenih bodova jednak ili manji u slučaju modela odlučivanja zasnovanog na otkrivanju preferencija.

Grafikon 5. Rezultati testiranja modela izbora multimodalne rute

Osim toga, za svakog korisnika izračunan je odnos kaznenih bodova (za model odlučivanja zasnovan na otkrivanju preferencija i za model odlučivanja zasnovan na vrijednostima kriterija ocijenjenim od korisnika.). Rezultat je prikazan na Grafikonu 6.

Grafikon 6. Odnos vrijednosti kaznenih bodova zbog grešaka redoslijeda alternativa

Objašnjenje dobivenih rezultata jest:

a) Ne postoji nijedan korisnik kod kojeg se bolje slažu rezultati redoslijeda alternativa za model odlučivanja zasnovan na vrijednostima kriterija ocijenjenim od korisnika u odnosu na redoslijed alternativa za model odlučivanja zasnovan na otkrivanju preferencija.
b) Postoje samo dva korisnika kod kojih se slažu rezultati redoslijeda alternativa za oba modela odlučivanja.
c) Kod četiriju korisnika redoslijed alternativa za model odlučivanja zasnovan na otkrivanju preferencija u potpunosti odgovara redoslijedu.
d) Ako se uzme kao „razumna mjera“ ovog odnosa kaznenih bodova 0,8, onda je prednost modela odlučivanja zasnovanom na otkrivanju preferencija pokazana u 90,5 % slučajeva.

Na osnovi tih rezultata, može se zaključiti da je model odlučivanja zasnovan na otkrivanju preferencija pokazao izrazitu prednost u odnosu na model odlučivanja zasnovan na vrijednostima kriterija ocijenjenim od strane korisnika.

7.3. Validacija modela

Validacija modela provedena je sukladno metodologiji opisanoj u poglavlju 7.2. i ima jače istaknuta kvantitativna obilježja (numeričko računanje odstupanja vrijednosti alternativa). U ovom slučaju sam redoslijed se ne uzima u obzir jer je to provedeno u postupku testiranja modela. Validacija je provedena za svaki scenarij, kao i za integralnu ocjenu (sva tri scenarija). Izračun vrijednosti alternativa dan je u Dodatku 8. Način računanja pojedinih grešaka modela odlučivanja opisan je u poglavlju 7.2. Rezultati validacije dati su u Dodatku 10.

Na Grafikonu 7. prikazana je distribucija grešaka ocjene vrijednosti alternativa Scenarija 1 za svakog korisnika. Iz grafikona je vidljivo da je za većinu korisnika greška ocjene alternative za model odlučivanja zasnovan na otkrivanju preferencija manja u odnosu na grešku ocjene alternative modela odlučivanja zasnovanog na vrijednostima kriterija ocijenjenim od strane korisnika.

Grafikon 7. Greške ocjene vrijednosti alternativa za Scenarij 1

Na Grafikonu 8. prikazan je odnos prethodnih grešaka ocjene vrijednosti alternativa za Scenarij 1. Napomena: korisnik 16 ima u stvarnosti 10 puta veću grešku nego što je prikazana zbog preglednosti grafičkog prikaza. U 71,43 % korisnika bolji su rezultati kod modela odlučivanja zasnovanog na otkrivanju preferencija.

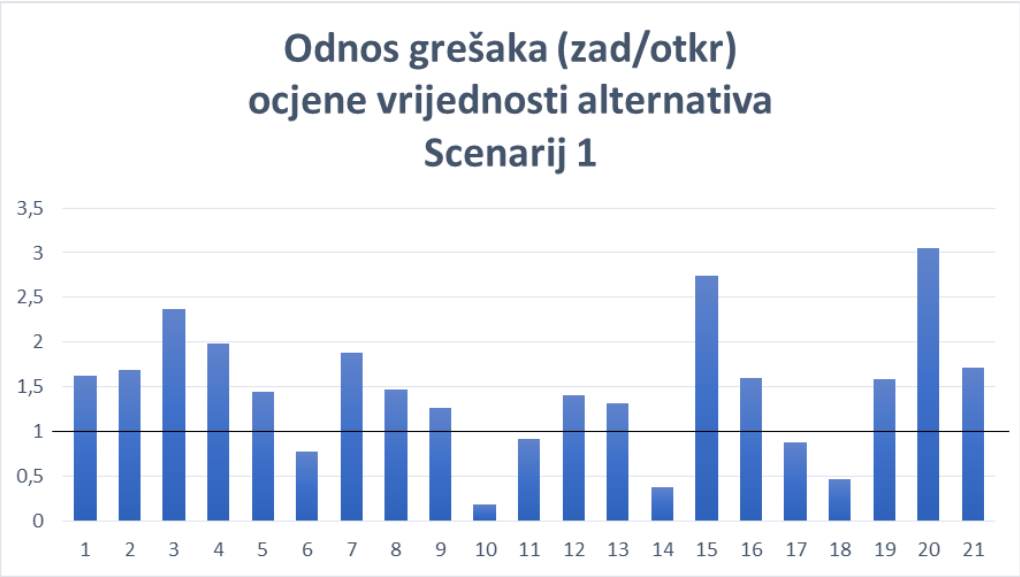

Grafikon 8. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 1

Na Grafikonu 9. prikazana je distribucija grešaka ocjene vrijednosti alternativa Scenarija 2 (za svakog korisnika). Iz grafikona je vidljivo da je za većinu korisnika greška ocjene alternative za model odlučivanja zasnovan na otkrivanju preferencija manja u odnosu na grešku ocjene alternative modela odlučivanja zasnovanom na vrijednostima kriterija ocijenjenim od korisnika.

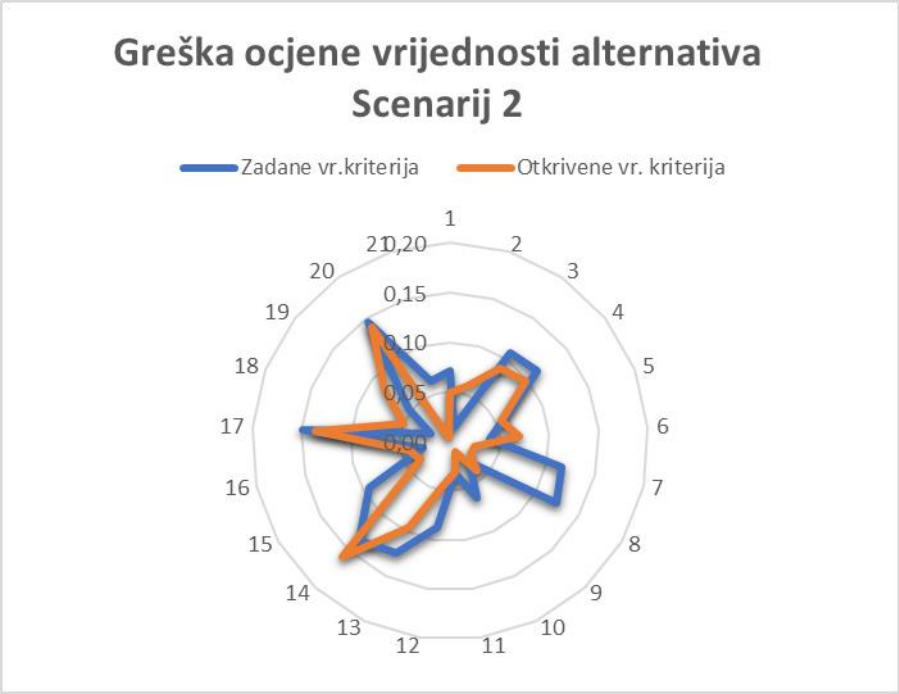

Grafikon 9. Greške ocjene vrijednosti alternativa za Scenarij 2

Na Grafikonu 10. prikazan je odnos grešaka ocjene vrijednosti alternativa za Scenarij 2. Napomena: korisnik 21 ima u stvarnosti 10 puta veću grešku nego što je prikazana zbog preglednosti grafičkog prikaza. U 66,67 % korisnika bolji su rezultati kod modela odlučivanja zasnovanog na otkrivanju preferencija.

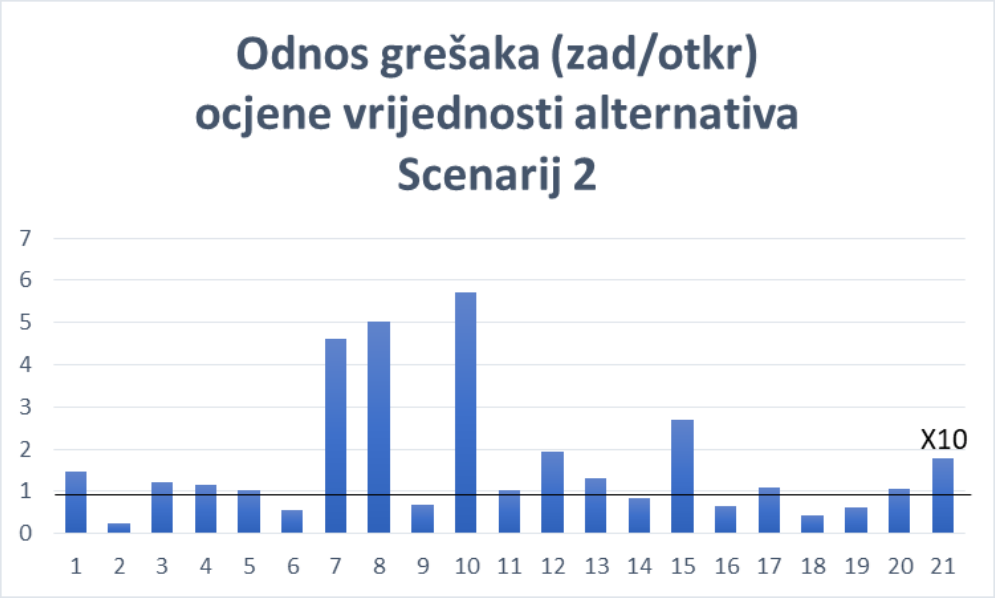

Grafikon 10. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 2

Na Grafikonu 11. prikazana je distribucija grešaka ocjene vrijednosti alternativa Scenarija 3 (za svakog korisnika). Iz grafikona je vidljivo da je za većinu korisnika greška ocjene alternative za model odlučivanja zasnovan na otkrivanju preferencija manja u odnosu na grešku ocjene alternative modela odlučivanja zasnovanog na vrijednostima kriterija ocijenjenim od strane korisnika.

Grafikon 11. Greške ocjene vrijednosti alternativa za Scenarij 3

Na Grafikonu 12. prikazan je odnos grešaka ocjene vrijednosti alternativa za Scenarij 3. Napomena: korisnik 21 ima u stvarnosti 10 puta veću grešku nego što je prikazana zbog preglednosti grafičkog prikaza. U 90,48 % korisnika bolji su rezultati kod modela odlučivanja zasnovanog na otkrivanju preferencija.

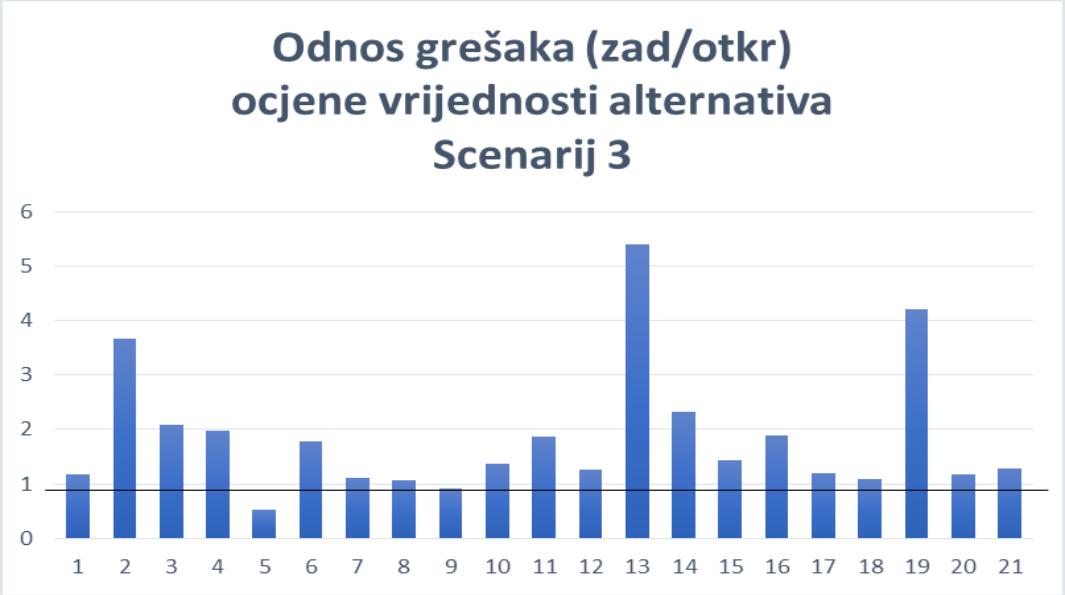

Grafikon 12. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 3

I konačno, na Grafikonu 13. prikazana je distribucija grešaka ocjene vrijednosti alternativa uzimajući u obzir sva tri scenarija za svakog korisnika. Iz grafikona je vidljivo da je za većinu korisnika greška ocjene alternative za model odlučivanja zasnovan na otkrivanju preferencija manja u odnosu na grešku ocjene alternative modela odlučivanja zasnovanog na vrijednostima kriterija ocijenjenim od strane korisnika.

Grafikon 13. Greške ocjene vrijednosti alternativa za sva tri scenarija

Na Grafikonu 14. prikazan je odnos grešaka ocjene vrijednosti alternativa za sva tri scenarija. U 85,71 % korisnika bolji su rezultati kod modela odlučivanja zasnovanog na otkrivanju preferencija.

Grafikon 14. Odnos grešaka ocjene vrijednosti alternativa za sva tri scenarija

7.4. Zaključak validacije

Provedena validacija pokazala je značajne prednosti modela odlučivanja zasnovanog na otkrivanju preferencija. To je, naravno, i očekivani rezultat. Naime, i u postojećoj literaturi koja opisuje višekriterijske modele odlučivanja ukazuje se na problem određivanja vrijednosti kriterija, čak i u jednostavnijim primjerima (mali broj kriterija). To vrijedi i za eksperte u pojedinim područjima primjene, a i značajno više za nestručnjake (engl. *non-experts*). Korisnici preporučiteljskih sustava u pružanju usluga multimodalnoga putovanja u najvećem su broju slučajeva, naravno, nestručni da bi ocijenili svoje kriterije izbora. Zbog toga je i predložen ovaj model, zasnovan na otkrivanju preferencija pomoću podataka o korisnikovim prethodnim izborima ponuđenih alternativa za konkretni slučaj (scenarij). Bolja uspješnost izbora za prikazana tri scenarija (ukupno kod 85,71 % korisnika) najbolja je ocjena predloženog pristupa.

8. ZAKLJUČNA RAZMATRANJA

Sukladno postavljenim ciljevima i znanstvenim hipotezama, rezultati ovog istraživanja realizirani su u okviru znanstvenih doprinosa, kako u dijelu razvoja novog modela za izbor multimodalnoga putovanja zasnovanog na preferencijama korisnika otkrivenih analizom prethodnih izbora, tako i kroz definiranje metodologije otkrivanja korisničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja korisnika.

Provedenim istraživanjem mogućnosti uporabe pojedinih metoda višekriterijske optimizacije (analiza prednosti i nedostataka) ustanovljeno je da je najprihvatljiviji model izbora multimodalnoga putovanja zasnovan na *Metodi težinskog zbroja* (WSM), koji uključuje i njenu *fuzzy* inačicu. Ova metoda omogućuje dobro strukturiranje problema koji se razmatra, eksplicitno opisuje alternative, kriterije i njihove relativne rezultate i težine. Posebno je važno istaknuti da nije zahtjevna za donositelja odluke te se jednostavno implementira. Analizirana metoda *Analitički hijerarhijski proces* (AHP) pokazala je značajan nedostatak (tijekom testiranja) za korektnu uporabu u okviru ove namjene zbog problema dosljedne primjene teorijskog omjera konzistentnosti u pokazanim primjerima za neeksperte. Osim toga, predložena je inovativna transformacija modela koji definira *Metodu težinskog umnoška* (WPM) u model po strukturi vrlo sličan WSM-u pa se i u tom slučaju mogu primjenjivati svi postupci kao i za WSM, a prije svega predložena metoda otkrivanja putničkih preferencija. Prednost ove primjene transformiranog WPM-a je u tome što nema potreba za prethodnom normalizacijom ulaznih podataka.

Metodologija otkrivanja korisničkih preferencija za multimodalna putovanja na temelju zabilježenih izbora pojedinih multimodalnih putovanja korisnika zasnovana je na postojanju direktne veze između izbora krajnjeg korisnika (putnika) i odgovarajućeg skupa njegovih preferencija za konkretnu aktivnost. Osim toga, u dosadašnjim istraživanjima uočeno je da preferencije koje su otkrivene nakon završenih aktivnosti, najtočnije opisuju korisnikovo ponašanje. Istraživanjem je utvrđeno da je odgovarajuće preferencije (iskazane, na primjer, preko numeričkih vrijednosti pripadajućih kriterija) najbolje identificirati za svakog korisnika individualno, za razliku od pojedinih pristupa koji se temelje na preferencijama odgovarajuće populacije kojoj (po nekom principu) pripada korisnik. U ovom istraživanju predložen je pristup zasnovan na identifikaciji vrijednosti odgovarajućih kriterija za preferencije korištenjem postupka zasnovanom na tzv. inverznom modelu procesa odlučivanja.

Matematički model inverznog procesa odlučivanja definiran je kao optimizacijska zadaća određivanja vektora težina kriterija preko minimizacije p-te norme greške aproksimacije modela procesa odlučivanja. U slučaju izbora kvadratne norme zadaća se svodi na klasičnu metodu najmanjih kvadrata greške aproksimacije rješenja sustava linearnih jednadžbi. Provedenim testiranjima i validacijom utvrđeno je veoma učinkovito dobivanje kvalitetnih rezultata provedenog postupka otkrivanja preferencija putnika kod multimodalnih putovanja.

U budućim istraživanjima planira se detaljnije istražiti proširenje ovog modela na složenije oblike fazifikacije, a prije svega kroz razvoj matematičkog modela određivanja eventualno prikladnijih funkcija pripadnosti za ovaj slučaj. Osim toga, moguća su i u istraživanju proširenja *fuzzy* modela i na matricu alternativa, gdje bi također vrijednosti atributa alternativa bile izražene *fuzzy* brojevima s odgovarajućim funkcijama pripadnosti.

LITERATURA

[1] United Nations, „World Urbanization Prospects The 2018 Revision“, New York, 2018.

[2] United Nations (Department of Economic and Social Affairs), „Transforming our world: the 2030 Agenda for Sustainable Development“. https://sdgs.un.org/goals (pristupljeno ožu. 17, 2022).

[3] European Automobile Manufaturers' Association (ACEA), „Vehicles in use Europe 2022“, Brussels, 2022. Pristupljeno: svi. 25, 2022. [Na internetu]. Available: https://www.acea.auto/files/ACEA-report-vehicles-in-use-europe-2022.pdf

[4] V. Albino, U. Berardi, i R. M. Dangelico, „Smart cities: Definitions, dimensions, performance, and initiatives“, *Journal of Urban Technology*, sv. 22, izd. 1, str. 3–21, 2015, doi: 10.1080/10630732.2014.942092.

[5] F. Zhao, O. I. Fashola, T. I. Olarewaju, i I. Onwumere, „Smart city research: A holistic and state-of-the-art literature review“, *Cities*, sv. 119, str. 103406, pros. 2021, doi: 10.1016/J.CITIES.2021.103406.

[6] A. Arroub, B. Zahi, E. Sabir, i M. Sadik, „A literature review on Smart Cities: Paradigms, opportunities and open problems“, u *Proceedings - 2016 International Conference on Wireless Networks and Mobile Communications, WINCOM 2016: Green Communications and Networking*, pros. 2016, str. 180–186. doi: 10.1109/WINCOM.2016.7777211.

[7] T. Tompson, „Understanding the Contextual Development of Smart City Initiatives: A Pragmatist Methodology“, *She Ji: The Journal of Design, Economics, and Innovation*, sv. 3, izd. 3, str. 210–228, ruj. 2017, doi: 10.1016/J.SHEJI.2017.11.004.

[8] R. Giffinger *i ostali*, „City-ranking of European Medium-Sized Cities“, u *51st IFHP World Congres „Futures of Cities“*, 2007, str. 12.

[9] G. P. Hancke, B. de C. de Silva, i G. P. Hancke, „The Role of Advanced Sensing in Smart Cities“, *Sensors*, sv. 13, izd. 1, str. 393–425, pros. 2012, doi: 10.3390/S130100393.

[10] A. Caragliu, C. del Bo, i P. Nijkamp, „Smart Cities in Europe“, *Journal of Urban Technology*, sv. 18, izd. 2, str. 65–82, tra. 2011, doi: 10.1080/10630732.2011.601117.

[11] C. Harrison *i ostali*, „Foundations for Smarter Cities“, *IBM J Res Dev*, sv. 54, izd. 4, srp. 2010, doi: 10.1147/JRD.2010.2048257.

[12] M. Bawa, D. Caganova, I. Szilva, i D. Spirkova, „Importance of internet of things and big data in building smart city and what would be its challenges“, u *Smart City 360°*, sv. 166, Cham: Springer, 2016, str. 605–616. doi: 10.1007/978-3-319-33681-7_52.

[13] P. Ribeiro, G. Dias, i P. Pereira, „Transport Systems and Mobility for Smart Cities“, *Applied System Innovation 2021, Vol. 4, Page 61*, sv. 4, izd. 3, str. 61, ruj. 2021, doi: 10.3390/ASI4030061.

[14] D. Mitchell, S. Claris, i D. Edge, „Human-Centered Mobility: A New Approach to Designing and Improving Our Urban Transport Infrastructure“, *Engineering*, sv. 2, izd. 1, str. 33–36, ožu. 2016, doi: 10.1016/J.ENG.2016.01.030.

[15] European Commission, „European Urban Mobility“, Brussels, 2017.

[16] S. Rupprecht, L. Brand, S. Böhler-Baedeker, i L. M. Brunner, „Guidelines for Developing and Implementing a Sustainable Urban Mobility Plan“, Brussels, 2016.

[17] Danish Energy Agency, „Energy and Climate Policies beyond 2020 in Europe-Overall and selected countries“, 2015.

[18] European Commission, „Key to Innovation Integrated Solution - Multimodal personal mobility“, Brussels, 2013. Pristupljeno: tra. 19, 2022. [Na internetu]. Available: https://silo.tips/download/smart-cities-stakeholder-platform-multimodal-personal-mobility

[19] D. Brčić i M. Ševrović, *Logistika prijevoza putnika*. Zagreb: Fakultet prometnih znanosti Sveučilište u Zagrebu, 2012.

[20] S. Winter i S. Nittel, „Ad-hoc shared-ride trip planning by mobile geosensor networks“, *International Journal of Geographical Information Science*, sv. 00, izd. 00, str. 1–22, 2006.

[21] European Commission, „Sustainable and Smart Mobility Strategy – putting European transport on track for the future“, Brussels, pros. 2020. Pristupljeno: svi. 18, 2022. [Na internetu]. Available: https://eur-lex.europa.eu/resource.html?uri=cellar:5e601657-3b06-11eb-b27b-01aa75ed71a1.0001.02/DOC_1&format=PDF

[22] „THE NEW EUROPEAN Urban Mobility Framework“. https://ec.europa.eu/commission/presscorner/detail/en/fs_21_6781 (pristupljeno lip. 01, 2022).

[23] C. Benevolo, R. P. Dameri, i B. D'Auria, „Smart mobility in smart city action taxonomy, ICT intensity and public benefits“, u *Empowering Organizations: Enabling Platforms and Artefacts*, sv. 11, T. Torre, A. M. Braccini, i R. Spinelli, Ur. Springer Heidelberg, 2016, str. 13–28. doi: 10.1007/978-3-319-23784-8_2.

[24] G. Lyons, „Getting smart about urban mobility – Aligning the paradigms of smart and sustainable“, *Transp Res Part A Policy Pract*, sv. 115, str. 4–14, ruj. 2018, doi: 10.1016/J.TRA.2016.12.001.

[25] L. Butler, T. Yigitcanlar, i A. Paz, „Smart urban mobility innovations: A comprehensive review and evaluation“, *IEEE Access*, sv. 8, str. 196034–196049, 2020, doi: 10.1109/ACCESS.2020.3034596.

[26] I. Bošnjak, *Inteligentni transportni sustavi - ITS 1*. Zagreb: Fakultet prometnih znanosti, Sveučilište u Zagrebu, 2006.

[27] A. Nuzzolo, A. Comi, U. Crisalli, i L. Rosati, „A new Advanced Traveler Advisory Tool based on personal user preferences“, u *17th IEEE International Conference on*

Intelligent Transportation Systems, ITSC 2014, 2014, str. 1561–1566. doi: 10.1109/ITSC.2014.6957915.

[28] F. Carrese, S. Carrese, S. M. Patella, M. Petrelli, i S. Sportiello, „A Framework for Dynamic Advanced Traveler Information Systems“, *Future Transportation*, sv. 1, izd. 3, str. 590–600, 2021, doi: 10.3390/futuretransp1030031.

[29] J. W. Grotenhuis, B. W. Wiegmans, i P. Rietveld, „The desired quality of integrated multimodal travel information in public transport: Customer needs for time and effort savings“, *Transp Policy (Oxf)*, sv. 14, izd. 1, str. 27–38, sij. 2007, doi: 10.1016/J.TRANPOL.2006.07.001.

[30] B. Mandžuka, D. Brčić, i P. Škorput, „Primjena multimodalnih putnih vodiča za gradska i prigradska putovanja“, u *Proceedings of the 34th Conference on Transportation Systems with International Participation, Automation in Transportation 2014*, 2014, str. 92–95.

[31] C. O. Cruz i J. M. Sarmento, „“Mobility as a Service” Platforms: A Critical Path towards Increasing the Sustainability of Transportation Systems“, *Sustainability 2020, Vol. 12, Page 6368*, sv. 12, izd. 16, str. 6368, kol. 2020, doi: 10.3390/SU12166368.

[32] P. Jittrapirom *i ostali*, „Mobility as a Service: A Critical Review of Definitions, Assessments of Schemes, and Key Challenges“, *Urban Plan*, sv. 2, izd. 2, str. 13–25, lip. 2017, doi: 10.17645/UP.V2I2.931.

[33] M. B. Matyas, „Investigating individual preferences for new mobility services: the case of “mobility as a service” products “, University College London - The Faculty of the Built Environment, London, 2020. Pristupljeno: lip. 21, 2022. [Na internetu]. Available: https://discovery.ucl.ac.uk/id/eprint/10091070/

[34] J. Sochor, H. Arby, I. C. M. A. Karlsson, i S. Sarasini, „A topological approach to Mobility as a Service: A proposed tool for understanding requirements and effects, and for aiding the integration of societal goals“, *Research in Transportation Business & Management*, sv. 27, str. 3–14, lip. 2018, doi: 10.1016/J.RTBM.2018.12.003.

[35] J. Spallek i D. Krause, „Process Types of Customisation and Personalisation in Design for Additive Manufacturing Applied to Vascular Models“, *Procedia CIRP*, sv. 50, str. 281–286, sij. 2016, doi: 10.1016/J.PROCIR.2016.05.022.

[36] R. van Nes i P. H. L. Bovy, „Multimodal traveling and its impact on urban transit network design“, *J Adv Transp*, sv. 38, izd. 3, str. 225–241, 2004, doi: 10.1002/ATR.5670380302.

[37] M. Bielli, A. Boulmakoul, i H. Mouncif, „Object modeling and path computation for multimodal travel systems“, *Eur J Oper Res*, sv. 175, izd. 3, str. 1705–1730, pros. 2006, doi: 10.1016/J.EJOR.2005.02.036.

[38] M. K. Anderson, „Behavioural Models for Route Choice of Passengers in Multimodal Public Transport Networks“, DTU Transport, 2013.

[39] P. Cheung i U. Sengupta, „Analysis of Journey Planner Apps and Best Practice Features“, 2016.

[40] ONN Bikes, „Possibilities of First and Last mile“, 2019. https://medium.com/@ONNBikes/possibilities-of-first-and-last-mile-travel-72216c511305 (pristupljeno lip. 06, 2022).

[41] ELTIS, „2018 - Year of Multimodality“. https://www.eltis.org/discover/news/2018-year-multimodality (pristupljeno tra. 19, 2022).

[42] A. K. Shaikhanova, A. D. Zolotov, E. M. Muhametov, M. P. Karpinski, i D. O. Kozhahmetova, „Anatomy and efficiency of urban multimodal mobility“, *Scientific Reports 2014 4:1*, sv. 4, izd. 1, str. 1–9, stu. 2014, doi: 10.1038/srep06911.

[43] A. Spickermann, V. Grienitz, i H. A. von der Gracht, „Heading towards a multimodal city of the future?: Multi-stakeholder scenarios for urban mobility“, *Technol Forecast Soc Change*, sv. 89, str. 201–221, stu. 2014, doi: 10.1016/J.TECHFORE.2013.08.036.

[44] H. Guo, A. Bhaskar, B. Casey, M. Miska, i E. Chung, „An Innovative Framework for Customised Intermodal and Multiobjective Trip Planner“, *International Journal of Intelligent Transportation Systems Research*, sv. 15, izd. 2, str. 117–125, svi. 2017, doi: 10.1007/S13177-016-0126-Y/FIGURES/5.

[45] C. Pronello, J. P. R. V. Simão, i V. Rappazzo, „The effects of the multimodal real time information systems on the travel behaviour“, *Transportation Research Procedia*, sv. 25, str. 2677–2689, sij. 2017, doi: 10.1016/J.TRPRO.2017.05.172.

[46] L. Gao, Z. Juan, A. Ni, i P. Jing, „The effect of travel information on travelers' choice of travel modes and routes: A case study of the travel between the campuses“, *Math Probl Eng*, sv. 2014, 2014, doi: 10.1155/2014/781395.

[47] A. Solar i A. Marqués, „ENHANCED WISETRIP: Wide Scale Multimodal and Intelligent Journey Planning“, *Procedia Soc Behav Sci*, sv. 48, str. 2940–2949, 2012, doi: 10.1016/J.SBSPRO.2012.06.1262.

[48] M. Boero, M. Garré, J. Fernandez, S. Persi, D. Quesada, i M. Jakob, „MyWay Personal Mobility: From Journey Planners to Mobility Resource Management“, *Transportation Research Procedia*, sv. 14, str. 1154–1163, 2016, doi: 10.1016/J.TRPRO.2016.05.186.

[49] S. Wells, P. Forbes, J. Masthoff, S. Gabrielli, i A. Jyllha, „SUPERHUB: Integrating digital behaviour management into a novel sustainable urban mobility system“, u *HCI 2013 - 27th International British Computer Society Human Computer Interaction Conference: The Internet of Things*, 2013. doi: 10.14236/EWIC/HCI2013.28.

[50] „Linking Danube - Interreg Danube“. https://www.interreg-danube.eu/approved-projects/linking-danube (pristupljeno lip. 21, 2022).

[51] „OJP4Danube - Interreg Danube“. https://www.interreg-danube.eu/approved-projects/ojp4danube (pristupljeno lip. 21, 2022).

[52] D. Esztergár-Kiss, „Framework of Aspects for the Evaluation of Multimodal Journey Planners“, *Sustainability 2019, Vol. 11, Page 4960*, sv. 11, izd. 18, str. 4960, ruj. 2019, doi: 10.3390/SU11184960.

[53] G. Gentile i K. Noekel, Ur., *Modelling Public Transport Passenger Flows in the Era of Intelligent Transport Systems*, 1. izd. Cham: Springer Cham, 2016. doi: 10.1007/978-3-319-25082-3.

[54] European Commission, „Urban ITS: EU-wide Multimodal Travel Information Services“, Brussels, stu. 2019. Pristupljeno: lip. 21, 2022. [Na internetu]. Available: http://ec.europa.eu/transport/themes/its/consultations/2015-its-mmtips_en.htm

[55] K. Rehrl, S. Bruntsch, i H. J. Mentz, „Assisting multimodal travelers: Design and prototypical implementation of a personal travel companion“, *IEEE Transactions on Intelligent Transportation Systems*, sv. 8, izd. 1, str. 31–42, ožu. 2007, doi: 10.1109/TITS.2006.890077.

[56] M. Jakob, J. Hrncir, L. Oliva, F. Ronzano, P. Zilecky, i J. Finnegan, „Personalized fully multimodal journey planner“, *Frontiers in Artificial Intelligence and Applications*, sv. 263, str. 1225–1226, 2014, doi: 10.3233/978-1-61499-419-0-1225.

[57] „DB Navigator, Aplikacije na Google Playu“. Pristupljeno: tra. 19, 2022. [Na internetu]. Available: https://play.google.com/store/apps/details?id=de.hafas.android.db&hl=hr&gl=US

[58] „BudapestGO Trip Planner“. https://go.bkk.hu/ (pristupljeno tra. 19, 2022).

[59] „BudapestGO Trip Planner“. https://go.bkk.hu/ (pristupljeno stu. 08, 2022).

[60] „Citymapper: Directions For All Your Transport, Aplikacije na Google Playu“. https://play.google.com/store/apps/details?id=com.citymapper.app.release&referrer=utm_medium%3Dweb%26utm_source%3Dcmweb%253Adesktop%253Ahome%253AheroBtn&hl= (pristupljeno tra. 19, 2022).

[61] „Citymapper: All Your Transport - Apps on Google Play“. https://play.google.com/store/apps/details?id=com.citymapper.app.release&hl=en&gl=US (pristupljeno stu. 08, 2022).

[62] „TripGo City Transport Directio – Apps on Google Play“. https://play.google.com/store/apps/details?id=com.buzzhives.android.tripplanner&hl=en_AU&gl=US (pristupljeno stu. 08, 2022).

[63] „MAAS in Helsinki: a precursor to a new urban mobility?“ https://blog.padam-mobility.com/en/2019/08/01/the-maas-in-helsinki-the-forerunner-of-a-new-urban-mobility/ (pristupljeno ožu. 27, 2022).

[64] Parangonnage international du CEREMA, „MaaS in Europe: Lessons from the Helsinki, Vienna and Hanover experiments“, 2019.

[65] „About Whim - MaaS Global“. https://whimapp.com/about-whim/ (pristupljeno lip. 22, 2022).

[66] „One app for bus, train, e-scooter, bike, taxi - Whim Helsinki“. https://whimapp.com/helsinki/en/ (pristupljeno stu. 08, 2022).

[67] „WienMobil app - Wiener Linien“. https://www.wienerlinien.at/web/wl-en/wienmobil-app (pristupljeno ožu. 30, 2022).

[68] S. Mandžuka, „Providing Multimodal Traveler Information Cross-Border Journey Planners Approach“, u *New Technologies, Development and Application IV*, 2021, sv. 233, str. 665–672. doi: 10.1007/978-3-030-75275-0_73/COVER/.

[69] F. Welle Donker i B. van Loenen, „How to assess the success of the open data ecosystem?“, *http://dx.doi.org/10.1080/17538947.2016.1224938*, sv. 10, izd. 3, str. 284–306, ožu. 2016, doi: 10.1080/17538947.2016.1224938.

[70] S. Paiva, M. A. Ahad, G. Tripathi, N. Feroz, i G. Casalino, „Enabling Technologies for Urban Smart Mobility: Recent Trends, Opportunities and Challenges“, *Sensors 2021, Vol. 21, Page 2143*, sv. 21, izd. 6, str. 2143, ožu. 2021, doi: 10.3390/S21062143.

[71] M. Kumar i A. Singh, „Probabilistic data structures in smart city: Survey, applications, challenges, and research directions“, *J Ambient Intell Smart Environ*, sv. 14, izd. 4, str. 229–284, sij. 2022, doi: 10.3233/AIS-220101.

[72] K. L.-M. Ang, J. K. P. Seng, E. Ngharamike, i G. K. Ijemaru, „Emerging Technologies for Smart Cities’ Transportation: Geo-Information, Data Analytics and Machine Learning Approaches“, *ISPRS International Journal of Geo-Information 2022, Vol. 11, Page 85*, sv. 11, izd. 2, str. 85, sij. 2022, doi: 10.3390/IJGI11020085.

[73] J. R. Keller i O. Thereaux, „Personal data in transport: exploring a framework for the future (report) – The ODI“, London, 2018. Pristupljeno: ožu. 11, 2022. [Na internetu]. Available: https://theodi.org/article/personal-data-in-transport-exploring-a-framework-for-the-future-report/

[74] K. Vidovic, S. Mandzuka, i M. Sostaric, „Data Quality Within National Access Point for Provision of Multimodal Travel Information within European Union“, u *Proceedings Elmar - International Symposium Electronics in Marine*, ruj. 2019, str. 15–19. doi: 10.1109/ELMAR.2019.8918828.

[75] „European Commission: Regulations - Commission Delegated Regulation (EU) 2017/1926“. https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017R1926&from=EN (pristupljeno lis. 23, 2022).

[76] B. Mandžuka, K. Vidović, M. Vujić, i C. Alexopoulos, „The Importance Of Open Data Accessibility For Multimodal Travel Improvement“, *Interdisciplinary Description of Complex Systems : INDECS*, sv. 20, izd. 2, str. 136–148, tra. 2022, doi: 10.7906/INDECS.20.2.6.

[77] F. prometnih Znanosti i Ericsson Nikola Tesla d.d., „Studija za pružanje multimodalnih informacija o prometu“, Zagreb, 2019.

[78] E. M. Schomakers, C. Lidynia, i M. Ziefle, „All of me? Users’ preferences for privacy-preserving data markets and the importance of anonymity“, *Electronic Markets*, sv. 30, izd. 3, str. 649–665, ruj. 2020, doi: 10.1007/S12525-020-00404-9/FIGURES/11.

[79] „TODO project (about project)“. https://todo-project.eu/en/about-project (pristupljeno lip. 20, 2022).

[80] F. R. Soriano, J. J. Samper-Zapater, J. J. Martinez-Dura, R. v. Cirilo-Gimeno, i J. Martinez Plume, „Smart mobility trends: Open data and other tools“, *IEEE Intelligent Transportation Systems Magazine*, sv. 10, izd. 2, str. 6–16, lip. 2018, doi: 10.1109/MITS.2017.2743203.

[81] V. Mahajan, N. Kuehnel, A. Intzevidou, G. Cantelmo, R. Moeckel, i C. Antoniou, „Data to the people: a review of public and proprietary data for transport models“, *Transp Rev*, sv. 42, izd. 4, str. 415–440, 2021, doi: 10.1080/01441647.2021.1977414/SUPPL_FILE/TTRV_A_1977414_SM3064.DOCX.

[82] T. A. Arentze i E. J. E. Molin, „Travelers' preferences in multimodal networks: Design and results of a comprehensive series of choice experiments“, *Transp Res Part A Policy Pract*, sv. 58, str. 15–28, 2013, doi: 10.1016/J.TRA.2013.10.005.

[83] M. Wanjek i G. Hauger, „Reliability of Travel Time: Challenges Posed by a Multimodal Transport Participation“, *IOP Conf Ser Mater Sci Eng*, sv. 254, izd. 4, doi: 10.1088/1757-899X/245/4/042029.

[84] S. Krygsman, M. Dijst, i T. Arentze, „Multimodal public transport: an analysis of travel time elements and the interconnectivity ratio“, *Transp Policy (Oxf)*, sv. 11, izd. 3, str. 265–275, srp. 2004, doi: 10.1016/J.TRANPOL.2003.12.001.

[85] E. Malichová, G. Pourhashem, T. Kováčiková, i M. Hudák, „Users' perception of value of travel time and value of ridesharing impacts on Europeans' ridesharing participation intention: A case study based on MoTiV European-wide mobility and behavioral pattern dataset“, *Sustainability (Switzerland)*, sv. 12, izd. 10, svi. 2020, doi: 10.3390/SU12104118.

[86] L. Boratto, M. Manca, G. Lugano, i M. Gogola, „Characterizing user behavior in journey planning“, *Computing*, sv. 102, izd. 5, str. 1245–1258, svi. 2020, doi: 10.1007/S00607-019-00775-8.

[87] A. Kramers, „Designing next generation multimodal traveler information systems to support sustainability-oriented decisions“, *Environmental Modelling & Software*, sv. 56, str. 83–93, lip. 2014, doi: 10.1016/J.ENVSOFT.2014.01.017.

[88] C. Pronello, J. P. R. V. Simão, i V. Rappazzo, „The effects of the multimodal real time information systems on the travel behaviour“, *Transportation Research Procedia*, sv. 25, str. 2677–2689, 2017, doi: 10.1016/J.TRPRO.2017.05.172.

[89] S. Seebauer, R. Stolz, i M. Berger, „Technophilia as a driver for using advanced traveler information systems“, *Transp Res Part C Emerg Technol*, sv. 60, str. 498–510, stu. 2015, doi: 10.1016/J.TRC.2015.10.009.

[90] C. Pronello, J. P. R. V. Simão, i V. Rappazzo, „The effects of the multimodal real time information systems on the travel behaviour“, *Transportation Research Procedia*, sv. 25, str. 2677–2689, sij. 2017, doi: 10.1016/J.TRPRO.2017.05.172.

[91] H. Weihrich, *Menadžment*. Zagreb: MATE, 1998.

[92] T. Hernaus, T. Hunjak, Ređep Begičević Nina, i P. Sikavica, *Poslovno odlučivanje*. Zagreb: Školska knjiga, 2014. Pristupljeno: lip. 23, 2022. [Na internetu]. Available: https://knjizaraum.hr/poslovno-odlucivanje-2/

[93] J. R. Gordon, R. W. Mondy, A. Sharplin, i S. R. Premeaux, *Management and organizational behavior*. Allyn and Bacon, 1990.

[94] Z. Baračkai, *Odlučivanje o poslovnim strategijama*, 1. izd. Sarajevo: Svjetlost, 1987. Pristupljeno: lip. 25, 2022. [Na internetu]. Available: http://katalog.nsk.hr/F/?func=direct&doc_number=000404137

[95] D. E. Bell, H. Raiffa, i A. Tversky, „Descriptive, Normative, and Prescriptive Interactions“, u *Decision Making*, Cambridge University Press, 2011, str. 9–30. doi: 10.1017/CBO9780511598951.003.

[96] L. Th. Heracleous, „Rational Decision Making: Myth or Reality?“, *Management Development Review*, sv. 7, izd. 4, str. 16–23, kol. 1994, doi: 10.1108/09622519410771628.

[97] M. Menger, „Teorija odlučivanja Herberta Simona: decizionistički pristup organizaciji“, *Politička misao: časopis za politologiju*, sv. 56, izd. 2, str. 66–86, lis. 2019, doi: 10.20901/PM.56.2.03.

[98] R. P. Larrick i D. C. Feiler, „Expertise in decision making“, u *The Wiley Blackwell Handbook of Judgment and Decision Making*, G. Keren i G. Wu, Ur. wiley, 2015, str. 696–721. doi: 10.1002/9781118468333.CH24.

[99] O. C. Koontz H i H. Weihrich, *Management Ed.7*, 7. izd. McGraw-Hill Book Company, 1980.

[100] K. G. Goulias, A. W. Davis, i E. C. McBride, „Introduction and the genome of travel behavior“, u *Mapping the Travel Behavior Genome*, K. G. Goulias i A. W. Davis, Ur. Elsevier, 2020, str. 1–14. doi: 10.1016/B978-0-12-817340-4.00001-2.

[101] B. Mandžuka, M. Jurčević, K. Vidović, i M. Vujić, „Multimodal Journey Route Selection as Decision-Making Process“, u *New Technologies, Development and Application V*, lip. 2022, str. 712–718. doi: 10.1007/978-3-031-05230-9_85.

[102] J. Johnson, *Designing with the mind in mind: simple guide to understanding user interface design guidelines*, 2. izd. Morgan Kaufmann, 2014.

[103] A. Tversky i D. Kahneman, „The Framing of Decisions and the Psychology of Choice“, *Science (1979)*, sv. 211, izd. 4481, str. 453–458, 1981, doi: 10.1126/SCIENCE.7455683.

[104] E. Triantaphyllou, „A Comparative Study“, u *Multi-criteria Decision Making Methods*, 1. izd., sv. 44, Boston, MA: Springer New York, NY, 2000, str. 265. doi: 10.1007/978-1-4757-3157-6.

[105] G. Bruno i A. Genovese, „Multi-Criteria Decision-Making: advances in theory and applications—an introduction to the special issue“, *Soft Computing 2018*, sv. 22, izd. 22, str. 7313–7314, ruj. 2018, doi: 10.1007/S00500-018-3531-0.

[106] S. Vlah, „Modeli višekriterijskog odlučivanja i heuristike za njihovo rješavanje“, Ekonomski fakultet, Zagreb, 2008. Pristupljeno: lip. 26, 2022. [Na internetu]. Available: https://www.bib.irb.hr/407750

[107] A. Singh, „Major MCDM Techniques and their application-A Review“, *IOSR Journal of Engineering*, sv. 4, izd. 5, str. 15–25, svi. 2014, doi: 10.9790/3021-04521525.

[108] C. Pattnaik, „Multi Attributes Decision-making: A Survey“, *Int J Res Appl Sci Eng Technol*, sv. 6, izd. 4, str. 3730–3747, tra. 2018, doi: 10.22214/IJRASET.2018.4620.

[109] E. Triantaphyllou, „Description of some MCDM methods“, u *Multi-criteria Decision Making Methods*, 2000. doi: 10.1007/978-1-4757-3157-6_2.

[110] H. Volarevic i I. Cosic, „Selekcija i evaluacija poslovnih partnera uz analitički hijerarhijski proces i aplikaciju Expert Choice “, u *Kontroling u praksi: Instrumenti kontrolinga*, M. Meter, Ur. Zagreb: Poslovna učinkovitost d.o.o., 2017, str. 149–158. Pristupljeno: lip. 26, 2022. [Na internetu]. Available: https://www.bib.irb.hr/981026

[111] E. Triantaphyllou, „Quantification of Qualitative Data for MCDM Problems“, u *Multi-criteria Decision Making Methods: A Comparative Study*, Springer, Boston, MA, 2000, str. 23–55. doi: 10.1007/978-1-4757-3157-6_3.

[112] M. Meng, A. Rau, i H. Mahardhika, „Public transport travel time perception: Effects of socioeconomic characteristics, trip characteristics and facility usage“, *Transp Res Part A Policy Pract*, sv. 114, str. 24–37, 2018, doi: 10.1016/J.TRA.2018.01.015.

[113] M. Gogola i A. Karadimce, „D2.2-Mobility and Travel Time Report“, Pristupljeno: tra. 16, 2022. [Na internetu]. Available: www.motivproject.eu

[114] Y. Ji, R. Zhang, L. Gao, i Y. Fan, „Perception of Transfer Waiting Time at Stops and Stations in Nanjing, China“, u *TRB 96th Annual Meeting Compendium of Papers*, 2017. Pristupljeno: tra. 16, 2022. [Na internetu]. Available: https://trid.trb.org/view/1437824

[115] G. Beirão i J. A. Sarsfield Cabral, „Understanding attitudes towards public transport and private car: A qualitative study“, *Transp Policy (Oxf)*, sv. 14, izd. 6, str. 478–489, stu. 2007, doi: 10.1016/J.TRANPOL.2007.04.009.

[116] R. Cascajo, E. Lopez, F. Herrero, i A. Monzon, „User perception of transfers in multimodal urban trips: A qualitative study“, *Int J Sustain Transp*, sv. 13, izd. 6, str. 393–406, srp. 2019, doi: 10.1080/15568318.2018.1476632.

[117] R. Carreira, L. Patrício, R. Natal Jorge, i C. Magee, „Understanding the travel experience and its impact on attitudes, emotions and loyalty towards the transportation provider–A quantitative study with mid-distance bus trips“, *Transp Policy (Oxf)*, sv. 31, str. 35–46, sij. 2014, doi: 10.1016/J.TRANPOL.2013.11.006.

[118] Y. Cornet, G. Lugano, C. Georgouli, i D. Milakis, „Worthwhile travel time: a conceptual framework of the perceived value of enjoyment, productivity and fitness while travelling“, *Transp Policy (Oxf)*, sv. 42, izd. 5, str. 580–603, 2022, doi: 10.1080/01441647.2021.1983067.

[119] S. Davies, „Stated vs Revealed Preferences - YouTube“, sij. 25, 2021. Pristupljeno: tra. 30, 2022. [Na internetu]. Available: https://www.youtube.com/watch?v=vyiE_desGKs

[120] Á. Winkler, „Experiments to Discover Passenger Preferences in Public Transport“, u *11th International Scientific Conference MOBILITA´11*, 2011.

[121] J. Tiihonen i A. Felfernig, „An introduction to personalization and mass customization“, *J Intell Inf Syst*, sv. 49, izd. 1, str. 1–7, kol. 2017, doi: 10.1007/S10844-017-0465-4/FIGURES/2.

[122] European Union, „MaaS4EU – State-of-the-art report“, ruj. 2018.

[123] D. Asanov, „Algorithms and Methods in Recommender Systems“, 2011.

[124] K. Najmani, E. habib Benlahmar, N. Sael, i A. Zellou, „A comparative study on recommender systems approaches“, u *BDIoT'19: Proceedings of the 4th International Conference on Big Data and Internet of Things*, lis. 2019, str. 1–5. doi: 10.1145/3372938.3372941.

[125] Q. Tran, L. Tran, L. C. Hai, N. van Linh, i K. Than, „From implicit to explicit feedback: A deep neural network for modeling sequential behaviours and long-short term preferences of online users“, *Neurocomputing*, sv. 479, str. 89–105, ožu. 2022, doi: 10.1016/J.NEUCOM.2022.01.023.

[126] L. Troiano, L. J. Rodríguez-Muñiz, i I. Díaz, „Discovering user preferences using Dempster–Shafer theory“, *Fuzzy Sets Syst*, sv. 278, str. 98–117, stu. 2015, doi: 10.1016/J.FSS.2015.06.004.

[127] M. Haqqani, X. Li, i X. Yu, „Estimating passenger preferences using implicit relevance feedback for personalized journey planning“, u *Artificial Life and Computational Intelligence*, sv. 10142, Cham: Springer Verlag, 2017, str. 157–168. doi: 10.1007/978-3-319-51691-2_14.

[128] M. Haqqani, H. Ashrafzadeh, X. Li, i X. Yu, „Conditional Preference Learning for Personalized and Context-Aware Journey Planning“, u *Proceedings of the 15th International Conference on Parallel Problem Solving from Nature (PPSN'2018)*, 2018, sv. 11101 LNCS, str. 451–463. doi: 10.1007/978-3-319-99253-2_36.

[129] R. Burke, „Knowledge-based recommender systems“, 2000, str. 23. Pristupljeno: lip. 24, 2022. [Na internetu]. Available: http://www.personallogic.com/

[130] „Exploring collaborative filtering for job recommendations“. https://www.welcometothejungle.com/en/articles/collaborative-filtering-job-recommendations (pristupljeno lis. 23, 2022).

[131] A. Felfernig, M. Jeran, G. Ninaus, F. Reinfrank, S. Reiterer, i M. Stettinger, „Basic Approaches in Recommendation Systems“, u *Recommendation Systems in Software Engineering*, 1. izd., M. P. Robillard, W. Maalej, R. J. Walker, i T. Zimmermann, Ur. Berlin: Springer Berlin, Heidelberg, 2014, str. 15–37.

[132] P. Yi, C. Li, C. Yang, i M. Chen, „An optimization method for recommendation system based on user implicit behavior“, u *Proceedings - 5th International Conference on*

Instrumentation and Measurement, Computer, Communication, and Control, IMCCC 2015, velj. 2016, str. 1537–1540. doi: 10.1109/IMCCC.2015.326.

[133] Y. Zheng i W. David, „Multi-Objective Recommendations: A Tutorial“, u *KDD '21: Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*, kol. 2021. doi: 10.48550/arxiv.2108.06367.

[134] M. Shinohara, „Inverse problems in AHP“, u *International Symposium of the Analytic Hierarchy Process 2014*, srp. 2014, str. 1–5.

[135] W. Gaul i D. Gastes, „Missing values and the consistency problem concerning AHP data“, u *Classification as a Tool for Research (Studies in Classification, Data Analysis, and Knowledge Organization)*, 2010, str. 693–700. doi: 10.1007/978-3-642-10745-0_76/COVER/.

[136] D. Gastes i W. Gaul, „The consistency adjustment problem of AHP pairwise comparison matrices“, u *Quantitative Marketing and Marketing Management: Marketing Models and Methods in Theory and Practice*, sv. 9783834937223, Gabler Verlag, 2012, str. 51–62. doi: 10.1007/978-3-8349-3722-3_2.

[137] K. Ogrodnik, „Multi-criteria analysis of design solutions in architecture and engineering: Review of applications and a case study“, *Buildings*, sv. 9, izd. 12, pros. 2019, doi: 10.3390/BUILDINGS9120244.

[138] D. M. Pavlicic, „Normalisation effects the results of MADM methods“, *Yugoslav Journal of Operations Research*, sv. 11, izd. 2. str. 251–265, sij. 2001.

[139] „eutrofikacija“, *Hrvatska enciklopedija, mrežno izdanje*. Leksikografski zavod Miroslav Krleža, 2021. Pristupljeno: tra. 19, 2022. [Na internetu]. Available: https://www.enciklopedija.hr/natuknica.aspx?ID=18675

POPIS SLIKA

Slika 1. Dio skupine ciljeva u okviru Agende 2030 (prilagodio autor) [2] 5
Slika 2. Komponente koncepta pametnoga grada (prilagodio autor) [7] 9
Slika 3. Smjernice i ciljevi inicijative 12
Slika 4. Koncept MaaS (prilagodio autor) [33] 16
Slika 5. Koncept multimodalnoga putovanja (prilagodio autor) [39] 20
Slika 6. Prikaz opcija prvog i posljednjeg kilometra kod multimodalnoga putovanja 21
Slika 7. Metoda organiziranja prekograničnih multimodalnih putovanja (prilagodio autor) [50] 24
Slika 8. Konceptualna razlika ponuđenih opcija 27
Slika 9. Prikaz sučelja multimodalnoga putnog planera DB Navigator [57] 30
Slika 10. Prikaz sučelja multimodalnoga putnog planera BudapestGO [59] 31
Slika 11. Prikaz sučelja multimodalnoga putnog planera Citymapper [61] 32
Slika 12. Prikaz sučelja multimodalnoga putnog planera TripGo [62] 33
Slika 13. Prikaz sučelja multimodalnoga putnog planera Whim [66] 34
Slika 14. Prikaz sučelja multimodalnoga putnog planera WienMobil [67] 35
Slika 15. Planiranje putovanja korištenjem prekograničnoga multimodalnoga putnog planera (prilagodio autor) [50] 36
Slika 16. Dionici nacionalne pristupne točke [77] 38
Slika 17. Klasifikacija teorija odlučivanja (prilagodio autor) [92] 44
Slika 18. Proces donošenja odluke u širem smislu [92] 47
Slika 19. Faze donošenja odluka neeksperta (izradio autor) 49
Slika 20. Općeniti koraci u rješavanju definiranoga problema višekriterijskoga odlučivanja (izradio autor) 53
Slika 21. Suradničko filtriranje – način rada (prilagodio autor) [130] 66
Slika 22. Grafički prikaz optimizacijske funkcije ispitanika A1.4 72
Slika 23. Grafički prikaz optimizacijske funkcije ispitanika A1.8 73
Slika 24. Grafički prikaz optimizacijske funkcije ispitanika A1.10 74
Slika 25. Struktura AHP modela kod kvantitativno definiranih elemenata matrice alternativa (izradio autor) 81
Slika 26. Metodologija testiranja i validacije (dijagram toka, prvi dio) 93
Slika 27. Metodologija testiranja i validacije (dijagram toka, drugi dio) 94

POPIS TABLICA

Tablica 1. Taksonomija razina integracije MaaS koncepta (prilagodio autor) 17
Tablica 2. Saatyjeva skala relativne važnosti 57
Tablica 3. Saatyjeva skala relativne važnosti s pridruženim parametrima pridružene trokutaste funkcije pripadnosti 85
Tablica 4. Svojstva normalizacije 89

POPIS GRAFIKONA

Grafikon 1. Trend porasta broja osobnih vozila na području Europske unije 6
Grafikon 2. Testiranje uvjeta konzistentnosti primijenjene AHP metode 80
Grafikon 3. Prikaz alternativa za slučaj pješačenja („korist“) 83
Grafikon 4. Prikaz alternativa za slučaj pješačenja („trošak“) 84
Grafikon 5. Rezultati testiranja modela izbora multimodalne rute 96
Grafikon 6. Odnos vrijednosti kaznenih bodova zbog grešaka redoslijeda alternativa 96
Grafikon 7. Greške ocjene vrijednosti alternativa za Scenarij 1 98
Grafikon 8. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 1 98
Grafikon 9. Greške ocjene vrijednosti alternativa za Scenarij 2 99
Grafikon 10. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 2 100
Grafikon 11. Greške ocjene vrijednosti alternativa za Scenarij 3 100
Grafikon 12. Odnos grešaka ocjene vrijednosti alternativa za Scenarij 3 101
Grafikon 13. Greške ocjene vrijednosti alternativa za sva tri scenarija 102
Grafikon 14. Odnos grešaka ocjene vrijednosti alternativa za sva tri scenarija 102

DODACI

Dodatak 1 – Obrazac istraživanja preferencija putnika (Zagreb)

Obrazac istraživanja preferencija putnika

Izbor multimodalnoga putovanja

Povećanjem populacije u urbanim sredinama, a samim time i porastom broja motornih vozila, pojavljuju se *izazovi* s kojima se urbane sredine kontinuirano suočavaju. Neadekvatna prometna infrastruktura, manjak prostora namijenjen ljudima, smanjenje mobilnosti i pristupačnosti, povećanje zagušenja te negativni učinci na okoliš neki su od glavnih problema koji ukazuju na potrebu sustavnog pristupa u njihovom rješavanju. Gradovi s najuspješnijim prometnim strategijama **prioritiziraju kretanje ljudi**, dajući im niz atraktivnih i ekološki prihvatljivih mogućnosti u javnom prijevozu.

Koncept multimodalnoga putovanja predstavlja korištenje različitih i optimalno kombiniranih načina prijevoza na jednostavan i ekološki prihvatljiv način. U tom pogledu, multimodalna putovanja predstavljaju održiv način putovanja kombinirajući dostupne načine prijevoza, ovisno o situaciji i osobnim preferencijama putnika.

Uvođenjem inteligentnih rješenja informiranja putnika, primjerice multimodalnih planera putovanja (npr. Google Maps), moguće je pojednostavniti proces putovanja iz točke A u točku B, *a pritom ponuditi uslugu koja će biti orijentirana putniku i njegovim* ***stvarnim potrebama***. Na slici su prikazane opcije multimodalnoga putovanja za isto ishodište i odredište, koje može ponuditi multimodalni planer putovanja.

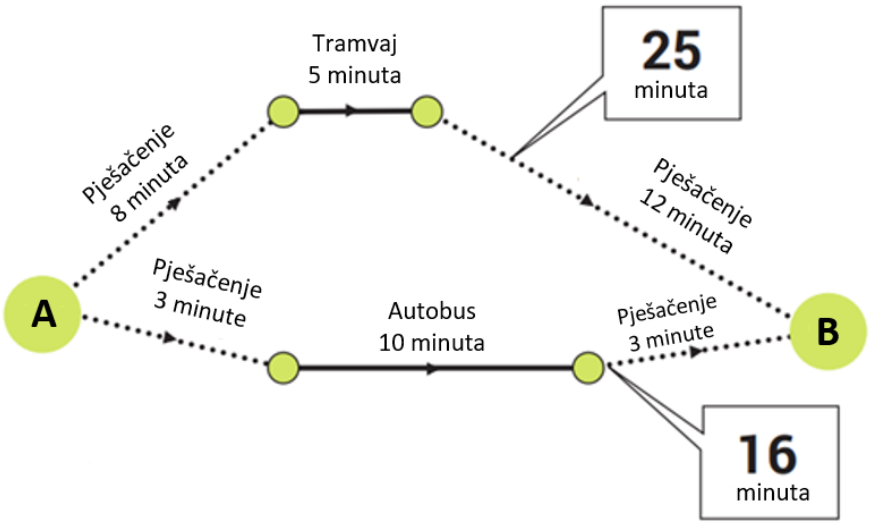

1. Preferencije putnika

Ponašanje putnika treba shvatiti kao složen proces. Taj složen proces uzima u obzir percepciju pojedinca, stav, mišljenje, osjećaje, uvjerenja, namjere itd. Ponašanje putnika prilikom planiranja i izbora načina putovanja može se shvatiti i kao proces odlučivanja, zasnovan na prikupljenim doživljajima, kao i razvijenim obrascima ponašanja tijekom putovanja. Stoga se može zaključiti da se donošenje odluke o multimodalnome putovanju temelji na skupu kriterija, tj. preferencija putnika. U nastavku su navedeni standardni/uobičajeni kriteriji koji će se rabiti za ovo istraživanje.

Skup kriterija:

K1 – ukupno vrijeme putovanja
K2 – broj presjedanja
K3 – ukupno vrijeme pješačenja

Koji od ovih kriterija smatrate važnijima tijekom multimodalnog putovanja?
Putem numeričke skale potrebno je usporediti važnost jednog kriterija u odnosu na drugi.

Primjer:

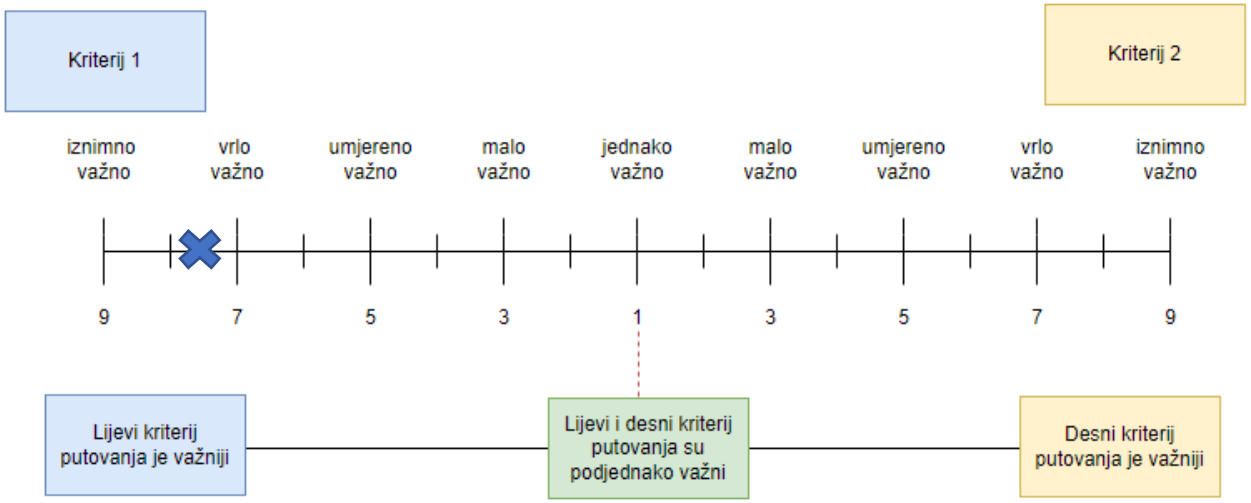

Ukupno vrijeme putovanja **Broj presjedanja**

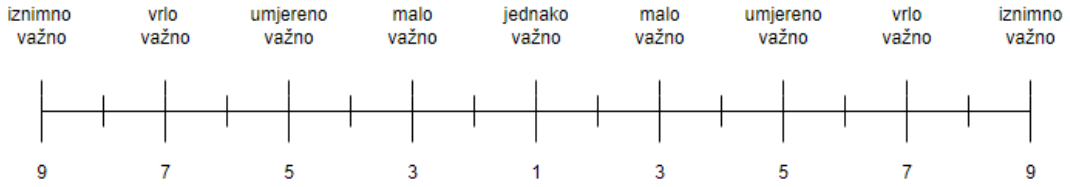

Ukupno vrijeme putovanja **Ukupno vrijeme pješačenja**

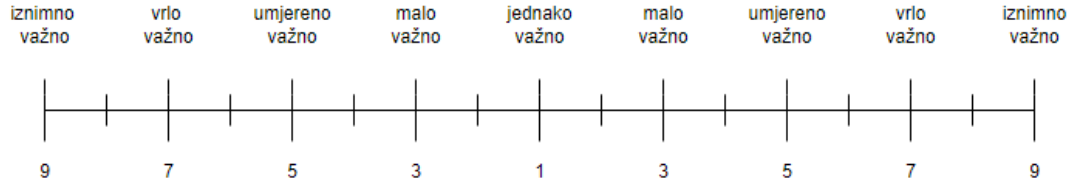

Broj presjedanja **Ukupno vrijeme pješačenja**

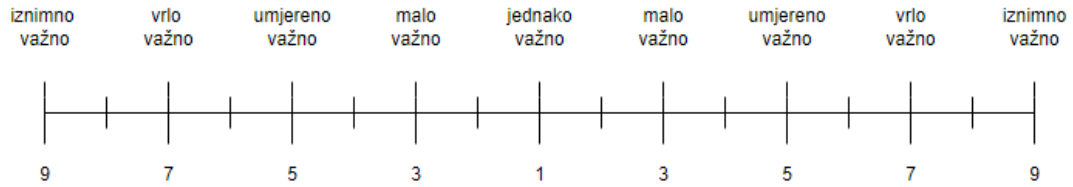

2. Izbor multimodalne rute

Za potrebe istraživanja izbora multimodalne rute, preuzeti su stvarni podaci s Google karata za rutu **Cmrok (Jurjevska ul.) – Odra** (u poslijepodnevnim satima).

Za potrebe istraživanja odabrane su tri alternativne rute, a pri izboru se težilo rutama čija je kombinacija vremena putovanja i pješačenja, načina prijevoza i linija **specifičnija**, znajući da se **preferencije od korisnika do korisnika razlikuju**.

Izabrane multimodalne rute obuhvaćaju tri kombinirana načina putovanja (pješačenje, tramvaj, autobus).

Na sljedećoj stranici ocijenite označene rute brojevima od 1 do 9, s tim da ruta ocijenjena brojem 9 predstavlja, za Vas, najprikladniju rutu.

☐	 **Ukupno vrijeme putovanja** = 1 h 7 min **Broj presjedanja** = 2 presjedanja **Ukupno vrijeme pješačenja** = 8 min
☐	 **Ukupno vrijeme putovanja** = 1 h 10 min **Broj presjedanja** = 3 presjedanja **Ukupno vrijeme pješačenja** = 5 min
☐	 **Ukupno vrijeme putovanja** = 1h 7 min **Broj presjedanja** = 2 presjedanja **Ukupno vrijeme pješačenja** = 23 min

Dodatak 2 – Istraživanje preferencija putnika (Zagreb) – ulazni podaci

Ispitanik	Ocjena odnosa kriterija						Ocjena alternativa		
	C1/C2		C1/C3		C2/C3				
	C1	C2	C1	C3	C2	C3	A1	A2	A3
A1.1	6			5		6	9	5	8
A1.2	5		7		3		9	7	6
A1.3	9			7		7	7	9	1
A1.4	7		5			5	7	2	5
A1.5	9		1 = jednako važno		7		8	9	5
A1.6	5		7		5		9	5	3
A1.7	5		7		7		9	5	3
A1.8	5		5		3		9	7	4
A1.9	5		1 = jednako važno		7		6	2	9
A1.10		7		5		7	8	7	3
A1.11	5		1 = jednako važno			5	4	3	6
A1.12		3	3		3		9	5	3
A1.13	7		1 = jednako važno			7	9	5	4
A1.14	1 = jednako važno		9		9		9	6	7
A1.15		3		1	3		6	3	9
A1.16		5	7		9		7	5	9
A1.17	1 = jednako važno		6		5		9	1	5
A1.18		3	6		6		8	2	7
A1.19	9		1			6	8	9	3
A1.20	7		7		5		9	7	4
A1.21	6		3		1		8	4	4
A1.22	5		7		1		9	7	3
A1.23	7		7		1		9	1	5
A1.24	5		7		1		9	3	6
A1.25	5			5	1		9	7	5
A1.26	1			5	1		9	8	5
A1.27	1		5		1		5	8	3
A1.28	9		9		7		9	5	7
A1.29	7		1			5	8	1	5
A1.30	9		5			5	9	5	1

Dodatak 3 – Istraživanje preferencija putnika (Zagreb) – omjer konzistentnosti

Ispitanik	CR (Omjer konzistentnosti)	Redoslijed alternativa – normalizirano		
		A1	A2	A3
A1.1	0,31	0,41	0,23	0,36
A1.2	0,07	0,41	0,32	0,27
A1.3	0,59	0,41	0,53	0,06
A1.4	0,19	0,50	0,14	0,36
A1.5	2,33	0,36	0,41	0,23
A1.6	0,19	0,53	0,29	0,18
A1.7	0,31	0,53	0,29	0,18
A1.8	0,14	0,45	0,35	0,20
A1.9	1,65	0,35	0,12	0,53
A1.10	0,63	0,44	0,39	0,17
A1.11	0,00	0,31	0,23	0,46
A1.12	0,14	0,53	0,29	0,18
A1.13	0,00	0,50	0,28	0,22
A1.14	0,00	0,41	0,27	0,32
A1.15	0,00	0,33	0,17	0,50
A1.16	0,22	0,33	0,24	0,43
A1.17	0,00	0,60	0,07	0,33
A1.18	0,14	0,47	0,12	0,41
A1.19	0,02	0,40	0,45	0,15
A1.20	0,31	0,45	0,35	0,20
A1.21	0,06	0,50	0,25	0,25
A1.22	0,01	0,47	0,37	0,16
A1.23	0,00	0,60	0,07	0,33
A1.24	0,01	0,50	0,17	0,33
A1.25	1,32	0,43	0,33	0,24
A1.26	0,31	0,41	0,36	0,23
A1.27	0,31	0,31	0,50	0,19
A1.28	0,46	0,43	0,24	0,33
A1.29	0,01	0,57	0,07	0,36
A1.30	0,12	0,60	0,33	0,07

Dodatak 4 – Istraživanje preferencija putnika (Zagreb) – rezultati odlučivanja

Ispitanik	Red. Altern. (ocjena)			Red. Altern. (AHP)			Vrijednost kriterija		
	A1	A2	A3	A1	A2	A3	Crit 1	Crit 2	Crit 3
A1.1	0,41	0,23	0,36	0,25	0,20	0,55	0,24	0,07	0,70
A1.2	0,41	0,32	0,27	0,31	0,34	0,34	0,73	0,19	0,08
A1.3	0,41	0,53	0,06	0,24	0,19	0,57	0,22	0,05	0,73
A1.4	0,50	0,14	0,36	0,30	0,31	0,39	0,72	0,07	0,22
A1.5	0,36	0,41	0,23	0,31	0,34	0,36	0,59	0,26	0,15
A1.6	0,53	0,29	0,18	0,31	0,35	0,34	0,72	0,22	0,07
A1.7	0,53	0,29	0,18	0,31	0,35	0,33	0,70	0,24	0,06
A1.8	0,45	0,35	0,20	0,31	0,34	0,35	0,70	0,20	0,10
A1.9	0,35	0,12	0,53	0,30	0,34	0,35	0,51	0,33	0,16
A1.10	0,44	0,39	0,17	0,24	0,20	0,56	0,07	0,22	0,72
A1.11	0,31	0,23	0,46	0,29	0,37	0,34	0,46	0,09	0,46
A1.12	0,53	0,29	0,18	0,28	0,59	0,13	0,28	0,58	0,14
A1.13	0,50	0,28	0,22	0,28	0,29	0,43	0,47	0,07	0,47
A1.14	0,41	0,27	0,32	0,30	0,37	0,32	0,47	0,47	0,05
A1.15	0,33	0,17	0,50	0,28	0,35	0,36	0,20	0,60	0,20
A1.16	0,33	0,24	0,43	0,29	0,40	0,31	0,23	0,72	0,05
A1.17	0,60	0,07	0,33	0,30	0,36	0,34	0,47	0,44	0,08
A1.18	0,47	0,12	0,41	0,29	0,38	0,32	0,30	0,63	0,07
A1.19	0,40	0,45	0,15	0,28	0,26	0,46	0,50	0,06	0,44
A1.20	0,45	0,35	0,20	0,32	0,35	0,34	0,75	0,18	0,06
A1.21	0,50	0,25	0,25	0,30	0,32	0,38	0,68	0,14	0,18
A1.22	0,47	0,37	0,16	0,31	0,33	0,36	0,75	0,13	0,12
A1.23	0,60	0,07	0,33	0,31	0,33	0,36	0,78	0,11	0,11
A1.24	0,50	0,17	0,33	0,31	0,33	0,36	0,75	0,13	0,12
A1.25	0,43	0,33	0,24	0,26	0,24	0,50	0,30	0,18	0,52
A1.26	0,41	0,36	0,23	0,26	0,26	0,48	0,18	0,30	0,52
A1.27	0,31	0,50	0,19	0,30	0,34	0,37	0,52	0,30	0,18
A1.28	0,43	0,24	0,33	0,32	0,35	0,33	0,79	0,17	0,05
A1.29	0,57	0,07	0,36	0,28	0,26	0,46	0,49	0,08	0,44
A1.30	0,60	0,33	0,07	0,30	0,31	0,39	0,74	0,06	0,21

Dodatak 5 – Obrazac istraživanja preferencija putnika (Beč)

Survey on **Discovering Traveller's Preferences in Multimodal Journeys**

By implementing intelligent passenger information solutions, such as Advanced Multimodal Journey Planners, it is possible to simplify the traveller's decision-making process for the journey from "point A to point B". In this sense, a service is offered based on the traveller's preferences and based on their actual needs. For example, the following figure shows the multimodal travel options for a travel scenario.

Please try to answer all questions consistently so that the result is as helpful as possible when applying the proposed methods for discovering travel preferences.

You do not need to sign in to Google account to save your progress because the survey is extremely short!

Example of Multimodal Journey

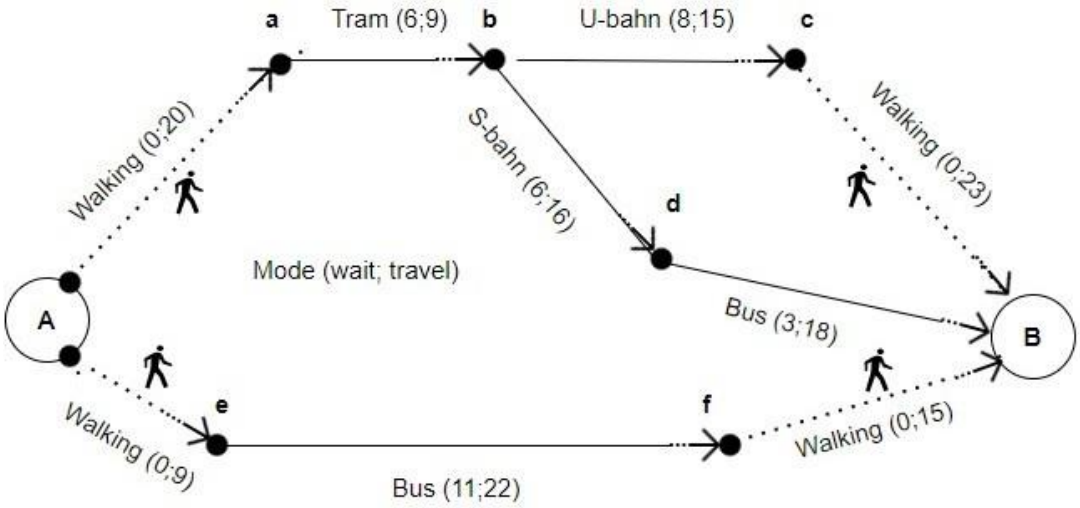

About Travellers' Preferences

The choice of a multimodal travel route is based on a set of "personal" criteria related to travellers' preferences. The criteria proposed for this research are listed below.

A set of criteria:

C1 – Travel time (the actual time it takes to travel from "point A to point B") C2 - Number of transfers (the number of transfers during the journey)
C3 – Walking time (the actual time you spent walking)
C4 – Waiting time (the actual time you spent waiting for transfers)

Which of these criteria do you think is more important for a multimodal journey? In the next section, please rate each criterion on a rating scale from 1 to 5.

C1 – Total Travel Time

	1	2	3	4	5	
Not important at all	○	○	○	○	○	Extremely important

C2 – Number of Transfers

	1	2	3	4	5	
Not important at all	○	○	○	○	○	Extremely important

C3 – My experience of walking time (Choose one answer)

- ☐ Walking time for me represents a benefit in total travel time (fitness & health reasons)
- ☐ Walking time for me represents a discomfort in total travel time

C3 – Total Walking Time

	1	2	3	4	5	
Not important at all	○	○	○	○	○	Extremely important

C4 – Total Waiting Time

	1	2	3	4	5	
Not important at all	○	○	○	○	○	Extremely important

Multimodal Route Choice

For each journey scenario, three alternative routes were generated. Multimodal routes with a specific combination of modes of transport, travel and walking times (including various waiting times) were proposed.

In the next section please rate the suggested routes on a scale from 1 to 5
(with 5 being the most suitable route for you).

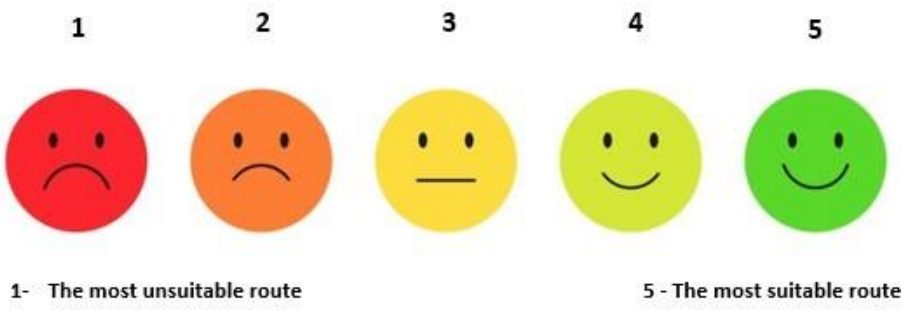

1 – Journey Scenario

1st Journey Scanario:

Origin: Forschungsglashaus, Peter-Jordan-Straße 63, 1190 Wien

Destination: Gröretgasse 76, 1110 Wien

Three (3) suggested alternative routes for 1st Journey Scenario (A, B, C)

Please rate each multimodal route in relation to the others!

A	 **Total Travel Time** = 72 [min] **Number of Transfers** = 2 **Total Walking Time** = 21 [min] **Total Waiting Time** = 9 [min]
B	 **Total Travel Time** = 71 [min] **Number of Transfers** = 3 **Total Walking Time** = 16 [min] **Total Waiting Time** = 13 [min]
C	 **Total Travel Time** = 87 [min] **Number of Transfers** = 1 **Total Walking Time** = 20 [min] **Total Waiting Time** = 6 [min]

1. **Rate Route A**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

2. **Rate Route B**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

3. **Rate Route C**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

2 – Journey Scenario

2nd Journey Scanario:

Origin: Azaleengasse 62, 1220 Wien

Destination: Dornbacher Str. 11, 1170 Wien

Three (3) suggested alternative routes for 2nd Journey Scenario (A, B, C)

Please rate each multimodal route in relation to the others!

A	 **Total Travel Time** = 77 [min] **Number of Transfers** = 2 **Total Walking Time** = 11 [min] **Total Waiting Time** = 15 [min]
B	 **Total Travel Time** = 81 [min] **Number of Transfers** = 3 **Total Walking Time** = 21 [min] **Total Waiting Time** = 9 [min]
C	 **Total Travel Time** = 83 [min] **Number of Transfers** = 2 **Total Walking Time** = 20 [min] **Total Waiting Time** = 8 [min]

1. **Rate Route A**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

2. **Rate Route B**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

3. **Rate Route C**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

3 – Journey Scenario

3rd Journey Scanario:

Origin: Großbauerstraße 56, 1210 Wien

Destination: Klg Oberwieden Parz, 1170 Wien

Three (3) suggested alternative routes for 3rd Journey Scenario (A, B, C)

Please rate each multimodal route in relation to the others!

A	 **Total Travel Time** = 61 [min] **Number of Transfers** = 3 **Total Walking Time** = 18 [min] **Total Waiting Time** = 15 [min]
B	 **Total Travel Time** = 63 [min] **Number of Transfers** = 3 **Total Walking Time** = 20 [min] **Total Waiting Time** = 15 [min]
C	 **Total Travel Time** = 69 [min] **Number of Transfers** = 2 **Total Walking Time** = 28 [min] **Total Waiting Time** = 17 [min]

1. **Rate Route A**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

2. **Rate Route B**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

3. **Rate Route C**

	1	2	3	4	5	
The most unsuitable multimodal route	◯	◯	◯	◯	◯	The most suitable multimodal route

Dodatak 6 – Istraživanje preferencija putnika (Beč) – ulazni podaci

	Criteria				S1			S2			S3		
Ispitanik	**C1 – Total Travel Time**	**C2 – Number of Transfers**	**C3 – Total Walking Time**	**C4 - Total Waiting Time**	**Rate Route A**	**Rate Route B**	**Rate Route C**	**Rate Route A**	**Rate Route B**	**Rate Route C**	**Rate Route A**	**Rate Route B**	**Rate Route C**
W1b	4,00	3,00	4,00	2,00	5,00	3,00	4,00	4,00	4,00	3,00	3,00	4,00	3,00
Nor	0,31	0,23	0,31	0,15	0,42	0,25	0,33	0,36	0,36	0,27	0,30	0,40	0,30
W2b	5,00	4,00	3,00	4,00	5,00	4,00	3,00	5,00	3,00	4,00	4,00	3,00	5,00
Nor	0,31	0,25	0,19	0,25	0,42	0,33	0,25	0,42	0,25	0,33	0,33	0,25	0,42
W3c	4,00	3,00	3,00	3,00	Nor	2,00	4,00	3,00	2,00	4,00	2,00	3,00	4,00
Nor	0,31	0,23	0,23	0,23	0,14	0,29	0,57	0,33	0,22	0,44	0,22	0,33	0,44
W4c	Nor	3,00	4,00	3,00	3,00	4,00	1,00	5,00	3,00	2,00	4,00	3,00	1,00
Nor	0,09	0,27	0,36	0,27	0,38	0,50	0,13	0,50	0,30	0,20	0,50	0,38	0,13
W5c	4,00	3,00	5,00	4,00	3,00	1,00	5,00	5,00	1,00	3,00	5,00	3,00	1,00
Nor	0,25	0,19	0,31	0,25	0,33	0,11	0,56	0,56	0,11	0,33	0,56	0,33	0,11
W6c	3,00	4,00	4,00	3,00	3,00	4,00	3,00	4,00	2,00	3,00	4,00	3,00	3,00
Nor	0,21	0,29	0,29	0,21	0,30	0,40	0,30	0,44	0,22	0,33	0,40	0,30	0,30
W7c	3,00	4,00	2,00	5,00	5,00	4,00	2,00	5,00	1,00	3,00	5,00	3,00	1,00
Nor	0,21	0,29	0,14	0,36	0,45	0,36	0,18	0,56	0,11	0,33	0,56	0,33	0,11
W8c	2,00	4,00	5,00	5,00	2,00	3,00	3,00	5,00	1,00	2,00	4,00	3,00	1,00
Nor	0,13	0,25	0,31	0,31	0,25	0,38	0,38	0,63	0,13	0,25	0,50	0,38	0,13
W9c	5,00	5,00	5,00	3,00	3,00	3,00	4,00	5,00	1,00	3,00	4,00	3,00	2,00
Nor	0,28	0,28	0,28	0,17	0,30	0,30	0,40	0,56	0,11	0,33	0,44	0,33	0,22
W10b	5,00	4,00	5,00	2,00	5,00	2,00	4,00	5,00	3,00	4,00	3,00	2,00	4,00
Nor	0,31	0,25	0,31	0,13	0,45	0,18	0,36	0,42	0,25	0,33	0,33	0,22	0,44
W11b	3,00	5,00	5,00	Nor	3,00	1,00	4,00	3,00	2,00	4,00	3,00	1,00	2,00
Nor	0,21	0,36	0,36	0,07	0,38	0,13	0,50	0,33	0,22	0,44	0,50	0,17	0,33

Dodatak 7 – Istraživanje preferencija putnika (Beč) – otkrivanje preferencija

W1				W7		
b	Zad. krit.	Otkr.krit		c	Zad. krit.	Otkr.krit
	0,308	0,413			0,214	0,302
	0,231	0,220			0,286	0,293
	0,308	0,251			0,143	0,270
	0,154	0,116			0,357	0,135
W2				W8		
b	Zad. krit.	Otkr.krit		c	Zad. krit.	Otkr.krit
	0,313	0,444			0,176	0,235
	0,250	0,292			0,286	0,304
	0,188	0,247			0,357	0,473
	0,250	0,017			0,357	0,133
W3				W9		
c	Zad. krit.	Otkr.krit		c	Zad. krit.	Otkr.krit
	0,308	0,000			0,278	0,455
	0,231	0,454			0,278	0,366
	0,231	0,327			0,278	0,388
	0,231	0,219			0,167	0,152
W4				W10		
c	Zad. krit.	Otkr.krit		b	Zad. krit.	Otkr.krit
	0,091	0,326			0,313	0,375
	0,273	0,232			0,250	0,332
	0,364	0,303			0,313	0,240
	0,273	0,140			0,125	0,053
W5				W11		
c	Zad. krit.	Otkr.krit		b	Zad. krit.	Otkr.krit
	0,250	0,051			0,214	0,288
	0,188	0,345			0,357	0,378
	0,313	0,362			0,357	0,108
	0,250	0,243			0,071	0,226
W6				W12		
c	Zad. krit.	Otkr.krit		b	Zad. krit.	Otkr.krit
	0,214	0,151			0,313	0,489
	0,286	0,356			0,250	0,298
	0,286	0,338			0,188	0,213
	0,214	0,155			0,250	0,000

W13		
b	Zad. krit.	Otkr.krit
	0,357	0,249
	0,214	0,464
	0,143	0,108
	0,286	0,179
W14		
c	Zad. krit.	Otkr.krit
	0,308	0,134
	0,154	0,281
	0,154	0,219
	0,385	0,366
W15		
b	Zad. krit.	Otkr.krit
	0,294	0,491
	0,235	0,201
	0,235	0,228
	0,235	0,081
W16		
b	Zad. krit.	Otkr.krit
	0,176	0,373
	0,294	0,247
	0,235	0,224
	0,294	0,156
W17		
c	Zad. krit.	Otkr.krit
	0,357	0,308
	0,286	0,274
	0,071	0,224
	0,286	0,193

W18		
c	Zad. krit.	Otkr.krit
	0,267	0,115
	0,333	0,328
	0,067	0,267
	0,333	0,290
W19		
b	Zad. krit.	Otkr.krit
	0,333	0,450
	0,267	0,235
	0,333	0,197
	0,067	0,119
W20		
c	Zad. krit.	Otkr.krit
	0,333	0,177
	0,267	0,276
	0,333	0,398
	0,067	0,149
W21		
c	Zad. krit.	Otkr.krit
	0,357	0,096
	0,357	0,349
	0,214	0,351
	0,071	0,204
Napomena		

Dodatak 8 – Istraživanje preferencija putnika (Beč) – izračun vrijednosti alt.

W1	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,799	0,417	0,814	0,538	0,364	0,633	0,462	0,300	0,529
2	0,308	0,250	0,413	0,542	0,364	0,488	0,446	0,400	0,476
3	0,631	0,333	0,537	0,662	0,273	0,562	0,538	0,300	0,471

W2	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,748	0,417	0,736	0,736	0,417	0,461	0,563	0,333	0,461
2	0,313	0,333	0,409	0,409	0,250	0,399	0,522	0,250	0,399
3	0,650	0,250	0,532	0,532	0,333	0,539	0,438	0,417	0,539

W3	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,536	0,143	0,352	0,769	0,333	0,781	0,769	0,222	0,546
2	0,538	0,286	0,327	0,300	0,222	0,188	0,646	0,333	0,481
3	0,508	0,571	0,738	0,485	0,444	0,706	0,231	0,444	0,454

W4	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,377	0,375	0,501	0,727	0,500	0,860	0,727	0,500	0,768
2	0,455	0,500	0,628	0,264	0,300	0,228	0,632	0,375	0,626
3	0,618	0,125	0,432	0,582	0,200	0,402	0,273	0,125	0,232

W5	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,471	0,333	0,359	0,750	0,556	0,758	0,813	0,556	0,655
2	0,563	0,111	0,413	0,298	0,111	0,225	0,688	0,333	0,570
3	0,500	0,556	0,660	0,469	0,333	0,623	0,188	0,111	0,345

W6	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,466	0,300	0,409	0,786	0,444	0,845	0,714	0,400	0,644
2	0,500	0,400	0,489	0,255	0,222	0,183	0,604	0,300	0,538
3	0,557	0,300	0,579	0,529	0,333	0,545	0,286	0,300	0,356

W7	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,548	0,455	0,507	0,643	0,556	0,865	0,714	0,556	0,708
2	0,357	0,364	0,572	0,378	0,111	0,217	0,632	0,333	0,578
3	0,671	0,182	0,482	0,657	0,333	0,455	0,286	0,111	0,293

W8	S1				S2			S3	
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,294	0,250	0,449	0,819	0,625	1,012	0,891	0,500	0,841
2	0,534	0,375	0,708	0,365	0,125	0,193	0,775	0,375	0,688
3	0,714	0,375	0,532	0,679	0,250	0,484	0,286	0,125	0,304

W9		S1			S2			S3	
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,182	0,300	0,696	0,833	0,556	1,208	0,722	0,444	0,994
2	0,556	0,300	0,842	0,235	0,111	0,282	0,597	0,333	0,803
3	0,500	0,400	0,596	0,472	0,333	0,557	0,278	0,222	0,366

W10		S1			S2			S3	
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,802	0,455	0,788	0,563	0,417	0,707	0,438	0,333	0,428
2	0,313	0,182	0,375	0,524	0,250	0,411	0,422	0,222	0,383
3	0,625	0,364	0,577	0,656	0,333	0,601	0,563	0,444	0,572

W 11	S1			S2			S3		
Alt.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.
1	0,777	0,375	0,696	0,571	0,333	0,666	0,286	0,500	0,514
2	0,214	0,125	0,288	0,490	0,222	0,398	0,304	0,167	0,464
3	0,714	0,500	0,690	0,750	0,444	0,701	0,714	0,333	0,486
W 12	S1			S2			S3		
Alt.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.
1	0,748	0,400	0,820	0,563	0,455	0,787	0,563	0,222	0,489
2	0,313	0,500	0,489	0,506	0,182	0,376	0,522	0,333	0,409
3	0,650	0,100	0,468	0,669	0,364	0,490	0,438	0,444	0,511
W 13	S1			S2			S3		
Alt.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.
1	0,748	0,300	0,675	0,571	0,333	0,713	0,643	0,273	0,428
2	0,357	0,200	0,249	0,507	0,111	0,344	0,582	0,273	0,387
3	0,614	0,500	0,730	0,629	0,556	0,741	0,357	0,455	0,572
W 14	S1			S2			S3		
Alt.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.
1	0,585	0,333	0,694	0,615	0,182	0,634	0,846	0,444	0,719
2	0,462	0,250	0,134	0,432	0,455	0,358	0,738	0,333	0,642
3	0,569	0,417	0,822	0,554	0,364	0,669	0,154	0,222	0,281
W 15	S1			S2			S3		
Alt.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.	Vr.alt. -kriter.	Vr. Alt.- ocjena	Vr.alt.- otkriv.
1	0,763	0,444	0,835	0,529	0,417	0,691	0,529	0,375	0,572
2	0,294	0,333	0,491	0,535	0,333	0,461	0,503	0,375	0,494
3	0,659	0,222	0,464	0,682	0,250	0,487	0,471	0,250	0,429

W 16	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,716	0,444	0,786	0,471	0,300	0,619	0,471	0,400	0,529
2	0,176	0,222	0,373	0,546	0,300	0,483	0,474	0,300	0,481
3	0,776	0,333	0,583	0,800	0,400	0,605	0,529	0,300	0,471
W 17	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,641	0,400	0,537	0,714	0,500	0,807	0,714	0,500	0,726
2	0,429	0,300	0,533	0,364	0,375	0,268	0,611	0,333	0,604
3	0,586	0,300	0,512	0,579	0,125	0,490	0,286	0,167	0,274
W 18	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,607	0,364	0,438	0,667	0,375	0,710	0,667	0,455	0,672
2	0,333	0,182	0,382	0,375	0,250	0,287	0,587	0,364	0,590
3	0,680	0,455	0,671	0,673	0,375	0,645	0,333	0,182	0,328
W 19	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,817	0,455	0,804	0,600	0,333	0,684	0,400	0,375	0,568
2	0,333	0,364	0,450	0,502	0,222	0,449	0,383	0,375	0,495
3	0,600	0,182	0,511	0,633	0,444	0,531	0,600	0,250	0,432

W 20	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,484	0,250	0,389	0,933	0,556	0,852	0,733	0,455	0,724
2	0,667	0,417	0,576	0,168	0,333	0,186	0,583	0,364	0,600
3	0,400	0,333	0,504	0,367	0,111	0,464	0,267	0,182	0,276
W 21	S1			S2			S3		
Alt.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.	Vr.alt.-kriter.	Vr. Alt.-ocjena	Vr.alt.-otkriv.
1	0,554	0,333	0,381	0,929	0,500	0,796	0,643	0,455	0,651
2	0,571	0,250	0,447	0,180	0,125	0,207	0,511	0,364	0,557
3	0,471	0,417	0,623	0,450	0,375	0,588	0,357	0,182	0,349

Dodatak 9 – Istraživanje preferencija putnika (Beč) – rezultati testiranja

Ispitanik	Kazna (Zadane vr. kriterija)	Kazna (Otkrivene vr. kriterija)	Odnos kazni
1	6	3	0,50
2	4	3	0,75
3	8	6	0,75
4	4	0	0,00
5	3	1	0,33
6	3	3	1,00
7	5	1	0,20
8	2	0	0,00
9	2	0	0,00
10	2	0	0,00
11	5	2	0,40
12	8	3	0,38
13	2	1	0,50
14	5	3	0,60
15	3	1	0,33
16	6	2	0,33
17	2	1	0,50
18	3	1	0,33
19	3	3	1,00
20	2	1	0,50
21	3	0	0,00

Dodatak 10 – Istraživanje preferencija putnika (Beč) – validacija rezultata

	S1			S2			S3			Sred.gr.		
Ispitanik	Greška krit	Gr. K/O	Greška otkr.	Greška krit	Gr. K/O	Greška otkr.	Greška krit	Gr. K/O	Greška otkr.	Greška krit	Gr. K/O	Greška otkr.
1	0,05	1,62	0,03	0,07	1,46	0,05	0,06	1,18	0,05	0,06	1,42	0,04
2	0,10	1,69	0,06	0,01	0,25	0,06	0,09	3,66	0,02	0,07	1,87	0,05
3	0,17	2,37	0,07	0,11	1,22	0,09	0,20	2,08	0,10	0,16	1,89	0,09
4	0,20	1,98	0,10	0,11	1,16	0,10	0,04	1,97	0,02	0,12	1,70	0,07
5	0,17	1,44	0,12	0,06	1,02	0,06	0,05	0,54	0,09	0,09	1,00	0,09
6	0,05	0,78	0,06	0,04	0,56	0,07	0,08	1,78	0,05	0,06	1,04	0,06
7	0,16	1,88	0,09	0,11	4,61	0,02	0,08	1,10	0,07	0,12	2,53	0,06
8	0,06	1,47	0,04	0,12	5,03	0,02	0,03	1,06	0,03	0,07	2,52	0,03
9	0,10	1,27	0,08	0,03	0,68	0,04	0,03	0,91	0,04	0,05	0,95	0,05
10	0,00	0,19	0,02	0,06	5,72	0,01	0,05	1,37	0,04	0,04	2,43	0,02
11	0,05	0,92	0,06	0,03	1,02	0,03	0,19	1,87	0,10	0,09	1,27	0,06
12	0,21	1,41	0,15	0,09	1,94	0,04	0,10	1,26	0,08	0,13	1,54	0,09
13	0,10	1,32	0,07	0,12	1,30	0,10	0,15	5,40	0,03	0,12	2,67	0,07
14	0,04	0,38	0,11	0,13	0,85	0,16	0,09	2,32	0,04	0,09	1,18	0,10
15	0,11	2,74	0,04	0,09	2,70	0,03	0,04	1,43	0,03	0,08	2,29	0,03
16	0,09	15,96	0,01	0,03	0,65	0,04	0,05	1,88	0,03	0,06	6,17	0,03
17	0,04	0,89	0,04	0,15	1,10	0,14	0,04	1,19	0,03	0,07	1,06	0,07
18	0,02	0,47	0,05	0,02	0,42	0,05	0,02	1,08	0,02	0,02	0,66	0,04
19	0,12	1,59	0,07	0,05	0,63	0,08	0,12	4,20	0,03	0,10	2,14	0,06
20	0,05	3,05	0,02	0,15	1,05	0,14	0,01	1,17	0,01	0,07	1,76	0,05
21	0,08	1,72	0,05	0,06	17,71	0,00	0,04	1,29	0,03	0,06	6,91	0,03

ŽIVOTOPIS

Bia Mandžuka rođena je 16. lipnja 1989. god. u Zagrebu. Osnovnu školu *„Rapska“* završila je 2004. god., a *„1. Gimnaziju“* 2008. god. Nakon toga, upisala je Fakultet prometnih znanosti *Sveučilišta u Zagrebu* gdje završava preddiplomski studij 2011. godine. Nakon preddiplomskog studija upisala je diplomski studij *Promet* (smjer „Gradski promet“) na Fakultetu prometnih znanosti. Za ostvarene rezultate tijekom studija uručena joj je Dekanova nagrada i Pohvala te joj je dodijeljena Stipendija Grada Zagreba za akademsku godinu 2012./2013. Titulu magistre inženjerke prometa stječe 2013. godine, obranivši diplomski rad na temu: „*Održiva urbana mobilnost podržana ITS uslugama*“ pod mentorstvom prof. dr. sc. Davora Brčića. Poslijediplomski doktorski studij „*Tehnološki sustavi u prometu i transportu*“ upisuje 2014. godine. Od početka studija aktivno sudjeluje na međunarodnim konferencijama u području prometa i transporta. Na temelju dobrih referenci dodijeljena joj je stipendija STSM (*Short-term Scientific Mission*) u okviru projekta ARTS, COST na Sveučilištu Aalto u Helsinkiju. Osim STSM-a, sudjelovala je na Ljetnoj školi *Transportation in Digital Age* na istom Sveučilištu. Od listopada 2014. do studenog 2016. godine volontirala je na znanstveno-istraživačkim i stručnim projektima na Zavodu za gradski promet. Tijekom 2013. i 2014. ak. god. predavala je i držala vježbe iz predmeta Inteligentni transportni sustavi na Veleučilištu Hrvatsko zagorje Krapina. Osim na Veleučilištu Hrvatsko Zagorje u Krapini, predavala je i izvodila auditorne vježbe iz istog predmeta tijekom ak. god. 2014. i 2015. na Pomorskom fakultetu Sveučilišta u Rijeci. Na Fakultetu prometnih znanosti, kao doktorand, izvodila je dio vježbi iz predmeta Urbana mobilnost, Upravljanje prometnim sustavom u urbanim sredinama, Upravljanje prijevoznom potražnjom u gradovima i na predmetu Osnove prometnog inženjerstva. Na Zavodu za prometno planiranje zapošljava se u svibnju 2016. godine kao suradnik na projektu „Subcontract for the Provision of services relating to iRAP Road Protection Scoring (RPS) of Highways England“. U suradničko zvanje asistenta iz područja tehničkih znanosti (polje tehnologija prometa i transporta) izabrana je 2016. godine. Trenutačno je zaposlena u svojstvu asistenta na Katedri za prometno pravo i ekonomiku pri Zavodu za prometno planiranje te izvodi vježbe i seminare iz predmeta Menadžment u prometu, Tehnologijski marketing i menadžment, Teorija logističkog odlučivanja, Upravljanje ljudskim potencijalima i Komunikologija.

Uključena je u projektne aktivnosti (H2020 – Twinning Open Data Operational – TODO, OJP4Danube – Coordination mechanisms for multimodal cross-border traveller information network based on OJP for Danube Region u okviru programa Interreg Danube). Istraživačko područje obuhvaća razvoj modela planiranja multimodalnih putovanja, multimodalne putne planere te problematiku otvorenih podataka u području tehnologije prometa i transporta. Engleski jezik izvrsno govori i piše, a služi se njemačkim jezikom.

Popis objavljenih radova u području disertacije (CROSBI)

1. Mandžuka, B., Jurčević, M., Vidović, K., Vujić, M. Multimodal journey route selection as decision-making process. In: Lecture Notes in Networks and Systems. Cham: Springer International Publishing; 2022. p. 712–8.

2. Mandžuka, B., Vidović, K., Vujić, M. The Importance of Open Data Accessibility for Multimodal Travel Improvement. Interdisciplinary Description of Complex Systems [Internet]. 2022

3. Vujić, M., Mandžuka, B., Škorput, P. Multimodal traveler information systems in maritime environment. In: 2016 International Symposium ELMAR. IEEE; 2016.

4. Vujić, M., Škorput, P, Mandžuka, B. Multimodal route planners in maritime environment. Pomorstvo [Internet]. 2015 [pristupljeno 26.06.2022.];29(1):1-7. Dostupno na: https://hrcak.srce.hr/140200

5. Mandžuka, B., Brčić, D., Škorput, P. Multimodal route planners in maritime environment. In: Rijavec, Robert Hernavs, Boštjan Gostišta, Blaž Gorup, Savim Anžek, Mario Kos, Serdjo Meše, Pavel, editor. ISEP 2015 – ITS for autonomus and cooperative transport. Electrotechnical Association of Slovenia; 2015.

6. Mandžuka, B., Brčić, D., Škorput, P. Primjena multimodalnih putnih vodiča za gradska i prigradska putovanja. In: Zbornik radova sa znanstvenog skupa Automatizacija u prometu 2014. Zagreb: KoREMA; 2014.

7. Škorput, P., Mandžuka, B., Vujić, M. The development of Cooperative multimodal travel guide. In: 22nd Telecommunications Forum Telfor (TELFOR). Belgrade: TELFOR; 2014. p. 1110–3.