

Pregled prikupljanja komunalnog otpada u gradu Zagrebu

Zovko, Magdalena

Master's thesis / Diplomski rad

2022

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

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:332524>

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

Download date / Datum preuzimanja: **2024-05-18**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Magdalena Zovko

Zagreb, 2022. godina.

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

DIPLOMSKI RAD

Mentor:

Prof. dr. sc. Goran Đukić

Studentica:

Magdalena Zovko

Zagreb, 2022. godina.

Izjavljujem da sam ovaj rad izradila samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem mentoru prof. dr. sc. Goranu Đukiću na mentorstvu i na stručnim savjetima tijekom pisanja ovog rada.

Zahvaljujem se i gosp. Danijelu Gulinu iz zagrebačkog komunalnog poduzeća Čistoća na ustupljenim informacijama.

Zahvaljujem se svojoj obitelji na podršci tijekom studiranja. Hvala mami Mirni, ocu Gojku, sestri Josipi i bratu Davidu. Hvala mojim bakama na molitvama.

Najveće zahvale idu mom Dinu. Hvala ti na ljubavi i motivaciji.

A handwritten signature in dark ink, reading 'Magdalena Zovko'. The script is cursive and fluid, with the first letters of the first and last names being capitalized and prominent.

Magdalena Zovko



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE



Središnje povjerenstvo za završne i diplomske ispite
Povjerenstvo za diplomske radove studija strojarstva za smjerove:
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment,
inženjerstvo materijala te mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum:	Prilog:
Klasa:	602-14/22-6/1
Ur. broj:	15-1703-22-

DIPLOMSKI ZADATAK

Student: **MAGDALENA ZOVKO**

Mat. br.: 0069050654

Naslov rada na hrvatskom jeziku: **Pregled prikupljanja komunalnog otpada u gradu Zagrebu**

Naslov rada na engleskom jeziku: **Municipal waste collection in Zagreb**

Opis zadatka:

U današnje vrijeme sustavi gospodarenja otpadom imaju sve veći značaj s aspekta održivosti. U sustavu gospodarenja otpadom značajan utjecaj na navedeno ima način prikupljanja komunalnog otpada u velikim gradovima.

U radu je potrebno:

- dati pregled sustava gospodarenja otpadom grada Zagreba, s naglaskom na prikaz procesa prikupljanja otpada
- za odabrano gradsko područje utvrditi utjecaj transporta na ukupnu održivost sustava
- primjenom metoda i modela rutiranja za skup vozila na odabranom području odrediti optimalne rute prikupljanja i usporediti sa stvarnim stanjem.

U radu je potrebno navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:
29. rujna 2022.

Rok predaje rada:
1. prosinca 2022.

Predviđeni datum obrane:
12. prosinca do 16. prosinca 2022.

Zadatak zadao: *A. Đukić*
prof. dr. sc. Goran Đukić

Predsjednica Povjerenstva:
Biserka Runje
prof. dr. sc. Biserka Runje

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	III
POPIS TABLICA.....	IV
POPIS KRATICA	V
SAŽETAK.....	VI
SUMMARY	VII
1. UVOD.....	1
1.1. Ukupne emisije CO ₂ za sektor prometa u Gradu Zagrebu	1
1.2. Indeks europskih zelenih gradova.....	2
2. OPTIMIZACIJA KRETANJA U MREŽAMA	4
2.1. Osnove teorije grafova	4
2.2. Povijest teorije grafova i suvremene primjene.....	4
2.3. Problem putujućeg trgovca	6
2.4. Algoritam najbližeg susjeda.....	9
2.5. Pohlepna heuristika	12
2.6. Algoritmi umetanja	12
2.6.1. Algoritam umetanja najbližeg.....	12
2.6.2. Algoritam umetanja najdaljeg.....	13
2.6.3. Algoritam umetanja najjeftinijeg	13
2.6.4. Algoritam ušteda	14
2.6.5. Aproksimacijski heuristički algoritam Christofidesa.....	20
2.6.6. Heuristički algoritmi i optimalna rješenja.....	20
2.7. Usporedba rezultata dobivenih algoritmom najbližeg susjeda i algoritma uštede...	21
3. ODREĐIVANJE RUTA PRIKUPLJANJA OTPADA I USPOREDBA SA STVARNIM STANJEM	22
3.1. Primjena algoritma ušteda za prvu rutu – podsljemenska zona	22
3.2. Primjena algoritma ušteda za drugu rutu – podsljemenska zona	30
3.3. Primjena algoritma ušteda za treću rutu.....	38
3.4. Analiza dobivenih rješenja.....	45

4. PRIJEDLOG UNAPREĐENJA KORIŠTENJEM SOFTVERSKOG RJEŠENJA	
UPRAVLJANJA TRANSPORTOM.....	47
4.1. Softversko rješenje Waste Hero	48
4.1.1. Automatizirano planiranje resursa i rute	49
4.1.2. Mobilna tehnologija u kabini vozila	50
4.1.3. Praćenje prikupljanja otpada uživo	51
4.1.4. Upravljanje na trenutne događaje uređivanjem ruta	52
4.1.5. Analiziranje i usporedba operativne izvedbe	53
4.1.6. Optimiziranje dnevnih operacija s opsežnim uvidima.....	54
4.2. Troškovi prikupljanja komunalnog otpada u gradu Zagrebu	55
4.3. Emisije stakleničkih plinova voznog parka grada Zagreba	57
4.3.1. Lokalni transport otpada	58
4.3.2. Međugradski transport otpada.....	58
4.4. Usporedba sustava gospodarenja komunalnim otpadom grada Zagreba i Ljubljane.	60
5. ZAKLJUČAK.....	62
LITERATURA.....	63
PRILOZI.....	64

POPIS SLIKA

Slika 1.	Veza između bogatstva i ekološke učinkovitosti [1]	3
Slika 2.	Mostovi Koenisberga	5
Slika 3.	Graf mostova Koenigsberga	5
Slika 4.	Lokacije na kojima se nalaze spremnici za staklo – odabrano područje grada Zagreba	7
Slika 5.	Primjer mogućih ruta putujućeg trgovaca	9
Slika 6.	Rješenje TSP algoritmom umetanja najbližeg	11
Slika 7.	Rute $0,i,0$	15
Slika 8.	Rješenje TSP heurističkim algoritmom ušteda	19
Slika 9.	Usporedba dobivenih rješenja	21
Slika 10.	Pozicije točaka za određivanje rute G-356	23
Slika 11.	Pozicije točaka za određivanje povratne rute do odlagališta Jakuševac	23
Slika 12.	Koraci rješenja TSP heurističkim algoritmom ušteda za rutu G-356	28
Slika 13.	Rješenje TSP heurističkim algoritmom ušteda za rutu G-356	29
Slika 14.	Prva ruta (podsljemenska zona) u primjeni zagrebačke Čistoće	30
Slika 15.	Pozicije točaka za određivanje rute G-474	31
Slika 16.	Pozicije točaka za određivanje povratne rute G-474 do odlagališta	32
Slika 17.	Rješenje TSP heurističkim algoritmom ušteda za rutu G-474	37
Slika 18.	Druga ruta (podsljemenska zona) u primjeni zagrebačke Čistoće G-474	38
Slika 19.	Pozicije točaka za određivanje rute G-437	39
Slika 20.	Rješenje TSP heurističkim algoritmom ušteda za rutu G-437	44
Slika 21.	Treća ruta u primjeni zagrebačke Čistoće (G-437)	45
Slika 22.	Usporedba rezultata tri analizirane rute	46
Slika 23.	Pozadina softvera Waste Hero	49
Slika 24.	Automatizirano planiranje resursa i rute	50
Slika 25.	Mobilna tehnologija u kabini vozila	51
Slika 26.	Prikaz praćenja lokacija uživo	52
Slika 27.	Evidencija vozača i ruta koje se odvijaju uživo	53
Slika 28.	Usporedba izmjerenih podataka realne i planirane rute	54
Slika 29.	Geografska područja odrađenih ruta	54
Slika 30.	Plan nabave zagrebačkog Holdinga za 2022. godinu	55
Slika 31.	Godišnja potrošnja energije za željeznički prijevoz otpada	59

POPIS TABLICA

Tablica 1. Prikaz emisija CO ₂ -ekv po sektorima [2].....	1
Tablica 2. Matrica udaljenosti vrhova, primjer za TSP.....	8
Tablica 3. Matrica udaljenosti vrhova, TSP – algoritam najbližeg susjeda	10
Tablica 4. Izračunate uštede za svaki par i,j iz Tablice 2.....	16
Tablica 5. Poredak ušteda od najveće do najmanje.....	17
Tablica 6. Matrica udaljenosti vrhova, ruta G-356	24
Tablica 7. Izračunate uštede za svaki par i,j iz Tablice 6.....	25
Tablica 8. Poredak ušteda od najveće do najmanje za rutu G-356.....	26
Tablica 9. Matrica udaljenosti vrhova, ruta G-474	33
Tablica 10. Izračunate uštede za svaki par i,j iz Tablice 9.....	34
Tablica 11. Poredak ušteda od najveće do najmanje za rutu G-474.....	35
Tablica 12. Matrica udaljenosti vrhova, ruta G-437	40
Tablica 13. Izračunate uštede za svaki par i,j iz Tablice 12.....	41
Tablica 14. Poredak ušteda od najveće do najmanje za rutu G-437.....	42
Tablica 15. Predviđeni troškovi voznog parka zagrebačkog Holdinga (podružnica Čistoća) prema Planu nabave za 2022. godinu	56
Tablica 16. Cestovna udaljenost gradova od Zagreba.....	58
Tablica 17. Ekonomski troškovi i emisije po cestovnoj udaljenosti pogona	58

POPIS KRATICA

Kratika	Opis
BDP	bruto domaći proizvod
C	ugljik
CH ₄	metan
CO ₂	ugljičkov dioksid
ekv	ekvivalent
EU	Europska unija
RH	Republika Hrvatska

SAŽETAK

U radu se analizira proces prikupljanja komunalnog otpada u gradu Zagrebu s aspekta utjecaja transporta na ukupnu održivost sustava. Proces prikupljanja otpada odvija se u cestovnoj infrastrukturi gradova tj. mrežama transportnih puteva, pa je logično rješenje primjena metoda rješavanja problema usmjeravanja vozila i korištenje pripadajućih algoritama.

U radu se prvo u poglavlju 2 prikazuju teorijske osnove optimizacije na mrežama, s detaljnijim pregledom metoda i algoritama koji se mogu primijeniti u optimizaciji prikupljanja komunalnog otpada. Nakon toga se u poglavlju 3 na temelju dostupnih izvora i dobivenim primjerima ruta prikupljanja proces analizira temeljem izračuna ruta odabranim algoritmom te usporedbama sa stvarnim rutama.

Poglavlje 4 posvećeno je pregledu funkcionalnosti jednog odabranog softverskog rješenja za rutiranje vozila, uz elemente ekonomske analize i analize emisija stakleničkih plinova procesa prikupljanja otpada, a s ciljem ilustracije mogućnosti ušteda koje bi se ostvarile. Dodatno je dan primjer upravljanja komunalnim otpadom u Ljubljani.

Ključne riječi:

Gospodarenje otpadom, prijevoz otpada, problem putujućeg trgovca, komunalni otpad, algoritam, algoritam ušteda, algoritam najbližeg susjeda, optimizacija, optimiziranje, komunalni otpad, rute, rutiranje.

SUMMARY

The paper analyzes the municipal waste collection process in the city of Zagreb from the perspective of the impact of transport on the overall sustainability of the system. The process of waste collection takes place in the road infrastructure of cities, i.e. networks of transport routes, so the logical solution is the application of methods for solving vehicle routing problems and the use of associated algorithms.

In chapter 2, the paper first presents the theoretical foundations of network optimization, with a more detailed overview of methods and algorithms that can be applied in the optimization of municipal waste collection. After that, in chapter 3, on the basis of available sources and obtained examples of collection routes, the process is analyzed based on the calculation of routes by the selected algorithm and comparisons with real routes.

Chapter 4 is devoted to an overview of the functionality of one selected software solution for vehicle routing, along with elements of economic analysis and analysis of greenhouse gas emissions of the waste collection process, with the aim of illustrating the potential savings that would be achieved. Additionally, an example of municipal waste management in Ljubljana is given.

Key words:

Waste management, waste transportation, the travelling salesman problem, municipal waste, algorithm, algorithm savings, nearest neighbour algorithm, optimization, optimization, municipal waste, routes, routing.

1. UVOD

Gospodarenje komunalnim otpadom izazov je za gradove sa velikim brojem stanovnika zbog brzog rasta količine otpada, visokih troškova skupljanja otpada, ograničenih kapaciteta obrade i ekoloških problema. U sustavima gospodarenja otpadom prioritet mora biti održivo gospodarenje otpadom. Kružno gospodarstvo uključuje i kružno gospodarenje otpadom. Prvi korak je taj da se samo prikupljanje komunalnog otpada organizira na takav način da će se njegovim prikupljanjem minimizirati negativni učinci na okoliš te da će se sami ekonomski troškovi svesti na minimum. To je u slučaju grada Zagreba još uvijek daleko od realizacije. Vozni park zagrebačke Čistoće, koja je odgovorna za prikupljanje komunalnog otpada u Gradu Zagrebu i Zagrebačkoj županiji, među ostalima, čine 168 vozila za odvoz otpada iz domaćinstva i od ostalih korisnika te su to većinom vozila koja su stara između 15 i 20 godina te koja troše veliku količinu goriva za pogon motora. To znači da se emitiraju i velike količine stakleničkih plinova koje vozni park proizvodi prilikom prikupljanja tj. prijevoza otpada. Kako bi se napravile uštede kod kupnje naftnih derivata, vozila se kreću po određenim optimiziranim rutama. Primjenama metoda i modela rutiranja za vozila moguće je optimizirati rute kojima vozila prolaze te na taj način osigurati da se postignu što kraće rute, a time i uštedi gorivo, kao i smanji onečišćenje zraka.

1.1. Ukupne emisije CO₂ za sektor prometa u Gradu Zagrebu

Više od 50 % ukupnih emisija stakleničkih plinova nastaje u gradovima i njihovoj okolini. Prema službenim podacima, u Europskoj uniji oko 80 % stanovništva živi u gradovima. To znači da je održivo upravljanje gradovima od iznimne važnosti za ublažavanje klimatskih promjena i zaštitu okoliša na globalnoj razini. Kvaliteta zraka u Zagrebu je osrednja. Emisije dušikovog oksida (N₂O) malo su ispod prosjeka ostalih europskih gradova, dok su emisije ozona, čestica i sumporovog dioksida (SO₂) više od prosjeka. Emisije CO₂ iznose 6,68 tona po stanovniku godišnje [1].

Tablica 1. Prikaz emisija CO₂-ekv po sektorima [2]


	Promet	Javna rasvjeta	Zgradarstvo	Ukupno po energentima
Emisija t CO ₂ -ekv	1.044.200	29.100	1.732.000	2.805.300
Udio	37.200	1.000	618.00	1.000.00

U sektoru prometa najveće emisije CO₂ nastale su potrošnjom dizel goriva (545.000 t CO₂) i benzina (433.000 t CO₂). Emisije metana (CH₄) i dušikovog oksida (N₂O) proračunate su u emisiji CO₂-ekv u Tablici 1.

1.2. Indeks europskih zelenih gradova

Indeks europskih zelenih gradova pokazuje blisku korelaciju između bogatstva i ukupnog učinka. Ova veza nije vidljiva samo u infrastrukturi, već i u politici: bogatiji gradovi imaju ambicioznije ciljeve. Jedna od najbližih korelacija u podacima prikupljenim za indeks je ona između BDP-a po glavi stanovnika gradova i njihove ukupne ocjene — zbirna brojka između 0 i 100 koja odražava izvedbu u svim mjeranim ekološkim pokazateljima.

Na razini infrastrukture, poveznica je očita. Visokokvalitetna zelena infrastruktura obično uključuje visoke početne troškove koje si mogu priuštiti samo bogatije države tj. gradovi. Siromašniji gradovi se moraju baviti sa širim rasponom razvojnih pitanja, od razine nezaposlenosti do rastućih neformalnih naselja, što može lako odvratiti pozornost od zelene strategije. Veza između BDP-a i pokazatelja politike unutar indeksa (koji prati ekološke akcijske planove i sudjelovanje javnosti u zelenoj politici, između ostalog) statistički još jača. Drugim riječima, bogatiji gradovi ne samo da mogu priuštiti održiviju infrastrukturu, već postavljaju i ambicioznije političke ciljeve nego njihovi manje bogati gradovi. Jedan od primjera pokazatelja je da dva od tri grada koji nemaju čak ni osnovni ekološki plan, su dva od tri najsiromašnija grada [1].



Slika 1. Veza između bogatstva i ekološke učinkovitosti [1]

Na Slici 1 je prikazana veza između bogatstva navedenih gradova u Europi, i njihove ekološke učinkovitosti. Zagreb bi trebao ostvarivati bolje ekološke performanse, u odnosu na visinu BDP-a (bruto domaći proizvod). Plavi krug označava stvarno stanje, dok je narančasta linija ono što bi navedeni grad trebao postizati, u odnosu na visinu BDP-a.

2. OPTIMIZACIJA KRETANJA U MREŽAMA

Za prijevoz otpada najvažniji je princip blizine. To znači da upravljanje i obradu otpada treba organizirati što je moguće bliže mjestu nastanka otpada kako bi sustav bio učinkovit, najviše zbog činjenice da prijevoz otpada ima značajan štetan utjecaj na okoliš, a i troškovi prijevoza rastu s udaljenošću pogona za obradu otpada.

Lokalni prijevoz otpada uključuje sustav koji se sastoji od prikupljanja, zaustavljanja te kretanja vozila za odvoz otpada. Potrebno je optimizirati rutu tako da ishod bude što racionalniji. Kod lokalnog transporta kraćih udaljenosti u gradskim uvjetima (stani-kreni), i slabe prosječne popunjenosti vozila, potrošnja energije ceste po toni i prijeđenom kilometru je 27,5 MJ. Što je veći broj odredišta za istovar otpada, to su troškovi prijevoza otpada manji, jer je i prijeđena udaljenost manja [3].

2.1. Osnove teorije grafova


Teorija grafova je područje matematike koje izučava grafove. U teoriji grafova nevažno je kolika je veličina točaka grafa, koja je duljina linije koja povezuje točke grafa, pa čak i da li je linija ravna ili zakrivljena.

Modeli optimizacije na grafovima predstavljaju značajno područje interesa u operacijskim istraživanjima. Naime, mnogi od tih koncepata i teorijskih problema proizlaze iz praktičnih razloga, za rješavanje stvarnih problema koji su karakterizirani strukturom grafa tj. mreže. Osim u matematici, primjenu teorije grafova možemo naći u kemiji, kompjuterskim znanostima (računalne mreže), transportnim mrežama, komunikacijskim mrežama, električnim mrežama, financijskom planiranju, sociologiji i sl. Osim rješavanja problema u realnim mrežama, postoji i čitav niz drugih problema koji se odnose na probleme optimizacije na grafu ili mreži, kao što su npr. mrežno planiranje u upravljanju projektima, ili problemi planiranja proizvodnje i raspoređivanje poslova [4].

2.2. Povijest teorije grafova i suvremene primjene


Teorija grafova ima relativno dugu povijest u klasičnoj matematici. Poznati problem mostova u Koenigsbergu u Njemačkoj (danas Kaliningrad u Rusiji), smatra se prvim formalnim rezultatom teorije grafova. Problem je riješen od strane švicarskog matematičara Eulera 1736. godine. U Koenigsbergu je bilo sedam mostova preko rijeke Prager [Slika 2], a postavljen

matematički problem je bio da li je moguće izvesti kompletnu rutu na način da se krene od jedne početne točke, prijeđe preko svih sedam mostova te vrati na početnu točku. Uvjet je bio da se preko svakog mosta prijeđe samo jedanput.



Slika 2. Mostovi Koenisberga [4]

Euler je riješio taj problem na način da je stvarnu situaciju predstavio grafom u kojem su dijelovi grada točke grafa, a mostovi linije koje povezuju te točke [Slika 3].



Slika 3. Graf mostova Koenigsberga [4]

Prikazani problem, do čega je došao i sam Euler, je nerješiv. Teorija grafova se dalje razvijala tijekom druge polovice 19. stoljeća i 30-ih godina prošlog stoljeća uglavnom na problemima iz algebre, topologije i kombinatorike, ali bilo je potrebno 200 godina do pojave prve knjige iz Teorije grafova – Koenig, "Theorie der endlichen und unendlichen Graphen", Teubner, Leipzig, 1936. Teorija grafova se od tada razvila u opsežnu i popularnu granu matematike, primijenjenu na mnoge probleme u matematici, računalnoj znanosti, kemiji, topologiji i dr. [4].

2.3. Problem putujućeg trgovca

Problem rutiranja transportnih vozila je čest problem kod transportnih i logističkih problema. U slučaju rutiranja nužno je pronaći redoslijed posjećivanje određenog broja lokacija, s početkom u određenoj lokaciji te da se postignu minimalni ukupni troškovi. Vozilo se vrlo često nakon obavljene rute mora vratiti u početnu lokaciju. Problem rutiranja jednog vozila naziva se i problem putujućeg trgovca ili problem trgovačkog putnika. S obzirom da se posjećuju točno određene lokacije, u mrežnim problemima ovakav problem spada u skupinu problema usmjeravanja s prolascima kroz čvorove.

Problem putujućeg trgovca (eng. traveling salesman problem) je problem pronalaženja optimalne rute kroz skup lokacija, na način da se svaka lokacija posjeti jedanput i isključivo jedanput te se vrati u početnu lokaciju. U terminologiji teorije grafova, V skup je $n+1$ vrhova (lokacija) $V=\{0,1,2,\dots,n\}$, problem je pronaći rutu (ciklus) koji počinje i završava u vrhu 0, a prolazi svim vrhovima od 1 do n točno jedanput, takvu da je ukupna udaljenost minimalna.

Problem trgovačkog putnika je pronalaženje Hamiltonovog ciklusa minimalne duljine [4].


Za primjer rješavanja metode problema putujućeg trgovca (TSP) prikazana je simulacija načina rješavanja, a kasnije u radu su riješene stvarne rute prikupljanja komunalnog otpada. U Tablici 2 je matrica udaljenosti primjera skupa 16 vrhova, a na Slici 4 nalaze se lokacije na kojima su spremnici za staklo na određenom području. Određena je ruta vozila sa dizalicom na način da se vozilom stane ispred svakog spremnika za staklo te ga pomoću dizalice isprazni i staklo prebaci u kontejner na vozilu. Pronađena je ruta vozila pomoću algoritama (uz prikaz koraka izvođenja). Vrh A odabran je za početni vrh.

Lokacije spremnika za staklo po točkama su:

- A) Ulica Ivana Cankara 20, 10000 Zagreb
- B) Ulica Ivana Cankara 21, 10000 Zagreb
- C) Prilaz baruna Filipovića 15, 10000 Zagreb
- D) Ulica Janka Vukovića 11, 10000 Zagreb
- E) Prilaz baruna Filipovića 12, 10000 Zagreb
- F) Ulica grada Mainza 34, 10000 Zagreb
- G) Ulica grada Mainza 23, 10000 Zagreb
- H) Međimurska ulica 9, 10000 Zagreb

- I) Slovenska ulica 15, 10000 Zagreb
- J) Trg dr. Franje Tuđmana 15, 10000 Zagreb
- K) Reljkovićeva ulica 2, 10000 Zagreb
- L) Vodovodna ulica 1, 10000 Zagreb
- M) Mandaličina ulica 17, 10000 Zagreb
- N) Selska cesta 7, 10000 Zagreb
- O) Ulica Sveti Duh 2, 10000 Zagreb
- P) Prilaz baruna Filipovića 13, 10000 Zagreb

Kasnije u radu će se raditi usporedba ruta u realnog primjeni. Odabrano je određeno područje te su označene lokacije na kojima se nalaze spremnici za staklo. Napravljena je primjena problema putujućeg trgovca za algoritam najbližeg susjeda i za algoritam ušteda.




Slika 4. Lokacije na kojima se nalaze spremnici za staklo – odabrano područje grada Zagreba [5]

Lokacije koje su navedene se nužno ne prikupljaju u istoj ruti te je cilj bio prikazati primjenu algoritama. U Tablici 2 se nalaze udaljenosti vrhova i te iste udaljenosti su prikazane na Slici 5. Prilikom udaljenosti ruta se vodilo računa i o tome da li je ulica jednosmjerna ili dvosmjerna te su se poštivali prometni propisi, kao što je puna crta.

Tablica 2. Matrica udaljenosti vrhova, primjer za TSP

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	–	240	500	730	830	1000	1120	1310	1300	1950	1670	1100	1300	400	540	568
B	240	–	740	730	830	1000	1120	1310	1300	1950	1670	1100	1300	640	780	500
C	808	568	–	230	330	500	620	810	800	1450	1170	600	800	2030	630	2198
D	1400	1640	1900	–	100	270	390	580	570	1220	940	370	570	1800	400	2140
E	1820	2060	1170	670	–	170	290	480	470	1120	840	270	470	1770	820	1238
F	1970	2210	1320	820	920	–	120	310	300	950	670	420	620	1920	970	1388
G	1850	2090	1200	700	800	420	–	190	180	830	550	300	500	1800	850	1268
H	1950	2190	1300	800	900	350	470	–	650	650	910	400	600	1900	950	1368
I	3010	3250	2360	1860	1960	1580	1700	300	–	650	910	1070	900	2200	1250	1668
J	2360	2600	1710	1940	1310	930	1050	1240	1230	–	260	810	1010	2310	1360	1778
K	1950	2190	1450	1680	1780	670	790	980	970	1620	–	550	750	2050	1100	1518
L	1550	1790	900	400	500	120	240	430	420	1070	790	–	200	1500	550	968
M	1200	1440	1100	550	650	320	440	630	620	1270	990	200	–	1600	700	1168
N	1140	1380	1000	1230	1330	1500	1620	1810	1800	2450	2170	1600	1800	–	140	1068
O	1000	1240	2400	2630	2730	2900	3020	3210	3200	3850	3570	3000	3200	1400	–	2468
P	740	500	2140	230	330	500	620	810	800	1450	1170	600	800	2030	630	–



Slika 5. Primjer mogućih ruta putujućeg trgovaca

Na Slici 5 su prikazane moguće rute, a primjenom algoritma najbližeg susjeda i algoritma ušteda je prikazano rješenje problema.

2.4. Algoritam najbližeg susjeda

Algoritam najbližeg susjeda je heuristički algoritam za generiranje rješenja problema putujućeg trgovca koji se temelji na pohlepnom dodavanju najbližeg vrha već dodanim vrhovima u ruti. Algoritam se sastoji od sljedećih koraka:

- Korak 1: Odaberi vrh i za početni vrh.
- Korak 2: Odredi iz nedodanih vrhova onaj koji je najbliži posljednjem dodanom vrhu i uključi ga u ruti.
- Korak 3: Ponavljaj 2. korak sve dok svi vrhovi nisu u ruti. Tada spoji prvi i zadnji vrh.

Tablica 3. Matrica udaljenosti vrhova, TSP – algoritam najbližeg susjeda

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	–	<u>240</u>	500	730	830	1000	1120	1310	1300	1950	1670	1100	1300	400	540	568
B	240	–	740	730	830	1000	1120	1310	1300	1950	1670	1100	1300	640	780	<u>500</u>
C	808	568	–	230	330	500	620	810	800	1450	<u>1170</u>	600	800	2030	630	2198
D	1400	1640	1900	–	<u>100</u>	270	390	580	570	1220	940	370	570	1800	400	2140
E	1820	2060	1170	670	–	<u>170</u>	290	480	470	1120	840	270	470	1770	820	1238
F	1970	2210	1320	820	920	–	<u>120</u>	310	300	950	670	420	620	1920	970	1388
G	1850	2090	1200	700	800	420	–	190	<u>180</u>	830	550	300	500	1800	850	1268
H	1950	2190	1300	800	900	350	470	–	650	650	910	<u>400</u>	600	1900	950	1368
I	3010	3250	2360	1860	1960	1580	1700	<u>300</u>	–	650	910	1070	900	2200	1250	1668
J	<u>2360</u>	2600	1710	1940	1310	930	1050	1240	1230	–	260	810	1010	2310	1360	1778
K	1950	2190	1450	1680	1780	670	790	980	970	<u>1620</u>	–	550	750	2050	1100	1518
L	1550	1790	900	400	500	120	240	430	420	1070	790	–	<u>200</u>	1500	550	968
M	1200	1440	1100	550	650	320	440	630	620	1270	990	200	–	1600	<u>700</u>	1168
N	1140	1380	<u>1000</u>	1230	1330	1500	1620	1810	1800	2450	2170	1600	1800	–	140	1068
O	1000	1240	2400	2630	2730	2900	3020	3210	3200	3850	3570	3000	3200	<u>1400</u>	–	2468
P	740	500	2140	<u>230</u>	330	500	620	810	800	1450	1170	600	800	2030	630	–

Korak 2:

Popunjavanje Tablice 3: popunjavanje se na način da izaberemo početni vrh od kojega krećemo. U ovome slučaju je to točka A. Redom pišemo najkraće udaljenosti u tablicu (Dijkstra). Kada

ispunimo red A krećemo na red B i tako do kraja (posebno se mora paziti na jednosmjerne ulice).

Konačna ruta dobivena primjenom algoritma najbližeg susjeda je:


A – B – P – D – E – F – G – I – H – L – M – O – N – C – K – J – A

Ukupna duljina puta je iz vrha A kao početnog vrha je:

$$240 + 500 + 230 + 100 + 170 + 120 + 180 + 300 + 400 + 200 + 700 + 1400 + 1000 + 1170 + 1620 + 2360 = 9690$$

Korak 3:

Ucrtavamo rutu krenuvši od točke A na Slici 6 Rute se ucrtavaju na način da se uz pomoć Tablice 3, krenuvši od točke A te se u tablici gleda koji joj je najbliži vrh, a to je vrh B. Dalje krećemo od B i gledamo koji je njemu najbliži vrh, a to je P itd.



Slika 6. Rješenje TSP algoritmom umetanja najbližeg

Zbog svoje pohlepnosti algoritam najbližeg susjeda ne daje dobre rezultate u usporedbi s ostalim heurističkim algoritmima. Kompleksnost ovog algoritma je $O(n^2)$, što znači da broj računanja ne raste za više od n^2 . Druga moguća primjena ovog algoritma je razmatranje svih n vrhova kao početne točke, čime raste kompleksnost na $O(n^3)$, ali se općenito dobije bolje rješenje [4].

2.5. Pohlepna heuristika

Pohlepna heuristika (eng. greedy heuristics) za TSP promatra se potpuni graf s n vrhova i bridovima duljine c_{ij} između svaka dva para vrhova i i j . Ruta putujućeg trgovca u takvom je grafu Hamiltonov ciklus u kojem je stupanj svih vrhova 2. Izgradnja rute je u koracima. Dodaju se bridovi, krenuvši od najmanjeg, a pritom se izostavlja brid koji je već u ruti, a koji bi zatvorio Hamiltonov ciklus s manje od n vrhova ili bi stvorio vrh trećeg stupnja.

Pohlepna heuristika je kompleksnosti $O(n^2 \log n)$. Sporija je od algoritma najbližeg susjeda, ali s malo boljim rezultatima.

2.6. Algoritmi umetanja

Algoritmi umetanja (ili algoritmi ubacivanja) su heuristički algoritmi u kojima se iterativno u trenutnu rutu umeću preostali vrhovi, čime se trenutna ruta širi sve do konačno generirane rute putujućeg trgovca. Razlikuju se po odabranom pravilu umetanja, koje može biti slučajan vrh, ili pak najdaljeg, najbližeg ili najjeftinijeg vrha.

2.6.1. Algoritam umetanja najbližeg

Algoritam umetanja najbližeg (eng. nearest insertion algorithm, NI) je algoritam kod kojeg se u trenutnu rutu umeće jedan od preostalih vrhova koji je najbliži nekom već dodanom vrhu. Koraci su idući:

- | | |
|----------|--|
| Korak 1: | Odaberi vrh i za početni vrh 0. |
| Korak 2: | Pronađi vrh k takav da je c_{0k} minimalno (vrh najbliži početnom) i formiraj trenutnu rutu $(0,k,0)$. |
| Korak 3: | Nađi vrh h koji nije u trenutnoj ruti, a najbliži je nekom čvoru u trenutnoj ruti (korak odabira vrha). |
| Korak 4: | Nađi brid (i,j) u trenutnoj ruti koja minimizira $c_{ih} + c_{hj} - c_{ij}$. Umetni vrh h između i i j (korak umetanja vrha). |

Korak 5: Ponavlja korak 3 sve dok svi vrhovi nisu u ruti.

Kompleksnost ovog algoritma je $O(n^2)$, a u pravilu rezultira boljim rješenjem od algoritma najbližeg susjeda. Modifikacijom algoritma razmatranjem svih n vrhova kao početne točke raste kompleksnost na $O(n^3)$, ali se također općenito dobije bolje rješenje [4].

2.6.2. Algoritam umetanja najdaljeg

Algoritam umetanja najudaljenijeg (eng. farthest insertion algorithm, FI) je također algoritam umetanja, pri čemu se je kriterij za odabir vrha koji se dodaje trenutnoj ruti najveća udaljenost od nekog vrha trenutne rute.

Korak 1: Odaberi vrh i za početni vrh 0.

Korak 2: Pronađi vrh k takav da je c_{0k} maksimalno (vrh najdalji početnom) i formiraj trenutnu rutu $(0,k,0)$.

Korak 3: Nađi vrh h koji nije u trenutnoj ruti, a najudaljeniji je od nekog čvora u trenutnoj ruti (korak odabira vrha).

Korak 4: Nađi brid (i,j) u trenutnoj ruti koja minimizira $c_{ih}+c_{hj}-c_{ij}$. Umetni vrh h između i i j (korak umetanja vrha).

Korak 5: Ponavlja korak 3 sve dok svi vrhovi nisu u ruti.

Algoritam umetanja najudaljenijeg općenito je bolji algoritam od prethodno opisanih jer uključuje segmente ruta koje predstavljaju najudaljenije lokacije, dok algoritmi najbližeg susjeda, kao i algoritmi umetanja najbližeg zbog svoje karakteristike „pohlepnih“ algoritama u svojim koracima teže minimalnom povećanju troška, što na kraju ne rezultira maksimalnom uštedom. Kompleksnost ovog algoritma također je $O(n^2)$ [4].

2.6.3. Algoritam umetanja najjeftinijeg

Algoritam umetanja najjeftinijeg (eng. cheapest insertion algorithm) je algoritam sličan algoritmu umetanja najbližeg. Jedina razlika je što se za umetanje ne odabire vrh koji je najbliži nekom već dodanom, već onaj za koji je trošak umetanja minimalan.

Korak 1: Počni s vrhom 0 kao početkom rute.

Korak 2: Pronađi vrh k takav da je c_{0k} minimalno (vrh najbliži početnom) i formiraj trenutnu rutu $(0,k,0)$.

Korak 3: Nađi brid (i,j) u trenutnoj ruti takav da je $c_{ih}+c_{hj}-c_{ij}$ minimalno. Umetni vrh h između i i j (korak umetanja vrha).

Korak 4: Ponavljaj korak 3 sve dok svi vrhovi nisu u ruti.

Ovaj algoritam je vrlo sličan algoritmu umetanja najbližeg. Kompleksnost ovog algoritma je $O(n^2 \log n)$.

2.6.4. Algoritam ušteda

Algoritam ušteda (eng. savings problem), ponekad nazivan po autorima algoritam Clarke-a i Wright-a je heuristički algoritam generiranja rute putujućeg trgovca koji se temelji na općenitijem algoritmu ušteda za rješavanje problema usmjeravanja vozila. Inicijalno se generira n ruta od početnog vrha do svih vrhova, te se zatim dodaju prečaci na temelju maksimalnih ušteda. Algoritam se može opisati na sljedeći način:

Korak 1: Generiraj rute $(0,i,0)$ za $i=1,\dots,n$.

Korak 2: Izračunaj uštede $s_{ij}=c_{0i} + c_{0j} - c_{ij}$ za $i,j=1,\dots,n$, za svaki par i,j .

Korak 3: Poredaj uštede od najveće do najmanje.


Korak 4: Počevši od najveće uštede, formiraj veće rute dodavanjem rute (i,j) i brisanjem ruta $(i,0)$ i $(0,j)$, ukoliko je ta nova ruta moguća.

Korak 5: Ponavljaj korak 4 sve dok potpuna ruta nije formirana.

U Tablici 4 izračunate su uštede iz matrice udaljenosti vrhova [Tablica 3], a na Slici 8 su koraci algoritma te konačno rješenje. Algoritam ušteda generira bolja rješenja od prethodno opisanih heurističkih algoritama, a kompleksnost mu je $O(n^2 \log n)$, tj. kao i algoritma umetanja najjeftinijeg.

Korak 1:

Generiramo rute $(0,i,0)$ za $i=1,\dots,n$.



Slika 7. Rute 0,i,0

Korak 2:

Izračunamo uštede $s_{ij} = c_{0i} + c_{0j} - c_{ij}$ za $i, j = 1, \dots, n$, za svaki par i, j .

Npr. uštede za $i=B$,

$$s_{BC} = c_{AB} + c_{AC} - c_{BC} \quad (1)$$

$$s_{BD} = c_{AB} + c_{AD} - c_{BD} \quad (2)$$

$$s_{BE} = c_{AB} + c_{AE} - c_{BE} \quad (3)$$

$$s_{BF} = c_{AB} + c_{AF} - c_{BF} \quad (4)$$

$$s_{BG} = c_{AB} + c_{AG} - c_{BG} \quad (5)$$

$$s_{BH} = c_{AB} + c_{AH} - c_{BH} \quad (6)$$

itd.

Tablica 4. Izračunate uštede za svaki par i,j iz Tablice 2.

S_{ij}	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
B	-	-	-	240	240	240	240	240	240	240	240	240	240	0	190	308
C	-	172	-	1000	1000	1000	1000	1000	1000	1000	1000	1000	1000	-1130	410	-1130
D	-	-670	-670	-	1460	1460	1460	1460	1460	1460	1230	1460	1460	-670	870	-842
E	-	-990	160	890	-	1660	1660	1660	1660	1660	1660	1660	1660	-540	550	160
F	-	-970	180	910	910	-	2000	2000	2000	2000	2000	1680	1680	-520	570	180
G	-	-730	420	1150	1150	1700	-	2240	2240	2240	2240	1920	1920	-280	810	420
H	-	-640	510	1240	1240	1960	1960	-	1960	2610	2070	2010	2010	-190	900	510
I	-	-1710	730	170	170	720	720	2310	-	2600	2060	1330	1700	-500	590	200
J	-	-410	740	740	1470	2020	2020	2020	2020	-	3360	2240	2240	40	1130	740
K	-	-280	720	720	720	2000	2000	2000	2000	2000	-	2220	2220	20	1110	720
L	-	-450	700	1430	1430	1980	1980	1980	1980	1980	1980	-	2200	0	1090	700
M	-	100	700	1480	1480	1980	1980	1980	1980	1980	1980	2200	-	100	1140	700
N	-	-740	-100	-100	-100	-100	-100	-100	-100	-100	-100	-100	-100	-	800	-100
O	-	-460	-1360	-1360	-1360	-1360	-1360	-1360	-1360	-1360	-1360	-1360	-1360	-460	-	-1360
P	-	308	-1072	1068	1068	1068	1068	1068	1068	1068	1068	1068	1068	-1062	478	-

Korak 3:

Poredak uštede od najveće do najmanje [Tablica 5].

Tablica 5. Poredak ušteda od najveće do najmanje

3360	JK	1700	IM	1000	CJ	172	CB	-1360	OG
2610	HJ	1680	FL	1000	CK	170	ID	-1360	OH
2600	IJ	1680	FM	1000	CL	170	IE	-1360	OI
2310	IH	1660	EF	1000	CM	160	EC	-1360	OJ
2240	GH	1660	EG	910	FD	160	EP	-1360	OK
2240	GI	1660	EH	910	FE	100	MB	-1360	OL
2240	GJ	1660	EI	900	HO	100	MN	-1360	OM
2240	GK	1660	EJ	890	ED	40	JN	-1360	OP
2240	JL	1660	EK	870	DO	20	KN	-1710	IB
2240	JM	1660	EL	810	GO	0	BN		
2220	KL	1660	EM	800	NO	0	LN		
2220	KM	1480	MD	740	JC	-100	NC		
2200	LM	1480	ME	740	JD	-100	ND		
2200	ML	1470	JE	740	JP	-100	NE		
2070	HK	1460	DE	730	IC	-100	NF		
2060	IK	1460	DF	720	IF	-100	NG		
2020	JF	1460	DG	720	IG	-100	NH		
2020	JG	1460	DH	720	KC	-100	NI		
2020	JH	1460	DI	720	KD	-100	NJ		
2020	JI	1460	DJ	720	KE	-100	NK		
2010	HL	1460	DL	720	KP	-100	NL		
2010	HM	1460	DM	700	LC	-100	NM		
2000	FG	1430	LD	700	LP	-100	NP		
2000	FH	1430	LE	700	MC	-190	HN		
2000	FI	1330	IL	700	MP	-280	GN		
2000	FJ	1240	HD	590	IO	-280	KB		
2000	FK	1240	HE	570	FO	-410	JB		
2000	KF	1230	DK	550	EO	-450	LB		
2000	KG	1150	GD	510	HC	-460	OB		
2000	KH	1150	GE	510	HP	-460	ON		
2000	KI	1140	MO	478	PO	-500	IN		
2000	KJ	1130	JO	420	GC	-520	FN		
1980	LF	1110	KO	420	GP	-540	EN		
1980	LG	1090	LO	410	CO	-640	HB		
1980	LH	1068	PD	308	BP	-670	DB		
1980	LI	1068	PE	308	PB	-670	DC		
1980	LJ	1068	PF	240	BD	-670	DN		
1980	LK	1068	PG	240	BE	-730	GB		
1980	MF	1068	PH	240	BF	-740	NB		
1980	MG	1068	PI	240	BG	-842	DP		
1980	MH	1068	PJ	240	BH	-970	FB		

1980	MI	1068	PK	240	BI	-990	EB		
1980	MJ	1068	PL	240	BJ	-1062	PN		
1980	MK	1068	PM	240	BK	-1072	PC		
1960	HF	1000	CD	240	BL	-1130	CN		
1960	HG	1000	CE	240	BM	-1130	CP		
1960	HI	1000	CF	200	IP	-1360	OC		
1920	GL	1000	CG	190	BO	-1360	OD		
1920	GM	1000	CH	180	FC	-1360	OE		
1700	GF	1000	CI	180	FP	-1360	OF		

Korak 4:

Počevši od najveće uštede, formiraj veće rute dodavanjem rute (i,j) i brisanjem ruta $(i,0)$ i $(0,j)$, ukoliko je ta nova ruta moguća.

Najveće moguće uštede daju iduće rute: JK, HJ, IH, GI, KM, ML, FG, EF, DE, LO, PD, BP, NC, ON.


Korak 5:

Ponavljaj korak 4 sve dok potpuna ruta nije formirana.

Konačna ruta dobivena primjenom Clarke i Wright algoritma je:

$A - B - P - D - E - F - G - I - H - J - K - M - L - O - N - C - A$.

Ukupna duljina puta (iz matrice udaljenosti vrhova u Tablici 2) iz vrha A kao početnog vrha je:
 $240 + 500 + 230 + 100 + 170 + 120 + 180 + 300 + 650 + 260 + 750 + 200 + 550 + 1400 + 1000 + 808 = 7458$.



Slika 8. Rješenje TSP heurističkim algoritmom ušteta

Na Slici 8 je prikazano konačno rješenje dobiveno TSP heurističkim algoritmom ušteta.

2.6.5. *Aproksimacijski heuristički algoritam Christofidesa*

Algoritam Christofidesa je heuristički algoritam za rješavanje problema trgovačkog putnika u potpunom grafu s trokutastom nejednakosti (eng. triangle inequality). Trokutasta nejednakost vrlo je prirodna restrikcija u problemu putujućeg trgovca: za bilo koja tri vrha (i,j,k) vrijedi da je udaljenost $c_{ij} \leq c_{ik} + c_{jk}$. Algoritam se temelji na određivanju minimalnog razapinjujućeg stabla te formiranjem Eulerovog grafa sparivanjem (eng. matching) neparnih vrhova tog stabla minimalne ukupne težine. Ruta putujućeg trgovca dobije se transformiranjem Eulerovog ciklusa korištenjem prečaca. Zbog toga se ovaj algoritam naziva i heuristika savršenog sparivanja (eng. perfect matching). Algoritam je sljedeći:

- Korak 1: Pronađi minimalno razapinjajuće stablo T .
- Korak 2: Pronađi savršeno sparivanje M između nepranih vrhova stabla T .
- Korak 3: Pronađi Eulerov ciklus $M \cup T$.
- Korak 4: Transformiraj Eulerov ciklus u TSP rutu izbjegavajući već posjećene vrhove korištenjem prečaca.

Christofidesov algoritam rezultira najboljim rješenjima od svih heuristika generiranja rute, ali i potrebno vrijeme računanja je veće u usporedbi s ostalima, tj. kompleksnost algoritma je $O(n^3)$.


2.6.6. *Heuristički algoritmi i optimalna rješenja*

Konstruktivski heuristički algoritmi koji su prethodno opisani koriste se za generiranje rješenja problema putujućeg trgovca. Ovisno o algoritmu, heuristički algoritmi uglavnom daju rješenja koja su lošija od optimalnih za 10 % - 22 %:

- Algoritam najbližeg susjeda (cca. 22 % od optimalnog).
- Algoritam umetanja najudaljenijeg (cca. 14 % od optimalnog).
- Pohlepna heuristika (cca. 14 % od optimalnog).
- Algoritam ušteda (cca. 12 % od optimalnog).
- Christofidesov algoritam (cca. 10 % od optimalnog).

2.7. Usporedba rezultata dobivenih algoritmom najbližeg susjeda i algoritma ušteda

Algoritmom ušteda za generiranje rješenja problema putujućeg trgovca je dobiveno bolje rješenje od primjene algoritma najbližeg susjeda za 29,93 % [Slika 9]. To se moglo i za očekivati jer je kompleksnost algoritma ušteda $O(n^2 \log n)$, dok je kompleksnost algoritma najbližeg susjeda $O(n^2)$.



Slika 9. Usporedba rješenja

Heurističke metode su metode koje karakterizira sposobnost brzog dolaska do rješenja, no bez garancije da će se postići optimalno rješenje. Karakterizira ih sposobnost brzog dolaska do dobrog rješenja. Mnogi realni problemi su ili takve veličine ili zahtijevaju brzo rješenje da primjena egzaktnih metoda nije prihvatljiva te se koriste heurističke metode [4].

3. ODREĐIVANJE RUTA PRIKUPLJANJA OTPADA I USPOREDBA SA STVARNIM STANJEM


Primjenom algoritma ušteta (algoritam Clarke-a i Wright-a), heurističkog algoritama generiranja rute putujućeg trgovca, analizirane su tri rute za prikupljanje komunalnog otpada koje su u realnoj primjeni. Podaci točnih adresa ustupljene su od strane zagrebačkog komunalnog poduzeća Čistoća, a te iste ključne adrese korištene su za određivanje točaka i izračuna ruta s najvećim uštedama. U prvoj ruti G-356 (nazvanoj prema vozilu) u 3 sata i 34 minute prijeđena su 63 km [Slika 14], dok su u drugoj ruti nazvanoj G-474 (nazvanoj prema vozilu) u 3 sata i 43 minute prijeđena 47 km [Slika 18], a u trećoj ruti nazvanoj G-437 (nazvanoj prema vozilu) su u 4 sata i 20 minuta prijeđena 54 km [Slika 21]. Ukratko, u ovom poglavlju napravljena je analiza postojećeg stanja prikupljanja komunalnog otpada u Gradu Zagrebu te su primijenjeni modeli optimizacije TSP-a (algoritam ušteta), a dobivena rješenja su uspoređena s rutama zagrebačkog komunalnog poduzeća Čistoća.

3.1. Primjena algoritma ušteta za prvu rutu – podsljemenska zona


Vozilo za jednu od tri realne rute kojim prolaze vozila zagrebačke Čistoće kreću sa parkirališta na Radničkoj cesti. Vozila su opremljena GPS sustavom, tako da se u svakom trenutku može provjeriti njihova točna lokacija. Za prvu rutu (podsljemenska zona) ključne adrese po kojima se kreću vozila za prikupljanje komunalnog otpada su sljedeće:

- A) Radnička cesta 82, 10000 Zagreb
- B) Vidovčica I 22, 10000 Zagreb
- C) Šestinski vrh 63, 10000 Zagreb
- D) Vrhovec 225, 10000 Zagreb
- E) Vidikovac 41, 10000 Zagreb
- F) Kruškovac 12, 10000 Zagreb
- G) Podvinje ulica 16A, 10000 Zagreb
- H) Granice 18, 10000 Zagreb
- I) Ulica Črnomerec 140, 10000 Zagreb
- J) Bademovac ulica 37, 10000 Zagreb
- K) Bijenik mali 36, 10000 Zagreb
- L) Ulica Miroslava Vaupotića 67, 10000 Zagreb
- M) Matijevka 6, 10000 Zagreb

- N) Prevoj 54, 10000 Zagreb
- O) Lukšić 71, 10000 Zagreb
- P) Sveti Duh 3, 10000 Zagreb
- R) Ulica Vatroslava Jagića 31A, 10000 Zagreb
- S) Sajmišna cesta 12, 10000 Zagreb



Slika 10. Pozicije točaka za određivanje rute G-356 [6]



Slika 11. Pozicije točaka za određivanje povratne rute do odlagališta Jakuševac [6]

Korak 1:

Generiraj rute $(0,i,0)$ za $i=1,\dots,n$.

Tablica 6. Matrica udaljenosti vrhova, ruta G-356

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	R	S
A	–	10500	10000	9100	7900	8400	9100	8600	8800	9400	10100	10900	11200	10500	10500	7200	5700	6400
B	10000	–	700	1200	3100	4700	5400	6100	6400	6100	4300	3900	4300	4300	2300	4300	4900	14000
C	9300	700	–	700	2500	4100	5400	5200	5600	5200	5000	4600	5100	5000	3000	3700	4300	13400
D	8700	1200	700	–	1900	3500	4700	4600	5000	4600	5500	5100	5600	5400	3500	3100	3700	12800
E	7600	3100	2500	1900	–	2300	3600	3500	3800	3500	4700	5300	6000	4200	5400	1900	2500	11600
F	7300	4700	4100	3500	2300	–	1600	1700	2000	1700	2700	3500	4000	2400	4200	750	2500	11300
G	8600	5600	5300	4700	3600	1400	–	1700	2300	2300	1700	2700	3300	1400	3200	2000	3800	12600
H	8300	5600	5000	4400	3200	1500	1700	–	600	650	2200	2100	2600	1900	3600	1700	3500	12300
I	8600	6000	5400	4800	3600	1900	2300	600	–	1000	2800	2500	3000	2500	4100	2100	3800	12600
J	8100	5500	4900	4200	3100	950	1700	650	1000	–	2800	2500	2900	2500	4100	1500	3200	12100
K	9700	4400	4800	5400	4700	2500	1700	2200	2800	2800	–	1400	2200	700	2000	3100	4900	13700
L	10100	4100	4500	5000	5000	3300	2700	2100	2500	2500	1600	–	800	1800	1600	3500	5300	14100
M	10500	4500	4900	5400	5500	3800	3300	2600	3000	2900	2200	800	–	2300	2100	4000	5700	14600
N	9400	4600	5000	5400	4300	2200	1400	1900	2500	2500	700	1800	2300	–	2200	2900	4400	13400
O	10400	2400	2800	3300	5200	4000	3200	3600	4100	4100	2000	1600	2100	2200	–	4600	6400	14900
P	6600	4300	3700	3100	1900	800	2000	1900	2200	1900	3200	3700	4200	2900	4600	–	1800	10900
R	5300	5200	4600	4000	2800	2700	4000	3800	4100	3800	5100	5600	6000	4700	6600	2000	–	9600
S	6900	14000	13400	12800	11600	11800	13900	13600	14000	13600	15000	15400	15100	14700	14500	11000	9500	–

Korak 2:

Izračunaj uštede $s_{ij}=c_{0i} + c_{0j} - c_{ij}$ za $i,j=1,\dots,n$, za svaki par i,j .

Tablica 7. Izračunate uštede za svaki par i,j iz Tablice 6.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	R	S
A	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
B	-	-	19800	18400	15300	14200	14200	13000	12900	13800	16300	17500	17400	16700	18700	13400	11300	2900
C	-	19800	-	18400	15400	14300	13700	13400	13200	14200	15100	16300	16100	15500	17500	13500	11400	3000
D	-	18400	18400	-	15100	14000	13500	13100	12900	13900	13700	14900	14700	14200	16100	13200	11100	2700
E	-	15300	15400	15100	-	14000	13400	13000	12900	13800	13300	13500	13100	14200	13000	13200	11100	2700
F	-	14200	14300	14000	14000	-	15900	15300	15200	16100	15800	15800	15600	16500	14700	5850	11600	3500
G	-	14000	13800	13500	13400	16100	-	16000	15600	16200	17500	17300	17000	18200	16400	14300	11000	2900
H	-	13500	13600	13300	13300	15500	16000	-	16800	17350	16500	17400	17200	17200	15500	14100	10800	2700
I	-	13300	13400	13100	13100	15300	15600	16800	-	17200	16100	17200	17000	16800	15200	13900	10700	2600
J	-	14400	14500	14300	14200	16850	16800	17350	17200	-	16700	17800	17700	17400	15800	15100	11900	3700
K	-	16200	15300	13800	13300	16000	17500	16500	16100	16700	-	19600	19100	19900	18600	14200	10900	2800
L	-	17300	16400	15000	13800	16000	17300	17400	17200	17800	19400	-	21300	19600	19800	14600	11300	3900
M	-	17200	16300	14900	13600	15800	17000	17200	17000	17700	19100	21300	-	19400	19600	14400	11200	3000
N	-	16400	15500	14200	14100	16700	18200	17200	16800	17400	19900	19600	19400	-	18800	14800	11800	3500
O	-	18600	17700	16300	13200	14900	16400	15500	15200	15800	18600	19800	19600	18800	-	13100	9800	2000
P	-	13400	13500	13200	13200	14800	14300	13900	13800	14700	14100	14400	14200	14800	13100	-	11100	2700
R	-	11000	11100	10800	10800	11400	10800	10500	10400	11300	10700	11000	10900	11500	9600	10900	-	2500
S	-	2900	3000	2700	2700	3000	1600	1400	1200	2200	1500	1900	2500	2200	2400	2600	2600	-

Korak 3:

Poredaj uštede od najveće do najmanje.

Tablica 8. Poredak ušteda od najveće do najmanje za rutu G-356

21300	LM	17200	HN	15800	OJ	14200	KP	13100	IE	2900	SB
21300	ML	17200	IJ	15600	FM	14200	ND	13100	OP	2800	KS
19900	KN	17200	IL	15600	GI	14200	PM	13100	PO	2700	DS
19900	NK	17200	JI	15600	IG	14100	HP	13000	BH	2700	ES
19800	BC	17200	LI	15500	CN	14100	NE	13000	EH	2700	HS
19800	CB	17200	MB	15500	HF	14100	PK	13000	EO	2700	PS
19800	LO	17200	MH	15500	HO	14000	DF	12900	BI	2700	SD
19800	OL	17200	NH	15500	NC	14000	EF	12900	DI	2700	SE
19600	KL	17000	GM	15500	OH	14000	FD	12900	EI	2600	IS
19600	LN	17000	IM	15400	CE	14000	FE	11900	JR	2600	SP
19600	MO	17000	MG	15400	EC	14000	GB	11800	NR	2600	SR
19600	NL	17000	MH	15300	BE	13900	DJ	11600	FR	2500	RS
19600	OM	16850	JF	15300	EB	13900	IP	11500	RN	2500	SM
19400	LK	16800	HI	15300	FH	13900	PH	11400	CR	2400	SO
19400	MN	16800	IH	15300	IF	13800	BJ	11400	RF	2200	SJ
19400	NM	16800	IN	15300	KC	13800	EJ	11300	BR	2200	SN
19100	KM	16800	JG	15200	FI	13800	GC	11300	LR	2000	OS
19100	MK	16800	NI	15200	IO	13800	KP	11300	RJ	1900	SL
18800	NO	16700	BN	15200	OI	13800	LE	11200	MR	1600	SG
18800	ON	16700	JK	15100	CK	13800	PI	11100	DR	1500	SK
18700	BO	16700	KJ	15100	DE	13700	CG	11100	ER	1400	SH
18600	KO	16700	NF	15100	ED	13700	DK	11100	GR	1200	SI
18600	OA	16500	FN	15100	JP	13600	HC	11100	PR		
18600	OK	16500	HK	15000	LD	13600	ME	11000	RB		
18400	BD	16500	KH	14900	DL	13500	CP	11000	RC		
18400	CD	16400	GO	14900	MD	13500	DG	11000	RL		
18400	DB	16400	LC	14900	OF	13500	EL	10900	KR		
18400	DC	16400	NB	14800	NP	13500	GD	10900	RM		
18200	GN	16400	OG	14800	PF	13500	HB	10900	RP		
18200	NG	16300	BK	14800	PN	13500	PC	10800	HR		
17800	JL	16300	CL	14700	DM	13400	BP	10800	RD		
17800	LJ	16300	MC	14700	FO	13400	CH	10800	RE		
17700	JM	16300	OD	14700	PJ	13400	EG	10800	RG		
17700	MJ	16200	GJ	14600	LP	13400	GE	10700	IR		
17700	OC	16200	KB	14500	JC	13400	IC	10700	RK		
17500	BL	16100	CM	14400	JB	13400	PB	10500	RH		
17500	CO	16100	DO	14400	MP	13300	EK	10400	RI		
17500	GK	16100	FJ	14400	PL	13300	HD	9800	OR		
17500	KG	16100	GF	14300	CF	13300	HE	9600	RO		
17400	BM	16100	IK	14300	FC	13300	KE	5850	FP		
17400	HL	16100	KI	14300	GP	13300	IB	3900	LS		

17400	JN	16000	GH	14300	JD	13200	CI	3700	JS		
17400	LH	16000	HG	14300	PG	13200	DP	3500	NS		
17400	NJ	16000	KF	14200	BF	13200	EP	3500	FS		
17350	HJ	16000	LF	14200	BG	13200	OE	3000	CS		
17350	JH	15900	FG	14200	CJ	13200	PD	3000	MS		
17300	GL	15800	FK	14200	DN	13200	PE	3000	SC		
17300	LB	15800	FL	14200	EN	13100	DH	3000	SF		
17300	LG	15800	JO	14200	FB	13100	EM	2900	BS		
17200	HM	15800	MF	14200	JE	13100	ID	2900	GS		

Korak 4:

Počevši od najveće uštede, formiraj veće rute dodavanjem rute (i,j) i brisanjem ruta $(i,0)$ i $(0,j)$, ukoliko je ta nova ruta moguća.

Najveće moguće uštede daju iduće rute:

LM, NK, BC, KL, MO, CD, HN, JI, IH, OG, FJ, DE, GP, EF, PR, RS.

Korak 5:


Ponavljaj korak 4 sve dok potpuna ruta nije formirana.

Konačna ruta dobivena primjenom Clarke i Wright algoritma je:

A – B – C – D – E – F – J – I – H – N – K – L – M – O – G – P – R – S – A.

Ukupna duljina puta (matrica udaljenosti vrhova u Tablici 6) iz vrha A kao početnog vrha je:


10500 + 700 + 700 + 1900 + 2300 + 1700 + 1000 + 600 + 1900 + 700 + 1400 + 800 + 2100
3200 + 2000 + 1800 + 9600 + 6900 = 49800 m.



Slika 12. Koraci rješenja TSP heurističkim algoritmom ušteta za rutu G-356

Na Slici 10 i Slici 11 prikazane pozicije točaka za određivanje rute nazvane G-356.

Na Slici 12 su prikazani koraci rješenja za rutu G-365, a na Slici 13 je rješenje dobiveno TSP heurističkim algoritmom ušteta. Slika 14 prikazuje ruta koju vozila zagrebačke Čistoće koriste.




Slika 13. Rješenje TSP heurističkim algoritmom ušteta za rutu G-356

Redoslijed prikupljanja komunalnog otpada prema ustupljenim adresama, razlikuje se od redoslijeda rute koja je generirana primjenom algoritma ušteta. Redoslijed određenih točaka prema ruti u primjeni je:

A – C – B – D – E – F – G – H – I – J – K – L – M – N – O – P – R – S – A.

Duljina rute u primjeni iznosi:

$$10000 + 700 + 1200 + 1900 + 2300 + 1600 + 1700 + 600 + 1000 + 2800 + 1400 + 800 + 2300 + 2200 + 4600 + 1800 + 9600 + 6900 = 53400 \text{ m.}$$



Slika 14. Prva ruta (podsljemenska zona) u primjeni zagrebačke Čistoće

Zagrebačka Čistoća nema u primjeni računalni program koji bih optimizirao rute za prikupljanje komunalnog otpada, iako bi se zasigurno ostvarile ekonomske uštede optimizacijom takvog procesa.


3.2. Primjena algoritma ušteda za drugu rutu – podsljemenska zona

Za drugu analiziranu rutu (podsljemenska zona) nazvanu G-474, ključne adrese po kojima se kreću vozila za prikupljanje komunalnog otpada su sljedeće:


- A) Radnička cesta 82, 10000 Zagreb
- B) Bolmanska ulica 5, 10000 Zagreb
- C) Ulica dr. Milana Rojca 20, 10000 Zagreb
- D) Ilica 251, 10000 Zagreb
- E) Črnomerečki potok 4, 10000 Zagreb
- F) Ulica Belčina I 5, 10000 Zagreb
- G) Miheljšćak ulica 8, 10000 Zagreb
- H) Galovići 9, 10000 Zagreb
- I) Talani 45, 10000 Zagreb
- J) Mikulići 186, 10000 Zagreb

- K) Gornji Mikulić 73, 10000 Zagreb
- L) Gornji Mikulić 10, 10000 Zagreb
- M) Veliki potok 12, 10000 Zagreb
- N) Gornji Lukšić 4, 10000 Zagreb
- O) Himper ulica 5, 10000 Zagreb
- P) Bračunova ulica 20, 10000 Zagreb
- R) Ilica 282, 10000 Zagreb
- S) Sajmišna cesta 12, 10000 Zagreb

Na Slici 15 i Slici 16 prikazane su točke prema kojima je izračunat redoslijed rute primjenom algoritama Clarke i Wright-a, nazvane G-474. Usporedba rute u realnoj primjeni i dobivenog rezultata korištenjem TSP heurističkog algoritma ušteda je u nastavku.



Slika 15. Pozicije točaka za određivanje rute G-474 [6]



Slika 16. Pozicije točaka za određivanje povratne rute G-474 do odlagališta Jakuševac [6]

Korak 1:

Generiraj rute $(0, i, 0)$ za $i=1, \dots, n$.

U Tablici 9 je matrica udaljenosti između zadanih vrhova.

Tablica 9. Matrica udaljenosti vrhova, ruta G-474

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	R	S
A	–	7800	7600	7600	8900	10100	10500	11600	12000	11200	11400	11700	10900	10300	9800	7600	7800	6400
B	7400	–	500	600	1300	2500	2800	3600	4300	4300	4600	4000	4600	4200	5600	600	800	12500
C	7400	130	–	650	1300	2500	2900	3600	4300	4300	4600	4100	4700	4200	5600	650	850	12200
D	7600	1000	900	–	2900	3800	4100	4500	5200	5200	5500	5000	5600	5600	7200	750	240	12100
E	8400	1700	1600	1700	–	1900	2300	3000	3700	3700	4000	3400	4100	3900	5500	1700	1900	13600
F	9600	2900	2800	2900	1900	–	650	1300	2100	2100	2300	1800	2500	2200	3800	2900	3100	14800
G	10000	3300	3200	3300	2300	650	–	850	1500	1500	1800	1300	2000	2000	3600	3300	3500	15100
H	10700	4000	3900	4000	3000	1300	850	–	1000	1000	1300	750	1400	1900	3500	4000	4200	14700
I	11400	4700	4600	4700	3700	2100	1500	1000	–	900	1200	600	1300	1800	3400	4700	4900	16600
J	11400	4700	4600	4700	3700	2100	1500	1000	900	–	550	500	450	950	2500	4700	4900	16000
K	11700	5000	4900	5000	4000	2300	1800	1300	1200	550	–	550	650	1200	2700	5000	5200	16200
L	11300	4500	4300	4400	3400	1800	1300	750	600	500	550	–	800	1500	3000	4400	4700	16300
M	11200	5100	5000	5000	4100	2500	2000	1400	1300	450	650	800	–	700	2300	5000	5300	15700
N	10600	4600	4500	4600	3900	2200	2000	1900	1800	950	1200	1500	700	–	1700	4600	4800	15100
O	10000	6100	6000	6100	6200	3700	4000	3500	3300	2500	2700	3000	2200	1600	–	6100	6300	14600
P	7700	270	140	260	1500	2700	3000	3700	4500	4500	4800	4200	4800	4400	5900	–	750	12900
R	7300	800	650	750	2000	3200	3600	4300	5000	5000	5300	4700	5400	4900	6400	500	–	11800
S	6900	11800	11700	11600	13000	13800	14200	14900	16000	15500	15700	15700	15300	14700	14100	11300	11900	–

Korak 2:

Izračunaj uštede $s_{ij}=c_{0i} + c_{0j} - c_{ij}$ za $i,j=1,\dots,n$, za svaki par i,j [Tablica 10].

Tablica 10. Izračunate uštede za svaki par i, j iz Tablice 9.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	R	S
A	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–
B	–	–	14900	14800	15400	15400	15500	15800	15500	14700	14600	15500	14100	13900	12000	14800	14800	1700
C	–	15270	–	14550	15200	15200	15200	15600	15300	14500	15200	15200	13800	13700	11800	14550	14550	1800
D	–	14400	14300	–	13600	13900	14000	14700	14400	13600	13500	14300	12900	12300	10200	14450	15160	1900
E	–	15000	14900	14800	–	17100	17100	17500	17200	16400	16300	17200	15700	15300	13200	14800	14800	1700
F	–	15000	14900	14800	17100	–	19950	20400	20000	19200	19200	20000	18500	18200	16100	14800	14800	1700
G	–	15000	14900	14800	17100	19950	–	21250	21000	20200	20100	20900	19400	18800	16700	14800	14800	1800
H	–	15400	15300	15200	17500	20400	21250	–	22600	21800	21700	22550	21100	20000	17900	15200	15200	3300
I	–	15100	15000	14900	17200	20000	21000	22600	–	22300	22200	23100	21600	20500	18400	14900	14900	1800
J	–	14300	14200	14100	16400	19200	20200	21800	22300	–	22050	22400	21650	20550	18500	14100	14100	1600
K	–	14200	14100	14000	16300	19200	20100	21700	22200	22050	–	22550	21650	20500	18500	14000	14000	1600
L	–	15000	15000	14900	17200	20000	20900	22550	23100	22400	22550	–	21800	20500	18500	14900	14800	1800
M	–	13600	13500	13500	15700	18500	19400	21100	21600	21650	21650	21800	–	20500	18400	13500	13400	1600
N	–	13500	13400	13300	15300	18200	18800	20000	20500	20550	20500	20500	20500	–	18400	13300	13300	1600
O	–	11500	11400	11300	12500	16200	16300	17900	18500	18500	18500	18500	18500	18500	–	11300	11300	1600
P	–	15130	15060	14940	15000	15000	15100	15500	15100	14300	14200	15100	13700	13500	11500	–	14650	1100
R	–	14800	14750	14650	14700	14700	14700	15100	14800	14000	13900	14800	13300	13200	11200	14900	–	2400
S	–	2400	2300	2400	2300	2700	2700	3100	2400	2100	2100	2400	2000	2000	2100	2700	2300	–

Korak 3:

U Tablici 11 su poredane uštede od najveće do najmanje.

Tablica 11. Poredak ušteda od najveće do najmanje za rutu G-474

23100	IL	20100	GK	16300	KE	14900	IP	14000	KD	2300	SC
23100	LI	20100	KG	16300	OG	14900	IR	14000	KP	2300	SE
22600	HI	20000	FI	16200	OF	14900	LD	14000	KR	2300	SR
22600	IH	20000	FL	16100	FO	14900	LP	14000	RJ	2100	SJ
22550	HL	20000	HN	15800	BH	14900	RP	13900	BN	2100	SK
22550	KL	20000	IF	15700	EM	14800	BD	13900	DF	2100	SO
22550	LH	20000	LF	15700	ME	14800	BP	13900	RK	2000	SM
22550	LK	20000	NH	15600	CH	14800	BR	13800	CM	2000	SN
22400	JL	19950	FG	15500	BG	14800	ED	13700	CN	1900	DS
22400	LJ	19950	GF	15500	BI	14800	EP	13700	PM	1800	CS
22300	IJ	19400	GM	15500	BL	14800	ER	13600	DE	1800	GS
22300	JI	19400	MG	15500	PH	14800	FD	13600	DJ	1800	IS
22200	IK	19200	FJ	15400	BE	14800	FP	13600	MB	1800	LS
22200	KI	19200	FK	15400	BF	14800	FR	13500	DK	1700	BS
22050	JK	19200	JF	15400	HB	14800	GD	13500	MC	1700	ES
22050	KJ	19200	KF	15300	CI	14800	GP	13500	MD	1700	FS
21800	HJ	18800	GN	15300	EN	14800	GR	13500	MP	1600	JS
21800	JH	18800	NG	15300	HC	14800	LR	13500	NB	1600	KS
21800	LM	18500	FM	15300	NE	14800	RB	13500	PN	1600	MS
21800	ML	18500	JO	15270	CB	14800	RI	13400	MR	1600	NS
21700	HK	18500	KO	15200	CE	14800	RL	13400	NC	1600	OS
21700	KH	18500	LO	15200	CF	14750	RC	13300	ND	1100	PS
21650	JM	18500	MF	15200	CG	14700	BJ	13300	NP		
21650	KM	18500	OI	15200	CK	14700	DH	13300	NR		
21650	MJ	18500	OJ	15200	CL	14700	RE	13300	RM		
21650	MK	18500	OK	15200	HD	14700	RF	13200	EO		
21600	IM	18500	OL	15200	HP	14700	RG	13200	RN		
21600	MI	18500	OM	15200	HR	14650	PR	12900	DM		
21250	GH	18500	ON	15160	DR	14650	RD	12500	OE		
21250	HG	18400	IO	15130	PB	14600	BK	12300	DN		
21100	HM	18400	MO	15100	IB	14550	CD	12000	BO		
21100	MH	18400	NO	15100	PG	14550	CP	11800	CO		
21000	GI	18200	FN	15100	PI	14550	CR	11500	OB		
21000	IG	18200	NF	15100	PL	14500	CJ	11500	PO		
20900	GL	17900	HO	15100	RH	14450	DP	11400	OC		
20900	LG	17900	OH	15060	PC	14400	DB	11300	OD		
20550	JN	17500	EH	15000	EB	14400	DI	11300	OP		
20550	NJ	17500	HE	15000	FB	14300	DC	11300	OR		
20500	IN	17200	EI	15000	GB	14300	DL	11200	RO		
20500	KN	17200	EL	15000	IC	14300	JB	10200	DO		
20500	LN	17200	IE	15000	LB	14300	PJ	3300	HS		

20500	MN	17200	LE	15000	LC	14200	JC	3100	RS		
20500	NI	17100	EF	15000	PE	14200	KB	2700	SH		
20500	NK	17100	EG	15000	PF	14200	PK	2700	SF		
20500	NL	17100	FE	14940	PD	14100	BM	2700	SG		
20500	NM	17100	GE	14900	BC	14100	JD	2400	SP		
20400	FH	16700	GO	14900	EC	14100	JP	2400	SB		
20400	HF	16400	EJ	14900	FC	14100	JR	2400	SD		
20200	GJ	16400	JE	14900	GC	14100	KC	2400	SI		
20200	JG	16300	EK	14900	ID	14000	DG	2400	SL		

Korak 4:

Počevši od najveće uštede, formiraj veće rute dodavanjem rute (i,j) i brisanjem ruta $(i,0)$ i $(0,j)$, ukoliko je ta nova ruta moguća.

Najveće moguće uštede daju iduće rute:

IH, LK, JI, KJ, ML, HG, NM, GF, ON, FE, CB, DR, EC, RP, DB.

Korak 5:

Ponavljaj korak 4 sve dok potpuna ruta nije formirana.


Konačna ruta dobivena primjenom Clarke i Wright algoritma je:

A – O – N – M – L – K – J – I – H – G – F – E – C – B – D – R – P – S – A.

Ukupna duljina puta (matrica udaljenosti vrhova u Tablici 9) iz vrha A kao početnog vrha je:

$9800 + 1600 + 700 + 800 + 550 + 550 + 900 + 1000 + 850 + 650 + 1900 + 1600 + 130 + 600 + 240 + 500 + 12900 + 6900 = 42170 \text{ m.}$

Slika 17 prikazuje konačno rješenje izračunato TSP heurističkim algoritmom ušteta.




Slika 17. Rješenje TSP heurističkim algoritmom ušteda za rutu G-474

Na Slici 18 se nalazi ruta koju vozila zagrebačke Čistoće koriste, a redoslijed prikupljanja komunalnog otpada prema ustupljenim adresama, razlikuje se od redoslijeda rute koja je generirana primjenom algoritma ušteda. Redoslijed određenih točaka prema ruti u primjeni je:

A – B – C – D – E – F – G – H – I – J – K – L – M – N – O – P – R – S – A.

Duljina rute u primjeni iznosi:

$$7800 + 500 + 650 + 2900 + 1900 + 650 + 850 + 1000 + 900 + 550 + 550 + 800 + 700 + 1700 + 6100 + 750 + 11800 + 6900 = 47000 \text{ m.}$$




Slika 18. Druga ruta (podsljemenska zona) u primjeni zagrebačke Čistoće G-474

3.3. Primjena algoritma ušteda za treću rutu

Za treću analiziranu rutu nazvanu G-437, ključne adrese po kojima se kreću vozila za prikupljanje komunalnog otpada su sljedeće:

- A) Radnička cesta 82, 10000 Zagreb
- B) Ulica Matije Ivanića 18A, 10000 Zagreb
- C) Duvanjska ulica 12, 10000 Zagreb
- D) Ulica Petra Zrinskog 21, 10000 Zagreb
- E) Kustošijanska ulica 322, 10000 Zagreb
- F) Kustošijanska ulica 268, 10000 Zagreb
- G) Kustošijanska ulica 48, 10000 Zagreb
- H) Ulica Svetog Nikole Tavelića 12, 10000 Zagreb
- I) Trščanska ulica 18, 10000 Zagreb

- J) Ulica Frana Mažuranića 4, 10000 Zagreb
- K) Ilica 494, 10000 Zagreb
- L) Ulica Ante Mike Tripala 2, 10000 Zagreb
- M) Ulica Vlade Gotovca 21, 10000 Zagreb
- N) Ulica Miroslava Milića 6, 10000 Zagreb
- O) Zagrebačka cesta 233, 10000 Zagreb
- P) Sajmišna cesta 12, 10000 Zagreb



Slika 19. Pozicije točaka za određivanje rute G-437 [6]

Na Slici 19 prikazane su točke prema kojima je izračunat redoslijed rute nazvane G-437.

Korak 1:

Generiraj rute $(0, i, 0)$ za $i=1, \dots, n$.

U Tablici 12 je prikazana matrica udaljenosti vrhova za rutu nazvanu G-437.

Tablica 12. Matrica udaljenosti vrhova, ruta G-437

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	–	8900	9000	9000	11300	10900	9100	9100	9100	9500	10500	8800	8600	8600	8300	6400
B	7700	–	190	350	3000	2500	750	500	450	1100	2100	3100	3500	3300	3000	11800
C	7800	190	–	450	3000	2500	700	500	550	1100	2100	3300	3700	3500	2800	12900
D	7900	190	170	–	2800	2400	600	350	550	900	2000	2700	3100	3000	2600	13000
E	10200	2900	3100	3500	–	450	2200	2700	3600	3300	4300	5600	6000	5900	5500	15300
F	9800	2500	2700	3000	450	–	1800	2300	3100	2800	3800	5200	5600	5400	5100	14900
G	8000	650	850	1200	2200	1800	–	500	1300	1100	2000	3400	3800	3600	2800	13100
H	8100	400	400	650	3000	2600	800	–	750	550	2100	2400	2800	2600	2300	13200
I	8300	450	450	750	3100	2600	850	650	–	500	2100	2300	2700	2600	2200	13300
J	7900	550	750	1100	3400	3000	1200	400	1200	–	1700	2400	2800	2700	2300	13000
K	11500	2000	2200	2600	4700	4000	2700	1900	2700	1600	–	2200	2500	2600	2100	14400
L	9700	2800	2900	2900	5800	5300	3500	2800	3000	2500	3500	–	450	260	260	12500
M	10100	3300	3400	3400	6200	5800	4000	3200	3500	3000	3100	450	–	230	750	13000
N	9000	3100	3200	3200	6000	5600	3800	3000	3300	2800	3800	260	230	–	500	12800
O	9400	2700	2800	2800	5700	5200	3400	2700	2900	2400	3400	650	500	450	–	12300
P	6900	12700	12800	12800	15000	14500	12400	13100	12900	13700	14100	13000	12800	12800	12500	–

Korak 2:

Izračunaj uštede $s_{ij}=c_{0i} + c_{0j} - c_{ij}$ za $i,j=1,\dots,n$, za svaki par i,j .

Tablica 13. Izračunate uštede za svaki par i,j iz Tablice 12.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P
A	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–	–
B	–	–	17710	17550	17200	17300	17250	17500	17300	17300	17300	14600	14000	14200	14200	3500
C	–	17710	–	17550	17300	17400	17400	17600	17550	17400	17400	14500	13900	14100	14500	2500
D	–	17710	17830	–	17500	17500	17500	17750	17550	17600	17500	15100	14500	14600	14700	2400
E	–	17300	17200	16800	–	21750	18200	17700	16800	17500	17500	14500	13900	14000	14100	2400
F	–	17300	17200	16900	21750	–	18200	19350	16900	17600	17600	14500	13900	14100	14100	2400
G	–	17350	17250	16900	18200	18200	–	17700	16900	17500	17600	14500	13900	14100	14600	2400
H	–	17600	17700	17450	17400	17400	17400	–	17450	18050	17500	15500	14900	15100	15100	2300
I	–	17550	17650	17350	17300	17400	17350	17550	–	18100	17500	15600	15000	15100	15200	2200
J	–	17850	17750	17400	17400	17400	17400	18200	17400	–	18300	15900	15300	15400	15500	2900
K	–	17400	17300	16900	17100	17400	16900	17700	16900	18400	–	17100	16600	16500	16700	2500
L	–	14900	14900	14900	14300	14400	14400	15100	14900	15800	15800	–	16950	17140	16840	2700
M	–	14200	14200	14200	13700	13700	13700	14500	14200	15100	16000	16950	–	16970	16150	2000
N	–	14400	14400	14400	13900	13900	13900	14700	14400	15300	15300	17140	16970	–	16400	2200
O	–	14500	14500	14500	13900	14000	14000	14700	14500	15400	15400	16450	16400	16450	–	2400
P	–	2600	2600	2600	2700	2800	3100	2400	2600	2200	2800	2200	2200	2200	2200	–

Korak 3:

Poredak ušteda od najveće do najmanje nalaze se u Tablici 14.

Tablica 14. Poredak ušteda od najveće do najmanje za rutu G-437

21750	EF	17400	CJ	16500	KN	14400	LG	2400	PH
21750	FE	17400	CK	16450	OL	14400	NB	2300	HP
19350	FH	17400	HE	16450	ON	14400	NC	2200	IP
18400	KJ	17400	HF	16400	NO	14400	ND	2200	NP
18300	JK	17400	HG	16400	OM	14400	NI	2200	PJ
18200	EG	17400	IF	16150	MO	14300	LE	2200	PL
18200	FG	17400	JD	16000	MK	14200	BN	2200	PM
18200	GE	17400	JE	15900	JL	14200	BO	2200	PN
18200	GF	17400	JF	15800	LJ	14200	MB	2200	PO
18200	JH	17400	JG	15800	LK	14200	MC	2000	MP
18100	IJ	17400	JI	15600	IL	14200	MD		
18050	HJ	17400	KB	15500	HL	14200	MI		
17850	JB	17400	KF	15500	JO	14100	CN		
17830	DC	17350	GB	15400	JN	14100	EO		
17750	DH	17350	ID	15400	OJ	14100	FN		
17750	JC	17350	IG	15400	OK	14100	FO		
17710	BC	17300	BF	15300	JM	14100	GN		
17710	CB	17300	BI	15300	NJ	14000	BM		
17710	DB	17300	BJ	15300	NK	14000	EN		
17700	EH	17300	BK	15200	IO	14000	OF		
17700	GH	17300	CE	15100	DL	14000	OG		
17700	HC	17300	EB	15100	HN	13900	CM		
17700	KH	17300	FB	15100	HO	13900	EM		
17650	IC	17300	IE	15100	IN	13900	FM		
17600	CH	17300	KC	15100	LH	13900	GM		
17600	DJ	17250	BG	15100	MJ	13900	NE		
17600	FJ	17250	GC	15000	IM	13900	NF		
17600	FK	17200	BE	14900	HM	13900	NG		
17600	GK	17200	EC	14900	LB	13900	OE		
17600	HB	17200	FC	14900	LC	13700	ME		
17550	BD	17140	LN	14900	LD	13700	MF		
17550	CD	17140	NL	14900	LI	13700	MG		
17550	CI	17100	KE	14700	DO	3500	BP		
17550	DI	17100	KL	14700	NH	3100	PG		
17550	IB	16970	NM	14700	OH	2900	JP		
17550	IH	16970	MN	14600	BL	2800	PF		
17500	BH	16950	LM	14600	DN	2800	PK		
17500	DE	16950	ML	14600	GO	2700	LP		
17500	DF	16900	FD	14500	CL	2700	PE		
17500	DG	16900	FI	14500	CO	2600	PB		
17500	DK	16900	GD	14500	DM	2600	PC		

17500	EJ	16900	GI	14500	EL	2600	PD		
17500	EK	16900	KD	14500	FL	2600	PI		
17500	GJ	16900	KG	14500	GL	2500	CP		
17500	HK	16900	KI	14500	MH	2500	KP		
17500	IK	16840	LO	14500	OB	2400	DP		
17450	HD	16800	ED	14500	OC	2400	EP		
17450	HI	16800	EI	14500	OD	2400	FP		
17400	CF	16700	KO	14500	OI	2400	GP		
17400	CG	16600	KM	14400	LF	2400	OP		

Korak 4:

Počevši od najveće uštede, formiraj veće rute dodavanjem rute (i,j) i brisanjem ruta $(i,0)$ i $(0,j)$, ukoliko je ta nova ruta moguća.

Najveće moguće uštede daju iduće rute:

EF, JK, FG, IJ, CD, HI, LN, KL, MN.

Korak 5:


Ponavljaj korak 4 sve dok potpuna ruta nije formirana.

Konačna ruta dobivena primjenom Clarke i Wright algoritma je:

A – B – C – D – E – F – G – H – I – J – K – L – M – N – O – P – A.

Ukupna duljina puta (matrica udaljenosti vrhova u Tablici 12) iz vrha A kao početnog vrha je:


$8900 + 190 + 450 + 2800 + 450 + 1800 + 500 + 750 + 500 + 1700 + 2200 + 450 + 230 + 500 + 12300 + 6900 = 40620 \text{ m.}$



Slika 20. Rješenje TSP heurističkim algoritmom ušteda za rutu G-437

Na Slici 20 se nalazi rješenje TSP heurističkim algoritmom ušteda, a na Slici 21 se nalazi ruta koju koriste u zagrebačkoj Čistoći, a ruta prikupljanja komunalnog otpada prema ustupljenim adresama se ne razlikuje se od rute koja je generirana primjenom TSP heurističkim algoritmom ušteda.

To bi trebalo značiti da bi i ruta u primjeni trebala iznositi 40620 m, iako se na Slici 21 vidi da ona iznosi 54000 m. Jedan od razloga te razlike može biti gustoća cestovnog prometa koja zavisi o vremenskom razdoblju u kojemu se odvija prikupljanje otpada. Iz tog razloga mogu se koristiti dulje rute kako bi se došlo do odredišta prikupljanja i izbjeglo prometnu gužvu.




Slika 21. Treća ruta u primjeni zagrebačke Čistoće (G-437)

Dobivena rješenja duljine rute se razlikuju, iako je redoslijed točaka za dobivenu rutu i rutu u primjeni jednak. Prijevoz komunalnog otpada u gradskim središtima je složen problem koji ima mnogo ograničenja. Odabir optimalne rute ne znači nužno maksimalne financijske i vremenske uštede. Mnogi faktori utječu na odabir rute, kao što su pravci prometa, širina ceste, broj obrata itd. Pri izradi ruta mora se voditi računa i o tome da svako vozilo za prikupljanje otpada ima ograničen kapacitet te količina otpada varira. Razlog tomu mogu biti brojni, jedan od njih može biti godišnje doba. Npr. u ljetnim mjesecima količina otpada može biti znatno manja, a kapacitet vozila neiskorišten. Kod veće količine otpada predviđena ruta se mora prekinuti, isprazniti vozilo te nastaviti gdje se stalo. Postoji opcija i da zaposlenici pozovu drugi tim te da oni nastave prikupljati otpad za prethodno određenu rutu. Svi navedeni parametri se moraju uzeti u obzir kod izračuna troškova.

3.4. Analiza dobivenih rješenja

U analizi su uspoređene sve tri rute u primjeni zagrebačkog komunalnog poduzeća Čistoća i rješenja dobivena TSP heurističkim algoritmom ušteda.



Slika 22. Usporedba rezultata tri analizirane rute

Primjenom TSP heurističkog algoritma ušteda (algoritam Clarke-a i Wright-a) za prvu rutu, rezultat je 7,23 % bolja ruta od rute zagrebačke Čistoće. Za drugu rutu rezultat je 11,45 % bolja ruta od rute u primjeni. Treća ruta u primjeni jednaka kao i ruta dobivena primjenom TSP heurističkog algoritma ušteda [Slika 22].

4. PRIJEDLOG UNAPREĐENJA KORIŠTENJEM SOFTVERSKOG RJEŠENJA UPRAVLJANJA TRANSPORTOM

Primjeri specifičnih digitalnih tehnologija koje se trenutno koriste, i za koje se očekuje da će u budućnosti imati veliki utjecaj na učinkovitost industrije otpada uključuju robotiku, internet, računalstvo u oblaku, umjetnu inteligenciju i analitiku podataka.

Digitalne tehnologije sve se više primjenjuju u gotovo svim područjima prikupljanja otpada. Određeni aspekti prikupljanja promijenjeni su napretkom u digitalizaciji, posebice logistika - proces organiziranja, raspoređivanja i slanja zadataka, osoblja i vozila. Digitalni alati nude potencijal za poboljšanje procesa pohranjivanjem, obradom, analizom i optimizacijom potrebnih informacija. Informacije nastale tijekom procesa prikupljanja, npr. o napredovanju zadatka ili incidentima, može se pratiti u stvarnom vremenu.

Kako se prikupljaju veće količine informacija, tako raste i složenost. U takvim slučajevima optimizacijski algoritmi pomažu pronaći najprikladnije opcije za raspodjelu resursa kao što su radna snaga ili vozila. Važne tehnologije uključuju telematiku, uključujući sustave rutiranja, softver za navigaciju i praćenje vozila, sustave za planiranje resursa poduzeća (ERP) i slično. Rezultat su poboljšanja koja su najočitija u povećanoj učinkovitosti. Drugi primjer su takozvane „internet stvari“ koje uključuju aplikacije kao što su pametni spremnici za odlaganje otpada i robotika za poluautonoma vozila za prikupljanje otpada.

Značajna poboljšanja se u budućnosti mogu ostvariti kod procesa prikupljanja otpada, kao i kod usklađivanja procesa s potrebama kružnog gospodarstva. Na primjer, potrebno je biti u mogućnosti fleksibilnije odgovoriti na promjenjive obrasce te olakšati provedbu usluga na zahtjev i prilagođenih usluga [7].

Drugi dio prikupljanja otpada je proces dokumentacije, komunikacije i naplate. Tekući prijelaz s papirnatih administrativnih sustava na digitalne sustave, kao što se može vidjeti u drugim industrijama, može dodatno povećati učinkovitost procesa i protoka informacija. Tehnologije uključuju digitalne identifikacijske oznake za kante i spremnike za otpad, digitalnu obradu narudžbi, digitalnu naplatu i plaćanje, digitalna korisnička sučelja za komunikaciju s potrošačima te povezivanje javnih pružatelja usluga prikupljanja otpada s drugim relevantnim državnim bazama podataka.

Ako se te digitalne tehnologije primjenjuju u procesima dokumentacije, mogu se koristiti za prikupljanje podataka o komunalnom otpadu. Vrijedne informacije analitikom podataka mogu podržati kružno gospodarstvo kroz bolje razumijevanje prostornih i vremenskih obrazaca stvaranja otpada. Osim toga, mogućnost prikupljanja mnogih pojedinačnih podatkovnih informacija umjesto samih izvještaja o kumulativnim vrijednostima može dati lokalnim vlastima dodatne uvide u stvarno stanje sustava [7].


4.1. Softversko rješenje Waste Hero

Na tržištu postoje mnogobrojna softverska rješenja za optimizaciju ruta prikupljanja otpada. Jedan od njih je Waste Hero - Sustav upravljanja prijevozom. Waste Hero definiranja područja za skupljanje komunalnog otpada te koristi standardne geografske podatke te može podržavati lokalne vlasti i privatne prijevoznike s digitalnim operativnim sustavima za gospodarenje komunalnim otpadom.

Upravljanje prikupljanjem otpada za desetke tisuća građana i korisnika komunalnih usluga uključuje složenu infrastrukturu, vozne parkove, rute i podatke o korisnicima. Za lokalne vlasti i privatne prijevoznike ove su informacije obično povezane u proračunske tablice te ih je teško pratiti.

Rutama se često upravlja ručno s ograničenim uvidom u podatke, što dovodi do neučinkovitih rasporeda prikupljanja i visokih troškova. Lokalne vlasti i privatni prijevoznici svjesni su toga da bih mogli funkcionirati održivije i učinkovitije, ali zastarjeli sustavi ne mogu se integrirati s novim tehnologijama - kao što su senzori razine punjenja i senzori težine. Maksimalno optimiziranje performansi je jedna od ključnih ciljeva koji se mogu postići korištenjem softvera.

Pomoću softvera moguće je smanjiti troškove i napraviti uštede radnih sati administrativnog opterećenja svaki tjedan pojednostavljujućim operacija prikupljanja otpada pomoću sustava upravljanja prijevozom, dizajniranog posebno za industriju otpada [8].




Slika 23. Pozadina softvera Waste Hero [8]

Primjena softvera Waste Hero će se u nastavku detaljnije opisati, kako bi se pojasnila primjena jednog takvog rješenja.

4.1.1. Automatizirano planiranje resursa i rute

Automatizirano planiranje ruta je manje zahtjevan te učinkovitiji proces od vremenski zahtjevnih Excel proračunskih tablica.

Nakon što se podaci o spremnicima za otpad unesu u sustav, postavi se kapacitet flote i standardna ograničenja, a zatim sustav generira optimizirane rute prikupljanja otpada u samo nekoliko sekundi. Upravitelji sustava i dalje imaju potpunu kontrolu, uz samostalno uređivanje rute pritiskom na gumb.




Slika 24. Automatizirano planiranje resursa i rute [8]

Na Slici 24 su prikazani operativni podaci o trenutnom stanju na terenu te lokacije na kojima se odvija prikupljanja komunalnog otpada.

4.1.2. Mobilna tehnologija u kabini vozila

Rute se automatski šalju određenom vozilu i vozaču putem mobilnog zaslona u kabini vozila, pružajući vozačima vizualne i verbalne upute od skretanja do skretanja za jednostavno obavljanje svakodnevnog posla.

Ako vozači naiđu na probleme u ruti, mogu jednostavno javiti problem osoblju pozadinskog ureda te zatražiti savjet i pomoć.




Slika 25. Mobilna tehnologija u kabini vozila [8]

Na Slici 25 prikazane identifikacijski brojevi kontejnera te trenutačna težina kontejnera (pomoću ugrađenih čipova) koje je potrebno isprazniti. U slučaju da kontejner za npr. staklo u toj ulici nije napunjen, ruta se generira na način da se ta ulica zaobiđe te se time skraćuje ruta tj. vrijeme potrebno za prikupljanje otpada.

4.1.3. Praćenje prikupljanja otpada uživo

Pomoću softvera moguće je praćenje operacije na terenu uživo za svako vozilo i vozača na terenu. Prenose se i informacije o lokaciji, točkama zaustavljanja, postavljenim upitima i nadolazećim točkama zaustavljanja. Moguća je i usporedba planirane te stvarne izvedbe kako ruta napreduje.

Svi prikupljeni podaci se prate uživo, uključujući preostale rute, preostalu udaljenost, preostale radne sate i preostale kontejnere. Na taj način upravitelj sustava može nadgledati cijeli proces te po potrebi javiti neki propust ili nedostatak.




Slika 26. Prikaz praćenja lokacija uživo [8]

Na Slici 26 prikazane su lokacije koje su posjećene i preostale lokacije. Točka 34 prikazuje trenutnu lokaciju vozila, a ako se vozilo zadržalo na jednoj lokaciji duže vremena od uobičajenog, softver to evidentira.

4.1.4. Upravljanje na trenutne događaje uređivanjem rute

Jedna od prednosti korištenja softvera je reagiranje na operacije uživo. Na taj način se pritužbe korisnika mogu odmah riješiti pomoću uređivanja rute uživo. Upravitelji sustava mogu sami mijenjati postojeće rute kako bi se obišli dodatni kontejneri ili izbrisali nepotrebna zaustavljanja kod kontejnera. To mogu riješiti sami, bez potrebe da kontaktiraju vozača.

Na Slici 27 su prikazane imena vozača te ruta koje trenutačno obilaze. Pomoću upravitelja sustava koji nadgleda sve operacije, vozača se rasterećuje dodatnih aktivnosti, kao i ostalih komunalnih zaposlenika tj. posao im se olakšava time što se neće morati zaustavljati na nepotrebnim lokacijama.



Slika 27. Evidencija vozača i ruta koje se odvijaju uživo [8]


S dostupnim informatičkim alatima kao što su praćenje uživo, upraviteljima sustava omogućava uređivanje ruta te potpunu vidljivost i kontrolu nad dnevnim operacijama.

4.1.5. Analiziranje i usporedba operativne izvedbe

Upotreba softvera omogućuje usporedbu planirane te stvarnu izvedbu (na temelju metrike), uključujući:

- Iskorištenost voznog parka.
- Trajanje rute.
- Prijedenu udaljenost.
- Broj prikupljanja.
- Broj istovara.

Upravitelji sustava isto tako mogu vidjeti i dijeliti detaljna izvješća dovršenih ruta, kao i popis ispražnjenih kontejnera. Kako bi se u budućnosti lakše donosile odluke, moguće je analizirati i izmjeriti važne ključne pokazatelje performansi. Takav način rada omogućuje da se na temelju provjerenih podataka optimiziraju operacije prikupljanja komunalnog otpada.




	Estimated	Real	Comparison
Start from	11:09 AM	11:12 AM	+ 3min
Finished at	12:45 PM	12:50 PM	+ 5min
Distance	10 km	10 km	-
Duration	03:02	03:12	+ 8min
Collections	56	54	- 2
Offload	2 times	3 times	+ 1
Fuel consumption	5 L	3.4 L	- 1.6 L
Weight	92 kg	92.5 kg	+ 0.5 kg
Volume	10 L	10.8 L	+ 0.8 L
Avg. time between collection	10 L	10 L	-
Avg. distance between collection	10 L	10 L	-
CO2 emission	-	-	-

Slika 28. Usporedba izmjerenih podataka realne i planirane rute [8]

Na Slici 28 je prikazana usporedba rute u realnoj primjeni te planirane rute. Uspoređeni podaci se prema prikazanom razlikuju, ali ne u velikoj mjeri.

4.1.6. Optimiziranje dnevnih operacija s opsežnim uvidima

Optimizacija operacija moguća je uz podatke o izvedbi rute. Upravitelji sustava mogu vidjeti ponašanje vozača, a kada integriraju podatke iz sustava vozila, imaju uvid u sve odrađene rute voznog parka [Slika 29].



Slika 29. Geografska područja odrađenih ruta [8]

4.2. Troškovi prikupljanja komunalnog otpada u gradu Zagrebu

U nastavku će se prikazati odabrano softversko rješenje za prikupljanje otpada, popraćeno prikazom troškova prikupljanja otpada i s time povezanim emisijama stakleničkih plinova, kako bi se dao prilog opravdanju investicija u takve softvere. Dodatno je za ilustraciju dan primjer kako to radi glavni grad Slovenije, Ljubljana.

Temeljem čl. 28. st.1. Zakona o javnoj nabavi (NN 120/2016) i čl.2. Pravilnika o planu nabave, registru ugovora, ... (NN 101/2017) javni nadzornik Zagrebački holding d.o.o. donosi Plan nabave za 2022. godinu

ZAGREBAČKI HOLDING d.o.o. PLAN NABAVE ZA 2022. godinu

Redni broj	Evidencijski broj nabave	Predmet nabave	Brojčana oznaka predmeta nabave iz Jedinstvenog rječnika javne nabave (CPV)	Procijenjena vrijednost nabave	Vrsta postupka (uključujući i jednostavnu nabavu)	Posebni režim nabave	Predmet podijeljen na grupe	Sklopa li se ugovor ili okvirni sporazum	Financira li se ugovor ili okvirni sporazum iz fondova EU?	Planirani početak postupka	Planirano trajanje ugovora ili okvirnog sporazuma	Napomena
1	2022-122	TRIFESIT, SUPSTRATI I KORA DRVETA ZA UZGOJ BILJA	09112200-9	2.800.000,00	Otvoreni postupak		DA	Okvirni sporazum	NE	1. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
2	2022-35	OPSKRBA PLINOM	09123000-7	17.000.000,00	Otvoreni postupak		NE	Okvirni sporazum	NE	1. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
3	2022-45	HUMUS	14212410-7	2.000.000,00	Otvoreni postupak		NE	Okvirni sporazum	NE	1. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
4	2022-140	BOL ZA POSIPANJE CESTA	34927100-2	23.635.000,00	Otvoreni postupak		DA	Okvirni sporazum	NE	2. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
5	2022-125	BITUMENSKJE EMULZIJE	44113610-4	1.700.000,00	Otvoreni postupak		NE	Okvirni sporazum	NE	3. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
6	2022-29	MISO I MIESNI PROIZVODI	15100000-9	4.550.000,00	Otvoreni postupak		DA	Okvirni sporazum	NE	2. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
7	2022-149	PAPIRNA KONFEKCIJA ZA Higijensku potrebu	33760000-5	1.691.000,00	Otvoreni postupak		NE	Okvirni sporazum	NE	1. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
8	2022-3	NAFTNI DERIVATI	09130000-9	88.014.000,00	Otvoreni postupak		DA	Okvirni sporazum	NE	2. kvartal	2 godine	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu
9	2022-36	LOŽIVO ULJE	09130000-9	7.200.000,00	Otvoreni postupak		NE	Okvirni sporazum	NE	1. kvartal	1 godina	Postupak nabave provodi Grad Zagreb kao središnje tijelo za nabavu

1/29

Slika 30. Plan nabave zagrebačkog Holdinga za 2022. godinu [9]

U Tablici 15 prikazani su svi troškovi voznog parka iz Plana nabave za 2022. godinu. Predmet nabave „Naftni derivati“ iznosi 88.014.000,00 HRK, dok predmet nabave „Opskrba električnom energijom“ iznosi 60.703.332,00 HRK. Značajna sredstva se troše na prikupljanje i prijevoz otpada, a kupnjom novijih energetski učinkovitijih teretnih vozila, zasigurno bi se ostvarile značajne uštede kod troškova za gorivo, kao i na održavanje vozila.

Tablica 15. Predviđeni troškovi voznog parka zagrebačkog Holdinga (podružnica Čistoća) prema Planu nabave za 2022. godinu [9]

Predmet nabave	Procijenjena vrijednost nabave	Planirano trajanje ugovora ili okvirnog sporazuma
Naftni derivati	88.014.000,00	2 godine
Najam osobnih i dostavnih vozila	14.724.000,00	2 godine
Najam dostavnih i teretnih vozila	3.747.000,00	2 godine
Povremeni najam vozila za prikupljanje otpada	12.000.000,00	2 godine
Rezervni dijelovi, popravak i servis mjenjača teretnih vozila marke ZF	1.800.000,00	2 godine
Rezervni dijelovi i servis za vozila marke Mercedes – teretni program	10.200.000,00	2 godine
Rezervni dijelovi i servis za vozila marke MAN – teretni program	6.100.000,00	2 godine
Rezervni dijelovi i servis za vozila marke Iveco	7.560.000,00	2 godine
Rezervni dijelovi, popravak i servis nadogradnji specijalnih komunalnih i teretnih vozila marke Faun, Farid i Smekon, Zepro, Kobit, Palfinger i Lavacassonetti	6.900.000,00	2 godine
Rezervni dijelovi, popravak i servis specijalnih vozila marke Mathieu, Johnston i Mitsubishi	3.700.000,00	2 godine
Popravak nadogradnje specijalnih vozila marke Cosesco, Kaoussis i Terberg	4.200.000,00	2 godine
Popravak i rezervni dijelovi hidraulike - sklopovi specijalnih vozila	4.530.000,00	2 godine
Potrošni materijal i pribor za njegu vozila	952.800,00	2 godine
Najam sustava za nadzor upravljanja voznim parkom	1.345.000,00	2 godine
Ulja i maziva za strojeve i vozila u jamstvenom roku	35.000,00	2 godine
UKUPNO:	165.807.800,00	

Predviđeni troškovi voznog parka zagrebačkog Holdinga prema Planu nabave za 2022. godinu su 165.807.800,00 HRK, što je 1,12 % ukupno predviđenog proračuna [Tablica 15]. Radi se o značajnim sredstvima, a da bi se postigli manji troškovi potrebna je nabava suvremenijeg i modernijeg voznog parka te bolje uređenim cjelokupnim sustavom gospodarenja komunalnim otpadom u Gradu Zagrebu. Isto tako potrebno je napraviti analizu isplativosti nabave programskog softvera koji bi maksimalno optimizirao rute, a koji trenutačno ne postoji u

zagrebačkoj Čistoći te koliko bi se uštedilo na naftnim derivatima primjenom optimiziranih ruta. Uštede od npr. 2 - 3 % kod naftnih derivata, znače financijsku uštedu (prema procijenjenoj vrijednosti nabave za 2022. godinu) od 1.760.280,00 – 2.640.420,00 HRK u razdoblju od dvije godine.

4.3. Emisije stakleničkih plinova voznog parka grada Zagreba

Hrvatska kao dio EU-a dijeli klimatsku ambiciju svih zemalja članica da bude klimatski neutralna do 2050. godine. Do 2030. godine očekuje se smanjenje emisije stakleničkih plinova od -55 %. Neki od općih ciljeva strategije niskougljičnog razvoja su učinkovito korištenje resursa, smanjenje energetske ovisnosti te smanjenje onečišćenja zraka i odnosi se na sve sektore gospodarstva i ljudskih aktivnosti. Cilj je smanjiti potrošnju prirodnih dobara, smanjiti nastanak opasnih i toksičnih tvari, smanjiti emisije u zrak, vodu i tlo te smanjiti ili spriječiti nastajanje otpada na mjestu nastanka tj. svesti na najmanju moguću mjeru. Jedan od ciljeva kružnog gospodarstva je da se vrijednost proizvoda, materijala i resursa što je dulje moguće zadržava u gospodarstvu [10].

U odnosu na 1990. godinu očekuje se da će se emisije stakleničkih plinova za sektor otpada povećati za 35 % do 2030., smanjenje za -7,6 % se očekuje do 2040., a do 2050. za -29,4 % u odnosu na 1990. godinu [10].

Jedan od uvjeta koje RH mora ispuniti do 2025. godine je smanjiti odlaganje komunalnog otpada na 25 % ukupne količine (po masi) nastalog komunalnog otpada ili manje. Kako bi se spriječilo odlaganje biootpada na odlagališta otpada i doprinijelo ostvarenju ostalih ciljeva gospodarenja otpadom nužno je potaknuti građane na odvajanje biootpada od ostalog kućnog (komunalnog) otpada odlaganjem u spremnike za biootpad.

Kao dio strategije niskougljičnog razvoja, ciljevi gospodarenja otpadom koje Republika Hrvatska mora ostvariti u području recikliranja komunalnog otpada su:

- najmanje 55 % mase komunalnog otpada mora se oporabiti recikliranjem i pripremom za ponovnu uporabu do 2025. godine
- najmanje 60 % mase komunalnog otpada mora se oporabiti recikliranjem i pripremom za ponovnu uporabu do 2030. godine
- najmanje 65 % mase komunalnog otpada mora se oporabiti recikliranjem i pripremom za ponovnu uporabu do 2035. godine [10].

4.3.1. Lokalni transport otpada

Utrošak nafte za lokalni odvoz otpada je između 5 - 15 litara nafte po toni otpada i prijeđenom kilometru [3]. Ako jedno vozilo za otpad troši 9 litara nafte po toni otpada i prijeđenom kilometru, a 54 litre za 6 tkm, dnevni ekonomski troškovi za naftu su otprilike 805,14 HRK. Uračunata cijena nafte je 14,91 HRK za litru dizel goriva.

Ekonomski troškovi za naftu jednog vozila, koje je u upotrebi npr. 350 dana u godini, mogu iznositi i do 281.799,00 HRK godišnje.

4.3.2. Međugradski transport otpada

Kod međugradskog prijevoza navedene su tri cestovne udaljenosti od Zagreba do pogona za obradu otpada, kompostane ili bioplinskog postrojenja [Tablica 16]. Promjena ekonomskih troškova je linearna, tj. s udaljenošću se povećavaju i troškovi prijevoza. Emisije stakleničkih plinova se isto tako povećavaju s udaljenošću mjesta za istovar otpada.

Tablica 16. Cestovna udaljenost gradova od Zagreba

Relacija	Cestovna udaljenost S / km
Zagreb - Velika Gorica	19
Zagreb - Karlovac	59
Zagreb - Novska	104

Troškovi i emisije su najmanji kod najkraće cestovne udaljenosti [Tablica 17].

Tablica 17. Ekonomski troškovi i emisije po cestovnoj udaljenosti pogona

Cestovna udaljenost S km	Utrošak nafte: l/povratan smjer	Ekonomski trošak za naftu: HRK/povratan smjer	Utrošak nafte: l/god	Ekonomski trošak za naftu: HRK/god	Emisije stakleničkih plinova: t CO ₂ -ekv/god
19	9,55	142,39	3.342,5	49.836,67	12,07
59	29,65	442,08	10.377,5	154.728,52	37,47
104	52,26	779,19	18.291,0	272.718,81	66,05

Za transport biorazgradivog komunalnog otpada nastalog u Gradu Zagrebu do kompostane i bioplinskog postrojenja u npr. Novskoj, koja je cestovno udaljena od Zagreba 104 km, bilo bi

utrošeno otprilike 34,84 litara nafte za jedno vozilo u jednom smjeru. Svakodnevni prijevoz jednog vozila do Novske za istovar biorazgradivog komunalnog otpada, je 12.194,0 litara nafte u jednom smjeru, a 18.291,0 litara nafte godišnje za prijevoz u oba smjera (računajući 50 % iznosa za povratan smjer ako je kamion prazan). Po sadašnjim cijenama nafte, 14,91 HRK za litru dizel goriva, to bi bio godišnji ekonomski trošak za naftu od 272.716,5 HRK za jedno vozilo (računajući 350 radnih dana).

Emisije stakleničkih plinova iznose otprilike 1,16 kg CO₂-ekv po kilometru i toni prijevoza otpada, znači za 104 km, iznosile bi 120,64 kg CO₂-ekv u jednom smjeru, u oba smjera 180,96 kg CO₂-ekv (računajući 50 % iznosa za povratan smjer ako je kamion prazan). To je 66.050,40 kg CO₂-ekv godišnje, tj. za svakodnevni prijevoz jednog vozila emisije stakleničkih plinova iznosile bi **66,05 t CO₂-ekv** godišnje [Tablica 17].

Izračunati troškovi su za povratan smjer jednog vozila za prijevoz otpada, a godišnje količine su izračunate za 350 radnih dana u godini.

Kod međugradskog transporta u kontinuitetu potrošnja energije ceste po toni i prijeđenom kilometru je 2,75 MJ, a kod prijevoza otpada vlakom potrošnja energije po toni i prijeđenom kilometru je 0,22 MJ [3].

Cestovni promet čini najveći udio u ukupnim emisijama iz prometa. U 2019. emitirao je 72 % svih stakleničkih plinova u domaćem i međunarodnom prometu [11].

Željeznički prijevoz S / km	Potrošnja energije E / MJ/god
20	4,40
59	12,98
116	25,52

Slika 31. Godišnja potrošnja energije za željeznički prijevoz otpada [3]

Željeznički prijevoz se koristi za prijevoz niskovrijednih tereta velikih količina na većim udaljenostima. Vlakovi održavaju konstantnu i relativno visoku brzinu prijevoza, a moguće je i povezivanje s ostalim modovima transporta. Prijevoz tereta vlakom je cjenovno niži od cestovnog prijevoza te je moguć i prijevoz otpada. Godišnja potrošnja energije je manja od

cestovne, ali je prijevoz otpada teže organizirati željezničkim putem. Za razliku od cestovnog transporta otpada, kod željezničkog se mora primijeniti multimodalni transport koji uključuje korištenje barem dvije različite grane prometa (cestovni, željeznički, itd.) [12].

4.4. Usporedba sustava gospodarenja komunalnim otpadom grada Zagreba i Ljubljane

Površina grada Zagreba je 641,32 km², dok je površina grada Ljubljane 275,0 km². Prema službenim podacima iz 2020. godine u Zagrebu živi 809.268 stanovnika, dok u Ljubljani živi 294.113 stanovnika, prema podacima iz 2020. godine.

Prema podacima iz 2015. godine, Ljubljana je uspjela smanjiti količinu otpada na odlagalištima za 59 %, dok su troškovi gospodarenja otpadom ostali među najnižima u Europi.

U posljednjih deset godina, Ljubljana je uspjela višestruko povećati odvojeno prikupljanje komposta i recikliranja te smanjiti količinu otpada na odlagalištima za 59 %. Istodobno je uspjela zadržati troškove gospodarenja otpadom među najnižima u Europi. Slovenski grad je uspio postići najvišu stopu odvojenog prikupljanja otpada od svih europskih prijestolnica. Komunalno poduzeće zaduženo za odvoz otpada u Ljubljani je još 2013. godine smanjilo učestalost prikupljanja miješanog otpada. U područjima s niskom gustoćom naseljenosti miješani otpad se isprva prikupljao jednom u dva tjedna, ali uskoro se to smanjilo na jednom u tri tjedna. U gusto naseljenim područjima (stambene zgrade) miješani otpad se prikupljao jednom tjedno, a otpad za recikliranje i kompostiranje nekoliko puta tjedno.

To je bilo dovoljno da se ispune ciljevi, tj. kada se materijali za recikliranje i kompostiranje odvoze češće, građani imaju poticaj da odvajaju otpad. Ukoliko ne žele dugo čekati na odvoz. Takvim pristupom organiziranje, pali su i mjesečni troškovi gospodarenja otpadom za kućanstva. Komunalno poduzeće za odvoz otpada korisnicima njihovih usluga nudi besplatni SMS podsjetnik za raspored i cijene odvoza, a mogu i ažurirati željene usluge preko njihove web stranice. Do 2015. godine 63 % otpada u Ljubljani je odvojeno sakupljeno, a do 2014. odlaganje otpada se smanjilo za 59 % u deset gradova u Sloveniji, dok se ukupna proizvodnja otpada smanjila za 15 %.

U usporedbi s Ljubljanom, u Zagrebu je stopa odvojenog sakupljanja otpada 32 %. U Zagrebu se ove godine krenulo s novim sustavom naplate prikupljanja otpada, po kojemu će se miješani komunalni otpad bacati isključivo u za to predviđene vrećice, koje se mogu kupiti u tri različite

litraže. Očekuje se da će takvim sustavom povećati odvojeno razvrstavanje otpada te smanjiti količina odloženog otpada [13].

5. ZAKLJUČAK

Financijski troškovi za prikupljanje komunalnog otpada su posebno bitna stavka u vremenima energetske krize. Optimiziranje i racionaliziranje ruta za prikupljanje otpada je jedan od načina kako te troškove umanjiti. Osim ušteda kod troškova za gorivo, s time se dolazi i do smanjenja emisija stakleničkih plinova. Korištenje digitalnih tehnologija je jedan od načina kako se troškovi mogu umanjiti te olakšati zaposlenicima posao. Usporedba tri realne rute u primjeni s rutama dobivenih TSP (problem putujućeg trgovca) heurističkim algoritmom ušteda, rezultirala je sa dva različita rješenja te jednim istim. Primjenom TSP heurističkog algoritma ušteda za prvu rutu rezultat je 7,23 % bolja ruta od rute zagrebačke Čistoće. Za drugu rutu rezultat je 11,45 % bolja ruta od rute u primjeni, dok je treća ruta u primjeni jednaka kao i ruta dobivena primjenom TSP heurističkog algoritma ušteda.

Rješenja dobivena heurističkim metodama su bez garancije da će se postići optimalno rješenje, iako ih karakterizira sposobnost brzog dolaska do rješenja. Heuristički algoritmi uglavnom daju 10 - 22 % lošija rješenja od optimalnog.

LITERATURA

- [1] Watson J. European Green City Indeks, London, Siemens AG, Economist Intelligence Unit, 2009.
- [2] AKCIJSKI PLAN energetske održivog razvitka i prilagodbe klimatskim promjenama grada Zagreba, Gradska skupština Grada Zagreba; 2019.
- [3] Dobrović, S. Predavanja iz kolegija Gospodarenje otpadom 2. Zagreb: Fakultet strojarstva i brodogradnje; 2021./2022.
- [4] Đukić, G. Predavanja iz kolegija Operacijska istraživanja I. Zagreb; Fakultet strojarstva i brodogradnje; 2019./2020.
- [5] Karta Hrvatske: <https://www.auto-karta-hrvatske.com/zagreb/>, Pristupljeno: 10. listopada 2022.
- [6] Google maps: <https://www.google.com/maps>, Pristupljeno: 15. listopada 2022.
- [7] Digital technologies will deliver more efficient waste management in Europe. Europska agencija za okoliš – Europska unija; 2021.
<https://www.eea.europa.eu/themes/waste/waste-management/digital-technologies-will-deliver-more>, Pristupljeno: 05. studenog 2022.
- [8] WasteHero ApS. Danska; 2022.
<https://wastehero.io/>, Pristupljeno 12. studenog 2022.
- [9] Plan nabave za 2022. godinu. Zagrebački holding. Zagreb; 2022.
<https://www.zgh.hr/nabava/plan-nabave/plan-nabave-zagrebackog-holdinga-za-2022-godinu/11653>, Pristupljeno: 25. listopada 2022.
- [10] Strategija niskougljičnog razvoja Republike Hrvatske do 2030. s pogledom na 2050. godinu. Ministarstvo gospodarstva i održivog razvoja. Republika Hrvatska; 2021.
- [11] Greenhouse gas emissions from transport in Europe. Europska agencija za okoliš; 2021.
- [12] Đukić, G. Predavanja iz kolegija Logistički menadžment. Zagreb; Fakultet strojarstva i brodogradnje; 2020./2021.
- [13] Oblak E. Zero Waste Europe; 2015.
https://zerowastecities.eu/wp-content/uploads/2019/07/zero_waste_europe_cs5_ljubljana_hr.pdf, Pristupljeno 19. studenog 2022.

PRILOZI

- I. Rute prikupljanja otpada u primjeni zagrebačkog komunalnog poduzeća Čistoća (A3 format dimenzija).

PREGLED KARTE

VOZILA

LOKACIJE

POVIJEST

KRETANJE

DNEVNO

POZICIJA

← Natrag

Izvoz

Spremi rutu

G-356 smečar

29.09.2022 13:42:27

29.09.2022 19:50:10

63 km 03h:34m:32s

DATUM	STATUS	BRZINA / TRAJANJE
29.09.2022 13:42:27	Stajanje [1]	00h:19m:25s
29.09.2022 14:01:52	Kontakt +	0 km/h
29.09.2022 14:02:06	Stajanje	00h:00m:19s
29.09.2022 14:03:52	Stajanje [2]	00h:03m:04s
29.09.2022 14:05:52	Stajanje	00h:00m:52s
29.09.2022 14:06:25	Vožnja	8 km/h
29.09.2022 14:06:27	Vožnja	8 km/h
29.09.2022 14:06:35	Vožnja	10 km/h
29.09.2022 14:06:36	Vožnja	10 km/h
29.09.2022 14:06:38	Vožnja	9 km/h
29.09.2022 14:06:42	Vožnja	11 km/h
29.09.2022 14:06:43	Vožnja	13 km/h
29.09.2022 14:06:45	Vožnja	15 km/h
29.09.2022 14:06:55	Vožnja	15 km/h
29.09.2022		

A detailed map of Zagreb, Croatia, showing a blue route with 30 numbered stops. The route starts in the north, near the Veliki potok, and winds through the city, ending near the Sava river. Key streets shown include Trg kraljice Marije, Trg bana Josipa Jelačića, and Trg bana Pavla Preradovića. The map also shows the Sava river and the city's layout with various districts and landmarks.

PREGLED KARTE

VOZILA

LOKACIJE

POVIJEST

KRETANJE

DNEVNO

POZICIJA

Natrag

Izvoz

Spremi rutu

G-437 smečar

29.09.2022 13:31:24

29.09.2022 20:10:27

54 km 04h:20m:33s

DATUM	STATUS	BRZINA / TRAJANJE
29.09.2022 13:31:24	Stajanje [1]	00h:03m:09s
29.09.2022 13:34:33	Kontakt -	00h:03m:09s
29.09.2022 13:39:36	Stajanje [2]	00h:24m:49s
29.09.2022 13:59:22	Kontakt +	0 km/h
29.09.2022 13:59:28	Stajanje [3]	00h:03m:05s
29.09.2022 14:02:27	Vožnja	6 km/h
29.09.2022 14:02:28	Vožnja	7 km/h
29.09.2022 14:03:46	Vožnja	7 km/h
29.09.2022 14:03:50	Vožnja	6 km/h
29.09.2022 14:04:53	Vožnja	8 km/h
29.09.2022 14:04:54	Vožnja	8 km/h
29.09.2022 14:05:17	Vožnja	8 km/h
29.09.2022 14:07:08	Vožnja	10 km/h
29.09.2022 14:07:10	Vožnja	16 km/h
29.09.2022		

A detailed map of Zagreb, Croatia, showing a blue route with 28 numbered stops. The route starts in the north, goes south through the city center, and then heads east towards the airport. A red location marker labeled 'B' is located near the airport. The map includes various street names, landmarks like Jarun, and a scale bar at the bottom left.

PREGLED KARTE

VOZILA

LOKACIJE

POVIJEST

KRETANJE

DNEVNO

POZICIJA

← Natrag

Izvoz

Spremi rutu

G-474 smečar

29.09.2022 13:42:37

29.09.2022 19:30:00

47 km 03h:43m:23s

DATUM	STATUS	BRZINA / TRAJANJE
29.09.2022 13:42:37	Stajanje [1]	00h:17m:57s
29.09.2022 14:00:34	Kontakt +	0 km/h
29.09.2022 14:00:42	Kontakt -	00h:00m:08s
29.09.2022 14:03:49	Stajanje [2]	00h:03m:10s
29.09.2022 14:03:52	Kontakt +	0 km/h
29.09.2022 14:04:02	Stajanje [3]	00h:11m:38s
29.09.2022 14:15:30	Vožnja	5 km/h
29.09.2022 14:15:32	Vožnja	9 km/h
29.09.2022 14:15:33	Vožnja	12 km/h
29.09.2022 14:15:35	Vožnja	15 km/h
29.09.2022 14:15:45	Vožnja	19 km/h
29.09.2022 14:15:46	Vožnja	17 km/h
29.09.2022 14:15:47	Vožnja	16 km/h
29.09.2022 14:15:52	Vožnja	13 km/h

A detailed map of Zagreb, Croatia, showing a blue route with 23 numbered stops. The route starts in the north, near the Veliki potok, and moves south through the city center. Key streets shown include Zagrebačka avenija, Jadranska avenija, and Savska avenija. The Sava river is visible in the south. The map includes various landmarks like Park Maksimir and Jarun. The route is marked with blue arrows indicating direction. Red circles with numbers 1 through 23 mark specific points along the route. The map also shows surrounding areas like Zemun and Novi Zagreb.