Optimiranje transportne mreže logističkog operatera primjenom matematičkih metoda

Perković, Karlo

Master's thesis / Diplomski rad

2018

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:119:627011

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**



Repository / Repozitorij:

Faculty of Transport and Traffic Sciences - Institutional Repository







SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI

Karlo Perković

OPTIMIRANJE TRANSPORTNE MREŽE LOGISTIČKOG OPERATERA PRIMJENOM MATEMATIČKIH METODA

DIPLOMSKI RAD

Zagreb, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI
POVJERENSTVO ZA DIPLOMSKI ISPIT

Zagreb, 27. ožujka 2018.

Zavod: **Zavod za transportnu logistiku**
Predmet: **Prijevozna logistika II**

DIPLOMSKI ZADATAK br. 4617

Pristupnik: **Karlo Perković (0135233077)**
Studij: Inteligentni transportni sustavi i logistika
Smjer: Logistika

Zadatak: **Optimiranje transportne mreže logističkog operatera primjenom matematičkih metoda**

Opis zadatka:

U okviru studije slučaja, provesti analizu transportne mreže logističkog operatera. Primjenom matematičkih metoda formulirati elemente optimiranja transportne mreže i prikazati očekivane rezultate primjene na konkretnom primjeru transportne mreže logističkog operatera.

Mentor:

izv. prof. dr. sc. Ratko Stanković

Predsjednik povjerenstva za diplomski ispit:

Sveučilište u Zagrebu
Fakultet prometnih znanosti

DIPLOMSKI RAD

OPTIMIRANJE TRANSPORTNE MREŽE LOGISTIČKOG OPERATERA PRIMJENOM MATEMATIČKIH METODA

APPLYING MATHEMATICAL METHODS IN OPTIMIZING TRANSPORTATION NETWORK OF THE LOGISTICS OPERATOR

Mentor: izv. prof. dr. sc. Ratko Stanković

Student: Karlo Perković
JMBAG: 0135233077

Zagreb, rujan 2018.

SAŽETAK

Logistički operater, kao nositelj distribucijskih aktivnosti, svojim odlukama bitno pridonosi uspješnoj organizaciji transportne mreže i na taj način promovira transport u presudnog čimbenika prilikom ostvarivanja konkurentskih prednosti na tržištu prijevoznih kapaciteta. Optimiranje ruta na transportnoj mreži logističkog operatera, ogleda se u određivanju najpovoljnijih putova kojima se grupa vozila služi prilikom opskrbljivanja korisnika. Problem takvog optimiranja transportnih ruta, u literaturi je opisan kao problem usmjeravanja vozila, radi čijeg su rješavanja razvijene brojne metode i algoritmi. Navedeni problem je u ovome radu prikazan na realnom primjeru logističke tvrtke koja posluje u Republici Hrvatskoj. U tu svrhu, uz prikupljanje podataka, izvršena je analiza postojećeg stanja ruta odnosno postojeće transportne mreže, nakon čega je iznijet prijedlog elemenata optimiranja, da bi u konačnici bio omogućen prikaz njihovih očekivanih učinaka.

KLJUČNE RIJEČI: transportna mreža; optimizacija ruta; matematičke metode

SUMMARY

Logistics operator, as the carrier of distribution activities, significantly contribute to the successful organization of transportation networks, and so promote transport as a crucial factor in achieving competitive advantages on the transport capacity market. Routes optimization on the transportation network of the logistics operator, is reflected into determining the most suitable paths that a group of vehicles uses when they are serving the customers. In the literature, that transport routes optimizing problem is described as a vehicle routing problem, for which solution many methods and algorithms have been developed. The mentioned problem was in this paper presented on the realistic example of a logistics company in the Republic of Croatia. For that purpose, along with the data collection, an analysis of the existing routes shape was carried out, a suggestion with all optimizing elements was put forward and ultimately, expected effects were introduced and shown.

KEYWORDS: transport network; routes optimization; mathematical methods

SADRŽAJ

1. UVOD 1

2. TRANSPORTNA LOGISTIKA 4

2.1. Međurelacijska povezanost transporta i logistike 6

2.2. Povijesni razvoj logistike 10

3. POJAM, KONCEPT STVARANJA I AFIRMACIJA LOGISTIČKOG OPERATERA 13

4. TRANSPORTNO POSLOVANJE LOGISTIČKOG OPERATERA 19

5. UDJEL TRANSPORTNIH TROŠKOVA U LOGISTIČKIM TROŠKOVIMA DISTRIBUCIJE 23

5.1. Glavni čimbenici pokretanja fiksnih i varijabilnih troškova 25

5.2. Varijable koje utječu na pokretače troškova 26

6. PROBLEM USMJERAVANJA VOZILA 29

6.1. Podproblemi usmjeravanja vozila 32

6.1.1. Problem usmjeravanja vozila s ograničenjem kapaciteta 35

6.1.2. Problem usmjeravanja vozila s ograničenjem duljine rute 39

6.1.3. Problem usmjeravanja vozila s vremenskim ograničenjem 43

6.1.4. Problem usmjeravanja vozila s dostavom i prikupljanjem 48

6.1.5. Problem usmjeravanja vozila s dostavom i povratnim prikupljanjem .. 53

6.2. Heuristički pristup u rješavanju problema usmjeravanja vozila 58

6.2.1. Heuristika najbližeg susjeda 59

6.2.2. Sweep algoritam 61

6.2.3. Clarke i Wright algoritam ušteda 64

6.3. Metaheuristički programski alat za optimizaciju i planiranje ruta 76

6.3.1. Implementirani algoritam unutar programskog alata 77

6.3.2. Struktura i okruženje programskog alata 78

7. OPTIMIZACIJA TRANSPORTNE MREŽE NA PRIMJERU IZ PRAKSE 85

7.1. Analiza transportne mreže 89

7.2. Prijedlog elemenata optimiranja transportne mreže 98

7.2.1. Prijedlog rješenja – slučaj 1 105

7.2.2. Prijedlog rješenja – slučaj 2 112

7.3. Prikaz očekivanih učinaka predloženih elemenata optimiranja 118

8. ZAKLJUČAK 127

POPIS LITERATURE 129

POPIS KRATICA 132

POPIS SLIKA 134

POPIS TABLICA 136

POPIS GRAFIKONA 137

1. UVOD

U suvremenom gospodarskom okruženju, u kojem vrijeme predstavlja novac, uštede postaju ključ uspjeha. Pritom, kada se govori o uštedama u logistici, najveći naglasak stavljen je na one koje se izbliza tiču transporta, iz čega jasno proizlazi potreba za njegovim konstantnim optimiranjem. Osim toga, brz i učinkovit transportni proces od iznimnog je značaja za sve subjekte koji sudjeluju u distribuciji dobara i usluga.

Posljednjih se godina organizacija takvog procesa svodi na jednu fizičku ili pravnu osobu – logističkog operatera. U njegovoj se domeni poslovanja danas očituje sve veći broj zahtjeva, a uzrok tome pripisuje se ubrzanom razvoju gospodarskih aktivnosti, transportnih tehnologija te informacijskih sustava. Sukladno tome, da bi logistički operater mogao ići ukorak s vremenom, potrebni su mu sofisticirani programski alati, utemeljeni na matematičkim metodama rješavanja raznih transportnih problema.

Jedan od tih problema je i problem usmjeravanja vozila, a upravo se njemu u ovome radu pridaje sva pažnja, budući da je to jedan od najvažnijih, najzastupljenijih, najproučavanijih i najsloženijih optimizacijskih problema u logistici. Njegove su izvedenice brojne, a sve se međusobno razlikuju po tome što imaju drugačija ograničenja. Tako primjerice transportna mreže nekog logističkog operatera može biti uvjetovana prostornom, vremenskom, kapacitativnom ili nekom drugom spriječenošću, što u konačnici dodatno otežava njegovo transportno poslovanje u svakodnevnoj praksi.

Na tom tragu leži i svrha rada u kojoj se, uporabom odgovarajućeg programskog dodatka, nastoje postići adekvatni rezultati optimiranja transportne mreže logističkog operatera. Za dobivena rješenja se očekuje da prije svega budu praktična, a potom i da rezultiraju minimiziranjem utrošenih resursa te maksimiziranjem stupnja njihove iskorištenosti. Prema krajnjem scenariju svrhe rada, rezultati mogu poslužiti i kao prijedlog poboljšanja kvalitete pružene usluge i jačanja konkurentnosti logističkog operatera.

Prateći iznesenu svrhu ovog rada, nameću se usputni ciljevi koje treba postići. Oni se ogledaju u stjecanju teorijskog znanja o pravilima izbora, filtriranja, poboljšavanja i odbacivanja prijedloga rješenja. Da bi se to u konačnici i postiglo, diplomski rad pod naslovom *Optimiranje transportne mreže logističkog operatera primjenom matematičkih metoda*, smišljeno je podijeljen u osam sljedećih cjelina koje sadržajno nadopunjavaju jedna drugu:

1. Uvod;
2. Transportna logistika;
3. Pojam, koncept stvaranja i afirmacija logističkog operatera;
4. Transportno poslovanje logističkog operatera;
5. Udjel transportnih troškova u logističkim troškovima distribucije;
6. Problem usmjeravanja vozila;
7. Optimizacija transportne mreže na primjeru iz prakse;
8. Zaključak.

Drugo poglavlje započinje predstavljanjem transporta kao jedne od najvažnijih društvenih djelatnosti, koja je svakodnevno prisutna u raznim oblicima. Potom se pojam transporta terminološki razgraničuje sa sličnim pojmovima u upotrebi, točnije prometom i prijevozom, a istovremeno se stavlja naglasak na njegovu međurelacijsku povezanost s logistikom. Na kraju poglavlja slijedi kratki opis logističke povijesti, kao uvod u pojavu koncepta logističkog operatera.

Treće poglavlje, osim što definira samog logističkog operatera, navodi i skup aktivnosti kojima se on bavi te ih uspoređuje s aktivnostima klasičnog špeditera. Zatim se slično kao i kod prethodnog poglavlja prikazuje evolucijski razvoj, ali ovoga se puta on detaljnije dotiče samo logističkog operatera, i to ne na osnovu godina, već na osnovu kompleksnosti usluga koje je pružao u početcima i koje pruža danas.

Budući da se jedna od tih usluga tiče isključivo transporta, u četvrtom je poglavlju obim poslovanja logističkog operatera konkretiziran i sveden samo na to odabrano područje. Tako se u ovom poglavlju pruža uvid u strukturu sudionika transportnog procesa, prolaze se njegove specifične faze i postavljaju se ciljevi realizacije. Poglavlje završava s isticanjem važnosti racionalne i učinkovite realizacije, obzirom na značajnu prisutnost transportnih troškova u svemu tome.

Peto poglavlje dublje ulazi u analizu transportnih troškova, budući da je na kraju prethodnog poglavlja prepoznata njihova snažna utjecajnost. Slijedom toga, da bi ih se bolje razumjelo i odvojilo od ostalih logističkih troškova, izvršena je njihova podjela na dvije glavne vrste – fiksne i varijabilne troškove. U nastavku poglavlju sve je podređeno upravo tim dvjema vrstama, gdje se postupno razmatraju čimbenici koji na njih utječu i varijable koje ih pokreću.

Peto poglavlje ujedno služi i kao priprema za ono što slijedi nakon njega, a to je šesto poglavlje u kojem se konkretnije ulazi u problematiku rada. Naime, šesto poglavlje se odnosi na problem usmjeravanja vozila, a jedan od ciljeva toga problema je i smanjenje troškova koji su prethodno obrađeni. No, daleko od toga da je ispunjenje ciljeva u ovome problemu jednostavno, štoviše, ono je još teže kada mu se dodaju razna ograničenja pa su ona u ovom poglavlju detaljno proučena, zajedno s pripadajućim matematičkim modelima i vizualnim prikazima. Da ipak ne bi sve ostalo samo na proučavanju, nakon toga su dodatno objašnjene i matematičke metode s kojima se ovaj problem i njegova ograničenja mogu uspješno rješavati u jednostavnijim situacijama. Pritom nisu zakinute ni one složenije situacije koje se zapravo najčešće i pojavljuju u praksi pa je posebno za njihovo rješavanje, na kraju poglavlja, predstavljen programski alat, odnosno njegova struktura i okruženje.

Jedna takva složenija situacija obrađena je u sedmom poglavlju, gdje je na praktičnom primjeru logističke tvrtke prenijeta sva prethodno iznesena teorija. Za tu je priliku korišten spomenuti programski alat uz čiju su pomoć iznesena dva prijedloga rješenja, kroz dva odvojena slučaja, radi optimiranja postojeće transportne mreže tvrtke koja je netom prije toga analizirana. Iza toga je još, kao posljednji doprinos radu, provedena i evaluacija očekivanih učinaka, nastalih na osnovu predloženih elemenata optimiranja.

2. TRANSPORTNA LOGISTIKA

Kretanja ljudi, roba i informacija oduvijek su bile temeljne komponente ljudskih društava pa je razvoj suvremenih poslovnih procesa redovito bivao praćen povećanjem mobilnosti i sve višim stupnjem pristupačnosti. Iako se početci ovoga trenda mogu povezivati čak i s vremenima industrijske revolucije, on je puni zamah dobio tek krajem dvadesetog stoljeća nakon što su ekonomski blokovi uspostavljeni, a trgovina liberalizirana.

Takvo okruženje podrazumijevalo je značajnije promjene i na transportnom tržištu budući da su društva sve više ovisila o transportnim sustavima. Naime, u ne tako davnoj prošlosti, većina poduzeća svoje je poslovanje zasnivala na samostalnom obavljanju transportnih aktivnosti. U to vrijeme, „svi su radili sve“ pa su tako poslovni sustavi u poduzećima morali imati sposobnost rada u području transporta jednako kao i u drugim područjima koja su bila neophodna za poslovno funkcioniranje.

Situacija je danas znatno drugačija jer kompanije prepuštaju transportne poslove i čitavu svoju logističku strategiju specijaliziranim poduzećima odnosno logističkim operaterima. Na taj način, kompanije se mogu maksimalno orijentirati svojoj osnovnoj djelatnosti[1] i pružiti joj punu pažnju. Za ovakav scenarij zaslužne su mnoge promjene u gospodarskom, političkom, ekonomskom i društvenom okruženju, koje su uzrokovale vrlo uočljive transformacije u transportnoj logistici. Osnovni inicijatori tih promjena zapravo su tehničko-tehnološka dostignuća koja su na velika vrata svjetskom tržištu iznjedrila trend globalizacije. Proces globalizacije nameće potrebu da se pod utjecajem razvitka svjetskoga gospodarstva i društva, reduciraju ili uklanjaju trgovinske barijere, a povećavaju poslovne mogućnosti i pojedina interesna tržišta na mnogo široj razini od nacionalne. [1] S takvim međunarodnim poslovanjem preoblikuju se svjetski trgovinski obrasci te se formiraju fizički robni tokovi. Posljedično s time, transportno specijalizirana poduzeća uspostavljaju strateške mreže diljem svijeta kako bi one mogle pružiti učinkovit i kvalitetan odgovor na globalnu potražnju iz bilo kojeg segmenta svjetskog tržišta. Integrirana organizacija takvih aktivnosti često se naziva globalnom logistikom, koja je ujedno postala i jezgrom globalne konkurentne moći.

[1] Glavni poslovni program (engl. *Core Business*).

Kritičnu točku takvog globalnog logističkog sustava predstavlja transport zbog svoje funkcije spajanja odvojenih aktivnosti, odnosno spajanja razmjerno velikih udaljenosti koje utječu na segregaciju kompanije i kupaca. Transport je okosnica cijelog opskrbnog lanca u kojem on sudjeluje kao ključni element te je ujedno i najzaslužniji za postizanje 7P koncepta[2] kojeg čine: [2]

1. Pravi proizvod (engl. ***P****roduct*);
2. Prava cijena (engl. ***P****rice*);
3. Pravi uvjeti (engl. ***P****hysical evidence*);
4. Pravo mjesto (engl. ***P****lace*);
5. Pravo vrijeme (engl. ***P****rocess*);
6. Pravi kupac (engl. ***P****eople*);
7. Pravi trošak (engl. ***P****romotion*).

Navedeni koncept sa svojim temeljnim odrednicama zapravo predstavlja laički opis logistike iz razloga što on, koliko god jednostavno izgledao, sadrži najvažnije elemente logistike. Primjerice, u njemu su naglašene prostorne i vremenske dimenzije što je opći preduvjet za shvaćanje pojma logistike. Nadalje, u konceptu su zastupljeni i troškovi kao veoma bitna komponenta logističkog operatera koji na osnovu njih analizira, valorizira, ocjenjuje i odlučuje o promjenama u logističkom sustavu. Vrlo je važan i značaj pružanja usluga potrošačima, a sve u cilju zadovoljenja njihovih želja i potreba.

Samim postojanjem koncepta i pridržavanjem njegovih načela, stvara se polazišna točka za podizanje kvalitete, bez koje se danas ne može zamisliti niti jedna logistička aktivnost. Iz toga proizlazi pojednostavljena osnovna ideja ovog koncepta prema kojoj kompanija mora izvršiti pravi zadatak, u pravo vrijeme i na konkurentnom tržištu.

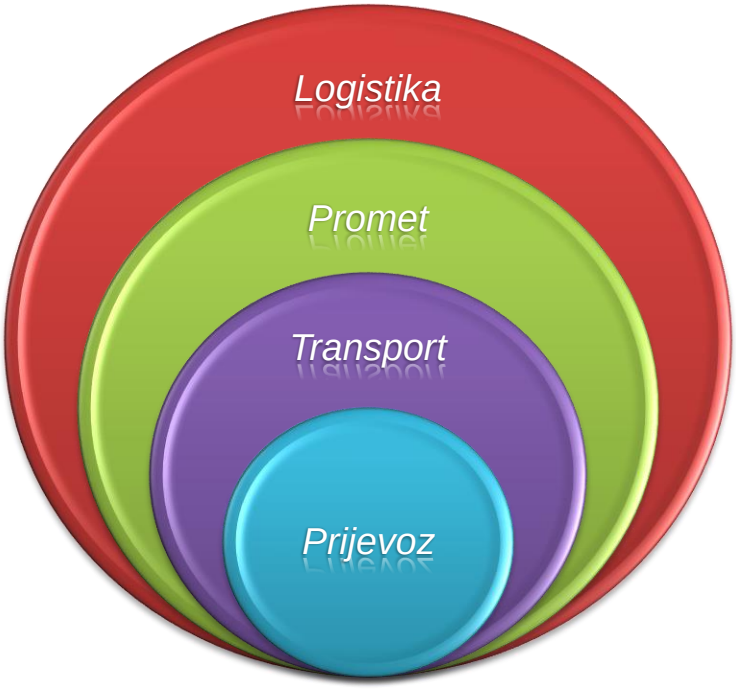
Sukladno navedenom, gotovo je nezamislivo da suvremena kompanija može funkcionirati bez pomoći prijevoza i njemu pripadajućih aktivnosti te se stoga za transport može kazati kako je on esencijalna podfunkcija logistike koja robi pridodaje vremensku i prostornu korisnost.

[2] Koncept sedam P (7P) podrazumijeva kompletnu logističku uslugu, po sistemu „od vrata do vrata“ (engl. *Door-to-Door*).

2.1. Međurelacijska povezanost transporta i logistike

Zajedno s realizacijom aktivnosti koje su vezane uz premještanje ljudi, dobara, usluga i informacija s jednog mjesta na drugo, isprepliće se nekoliko vrlo sličnih pojmova koji se u svakodnevnom govoru vrlo često pojavljuju, a međusobno se prožimaju i isprepliću (Slika 1): [3]

- Prijevoz;
- Transport;
- Promet;
- Logistika.



Slika 1. Hijerarhijski prikaz povezanosti terminoloških pojmova
Izvor: Izradio autor prema [3]

Prijevoz se može definirati kao stvarno fizičko premještanje ljudi i dobara od jednog mjesta do drugog, ne obuhvaćajući pritom pripremne radnje kao što su izdavanje prijevoznih isprava, pakiranje robe, preuzimanje prtljage, ukrcaj, prekcraj, iskrcaj i razne druge aktivnosti. [3]

Pod pojmom *transporta* i transportne djelatnosti podrazumijeva se širi aspekt, budući da on uz prijevoz obuhvaća i sve druge aktivnosti vezane uz proces

premještanja ljudi i dobara s jednog na drugo mjesto. U te aktivnosti uključene su sve radnje i procesi vezani uz pripremu i odabir vozila, prijevoznu dokumentaciju, pripremu putnika i robe za proces prijevoza i premještanja, kao i druge djelatnosti koje omogućuju realizaciju transportnog procesa. [3]

Promet se može definirati kao gospodarska djelatnost čija je zadaća zadovoljenje potreba za premještanjem ljudi i dobara u prostoru, uzimajući pritom u obzir i vrijeme potrebno za realizaciju tog procesa. U njemu su, uz prijevoz i transport, sadržane dodatne usluge (agencijski poslovi, burze prijevoznih kapaciteta, skladištenje itd.) i ostale aktivnosti. [3]

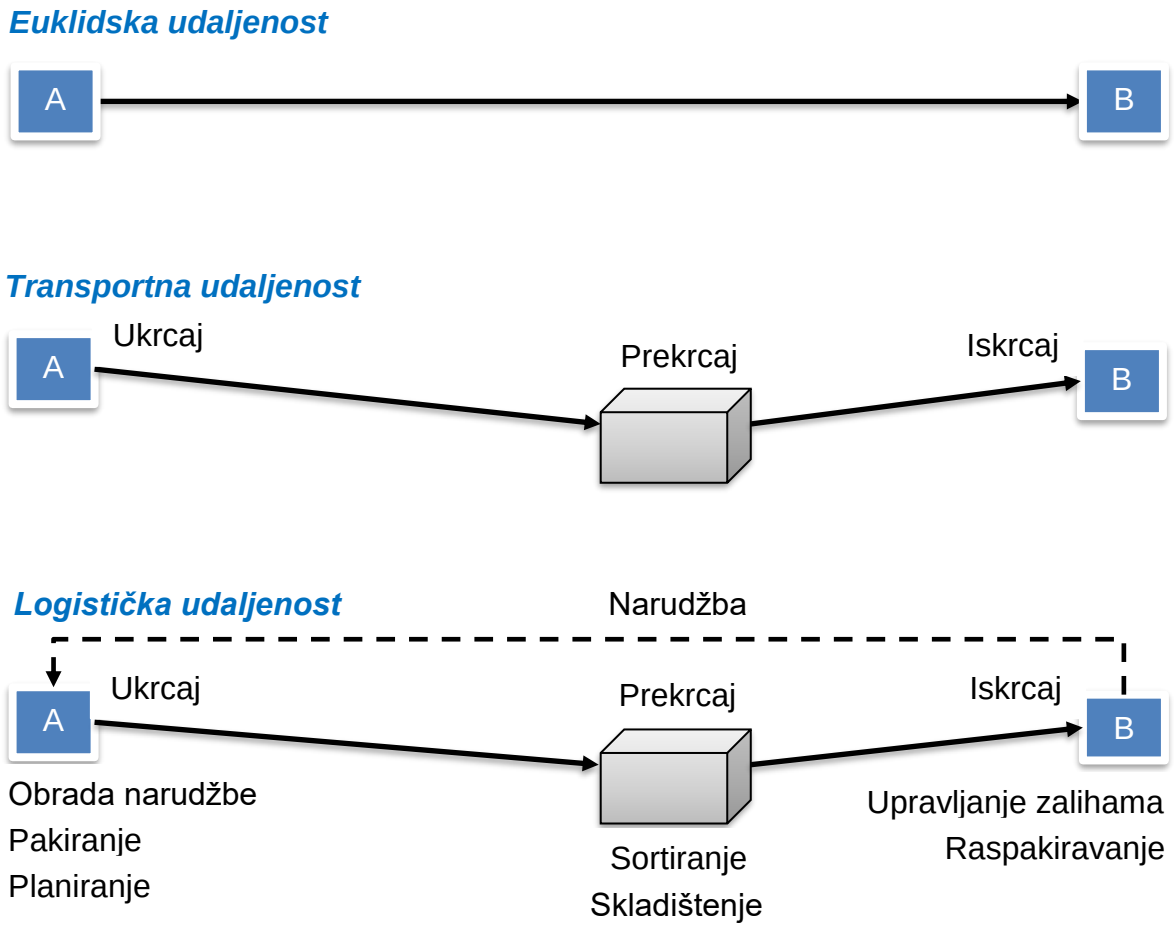
Logistika je najširi pojam od svih prethodno navedenih jer ona u sebi pojmovno sadrži sve tri razine djelatnosti premještanja dobara, a može se promatrati kao znanost i kao aktivnost.

Kao znanost, logistika predstavlja skup interdisciplinarnih i multidisciplinarnih znanja koja izučavaju i primjenjuju zakonitosti mnogobrojnih složenih aktivnosti (funkcija, procesa, mjera, poslova, pravila, operacija, radnji i dr.), koje funkcionalno i djelotvorno povezuju sve djelomične procese svladavanja prostornih i vremenskih transformacija (materijala, dobara, stvari, tvari, (polu)proizvoda, repromaterijala, živih životinja, kapitala, znanja, ljudi, informacija i dr.) u sigurne, brze, racionalne i jedinstvene logističke procese (tokove i protoke materijala, kapitala, znanja i informacija), od točke isporuke, preko točke ili točaka razdiobe/koncentracije, do točke primitka, s ciljem da se uz minimalno uložene potencijale i resurse (ljudske, proizvodne, financijske i dr.) maksimalno zadovolje zahtjevi tržišta (kupca robe, korisnika usluge, potrošača, konzumenta i dr.). [4]

Logistika kao aktivnost predstavlja skup planiranih, koordiniranih, reguliranih i kontroliranih aktivnosti (funkcija, procesa, mjera, poslova, pravila, operacija, radnji i dr.), kojima se funkcionalno i djelotvorno povezuju svi djelomični procesi svladavanja prostornih i vremenskih transformacija (materijala, dobara, stvari, tvari, (polu)proizvoda, repromaterijala, živih životinja, kapitala, znanja, ljudi, informacija i dr.) u sigurne, brze i racionalne jedinstvene logističke procese (tokove i protoke materijala, kapitala, znanja, informacija i dr.), od pošiljatelja (sirovinske baze, skladišta,

(polu)proizvođača, terminala, prodavatelja, izvoznika i dr.), preko točke ili točaka razdiobe/koncentracije, do primatelja (skladišta, (polu)proizvođača, terminala, kupca, uvoznika, korisnika, potrošača i dr.), a sve s ciljem da se uz minimalno uložene potencijale i resurse (ljudske, proizvodne, financijske, informacijske i dr.) maksimalno zadovolje zahtjevi tržišta (kupca robe, korisnika usluge, potrošača, konzumenta i dr.). [4]

Odnosi logistike i transporta te pojedinosti po kojima se ta dva pojma međusobno razlikuju mogu se vrlo praktično prikazati uz pomoć udaljenosti koja čini osnovni temelj transporta. Naime, udaljenost se može prikazati na različite načine, počevši od najjednostavnije euklidske udaljenosti, odnosno ravne linije između dva mjesta, do onoga što se naziva logističkom udaljenosti, a odnosi se na kompletan skup zadataka koje je potrebno izvršiti kako bi se određena udaljenost mogla nadvladati (Slika 2).



Slika 2. Prikaz varijanti udaljenosti s aspekta transporta i logistike
Izvor: Izradio autor prema [5]

Euklidska udaljenost jest ravna linija između dva mjesta kod koje se udaljenost izražava u zemljopisnim jedinicama, primjerice, u kilometrima. To je najjednostavnija funkcija koja se koristi za približno (aproksimativno) određivanje udaljenosti, ali gotovo nikada nema praktičnu upotrebu zbog svoje slabije preciznosti. [5]

Transportna udaljenost ogleda se u nešto složenijem prikazu te se kod nje u obzir uzimaju aktivnosti poput ukrcaja, iskrcaja i prekrcaja. Konkretno, između lokacija A i B uključeni su ukrcaj, otprema i transport do točke razdiobe/koncentracije, prekrcaj pa ponovni transport do točke isporuke te konačno prihvat i iskrcaj (Slika 2). Ovakva se udaljenost također izražava u zemljopisnim jedinicama, a njeni dodatni elementi još su troškovi i vrijeme. [5]

Logistička udaljenost predstavlja najsloženiji prikaz koji obuhvaća sve zadatke potrebne za odvijanje tokova između dviju lokacija. Osim tokova, logistička udaljenost uključuje i čitav skup pomoćnih aktivnosti koje služe kao podrška upravljanju tim tokovima. U te se aktivnosti ubrajaju obrada narudžbi, pakiranje, sortiranje i upravljanje zalihama. Čimbenici troška i vremena ovdje su vrlo značajni dok su same zemljopisne jedinice manje relevantne. Pritom valja istaknuti kako se vrijeme ne odnosi samo na vrijeme kašnjenja, već i na to kako se ono koristi prilikom planiranja otpreme i prihvata robe. Između lokacija A i B, ova udaljenost uključuje narudžbu koja ima obrnuti smjer (B prema A) od smjera slanja robe. Potom se roba na lokaciji A obrađuje, pakira i planira za otpremu. Na lokaciji razdiobe/koncentracije odvijaju se aktivnosti prekrcaja, sortiranja i skladištenja, dok se na lokaciji odredišta pošiljka prihvaća, iskrcava, raspakirava i priprema za predviđenu upotrebu (Slika 2). [5]

Zaključno sa svim navedenim jasno proizlazi da transportni i logistički sustavi imaju međusobno povezane odnose, a dodatno u prilog tome ide i činjenica da je logističkom menadžmentu transport jednostavno neophodan za obavljanje vlastitih aktivnosti.

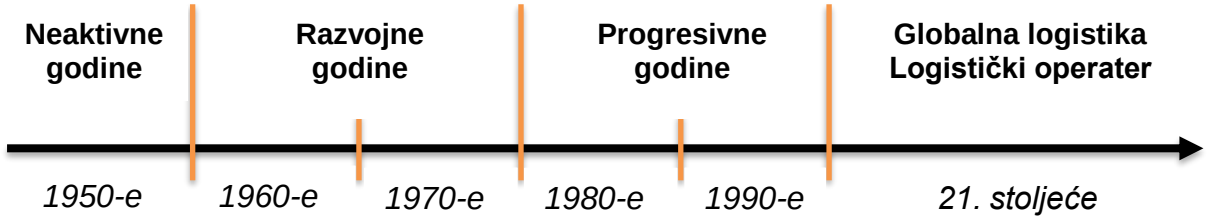
Prema tome, bez kvalitetno razvijenih transportnih sustava, logistika ne bi mogla ispuniti sav potencijal svojih prednosti, a s druge pak strane, potentan i zanimljiv, ali nedorečen transportni sustav, mogao bi kroz logističke aktivnosti pružiti još bolju učinkovitost, smanjiti operativne radne troškove te proširiti obim i unaprijediti kvalitetu usluge koju nudi na konkurentnom tržištu.

2.2. Povijesni razvoj logistike

Originalno podrijetlo pojma logistike dolazi od grčke riječi *logos* koja ističe da je to znanost o principima i oblicima pravilnog mišljenja i prosuđivanja, ali i riječi *logistikos* koja u prijevodu znači „vješt u računanju“, odnosno ima značenje iskustva, vještine i znanja o očuvanju, procjeni i prosudbi svih relevantnih elemenata u prostoru i vremenu, potrebnih za optimalno rješavanje taktičkih i strateških zadataka u svim područjima ljudskih aktivnosti. [6]

Logistika je u početku imala obrise isključivo vojne aktivnosti gdje je bilo potrebno vojnike i vojnu opremu organizirano dopremiti do bojnog polja, dok se u sadašnjem vremenu ona smatra sastavnim i nezaobilaznim dijelom svakog poslovnog procesa. Budući da se vojne definicije logistike obično povezuju s opskrbom, kretanjem, okupljanjem i grupiranjem vojnika, nerijetka istraživanja znanstvenika imala su za cilj ustanoviti mogućnost primjene logistike iz vojnih aktivnosti na poslovne aktivnosti. Unatoč takvim i brojnim drugim istraživanjima, poslovna logistika nije imala status akademskog predmeta sve do 60-ih godina prošlog stoljeća iako je ključni element logistike, kompromis između troškova prijevoza i zaliha, formalno priznat u ekonomiji još od sredine 80-ih godina 19. stoljeća. [7]

Ukoliko se te 60-te godine prošlog stoljeća uzmu kao začetak suvremene logistike, tada se njezin razvojni napredak može podijeliti u četiri glavna razdoblja odnosno karakteristične faze: period od 1950. do 1960. godine, period između 1960. i 1970. godine, period između 1980. i 1990. godine te period nakon 1990. godine i ulaska u novo stoljeće (Slika 3).



Slika 3. Ključni periodi u razvoju logistike
Izvor: Izradio autor prema [8]

50-ih godina prošlog stoljeća, logistika je bila tek u povojima, prikrivena od očiju javnosti. U tom razdoblju, središnja okupacija menadžera bila je proizvodnja pa su sredstva za proizvodnju bila na najvišem stupnju iskorištenosti. Industrijska logistika smatrala se „nužnim zlom“ pa je proizvodnja robe za skladište bila neznatna. Tada, kao posebna poslovna funkcija, logistika je po prvi puta uvedena u gospodarstvo, točnije u poduzeća za proizvodnju i distribuciju robe široke potrošnje. Krajem 50-ih godina sve se više pažnje posvećivalo raspoloživosti proizvoda u mjestima prodaje, a logističke aktivnosti bile su raspoređene u svim strukturama kompanije.

Tijekom 1960-ih i 1970-ih, tendencija je bila na uvođenju novih ideja u upravljanju poslovnim procesima. Poduzete su intenzivne mjere i akcije u cilju unaprjeđenja prodaje i marketinga u poduzećima. Tada se još nije u dovoljno velikoj mjeri vodilo računa o porastu troškova uzrokovanih širenjem zaliha u skladištima, kao ni o troškovima nastalima povećanjem asortimana i uvođenjem sve kraćih rokova isporuke robe. 70-ih godina uvodi se sve više poveznica s logistikom, a na to se nastavljaju i sve učestalije istraživačke aktivnosti u području logistike. Kompanije su to prepoznale pa su se aktivnosti u njima počele grupirati oko upravljanja materijalima i fizičkom distribucijom. Nadalje, u tim se godinama počela mijenjati percepcija logistike. Tako se od izrazite koncentracije na proizvodne aktivnosti, gdje je racionalizacija bila usmjerena na troškove proizvodnje, pažnja sve češće i više prenosila na aktivnosti koje su se obavljale u svrhu zadovoljenja potrošača. Posljedica toga bila je sve veće zanimanje za pojedine logističke elemente kao što su vrijeme isporuke, način isporuke i stupanj raspoloživosti proizvoda.

U periodima 80-ih i 90-ih, u većini poduzeća počinje prevladavati saznanje da se na području logistike nalaze značajne neiskorištene rezerve racionalizacije te da logistika postaje područje iznimne međusobne konkurentnosti, od čega se osobito ističe konkurentnost trećih zemalja po pitanju materijala i proizvoda.. Za ovaj je period karakterističan razvoj poslovanja koji je obilježen snažnom ekspanzijom i proširenjem na različita tržišta. To je dovelo do rasta potreba za koordinacijom i kontrolom kretanja svih materijalnih i robnih tokova.

S početkom 21. stoljeća javlja se najnovija etapa u razvoju logistike gdje poduzeća shvaćaju značaj neprekidnosti procesa kojim se može kontrolirati tok robe i usluga do krajnjeg korisnika. Posebna se pažnja posvećuje kvaliteti profita, odnosno postaje jasno da se profit ne može više ostvarivati stalnim povećanjem obujma proizvodnje i prodaje, već pažljivom kontrolom i racionalizacijom troškova opsluživanja tržišta i klijenata (umjesto isključivo troškova proizvodnje). Potom je integracijom sustava dobavljača, proizvođača i potrošača načinjen opskrbni lanac, a uloga organizatora, koordinatora i/ili izvršitelja aktivnosti u njemu, pripala je logističkim operaterima.

3. POJAM, KONCEPT STVARANJA I AFIRMACIJA LOGISTIČKOG OPERATERA

U današnjim gospodarskim uvjetima, gdje je optimizacija poslovanja okarakterizirana brzim promjenama, heterogenošću, raznovrsnošću, porastom konkurencije, skraćenjem životnog ciklusa proizvoda te ujednačenjem tehnološke osnovice poslovanja, naglasak se stavlja na brzinu, točnost i pouzdanost dostave. Skraćenje vremena i smanjenje transportnih troškova omogućuje postizanje značajnih ušteda i manjih cijena proizvoda, a kako brz i jeftin transport rezultira povećanjem efektivne raspoloživosti različitih resursa, to onda utječe i na porast značenja drugih nematerijalnih čimbenika proizvodnje. U prvom redu se to odnosi na znanje i specijalne vještine radnika, pa tako, umjesto fizičkog i financijskog kapitala, kritični resurs suvremenog poslovanja postaje intelektualni kapital. [1]

Posljedično s time, klasična špedicija s obimom osnovnih i specijalnih poslova u svezi s organizacijom otpreme, dopreme i provoza, postaje sve više stvar prošlosti. Suvremeni zahtjevi vanjskotrgovinskog i prometnog sustava, proces globalizacije, širenje tržišta, porast konkurencije između vrsta transporta, *outsourcing*[3] te snažni razvoj informacijske i komunikacijske tehnologije, dovode do transformacije i restrukturiranja temeljne djelatnosti klasičnog špeditera u modernog, tzv. logističkog operatera[4]. [9]

Prema definiciji, logistički operater je registrirana i ovlaštena, pravna ili fizička osoba, koja redovito u svoje ime i za svoj račun, obavlja ili organizira brojne logističke aktivnosti u svezi s manipuliranjem, prijevozom, prijenosom, premještanjem i distribucijom (sirovina, poluproizvoda, repromaterijala, gotovih proizvoda, robe, stvari, stvari, živih životinja i dr.), od točke isporuke (sirovinske baze, skladišta, (polu)proizvođača, terminala, prodavatelja, izvoznika i dr.), preko točke ili točaka razdiobe/koncentracije, do točke primitka (skladišta, (polu)proizvođača, terminala,

[3] Izdvajanje posla (engl. *outsourcing*) označuje davanje određenog posla vanjskim dobavljačima. Tvrtke ovakav princip poslovanja primjenjuju kako bi smanjile troškove koji nastaju podmirivanjem potreba za djelatnostima koje im nisu temeljne. Tu je uglavnom riječ o uslužnim djelatnostima: čišćenju, održavanju, prijevozu, zaštiti i sl.

[4] Logistički operater - arhitekt transporta; odvjetnik nalogodavca; car prometa; poduzetnik cjelokupnog transportnog pothvata; menadžer modernih prijevoznih tehnologija; div u sjeni i sl.

kupca, uvoznika, korisnika, potrošača i dr.), a sve s ciljem da se uz minimalno uložene potencijale i resurse (ljudske, proizvodne, financijske, informacijske i dr.) maksimalno zadovolje zahtjevi tržišta, nalogodavaca i/ili partnera (kupca robe, korisnika usluge, potrošača, konzumenta i dr.). [10]

Uspoređujući opseg aktivnosti klasične špedicije s opsegom aktivnosti logističkog operatera, može se ustvrditi kako je opseg potonjeg za 30% veći od opsega prvotnog. Naime, pojam logističkog operatera, osim aktivnosti klasičnog špeditera, obuhvaća i određene specifične logističke aktivnosti. To su: [11]

- prerada, dorada, obrada i održavanje sredstava za rad;
- pakiranje, signiranje, slaganje, vaganje i mjerenje tereta;
- ukrcaj, iskrcaj i prekrcaj;
- skladištenje i/ili paletiziranje predmeta prometovanja;
- punjenje/pražnjenje kontejnera i/ili prijevoznih sredstava;
- fumigacija, deratizacija i dezinsekcija;
- posredovanje, osiguranje, carinjenje i kupoprodaja;
- distribucija, marketing, menadžment, kalkulacije, financije i kontroling;
- praćenje izvršavanja određenih aktivnosti;
- pravno-ekonomsko reguliranje odnosa između brojnih sudionika u logističkim procesima i dr.

Iz priloženog se vidi kako su zahtjevi za organiziranjem otpreme, dopreme ili provoza tereta sve brojniji i zahtjevniji pa se upravo zbog brže i učinkovitije organizacije, cjelokupan proces od nabave, prijevoza, skladištenja, carinjenja, pakiranja i dopreme proizvoda do konačne lokacije, povjerava jednoj osobi ili poduzeću s logističkom djelatnošću – logističkom operateru.

Logistički operater, ponajviše zaslugom *outsourcinga*, postaje fizička ili pravna osoba koja uz pomoć svojih intelektualnih sposobnosti[5] značajno utječe na efikasno i uspješno transportno poslovanje te njegovo veće značenje, ulogu i integraciju u logističkom lancu. Razlog pojave *outsourcinga* sastoji se u tome što danas kompanija ne može uspjeti ako ne proizvodi uslugu koju radi najbolje. Zbog toga, koncentrirajući

[5] Interdisciplinarnih i multidisciplinarnih znanja.

se na svoju osnovnu djelatnost, kompanija svoje sporedne djelatnosti prebacuje na specijalizirane pružatelje usluga, tzv. 3PL, 4PL i 5PL operatere[6]. Obično se u takvim situacijama izdvaja više od jedne djelatnosti. Najčešće su to skladištenje i transport, a prate ih aktivnosti konsolidacije i informatizacije (Tablica 1).

Tablica 1. Dimenzije strategije izdvajanja posla

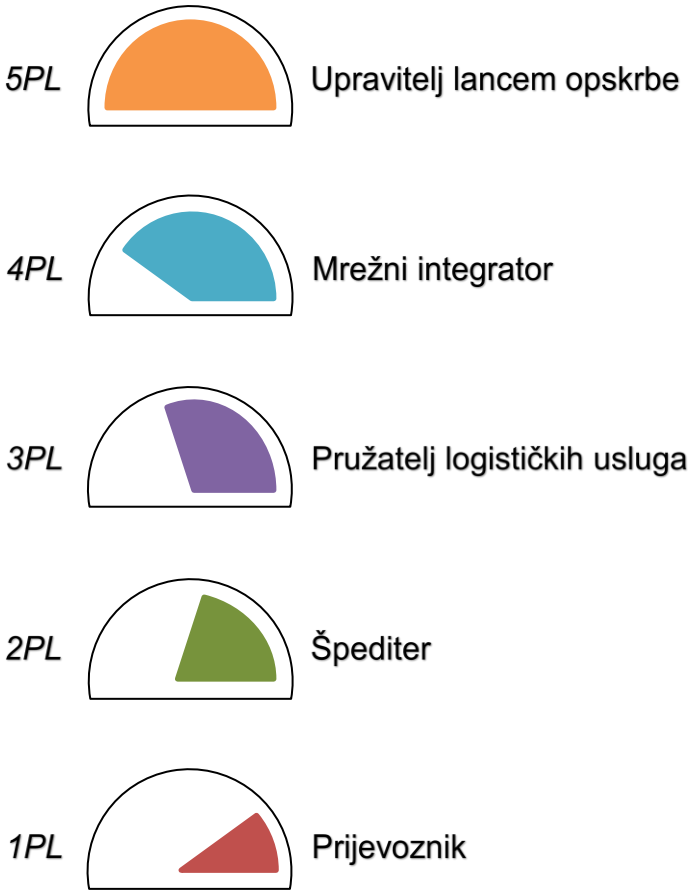
Poslovi koji se najčešće izdvajaju	**Udjel izdvajanja**
Upravljanje skladištem	45%
Konsolidacija (okrupnjavanje) isporuka	45%
Popunjavanje ponude	26%
Pakiranje robe	6%
Transport	28%
Distribucija	21%
Kompjuterizacija sustava	32%
Postprodajne usluge (povrati)	2%
Vanjskotrgovinski poslovi	21%
Upravljanje narudžbama	6%

Izvor: Izradio autor prema [12]

Poboljšanje logistike za kompaniju predstavlja primarni izvor generiranja novog profita, a reflektira se i na održavanju konkurentskih prednosti na tržištu prijevoznih kapaciteta. Upravo je zbog toga uveden koncept logističkog operatera, koji se razvio iz potrebe za proširenjem transportnih usluga od strane prijevoznih poduzeća, kako bi se njihovim korisnicima pružila kvalitetnija i potpunija logistička usluga. Sami koncept nastao je tijekom deregulacije industrije teretnog prometa 80-ih godina prošlog stoljeća, a u praktičnu upotrebu progresivno je bivao uvođen 90-ih godina i početkom novog stoljeća. [13]

Njegov evolucijski razvoj tekao je paralelno s razvojem logistike i logističkih strategija. Taj se razvoj može opisati kao uzvodna promjena funkcija u pogledu logističkih usluga - od skladišta i voznih parkova za vlastite potrebe (1PL[7]), preko klasičnih javnih skladišta te transportnih, špediterskih i drugih kompanija (2PL[8]), do današnjih 3PL, 4PL i 5PL pružatelja logističkih usluga (Slika 4).

[6] Treća, četvrta i peta strana u logistici (engl. ***3rd Party Logistics; 4th Party Logistics; 5th Party Logistics***).
[7] Prva strana logistike (engl. ***1st Party Logistics***).
[8] Druga strana logistike (engl. ***2nd Party Logistics***).



Slika 4. Kompleksnost usluga od 1PL do 5PL operatera
Izvor: Izradio autor

Koncept logističkog operatera započeo je razvojem prijevoznih poduzeća, koja su sve svoje logističke operacije obavljala isključivo sama. Danas se takva poduzeća nazivaju 1PL operateri. To su uglavnom manja poduzeća koja kupuju i prodaju na istim tržištima, a ujedno su i prijevoznici. Kao takvi, 1PL operateri organiziraju prijevoz robe i biraju način transporta, a potrebno je naglasiti i kako samostalno surađuju sa skladištima, službama otpreme i prihvata, carinama i drugim sudionicima u transportnom procesu.

Nešto kasnije, usporedno sa širenjem logističkih granica, počelo se razmišljati o dodatnim uslugama koje su bile predodređene za ulogu pratećih aktivnosti osnovnom prijevozu. Posljedica toga bila je da su pojedine logističke operacije sve više preuzimali špediteri kao 2PL operateri. Time je proces prijevoza postao znatno lakši, jednostavniji i učinkovitiji, budući da su prijevoznici svoje poslove mogli obavljati odmah i na jednom mjestu, uz pomoć i asistenciju špeditera. S povećanjem zahtjeva

kupaca, mnogi 2PL operateri počeli su se razvijati u 3PL operatere, na način da su u svoj postojeći djelokrug usluga dodali nove logističke mogućnosti i funkcije, a istodobno poslovanje učinili integriranim. Tako je došlo do spajanja više logističkih operacija i dodatnih logističkih usluga, uz širenje značaja logistike u opskrbnom lancu te prihvaćanja većih obaveza i odgovornosti.

Sukladno navedenom, 3PL operateri danas nude obavljanje svih usluga u čitavom transportnom lancu, od prijema do isporuke, i to na efikasniji i pouzdaniji način nego što je to ranije bio slučaj. Te usluge rezultiraju povećanjem vlastite vrijednosti kroz temeljitu razradu, korištenje i vođenje informacijsko-komunikacijskih sustava, praćenje tereta tijekom transporta te kroz osiguranje pomoći u logističkom planiranju.

Čak i kada ne posjeduju vlastita skladišta i prijevozne jedinice, 3PL operateri u mogućnosti su pružati niz usluga kao što su markiranje, rezerviranje, usmjeravanje, kalkuliranje i organiziranje prijevoza; istraživanje financijskih i operativnih uvjeta isporuke; analiziranje tržišne situacije, distribucijskih i transportnih puteva; pregovaranje i sl. Pored toga, u stanju su zadovoljiti i mnoge druge zahtjeve svojih klijenata pa se slobodno može reći kako je transportni lanac, s pojavom 3PL operatera, postao apsolutno naklonjen prodavačima i kupcima, iz razloga što se oni više ne moraju angažirati oko biranja transportnih modova, puteva te brojnih povezanih radnji i administrativnih zadataka vezanih uz realizaciju logističkih operacija. Time 3PL operater postaje više partner nego dobavljač. Takva bliskost čini 3PL operatere neophodnima za svoje klijente pa se oni znatno teže odlučuju za njihovu promjenu, što nije slučaj s 2PL operaterima.

Zbog toga većina 2PL operatera stremi postati upravo 3PL operaterima. 3PL operateri su manje osjetljiviji na imovinu od 2PL operatera pa stoga posjeduju tek manji dio vlastite imovine (distribucijske centre na strateškim lokacijama i malu flotu vozila za transport), a većinu svojih kapaciteta izdvajaju od drugih sudionika, među kojima su 1PL i 2PL operateri. Prema tome, može se reći kako 3PL operateri bivaju usredotočeni na logistička rješenja i traže optimalnu kombinaciju imovine koja je dostupna kod preostalih pružatelja potrebnih kapaciteta (1PL i 2PL operatera).

Pružatelj 4PL usluga u svojoj je suštini logistički integrator, a to znači da predstavlja viši organizacijsko-upravljački oblik logističkog posrednika. Zbog toga je idealan za ulogu komunikatora s klijentima i njihovim zahtjevima oko izdvajanja logističkih aktivnosti. On je ujedno odgovaran za okupljanje i uključivanje različitih 2PL i 3PL operatera u realizaciju cjelokupnog logističkog procesa, kao i za upravljanje konačnim rješenjima. Osim toga, 4PL mrežni integrator sposoban je ponuditi najveću dodatnu vrijednost usluge klijentima, kroz mogućnosti planiranja, naručivanja i praćenja prijevoza, logističkog savjetovanja, primijenjenih rješenja te financijskih usluga. Uz to omogućuje vrlo bliske i jake veze s poslovnim okruženjem. [14]

Ovdje također, kao i kod odnosa između 2PL i 3PL operatera, postoji namjera od strane 3PL poduzeća da pokušaju unaprijediti svoje poslovanje i postati 4PL operateri, a sve kako bi pružili usluge s kojima će njihovi povezani korisnici biti zadovoljniji. Tome u prilog ide i činjenica da se usluge 3PL operatera nerijetko preklapaju s uslugama 4PL operatera pa je namjera 3PL operatera u potpunosti opravdana. Štoviše, ta namjera ne samo da je opravdana, nego je i očekivana, ukoliko se u obzir uzme da je 4PL koncept znatno unosniji budući da u njemu poduzeća naplaćuju i konzultantske naknade. Međutim, takva transformacija nije nimalo jednostavna, jer da bi 3PL operater postao 4PL operater, on mora pronaći pravi način za izgradnju snažnih poveznica i odnosa između sebe i svojih klijenata, a da pritom dosegne najveću razinu učinkovitosti usluga koje pruža.

Tek je nakon jedne takve transformacije, a potom i višegodišnje afirmacije, moguće stvoriti preduvjete za uvođenje novog pristupa u konceptu logističkog operatera koji može biti definiran kao 5PL. 5PL operater usmjeren je na osiguranje cjelovitih logističkih rješenja za čitavi opskrbni lanac. Upravljanje lancem opskrbe ogleda se u integraciji aktivnosti povezanih s protokom i transformacijom robe kroz logističke mreže, putem poboljšanih odnosa u opskrbnom lancu, temeljenih na zajedničkoj okosnici koja omogućuje stvaranje bliskih, suradničkih i dobro koordiniranih mrežnih odnosa, ključnih za postizanje konkurentskih prednosti. [15]

4. TRANSPORTNO POSLOVANJE LOGISTIČKOG OPERATERA

Organizacija, koordinacija i izvršavanje transportnih zadataka u cjelini, predstavljaju vrlo važan proces tijekom transportnog poslovanja logističkog operatera. Njegov središnji cilj ogleda se u isporučivanju robe od mjesta otpreme do mjesta isporuke, no svaki logistički operater ima svoje prioritete. Tako jedan očekuje da će roba biti isporučena na brz, ekonomičan i siguran način, dok drugi ide za većom zaradom u transportu pa je tada za očekivati i veću cijenu same robe. Ipak, kako bi se takva poslovna (komercijalna) razmjena održala, potrebno je provesti detaljne analize, u kojima se logistički operater ne smije ograničiti na samo jednu granu prijevoza. Naime, prilikom planiranja tijeka transportnog zadatka, logistički operater treba ići za time da svaka narudžba ima svoje specifičnosti. Svaki zadatak, čak i onaj koji je najsličniji nekom već ranije realiziranom, treba biti analiziran s posebnom pažnjom, uzimajući pritom u obzir sve povezane aspekte.

Vidljivo je, dakle, da logistički operater, kao osoba koja je odgovorna za organizaciju prijevoza, ima izuzetno zahtjevnu zadaću. On mora pomiriti očekivanja klijenata koji žele robu prenijeti na brz, jeftin i pouzdan način, s ciljevima vlastitog poduzeća koji se odražavaju na postizanju maksimalne dobiti. Tako s jedne strane on mora imati na umu da se procesi trebaju planirati na način koji bezuvjetno osigurava isporuku svih transportnih naloga. To konkretno znači da roba mora biti dostavljena na pravom (odredišnom) mjestu, u pravo (dogovoreno) vrijeme i bez ikakvih gubitaka, odnosno štete na robi. S druge pak strane, prilikom planiranja transporta, logistički operater mora voditi računa i o tome kako smanjiti transportne troškove.

Da bi to bio u stanju postići, logistički operater mora imati obvezu stjecanja raznih znanja i vještina u području transportnog poslovanja pa stoga njegove kompetencije moraju biti povezane poslovno, logistički i upravljački. Osim optimizacije transportne mreže, nužnim se smatra i razumijevanje te vođenje projekata, njihovo financiranje i posjedovanje znanja u području komercijalnog i prometnog prava jer jedino s takvim kompetencijama oni mogu prijevoz učiniti neprekidnim, omogućiti što kraće vrijeme dostave, umanjiti troškove i konačno zadovoljiti korisnike njihovih usluga. [3]

Potonje navedeno vrlo je važno budući da transportno poslovanje logističkog operatera, korištenje prometne infrastrukture i suprastrukture te stjecanje konkurentskih prednosti na tržištu transportnih usluga ovisi upravo o zahtjevima, potrebama i interesima korisnika tih usluga. Neimanje korisnika i klijenata ukazuje na to da logistički operater nudi uslugu koju nitko ne treba, a ukoliko se temeljna načela poslovanja ne temelje na realizaciji i ispunjenju korisničkih zahtjeva, tada je transportno poslovanje logističkog operatera vrlo upitno.

Sukladno tome, polazišna točka u planiranju transportnog poslovanja logističkog operatera treba proizaći iz potrebe za izvršavanjem prijevoza, odnosno iz zahtjeva korisnika logističkih usluga. Da bi prijevoz bio izvršen u skladu sa zahtjevima i očekivanjima korisnika, sve poslovne akcije, povezane s transportom, moraju biti pravilno isplanirane. U cilju pravilnog planiranja, u obzir je potrebno uzeti sljedeće pretpostavke: [16]

- Odabir najboljeg mogućeg puta i vozila, uz izbjegavanje „praznih kilometara“, omogućuje smanjenje troškova prijevoza;
- Optimizacija ruta osigurava kraće vrijeme trajanja transporta.

Uz postavljanje pretpostavki, vrlo važno je i definiranje broja, odnosno strukture sudionika poslovnog procesa. Tako su uobičajeni akteri, koji sudjeluju u ovome procesu, sljedeći: [16]

1. *Klijent* (korisnik usluge) koji naručivanjem prijevoza očekuje njegovo izvršenje na njemu poželjan način, što nije uvijek u skladu s kapacitetima logističkog operatera;
2. *Logistički operater* (davatelj usluge) koji sam ili uz pomoć svojih partnera realizira zatraženi zahtjev od strane klijenta. Partneri u pružanju asistencije logističkom operateru uglavnom su sljedeći:

a) *Stručnjaci za korisničku službu* čiji je zadatak učinkovito komunicirati s korisnicima i osobama unutar same organizacije;

b) *Špediteri* koji organiziraju, koordiniraju i prate izvršenje zadataka unutar transportnog procesa;

c) *Stručnjaci za analizu transportnih troškova* koji procjenjuju profitabilnost poslovnog zahvata logističkog operatera;

d) *Vozači,* kao osnovni sudionici u transportnom procesu, koji odgovaraju za fizički tok robe;
e) *Operateri viličara, skladišni operativci i sl.* koji su neizravno uključeni u transportne procese.

Odabir sudionika u velikoj mjeri ovisi o postavljenim ciljevima koji se iz realiziranog poslovnog procesa trebaju postići. To su ponajprije: [16]

- Povećanje učinkovitog rada u transportu;
- Ubrzanje i pojednostavljenje operacija ukrcaja, iskrcaja i prekrcaja;
- Mogućnost proširenja transportnih kapaciteta unutarnjom preraspodjelom;
- Ubrzanje protoka robe skraćenjem trajanja prijevoza;
- Smanjenje troškova ambalaže;
- Smanjenje nesreća u transportu;
- Bolji kontinuitet transportnih procesa;
- Smanjenje udjela ljudskog rada u prijevoznim aktivnostima.

Planiranje tijeka transporta, uz spomenute sudionike i ciljeve, ovisi o još jednom važnom elementu kojeg treba pozorno razmotriti. Radi se o specifičnim fazama transportnog procesa, a one su redom sljedeće: [16]

1. *Prihvaćanje narudžbe klijenta* predstavlja fazu iz koje se razvija početni koncept za pripremu poslovnog pothvata;
2. *Planiranje rute znači da je* organizacija transporta već u jeku. U toj se fazi detaljno analiziraju prijevozna sredstva i putovi;
3. *Priprema robe za prijevoz* podrazumijeva osiguranje svih potrebnih preventivnih i zaštitnih mjera;
4. *Ukrcaj robe* (predmeta prijevoza) u prijevozno sredstvo;
5. *Fizički prijevoz robe* od mjesta polazišta do mjesta odredišta;
6. *Iskrcaj* na lokaciji koju je definirao klijent.

Posljednja faza, koja se ogleda u iskrcaju robe na mjestu koje je predvidio klijent, ne znači da je transportni proces završio. On se nastavlja s poslovnim postupcima koji se tiču zaključivanja pravnih i financijskih pitanja te završnom procjenom i analizom troškova koji su nastali tokom transporta. [16]

Kod ovih faza posebno treba naglasiti da, ovisno o vrsti transportirane robe, planiranje tijeka transportnog procesa može imati sasvim drugačiju strukturu i redoslijed. Ne postoji nešto što se zove univerzalna metoda planiranja. Svaki logistički operater ima svoju metodu planiranja transportnog procesa, odnosno svrsishodno primjenjuje specifične algoritme.

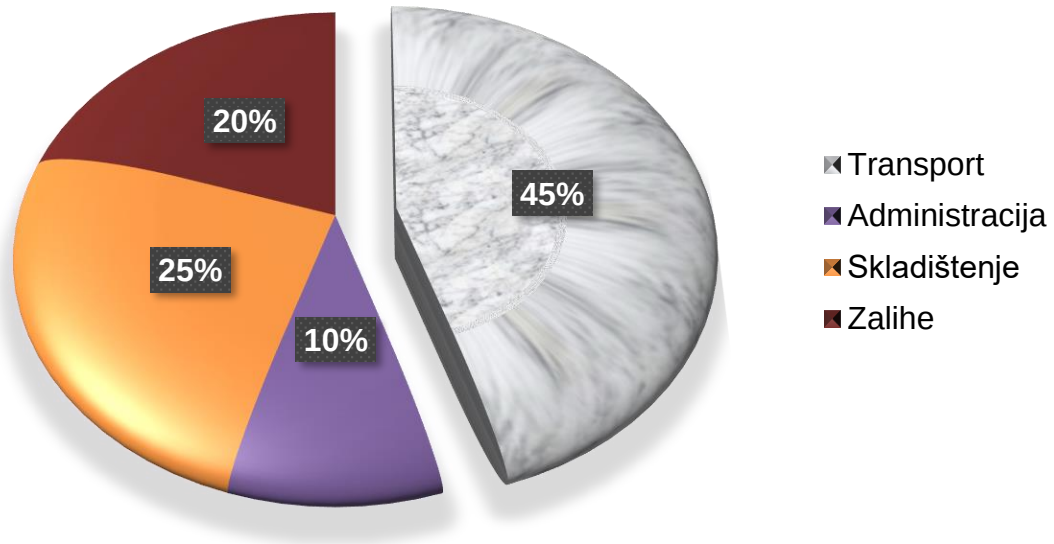
Ti algoritmi predstavljaju okvirne sheme ponašanja u pojedinim fazama planiranja određenog zadatka. Od logističkog se operatera zato očekuje uspostavljanje procedure planiranja iz jednog jednostavnog razloga, a to je da ona pojednostavljuje samo planiranje i praćenje realizacije transporta. Pritom se ne smije zaboraviti da jednom kada se razvije, procedura (algoritam) nije kruta, već je podložna promjenama. Takva sličnost se može prenijeti i na polje ekonomije gdje se stvari neprestano mijenjaju. Promjene mora slijediti i logistički operater kako bi mogao ažurirati svoje specifične organizacijske procedure i tako povećati poslovni profit, uz održavanje zadovoljavajuće razine usluge prema svojim korisnicima.

Iz toga proizlazi da je na logističkim operaterima velika odgovornost da racionalnim poslovanjem čine ono što se od njih i očekuje, točnije da osiguraju maksimalne ekonomske i druge učinke, i to uz minimalne troškove i druge štetne posljedice u logističkom sustavu. Uostalom, sva dosadašnja razmatranja idu u prilog zaključku da je planiranje transportnog poslovanja zadatak o kojem uvelike ovisi hoće li logistički procesi proteći glatko i uspješno. Naravno, puno toga ovisi i o samoj složenosti procesa, no nevezano uz to, transportno poslovanje uvijek je od velikog značaja, a kao dokaz tomu svjedoči i izuzetno veliki prosječni udjel transportnih troškova u čitavom skupu logističkih troškova.

Budući da troškovi transporta čine najveći udio ukupnih logističkih troškova, poboljšanje transportne efikasnosti znatno utječe na povećanje ukupnih performansi logističkog lanca, iz čega proizlazi da transport izravno djeluje na rezultate logističkih aktivnosti. Transportni troškovi tako postaju nezaobilazan komadić slagalice logističkog lanca pri čemu postoji snažna potreba za njihovom optimizacijom od strane logističkog operatera.

5. UDJEL TRANSPORTNIH TROŠKOVA U LOGISTIČKIM TROŠKOVIMA DISTRIBUCIJE

Transport je baza učinkovite ekonomije u poslovnoj logistici i njegove su pripadajuće tehnike potrebne u gotovo svakoj logističkoj aktivnosti. Ne čudi stoga da transportni sustav, kao što je već ranije spomenuto, predstavlja najvažniju gospodarsku djelatnost među komponentama poslovne logistike. U prilog tome ide i činjenica da transport u prosjeku zauzima oko trećinu do dvije ukupnih logističkih troškova kompanije (Grafikon 1).



Grafikon 1. Prosječni udjel troška transporta u ukupnim logističkim troškovima
Izvor: Izradio autor prema [17]

Na grafikonu je prikazana jedna prosječna struktura troškova prema kojoj oni transportni čine između 40 i 50 posto ukupnih troškova logistike. Valja napomenuti da to nije izolirani slučaj i da prikazana podjela ne mora vrijediti uvijek i za svaku tvrtku. Primjerice, transportni troškovi uglavnom će se razlikovati u proizvodnim i maloprodajnim tvrtkama jer su u maloprodaji ti troškovi obično mnogo značajniji i veći u usporedbi s proizvodnom industrijom. No, bez obzira na to jesu li oni manji ili veći, odnosno pojavljuju li se s većim ili manjim udjelom u ukupnim troškovima, logistički operater im uvijek pridaje veliku pozornost i pažnju. To je i razumljivo budući da s njihovog aspekta transportni troškovi predstavljaju novčanu mjeru za utrošena sredstva i rad s kojima se omogućuje izvršenje samog transportnog procesa.

Da bi ih se moglo još bolje shvatiti i razdvojiti od ostalih logističkih troškova, potrebno ih je konkretnije i jasnije definirati, a to se najbolje može učiniti njihovom detaljnijom podjelom. Naime, transportni troškovi se mogu pojavljivati u obliku fiksnih (amortizacija, registracija, osiguranje, režijski troškovi, plaće zaposlenika, razne pristojbe i sl.) i varijabilnih (gorivo, ulja i maziva, održavanje vozila i sl.) troškova, ovisno o nizu uvjeta povezanih s geografijom, infrastrukturom, administrativnim barijerama, energijom i načinom na koji se roba transportira.

Fiksni troškovi su stalno prisutni troškovi koji se ne mijenjaju s volumenom, odnosno količinom transportnih aktivnosti. Ti troškovi eventualno mogu varirati nakon nekog vremena (jedne ili više godina poslovanja).

Varijabilni troškovi novčano kvantificiraju one transportne resurse koji se razlikuju odnosno mijenjaju usporedno s promjenama u volumenu robe koja se distribuira i/ili s udaljenostima koje je potrebno prijeći za isporuku te robe.

Ovi se troškovi razlikuju po vrstama transportnih resursa, ali su istovremeno i u međusobnoj ovisnosti. Najbolji primjeri za to su sljedeći: [18]

- Veličina vozila (fiksni trošak) koja se namjerava koristiti za distribuciju robe, utjecat će na operativni trošak realizirane isporuke (varijabilni trošak);
- Teže i/ili veće vozilo za posljedicu ima povećanje troškova goriva s kojim je potrebno prijeći određenu udaljenost.

Nadalje, na fiksne i varijabilne troškove utječu isti čimbenici, iako na različite načine. Primjerice, značajno povećanje broja odredišnih točaka utjecat će na varijabilne troškove tako što će se povećati udaljenosti koje moraju biti prijeđene (raste trošak goriva), a fiksni troškovi time mogu biti pogođeni ukoliko raspoloživa flota vozila nije dovoljna za prevaljivanje udaljenosti unutar određenog vremenskog razdoblja (raste broj dodatnih vozila). [18]

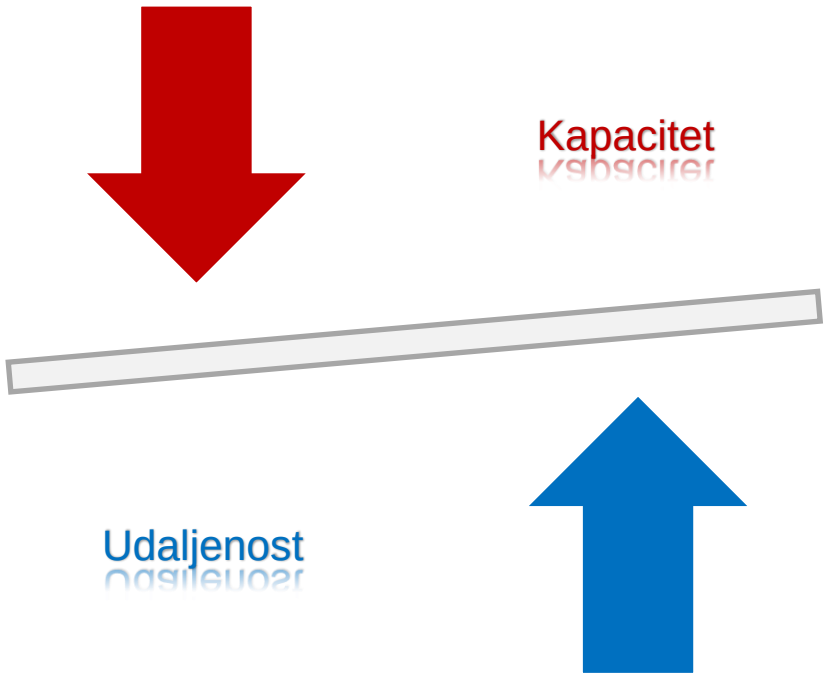
5.1. Glavni čimbenici pokretanja fiksnih i varijabilnih troškova

Čimbenici pokretanja fiksnih i varijabilnih troškova imaju utjecaj na one fiksne i varijabilne troškove za koje postoji opravdana sumnja da bi se mogli promijeniti, ako se budu mijenjali i sami čimbenici. Takvi se čimbenici nazivaju pokretačima troškova, a u njihovoj analizi posebno su bitna dva pokretača. To su: [18]

- Ukupni predviđeni kapacitet za distribuciju;
- Ukupna udaljenost distribucije.

Fiksni i varijabilni troškovi nastupit će ovisno o tome u kojoj se mjeri ta dva čimbenika koriste. Prvi čimbenik, kapacitet, odnosi se na veličinu i broj raspoloživih distribucijskih vozila pa on time utječe na fiksne troškove koji su nastali distribucijom robe. Drugi čimbenik, ukupna prijeđena udaljenost vozila u distribuciji, utječe na pojavu varijabilnih troškova.

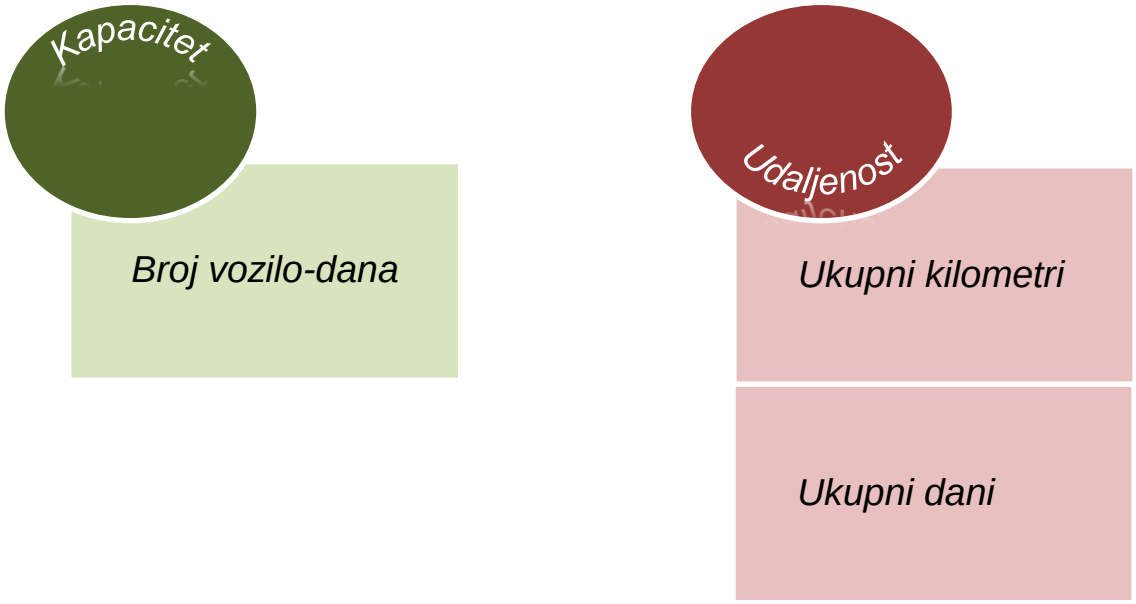
Kompromis između ova dva čimbenika je, s financijskog aspekta, često u središtu definiranja najisplativijih rješenja u području transportnih problema te predstavlja osnovno polazište za većinu pitanja vezanih uz transportne troškove (Slika 5).



Slika 5. Dva često suprotstavljena pokretača transportnih troškova
Izvor: Izradio autor

5.2. Varijable koje utječu na pokretače troškova

Prije navođenja varijabli, potrebno je definirati odgovarajuće pokazatelje i mjerne jedinice pokretača troškova. Za kapacitet je to broj vozilo-dana[9], dok udaljenost opisuju ukupni kilometri i ukupni dani (Slika 6).



Slika 6. Mjerne jedinice pokretača transportnih troškova
Izvor: Izradio autor

Slijedom navedenog, varijable koje utječu na pokretače troškova, a povezane su s kapacitetom i brojem vozilo-dana, redom su sljedeće: [18]

- Vrste vozila ili drugih transportnih sredstava te njihovi nosivi kapaciteti (npr. kubni metri kojima se može napuniti transportni prostor pojedinog vozila ili nekog drugog transportnog sredstva);
- Broj vozila;
- Broj vozilo-dana koji su dostupni za rad (npr. u jednoj godini), ne uključujući dane blagdana i dane u kojima je predviđeno održavanje vozila;

[9] Vozilo-dani su praktična i korisna mjerna jedinica distribucijskog kapaciteta zato što kvantificiraju kapacitet, odnosno označuju broj dana (npr. u jednoj godini) u kojima je vozilo dostupno za rad ili broj dana u kojima je vozilo bilo u pogonu. S ovakvim se pristupom procjenjuje sposobnost vozila da u određenom vremenskom razdoblju isporuči odgovarajući volumen robe, temeljem broja vozilo-dani koji su potrebni za dovršetak isporuke. Rezultat procjene se obično uspoređuje s brojem vozilo-dana u kojima je vozilo uistinu i dostupno za rad, kako bi se u konačnici odredio ukupan broj potrebnih vozila.

- Broj sati u danu u kojima vozač smije upravljati vozilom (obično je to 9 sati unutar 24-satnog perioda);
- Broj vozača;
- Postotak vremena u kojem je vozilo u funkciji distribucije.

Nadalje, najučestalije varijable koje su povezane s čimbenikom udaljenosti i ukupnim brojem kilometara, jesu: [18]

- Mjesto isporuke;
- Udaljenost do i između točaka na transportnoj mreži;
- Učestalost putovanja;
- Ograničenja u pogledu državnih/regionalnih/lokalnih granica.

Varijable koje se također dotiču čimbenika udaljenosti, ali se odnose na ukupne dane, su: [18]

- Ukupni kilometri koji će biti prijeđeni (korak iznad);
- Brzina vozila za prevaljivanje predviđene udaljenosti;
- Vrijeme koje je potrebno za provedbu bitnih distribucijskih funkcija, odnosno logističkih aktivnosti, dok je vozilo u pogonu (ukrcaj, iskrcaj, prekrcaj, pregled i provjera isporučene robe i dr.);
- Broj sati u danu u kojima vozač smije upravljati vozilom (obično je to 9 sati unutar 24-satnog perioda).

Nije na odmet zamijetiti da, s obzirom na prirodu varijabli koje utječu na pokretače troškova, jedna varijabla može biti ograničavajuća za drugu. Primjerice, varijable koje utječu na ukupne dane, a koje su potrebne za prevaljivanje predviđene udaljenosti (brzina vozila, vrijeme ukrcaja i iskrcaja robe na svakoj lokaciji i dr.), ograničit će ukupne kilometre koji će biti prijeđeni u jednome danu. Nadalje, varijabla kao što je dopušteno vrijeme, odnosno radni sati u kojima vozač može upravljati vozilom, odredit će broj vozilo-dana (mjereno u kapacitetu), ali će također imati utjecaj i na ukupne dane koji su potrebni za prevaljivanje predviđene udaljenosti. [18]

Iz ovoga je vidljivo kako idealno transportno rješenje nije lako postići jer će jedna varijabla u velikom broju slučajeva limitirati drugu, odnosno jedna će varijabla umanjivati transportni trošak, nauštrb druge koja će na transportni trošak utjecati nepovoljno i povećavati ga. Radi toga, u svakodnevnom poslovnom okruženju, upravljanje transportom i pripadajućim troškovima zahtijeva primjenu optimizacijskih alata, a sve u cilju pronalaska optimalnog rješenja koje će u određenoj, ali ne i potpunoj mjeri, udovoljavati željama korisnika s jedne strane, a mogućnostima logističkog operatera s druge strane.

Pronalazak takvog optimalnog rješenja može se opisati kroz postupak usmjeravanja vozila unutar transportne mreže. Taj postupak podrazumijeva uvođenje određenih organizacijskih promjena zbog unaprjeđenja transportnih procesa prilikom distribucije robe i usluga. Postupak se odvija po principu u kojemu se, usporedno s približavanjem konačnom rješenju, nastoje postići značajnije uštede u vidu prijeđenog puta, utrošenog vremena i nastalog troška.

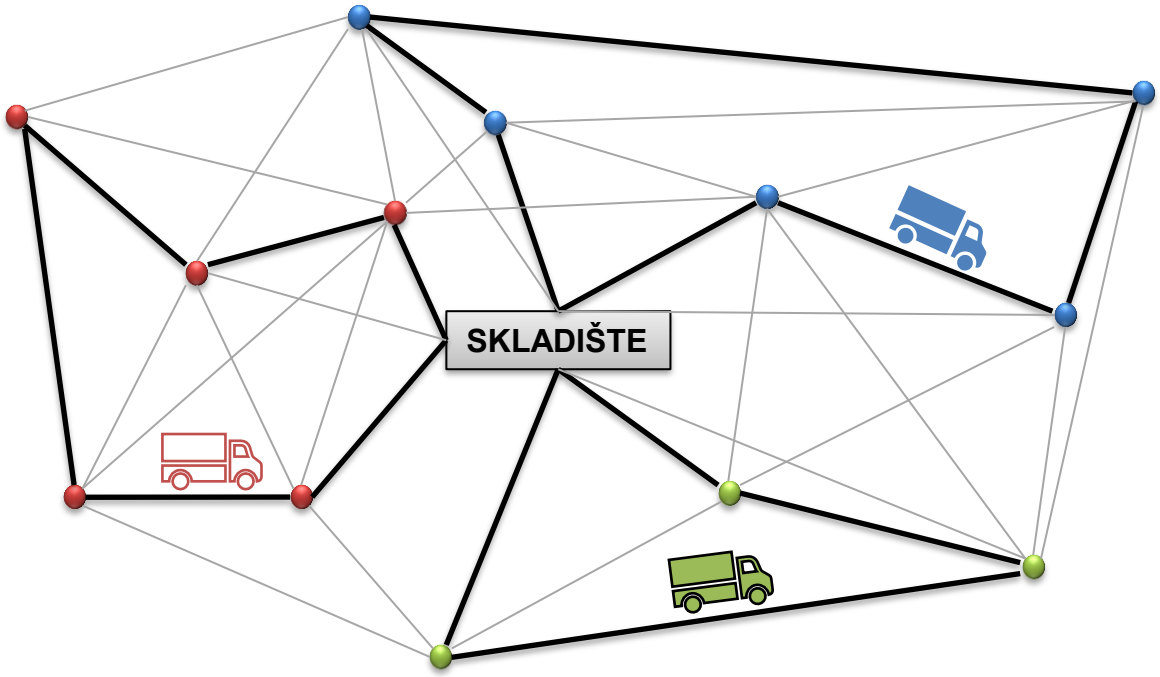
6. PROBLEM USMJERAVANJA VOZILA

Uspješno upravljanje poduzećem zahtijeva od logističkog operatera uvođenje određenih organizacijskih promjena, u cilju unaprjeđenja procesa i smanjenja troškova, a jedan od postupaka za takvo što može se pronaći u rješavanju problematike oko usmjeravanja vozila.

Problem usmjeravanja vozila[10] (VRP[11]) predstavlja općenito ime za cjelokupni skup optimizacijskih problema, a sastoji se od sljedećih komponenti (Slika 7):

1. *Jedno ili više polazišta, uobičajeno skladišta:* Skladište se smatra početnim i završnim vrhom svakog VRP-a. Najčešće je ono samo jedno, ali valja istaknuti kako postoje situacije u kojima je moguće imati i više od jednog skladišta.
2. *Veći broj odredišta (korisnici, gradovi i sl.):* Odredišta se nalaze uokolo skladišta na prostorno disperziranim lokacijama i karakterizira ih određena potražnja za robom.
3. *Vozila:* U svakom VRP-u postoji određeni broj vozila koja opslužuju korisnike i imaju pripadajuća ograničenja. Obično su to ograničenja u vidu kapaciteta, ali mogu biti vezana i uz trošak, maksimalno vrijeme putovanja i sl.
4. *Rute:* Rute su sumirani putovi koje vozilo koristi prilikom služenja korisnika. Različite rute mogu imati različite troškove i vremena putovanja, a putovi u njima mogu biti jednosmjerni ili dvosmjerni.

[10] (engl. ***V**ehicle **R**outing **P**roblem*)
[11] U radu će se koristiti ova kratica, budući da se ista koristi u većini tematsko povezanih literatura, kako stranih, tako i domaćih.



Slika 7. Vizualni prikaz problema usmjeravanja vozila i njegovih komponenti
Izvor: Izradio autor

Kod uobičajenog procesa usmjeravanja, skup korisnika biva služen od skupa vozila u zadanom vremenu. Vozila kreću iz skladišta i pri transportu koriste mrežu prometnica. [19]

Mreža prometnica koja se koristi za transport najčešće se opisuje grafom. Za graf se može reći da je potpun onda kada je svaki par vrhova povezan jednim lukom. [20] U takvom grafu lukovi predstavljaju prometnice, a vrhovi grafa – korisnike i skladišta (Slika 7). Lukovi mogu biti jednosmjerni ili dvosmjerni, a uz svaki se luk obično nalazi ponder koji korespondira s geometrijskom udaljenošću, vremenom vožnje prijevoznog sredstva ili cijenom cjelokupnog puta između dva korisnika.

Transport robe se osigurava pomoću grupe vozila koja svojom veličinom i karakteristikama zadovoljavaju zahtjeve korisnika. Definirajući karakteristike vozila, ne smije se zaboraviti na vozače kod kojih se u obzir moraju uzeti zahtjevi kao što su dopuštena vremena vožnje i ukupnog rada (sati vožnje i radni sati), broj obveznih stajanja itd. Ti su zahtjevi bitni jer se izravno prenose na značajke vozila, a značajke vozila su sljedeće [19]:

- Početno skladište iz kojeg vozilo kreće te procjena vjerojatnosti da se nakon posluživanja korisnika vozilo vrati u drugo skladište;
- Kapacitet vozila izražen kroz maksimalnu težinu, volumen ili broj paleta koje vozilo može prihvatiti;
- Mogućnost vozila da raspodijeli teretni prostor u komore određenog kapaciteta i određene namjene, ovisno o robi koja je predviđena za ukrcaj i prijevoz.
- Troškovi povezani s korištenjem vozila prema prijeđenoj udaljenosti, utrošenom vremenu i odabranoj ruti.

Rute preko kojih se korisnici poslužuju, započinju i završavaju u jednom ili više skladišta, pri čemu je svako skladište determinirano brojem i vrstama vozila koja ga poslužuju, kao i količinom robe koja se pohranjuje u njemu. U realnim uvjetima, pojedino vozilo može odraditi veći broj ruta unutar radnog vremena, a same rute mogu potrajati dulje od jednog dana. Takve situacije nerijetko nastaju kada nije unaprijed poznata količina dobara koju korisnik zahtijeva pa je uvijek poželjno detaljnije razmotriti neizvjesnu situaciju u kojoj nisu poznate sve zakonitosti problema. [19]

Nadalje, rute moraju zadovoljavati i operativna ograničenja koja se najčešće javljaju kroz karakteristike vozila i korisnika, a mogu se ticati i samih prirodnih zapreka u transportu. Neki od takvih tipičnih operativnih zahtjeva koji se stavljaju pred logističkog operatera jesu sljedeći: [19]:

- Pri vožnji, vozilo ne smije prevoziti više tereta od dopuštenog (nazivnog);
- Korisnik je u mogućnosti zahtijevati dostavu, prikupljanje ili oboje odjednom;
- Korisnik se mora poslužiti unutar određenog vremenskog perioda na kojemu on sam inzistira, ali se pritom ne smije ići u suprotnost s radnim vremenom vozača.[12]

Uvođenjem ovih i sličnih ograničenja, izravno se utječe na konstrukciju ruta prilikom optimizacijskog procesa. Zbog toga se VRP vrlo često dekomponira na nekoliko odvojenih podproblema od koji svaki ima neko specifično ograničenje koje se mora ispoštovati i uključiti u sami proces optimizacije.

[12] Ponekad nije moguće u potpunosti ispuniti zahtjeve korisnika pa se tada logistički operater odlučuje na nepopularne poteze kao što su smanjenje količine robe ili uskraćivanje posluživanja određenog podskupa korisnika.

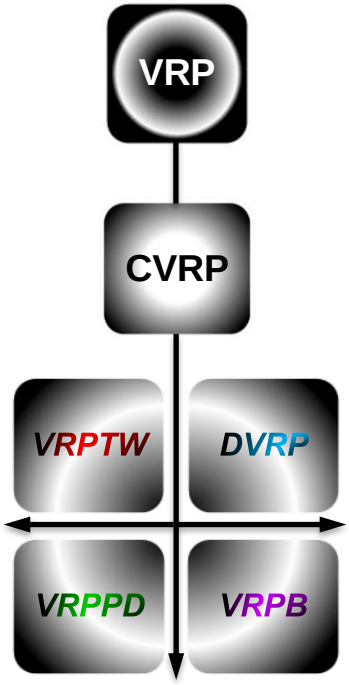
6.1. Podproblemi usmjeravanja vozila

Ovaj prometni problem definiran je 1959. godine, a pokretač svega bila je potreba za racionalizacijom benzinskih postaja prilikom njihovog opskrbljivanja gorivom. Stoga se može reći da je VRP najprije bio poznat kao problem otpremanja kamiona. [21]

Takva osnovna definicija problema usmjeravanja vozila, tijekom proteklih je godina proširena mnogobrojnim ograničenjima. Razlog uvođenja dodatnih ograničenja jest taj što je VRP previše jednostavan kao apstrakcija da bi se njime problemi transporta mogli modelirati. Zato su se tijekom vremena razvile mnoge varijacije VRP-a koje ulaze u same istančanosti svakog pojedinog podproblema te na taj način omogućuju lakše sagledavanje i razumijevanje VRP-a u cjelini (Slika 8):

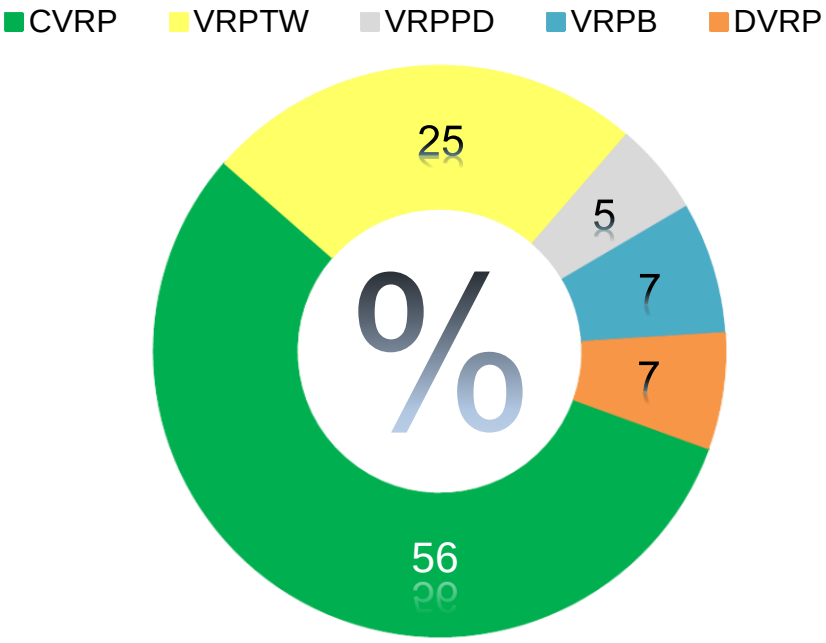
- Problem usmjeravanja vozila s ograničenjem kapaciteta (engl. ***C****apacitated* ***V****ehicle* ***R****outing* ***P****roblem* – CVRP);
- Problem usmjeravanja vozila s ograničenjem duljine rute (engl. ***D****istance-constraint* ***V****ehicle* ***R****outing* ***P****roblem* – DVRP);
- Problem usmjeravanja vozila s vremenskim ograničenjem (engl. ***V****ehicle* ***R****outing* ***P****roblem with* ***T****ime* ***W****indows* – VRPTW);
- Problem usmjeravanja vozila s dostavom i prikupljanjem (engl. ***V****ehicle* ***R****outing* ***P****roblem with* ***P****ickup and* ***D****elivery* – VRPPD);
- Problem usmjeravanja vozila s dostavom i povratnim prikupljanjem (engl. ***V****ehicle* ***R****outing* ***P****roblem with* ***B****ackhauls* – VRPB).

Različite kombinacije i situacije navedenih podproblema mogu generirati mnoge varijacije VRP-a, ali njegov zadatak uvijek ostaje isti, a to je da skupinom vozila, koja su locirana u skladištu, obiđe sve korisnike, uz uvjet da svakog korisnika posjeti samo jedno vozilo i da se sva vozila vrate u skladište. Pri tome je glavni cilj omogućiti pronalazak onih transportnih ruta koje su obilježene minimalnim vrijednostima, bilo da se radi o trošku, udaljenosti, vremenu, broju vozilu i vozača ili nekom drugom faktoru.



Slika 8. Hijerarhijski prikaz podproblema VRP-a
Izvor: Izradio autor

Na temu VRP-a i pripadajućih podproblema, izrađen je veliki broj znanstveno-istraživačkih radova. U grafikonu je dan njihov pregled prema relativnoj prisutnosti (važnosti), odnosno prema količini objavljenih radova i članaka o njima (Grafikon 2).



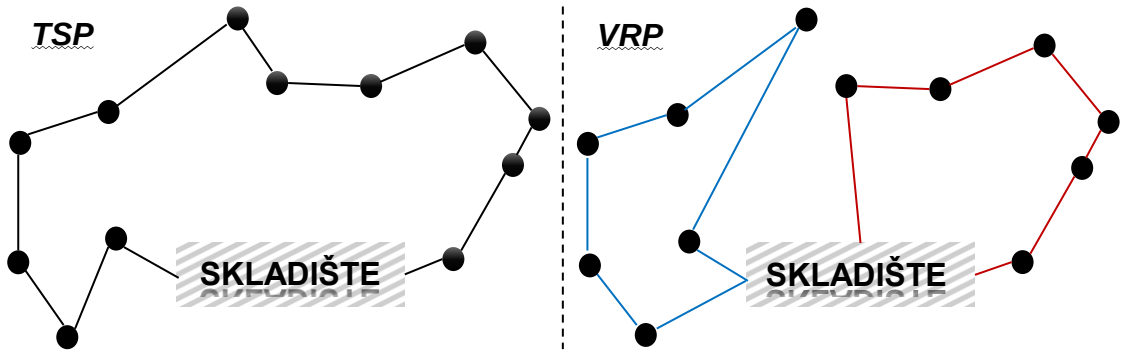
Grafikon 2. Relativna prisutnost podproblema VRP-a u istraživanjima
Izvor: Izradio autor prema [22]

Iz grafikona se jasno može vidjeti kako je CVRP najčešća varijanta u razmatranju podproblema VRP-a. Konkretno, od 144 znanstvena rada koja se bave pitanjima VRP-a, kod njih 128 postoji doticanje s problematikom CVRP-a. To je gotovo 90% udjela ukoliko se u obzir uzimaju svi postojeći podproblemi, odnosno 56% udjela ukoliko se naglasak stavlja samo na one najznačajnije podprobleme koji su prethodno spomenuti i prikazani.

Druga popularna varijanta je ona s vremenskim ograničenjem, odnosno vremenskim prozorom. Tako se od 144 znanstvena rada, VRPTW spominje u njih 57, što je približno 40% udjela od svih dosad istraženih podproblema VRP-a. U odnosu na samo one najznačajnije podprobleme, VRPTW zauzima oko 25% udjela.

VRP s dostavom i povratnim prikupljanjem (VRPB) svoje mjesto nalazi u 17 radova (12%), VRP s ograničenjem duljine rute u 15 radova (10%), dok VRP s dostavom i prikupljanjem biva opisivan u 12 od 144 znanstvena rada, a to je nešto više od 8% ukupne prisutnosti. Naravno, taj postotak je manji ukoliko se omjer radi samo za 5 glavnih podproblema VRP-a, stoga u tom slučaju iznosi 5%.

Osim navedenih podproblema, postoji i jedan specijalni slučaj VRP-a. Radi se o problemu trgovačkog putnika (engl. ***T**ravelling **S**alesman **P**roblem* – TSP), u kojemu se raspolaže samo s jednim vozilom (umjesto s dva ili više) i kod kojega ne postoje dodatna ograničenja. Cilj i zadatci takvog problema ostaju isti, no on se uglavnom odvaja od ostalih podproblema te se smatra zasebnim u odnosu na problem VRP-a (Slika 9).



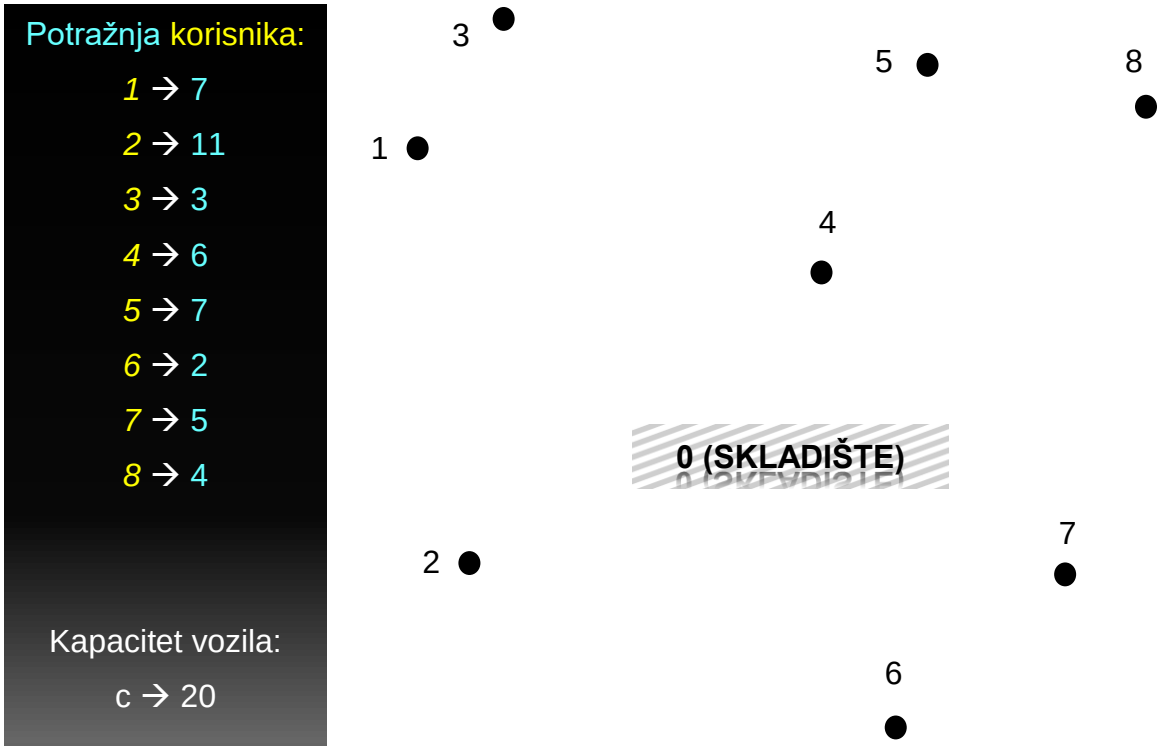
Slika 9. Osnovna razlika između TSP-a i VRP-a
Izvor: Izradio autor

Na slici se može primijetiti da je rješenje TSP-a sačinjeno od samo jedne rute, dok kod VRP-a rješenje problema čini skup ruta (dvije ili više). Zbog toga se ta dva problema vrlo često odvajaju u zasebne cjeline, gdje istraživanje jednog isključuje drugi problem. Samim time TSP ne ulazi u domenu ovog istraživanja, a prvi podproblem koji ulazi i koji se detaljnije razmatra, jest CVRP problem.

6.1.1. Problem usmjeravanja vozila s ograničenjem kapaciteta

CVRP je glavni i najzastupljeniji podproblem VRP-a, a ujedno je i najjednostavniji. Zbog toga se u neformalnom govoru CVRP nerijetko koristi kao općeniti naziv za klasu problema usmjeravanja vozila (Slika 8).

U CVRP-u, dakle, svako vozilo koje se koristi za transport i distribuciju ima ograničeni kapacitet tereta, a isto tako svaki od korisnika ima određenu potražnju za teretom koji mu treba biti dostavljen. U takvom su odnosu unaprijed poznati svi korisnici, točnije zahtjevi korisnika. Nadalje, vozila su identična i svima im je zajednički polazni vrh u glavnom skladištu (Slika 10). [19]



Slika 10. Primjer CVRP-a
Izvor: Izradio autor

CVRP, ali i ostali podproblemi VRP-a, mogu se jednostavno izraziti uz pomoć teorije grafova[13], sljedećim izrazima: [19]

- G (V,A) – potpuni graf
- V (0, …, n) – skup vrhova (vrhovi *i = 1, …, n* predstavljaju korisnike, dok vrh s indeksom *0* predstavlja skladište)
- A – skup lukova (bridova)

Svaki korisnik *i (i = 1, …, n)* povezan je s poznatim zahtjevom q_i, dok skladište ima fiksni zahtjev $q_o = 0$ jer ne postoji takav uvjet u kome stoji da se u skladište mora dopremiti/vratiti određeni teret. Također, u skladištu se nalazi skup od *k* identičnih vozila gdje svako vozilo ima kapacitet *c*. Pritom svako vozilo može odraditi najviše jednu rutu. [19]

Ukoliko se povuče paralela ovih izraza s danim primjerom CVRP-a (Slika 10), tada se može vidjeti kako *0* u primjeru simbolizira centralno skladište, dok brojevi od *1* do *8* označavaju lokacije korisnika koje trebaju biti posjećene.

Dalje, potrebno je osigurati i istinitost uvjeta $q_i \leq c$ za svaki *i (i = 1, …, n)*. Naravno, za ispunjenje tog uvjeta pretpostavlja se da *k* nije manji od k_{min}, gdje k_{min} označava minimalni broj vozila nužnih za posluživanje svih korisnika. [19]

Nakon toga se rješavanje samog problema ogleda u određivanju *x* ruta, a pritom svaka ruta treba biti povezana samo s jednim vozilom. Osim tog uvjeta, rješenje treba zadovoljavati i sljedeće uvjete: [19]

- Svaki korisnik sudjeluje isključivo u jednoj ruti;
- Svaka ruta treba započeti i završiti u skladištu;
- Suma zahtjeva od strane korisnika ne smije biti veća od kapaciteta vozila, i tako za svaku pojedinu rutu.

[13] Teorija grafova jedna je od grana matematike koja nalazi veliku primjenu u prometnoj djelatnosti. Grafom je moguće opisivati modele određenog realnog sustava, kao što su gradovi povezani s cestama, što je od posebnog značaja za potrebe opisivanja problema usmjeravanja vozila.

Matematička formulacija dosad navedenih izraza, uvjeta i pravila, može biti predstavljena sljedećim modelom:

$$\min F = \sum_{i=0}^{n} \sum_{j=0}^{n} w_{ij} \cdot x_{ij} \tag{1}$$

$$\sum_{i=0}^{n} x_{ij} = 1 \qquad \forall\, j = 1, 2, \ldots, n \tag{2}$$

$$\sum_{j=0}^{n} x_{ij} = 1 \qquad \forall\, i = 1, 2, \ldots, n \tag{3}$$

$$\sum_{i=1}^{n} x_{0i} = k \tag{4}$$

$$\sum_{i=1}^{n} x_{i0} = k \tag{5}$$

$$x_{ij} \in \{0,1\} \qquad \forall\, i, j \in V \tag{6}$$

gdje je:

n broj korisnika

w_{ij} cijena na luku od korisnika *i* do korisnika *j*

x_{ij} binarna varijabla odnosno varijabla odluke (ima vrijednost 1 ukoliko vozilo prevozi teret između korisnika *i* i *j*, a u suprotnom njena vrijednost iznosi 0)

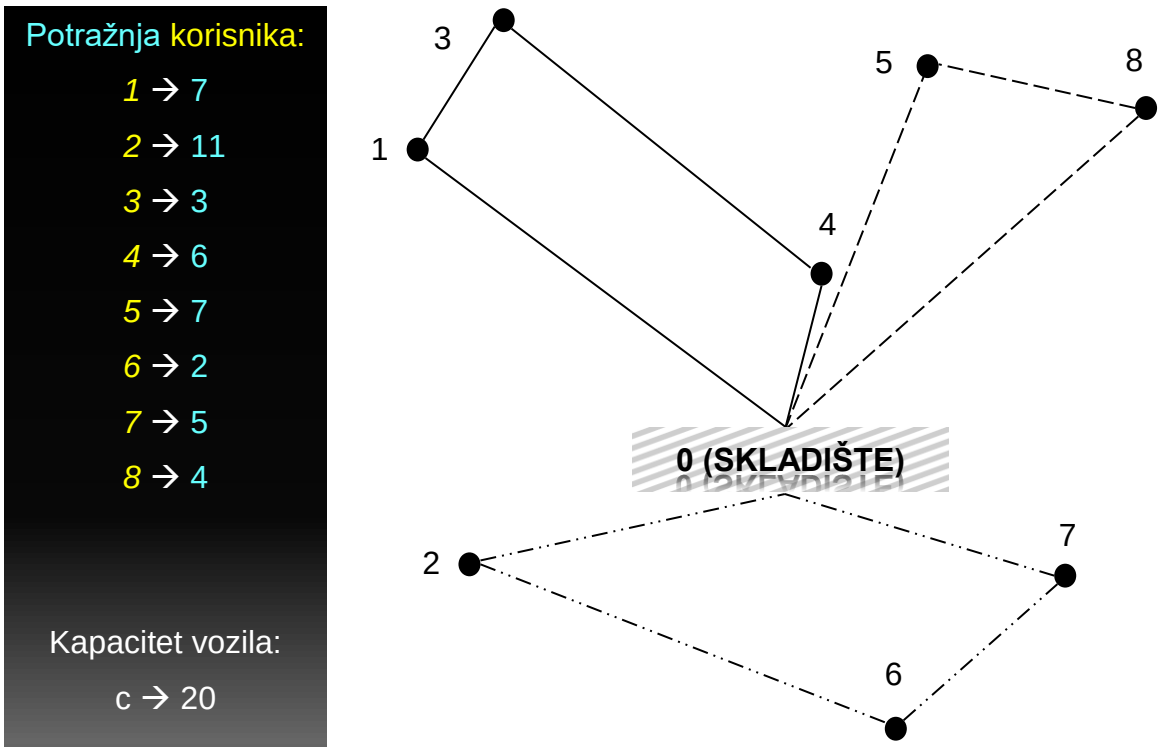
k broj vozila

Funkcija cilja CVRP-a, dana jednadžbom (1), ogleda se u minimiziranju ukupnog troška transporta prilikom posluživanja svih korisnika. Dodatno smanjenje troška može se postići na način da se, uz smanjenje ukupne cijene lukova, smanji i broj ruta. Smanjenjem broja ruta posljedično se ostvaruju uštede i na troškovima vozila (manji je broj vozila).

Ograničenja dana jednadžbom (2) i jednadžbom (3) ukazuju da jedno vozilo dolazi do korisnika, kao i da jedno vozilo odlazi od korisnika. Jednako tako, ograničenja dana jednadžbama (4) i (5) ukazuju da *k* vozila odlazi/dolazi iz/u skladišta/e.

Ograničenje dano izrazom (6) definira x_{ij} kao binarnu varijablu, a to znači da ona može poprimiti isključivo vrijednosti 0 ili 1. Vrijednost 0 će poprimiti za one lukove *i* i *j* koji ne ulaze u rješenje problema CVRP-a, dok će vrijednost 1 poprimiti za one lukove *i* i *j* koje vozilo koristi u optimalnoj ruti, sukladno rješenju.

Nakon ovakvog slojevitog i temeljitog pojašnjenja problematike CVRP-a, rješenje početnog primjera više nije nepoznanica. Uz zadani kapacitet vozila od 20 jedinica tereta i sukladno potražnji svakog pojedinog korisnika, konstruirane su tri rute (Slika 11).



Slika 11. Rješenje primjera CVRP-a
Izvor: Izradio autor

Prva ruta ima redoslijed obilaska *0 – 2 – 6 – 7 – 0* i iz priloženog se vidi kako ruta udovoljava početnim uvjetima kapaciteta. Suma zahtjeva od strane korisnika u toj ruti iznosi 18 jedinica tereta (11 + 2 + 5), što je za dvije jedinice manje od raspoloživog kapaciteta vozila od 20 jedinica tereta. Dodavanje još jednog susjednog vrha, odnosno još jednog susjednog korisnika, za ovu bi rutu značilo prekoračenje dopuštenog kapaciteta vozila od 20 jedinica tereta i zbog toga ova ruta ima redoslijed obilaska sukladno navedenom.

Iduća ruta koja slijedi, jest ruta s redoslijedom obilaska *0 – 1 – 3 – 4 – 0.* I ova ruta, kao i prethodna joj, odgovara uvjetima ograničenja kapaciteta. Suma zahtjeva korisnika u toj ruti iznosi 16 jedinica tereta (7 + 3 + 6).

Preostali su još vrhovi 5 i 8 pa se korisnici u njima dodjeljuju trećoj zasebnoj ruti, s redoslijedom obilaska *0 – 5 – 8 – 0.* Da bi se preostali vrhovi mogli spojiti u jednu rutu, potrebno je također provjeriti ograničavajući uvjet kapaciteta i ustvrditi da nema prepreka za njihovo spajanje. U ovom slučaju, taj je kriterij zadovoljen budući da suma zahtjeva korisnika iznosi 11 jedinica tereta (7 + 4) pa se teret bez problema može ukrcati u vozilo koje raspolaže teretnim prostorom za 20 jedinica.

Osim ove provjere u kojoj suma zahtjeva u svakoj pojedinoj ruti ne prelazi dopušteni kapacitet vozila, potrebno je još potvrditi dva početna uvjeta. Jedan od njih nalaže da svaki korisnik može učestvovati u samo jednoj ruti, a drugi da svaka ruta mora započeti i završiti u skladištu. Iz rješenja primjera CVRP-a jasno se vidi kako su i ti uvjeti u svakoj ruti zadovoljeni.

Konačno, ukoliko se ograničenje kapaciteta zamjenjuje ograničenjem maksimalnog puta ili vremenskog trajanja, CVRP se tada pretvara u varijantu podproblema koja se naziva DVRP, odnosno tada se radi o problemu usmjeravanja vozila s ograničenjem duljine rute.

6.1.2. Problem usmjeravanja vozila s ograničenjem duljine rute

U ovome problemu udaljenost d_{ij} ne smije prelaziti maksimalno dozvoljeni put d na ruti, a ukoliko se lukovi vrednuju vremenom putovanja, tada vrijeme t_{ij} ne smije prelaziti maksimalno dozvoljeno vrijeme t provedeno na ruti. U potonjem slučaju, vremenu putovanja potrebno je dodati i vrijeme posluživanja s koje predstavlja vrijeme zadržavanja vozila kod korisnika. Ono uključuje obavljanje potrebnih radnji kao što su iskrcaj, rješavanje dokumentacije vezane uz transport i sl. [19]

Rješavanje problema DVRP-a sastoji se od utvrđivanja *x* ruta u kojima je ukupna prevaljena udaljenost minimizirana. Pri tome se trebaju ispoštovati sljedeći uvjeti: [23]

- Svaki korisnik može biti posjećen samo u jednoj ruti;
- Svaka ruta mora započeti iz skladišta, nakon toga posjetiti podskup korisnika i na koncu se vratiti u skladište;
- Svako vozilo može sudjelovati u najviše jednoj ruti;
- Svaka ruta mora prijeći manju udaljenost ili imati kraće vrijeme trajanja prijevoza od maksimalno dopuštenih vrijednosti.

Iz ovih se uvjeta jasno vidi kako DVRP u mnogočemu može biti poistovjećen s CVRP-om pa se tako i formulacija problema, zajedno s relacijama i ograničenjima, odvija na gotovo identičan način kao i kod CVRP-a, s jednom jedinom promjenom u funkciji cilja:

$$\min \mathrm{F} = \sum_{i=0}^{n} \sum_{j=0}^{n} d_{ij} \cdot x_{ij} \tag{7}$$

$$\sum_{i=0}^{n} x_{ij} = 1 \qquad \forall\, j = 1, 2, \ldots, n \tag{8}$$

$$\sum_{j=0}^{n} x_{ij} = 1 \qquad \forall\, i = 1, 2, \ldots, n \tag{9}$$

$$\sum_{i=1}^{n} x_{0i} = k \tag{10}$$

$$\sum_{i=1}^{n} x_{i0} = k \tag{11}$$

$$x_{ij} \in \{0,1\} \qquad \forall\, i, j \in V \tag{12}$$

gdje je:

n broj korisnika

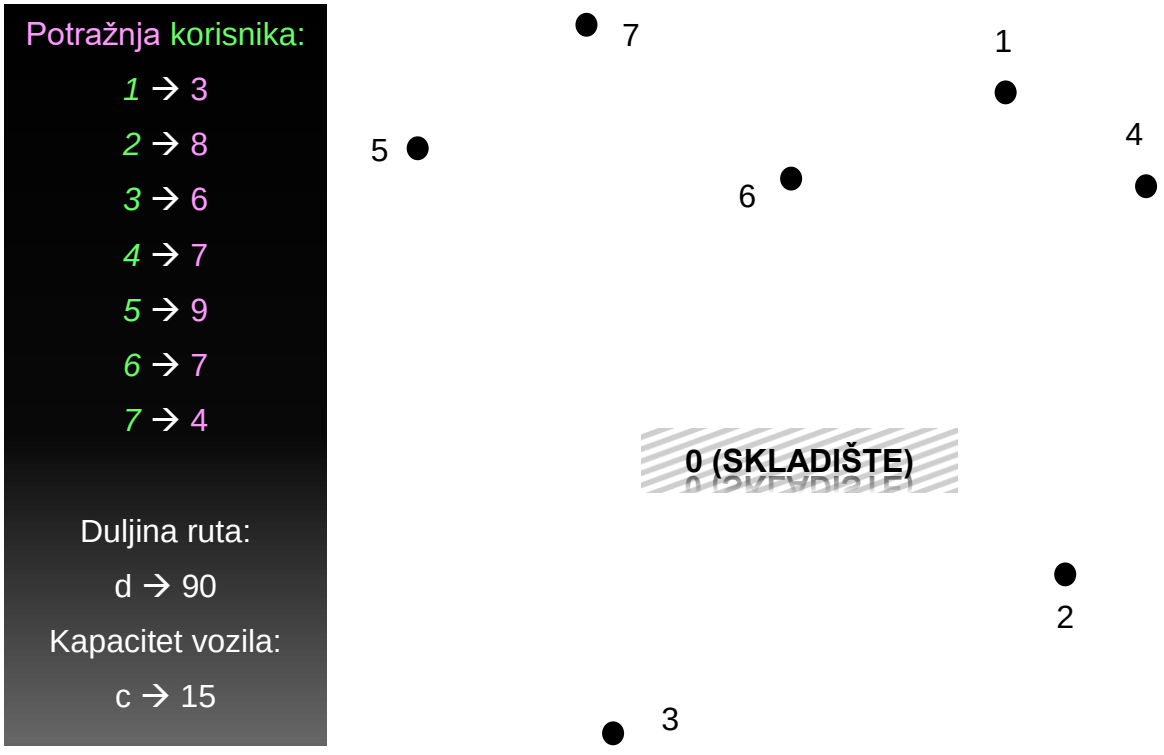
d_{ij} duljina luka između korisnika *i* i *j*

x_{ij} binarna varijabla/varijabla odluke (ima vrijednost 1 ukoliko vozilo prevozi teret između korisnika *i* i *j*, a ako ga ne prevozi, njena vrijednost iznosi 0)

k broj vozila

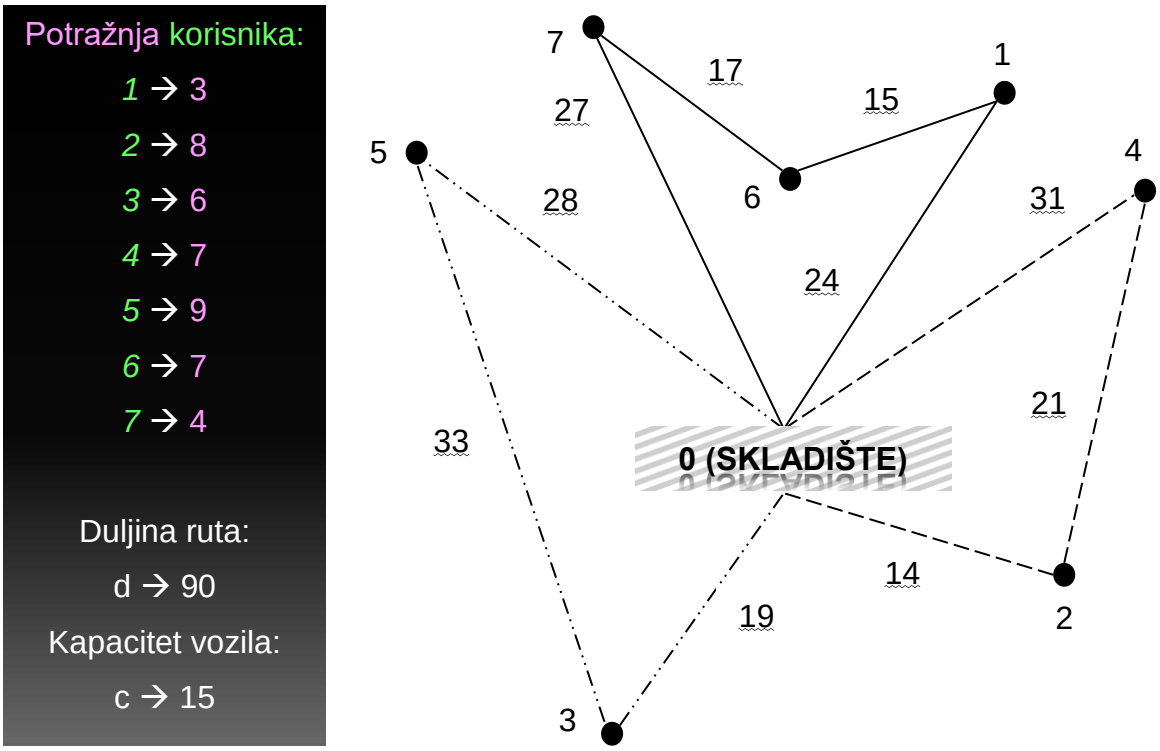
U ovoj formulaciji funkcija cilja, prikazana jednadžbom (7), zahtijeva minimiziranje udaljenosti u prijeđenom putu prilikom posluživanja korisnika. Pored toga, ograničenja dana jednadžbama (8) i (9) osiguravaju da svaki korisnik biva posjećen i poslužen samo jedanput, dok ograničenja dana jednadžbom (10) i jednadžbom (11) nalažu da *k* vozila bude korišteno prilikom napuštanja skladišta radi distribucije, ali i vraćanja u isto nakon njene realizacije. Ograničenje dano izrazom (12) iziskuje korištenje binarnih varijabli 0 i 1 prilikom određivanja ruta koje (ne)ulaze u konačno rješenje DVRP problema.

Nakon ovoga treba još spomenuti i posebnu varijantu VRP-a koja se često pojavljuje u realnim transportnim situacijama, a koja kombinira ograničenja iz dva dosad obrađena podproblema – ograničenja kapaciteta i ograničenja duljine rute. Takva se varijanta VRP-a naziva problemom usmjeravanja vozila s ograničenom udaljenošću i kapacitetom (engl. ***D**istance-constrained **C**apacitated **V**ehicle **R**outing **P**roblem* - DCVRP). Ona je, zbog česte primjene u realnim logističkim sustavima, posebno pogodna za davanje primjera u kojima se pojašnjava način i koraci rješavanja problema usmjeravanja vozila (Slika 12).



Slika 12. Primjer DCVRP-a
Izvor: Izradio autor

U primjeru su dana dva ograničenja koja moraju biti vodilje u postupku rješavanja DCVRP-a. Jedno od njih tiče se ograničenja kapaciteta vozila koje u konkretnom primjeru iznosi 15 jedinica tereta, a drugo se svodi na ograničenje duljine rute, a iznosi 90 jedinica udaljenosti. Temeljem obznanjenih i opisanih formula, jednostavnim matematičkim postupcima može se doći do rješenja ovoga problema (Slika 13).



Slika 13. Rješenje primjera DCVRP-a
Izvor: Izradio autor

Slijeđenjem početnih uputa, poštivanjem danih ograničenja i postupnim dolaženjem do rješenja problema, iskristalizirale su se tri rute. Redoslijed obilaska prve, ujedno i najdulje rute, jest *0 – 1 – 6 – 7 – 0*. Suma zahtjeva u toj ruti iznosi 14 jedinica tereta (3 + 7 + 4), dok ukupna duljina rute iznosi 83 jedinice udaljenosti (24 + 15 + 17 + 27). Iz računa je vidljivo kako ruta u potpunosti odgovara postavljenim ograničenjima kapaciteta i duljine rute (14 < 15 i 83 < 90).

Druga ruta ima redoslijed *0 – 2 – 4 – 0* te je ona ujedno i najkraća. Zbroj duljina lukova u njoj iznosi 66 jedinica udaljenosti (14 + 21 + 31), a suma zahtjeva je identična dopuštenom kapacitetu jer iznosi 15 jedinica tereta (8 + 7). Ova ruta također

zadovoljava početna ograničenja budući da suma zahtjeva ne prelazi dopušteni kapacitet, a njena duljina je manja od maksimalne dopuštene (66 < 90).

Posljednja ruta slična je prethodnoj. Imaju isti broj korisnika koje je potrebno posjetiti, ali je ova ruta znatno dulja i sukladno tome zahtjevnija. Redoslijed obilaska u njoj je *0 – 3 – 5 – 0*. Dodatna sličnost s prethodnom rutom ostvaruje se u sumi zahtjeva, koja i kod ove rute iznosi 15 jedinica tereta (6 + 9). Nadalje, kao što je i navedeno, ruta je s 80 jedinica udaljenosti (19 + 33 + 28) osjetno dulja, ali i dalje ostaje unutar dopuštenih granica maksimalne udaljenosti (80 < 90).

Proširenje ove varijante VRP-a dovodi do problema usmjeravanja vozila s vremenskim ograničenjem (VRPTW). Za razliku od DVRP-a, u kojemu je glavni cilj minimiziranje ukupno prijeđene udaljenosti, kod VRPTW-a se primarni cilj ogleda u minimiziranju broja vozila, dok je tek u sekundarnom cilju pozornost potrebno posvetiti minimiziranju ukupne udaljenosti ili vremena. U VRPTW-u tako, pored prethodno navedenih ograničenja, postoje i vremenska ograničenja vezana uz neke, a vrlo često i sve korisnike.

6.1.3. Problem usmjeravanja vozila s vremenskim ograničenjem

Početak razmatranja VRPTW problema kreće od spoznaje da se *k* vozila nalazi u skladištu, dok *n* korisnika čeka na posluživanje. Pritom svaki od korisnika *i (i = 1, …, n)* ima q_i zahtjev (potražnju) za teretnim jedinicama. Nadalje, svako vozilo ima kapacitet c_k *(k = 1, …, m)* pa treba osigurati da količina robe ne prelazi raspoloživi kapacitet vozila. K tome je pretpostavka da sva vozila imaju jednak kapacitet, kao što je i pretpostavka da sva vozila imaju jednaku brzinu *v*.

Ukoliko zahtjevi korisnika premašuju dopušteni kapacitet vozila, ono ne može odjedanput poslužiti sve korisnike u ruti pa tada na raspolaganju preostaju dvije mogućnosti: [24]

1. Ukrcati manju količinu robe samo za određeni broj korisnika, potom se vratiti (jednom ili više puta) u skladište radi ostatka robe i tek onda distribuirati ostatak robe preostalim korisnicama.
2. Pripremiti još jedno ili više dodatnih vozila za ispunjavanje zahtjeva korisnika.

Ono što je specifično kod VRPTW-a, u odnosu na druge probleme, jest to da posluživanje svakog korisnika mora biti izvršeno unutar zadanog vremenskog intervala, odnosno prozora [a_i, b_i]. Trajanje posluživanja s unaprijed je poznato za svakog korisnika i potrebno ga je uračunati u ukupno vrijeme prilikom planiranja ruta. [25]

Osim vremena posluživanja s i vremena koje vozilo provede na svakom luku t_{ij}, dodatno se uračunava i vrijeme t_i *koje* označuje trenutak kada vozilo pristiže do korisnika *i.*

Ukoliko vozilo prije vremena a_i dođe do korisnika, u pravilu mu je dozvoljeno čekati do trenutka a_i, nakon čega se može započeti s posluživanjem. Ipak, u teoriji će prijevremeni dolazak prouzrokovati trošak e, kao što će i kašnjenje vozila uzrokovati plaćanje unaprijed ugovorenih penala (kazni) f.

Da bi se iz ovih podataka mogla uspješno izvesti matematička formulacija, problem je najprije potrebno opisati riječima. Tako se funkcija cilja i pripadajuća ograničenja mogu svesti na najjednostavniju moguću razinu, koja je lako razumljiva i upotrebljiva.

Otuda proizlaze iduće konstatacije koje tekstualno opisuju glavne pojedinosti problema. U njima se naglašava da rješenje problema predstavlja skup ruta koje će s minimalnim troškom poslužiti sve unaprijed definirane korisnike, uz zadovoljavanje sljedećih uvjeta: [19]

- Svaka ruta započinje i završava u centralnom skladištu;
- Svaki se korisnik posjećuje samo jedanput;
- Tijekom posluživanja korisnika u ruti, suma njihovih zahtjeva ne premašuje kapacitet vozila c;
- Posluživanje svakog korisnika započinje u točno definiranom vremenskom razdoblju [a_i, b_i];
- Za vrijeme posluživanja s_i, vozilo je zaustavljeno.

Nakon što je problem teorijski potkrijepljen, slijedi njegovo matematičko opisivanje:

$$\text{minF} = \sum_{i=0}^{n} \sum_{j=0}^{n} w_{ij} \cdot x_{ij} + \sum_{i=1}^{n} max\{e \cdot (a_i - t_i); 0; f \cdot (t_i - b_i)\} \quad (13)$$

$$t_{ij} = \sum x_{ij} \cdot \left(t_i + \frac{d_{ij}}{v} + s_i \right) \qquad \forall\, t_0 = 0,\ \ s_0 = 0 \quad (14)$$

$$\sum_{i=1}^{n} x_{0i} = \sum_{i=1}^{n} x_{i0} = k \quad (15)$$

$$\sum_{i=0}^{n} x_{ij} = 1 \qquad \forall\, j = 1, 2, \dots, n \quad (16)$$

$$\sum_{j=0}^{n} x_{ij} = 1 \qquad \forall\, i = 1, 2, \dots, n \quad (17)$$

$$\sum_{i=0}^{n} \sum_{j=0}^{n} x_{ij} \cdot q_i \leq c \quad (18)$$

$$x_{ij} \in \{0,1\} \qquad \forall\, i, j \in V \quad (19)$$

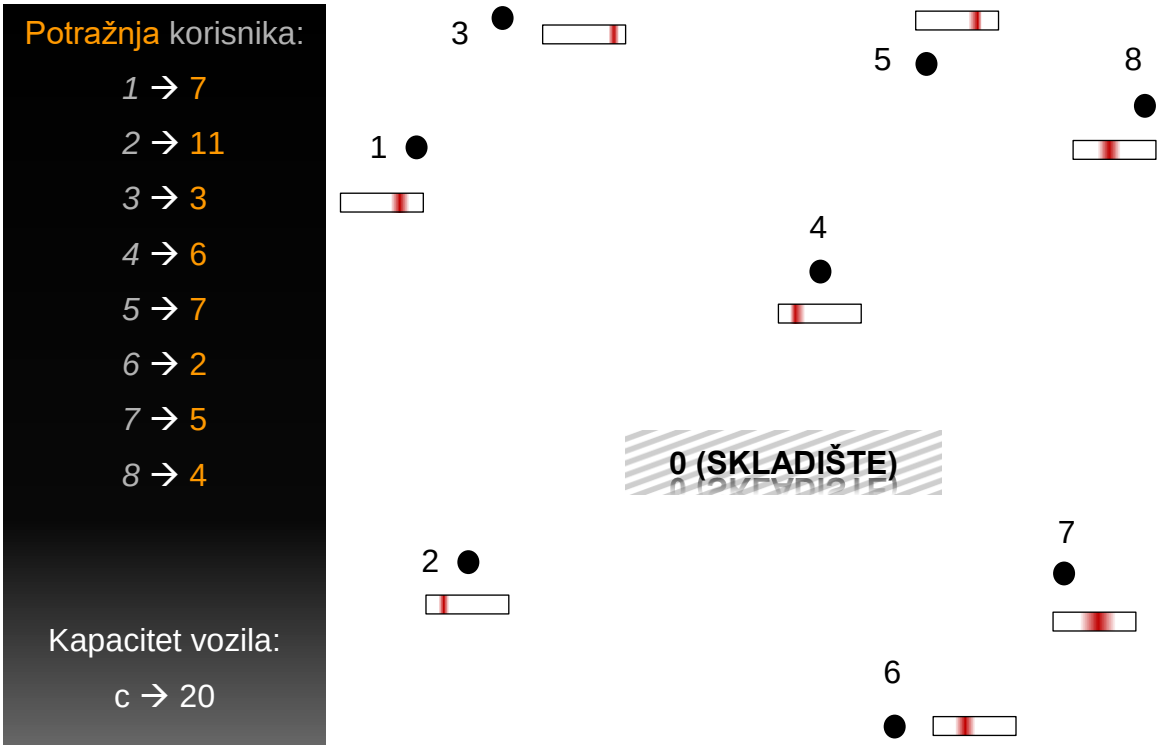
gdje je:

n	broj korisnika
w_{ij}	cijena na luku od korisnika *i* do korisnika *j*
x_{ij}	binarna varijabla/varijabla odluke (ima vrijednost 1 ukoliko vozilo prevozi teret između korisnika *i* i *j*, a u suprotnom poprima vrijednost 0)
e	trošak prouzrokovan prijevremenim dolaskom vozila na lokaciju korisnika
a_i	početak vremenskog prozora na lokaciji korisnika *i*
t_i	vrijeme pristizanja vozila do korisnika *i*
f	kazna prouzrokovana kašnjenjem vozila na lokaciju korisnika
b_i	završetak vremenskog prozora na lokaciji korisnika *i*
t_{ij}	vrijeme koje vozilo provodi na luku između korisnika *i* i *j*
d_{ij}	duljina luka između korisnika *i* i *j*
v	brzina vozila
s_i	vrijeme posluživanja korisnika *i*
k	broj vozila
q_i	zahtjev (potražnja) korisnika *i* za teretnim jedinicama
c	kapacitet vozila

Kod funkcije cilja koja je dana jednadžbom (13), prvi se dio formule ponavlja iz prethodnih jednadžbi, dok drugi dio formule definira vremenska ograničenja, gdje t_i predstavlja vrijeme dolaska vozila na lokaciju korisnika *i*, a $a_i - t_i$ vrijeme čekanja vozila na lokaciji korisnika *i*. Iz iduće formule (14) vrijedi izdvojiti s_i kao vrijeme posluživanja i t_{ij} kao vrijeme putovanja vozila između korisnika *i* i *j*. Ovdje treba napomenuti da kada je vozilo u skladištu ($i = 0$), tada vrijede uvjeti $s_0 = t_0 = 0$.

Nadalje, ograničenje dano jednadžbom (15) reprezentira broj vozila koja svoje putovanje započinju i završavaju u skladištu. Ograničenja dana jednadžbama (16) i (17) uvjetuju da svaki korisnik može biti služen od samo jednog vozila. U ograničenju koje je predstavljeno jednadžbom (18), ističe se da količina robe koju svako vozilo prevozi, ne smije prijeći dopušteni kapacitet *c*. Konačno, u posljednjem ograničenju koje je dano izrazom (19), profilirana je varijabla odluke koja dovodi do konačnog izgleda ruta.

Izgled i redoslijed obilaska ruta u VRPTW-u mogu se bitno razlikovati od izgleda i redoslijeda ruta u nekim drugim problemima. Primjerice, dizajniranje transportne mreže s CVRP ograničenjem, rezultirat će drugačijim izgledom i redoslijedom ruta u odnosu na istu transportnu mrežu koja je dizajnirana s VRPTW ograničenjem. To se jasno može vidjeti kada se primjeru CVRP-a iz jednog od prethodnih potpoglavlja (Slika 10), dodaju vremenska ograničenja obrađena kroz VRPTW formulaciju problema (Slika 14).

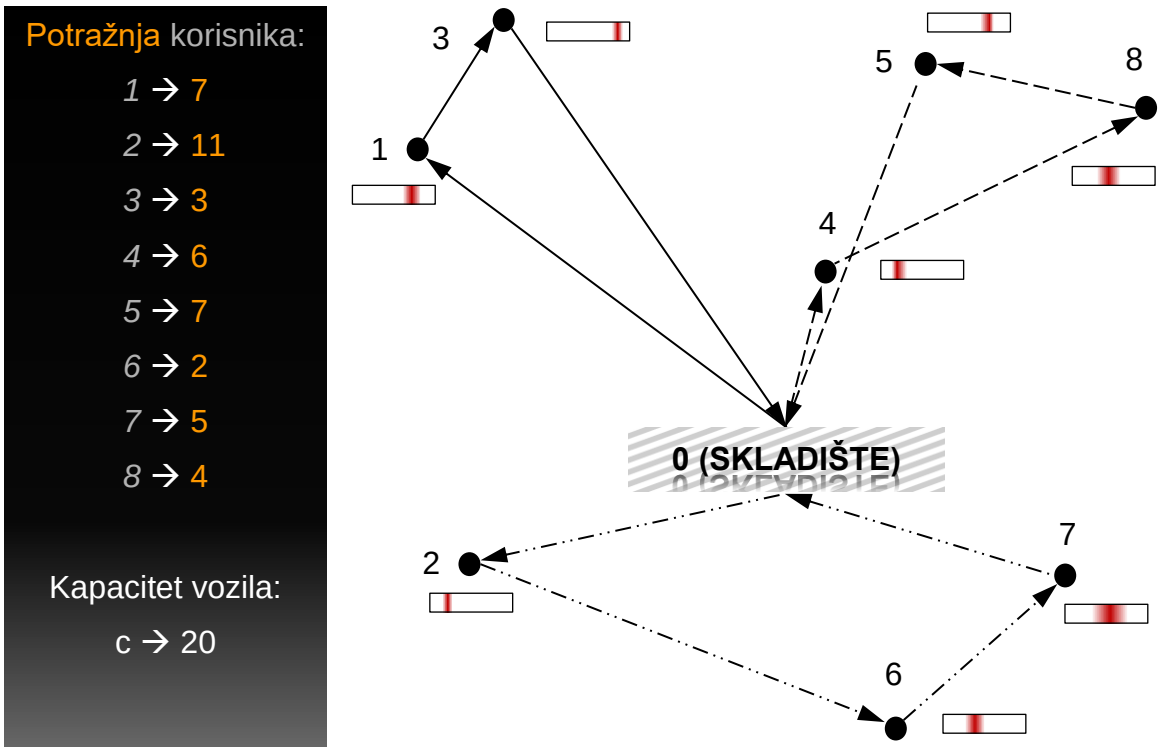


Slika 14. Primjer VRPTW-a
Izvor: Izradio autor

Na slici je prikazano zadavanje primjera VRPTW-a, u kojem, kao i u primjeru CVRP-a, broj *0* prikazuje centralno skladište, a brojevi od *1* do *8* predstavljaju lokacije korisnika koje trebaju biti posjećene. Brojčane vrijednosti s lijeve strane predstavljaju zahtjeve (potražnju) za teretom od strane svakog pojedinog korisnika, sukladno ograničavajućem kapacitetu vozila.

Razlika u odnosu na CVRP-a i druge primjere VRP-a, jesu pravokutnici koji se nalaze uz vrhove grafa. Ti pravokutnici predstavljaju vremenski horizont, a njihova širina odgovara razlici između vremena otvaranja i zatvaranja skladišta. Osjenčani dio unutar pravokutnika predstavlja položaj i širinu vremenskog prozora tijekom kojega se korisnik mora poslužiti. [25]

Dodavanje takvih vremenskih prozora zadanom primjeru CVRP-a, učinit će da konačno rješenje poprimi bitno drugačiji izgled i redoslijed obilaska ruta, a to će posljedično zahtijevati puno kompleksniji pristup prilikom planiranja transportnog procesa (Slika 15).



Slika 15. Rješenje primjera VRPTW-a
Izvor: Izradio autor

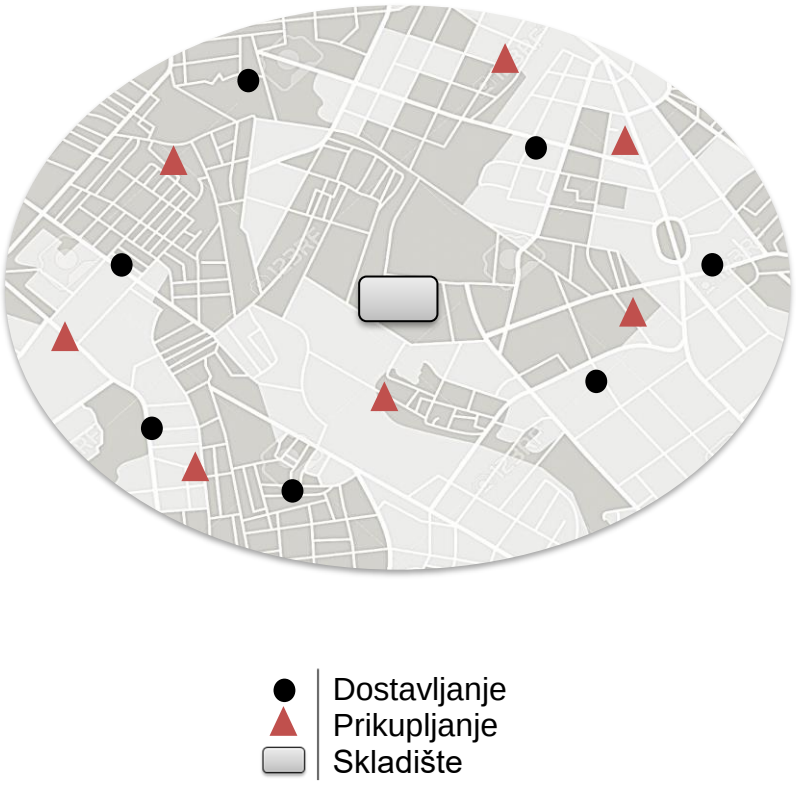
Iz priloženog se vidi kako prva ruta iz primjera CVRP-a ostaje ista i ne nailazi na promjene (*0 – 2 – 6 – 7 – 0*), dok preostale dvije rute (*0 – 1 – 3 – 0 i 0 – 4 – 8 – 5 – 0*) mijenjaju svoj izgled, odnosno redoslijed obilaska. Vidljivo je također da rute i dalje udovoljavaju unaprijed postavljenom ograničenju kapaciteta, ali je ovdje mnogo važnije da svaka ruta uspije zadovoljiti novopostavljeno ograničenje u obliku vremenskih prozora. Nakon što je to utvrđeno, moguće je krenuti sa serijom problema koji uz zahtjeve dostavljanja robe, imaju i zahtjeve prikupljanja robe. Prvi takav slučaj krije se u VRPPD problemu, a odmah iza njega slijedi i slučaj s VRPB problemom.

6.1.4. Problem usmjeravanja vozila s dostavom i prikupljanjem

Osnovni oblik VRPPD-a podrazumijeva problemsko pitanje u kojem je neposredno nakon obavljene dostave potrebno ukrcati određenu količinu robe na istoj lokaciji. [26] U praksi je ovaj slučaj često prisutan prilikom distribucije pića i pekarskih proizvoda, kada se nakon obavljene dostave, od korisnika treba prikupiti i njegova prazna ambalaža. Uobičajeno je da se tada izvor i odredište zahtjeva nalaze u centralnom skladištu. [25], [19]

Temeljno definiranje ovoga problema odvija se na način da se svakom korisniku *i* dodjeljuju dvije vrijednosti q_i i p_i. One predstavljaju zahtjeve za dostavom, odnosno prikupljanjem robe. Ponekad se može koristiti samo jedna od tih vrijednosti i tada će ona predstavljati razliku između zahtjeva dostave i zahtjeva prikupljanja ($q_i - p_i$). U tom slučaju, zajednička vrijednost može imati i negativno obilježje, što znači da se od korisnika *i* odveze više robe nego što mu se dostavi.

Postoji i nešto drugačija izvedenica ovoga problema koja ima obilježje da robu dostavlja na jednoj lokaciji, a prikuplja ju na drugoj (Slika 16). Za razliku od osnovnog oblika VRPPD-a, u kojem samo jedna lokacija predstavlja zahtjev za posluživanjem (na istoj lokaciji se obavlja i dostavljanje i prikupljanje), kod ove izvedenice zahtjevi za posluživanjem mogu biti opisani dvjema lokacijama. Na jednoj se vrši dostavljanje, a na drugoj prikupljanje. Da bi uopće bilo moguće definirati takve zahtjeve, potrebno je za svakog korisnika *i* znati mjesto dostave o_i te prethodno i iduće mjesto prikupljanja l_i. [19]



Slika 16. Primjer VRPPD-a
Izvor: Izradio autor

Rješavanje tako strukturiranog problema, osim zadovoljenja ograničenja kapaciteta vozila, podrazumijeva i zadovoljenje ograničenja redoslijeda obilaska lokacija, kao i njihove međusobne povezanosti (istim vozilom se mora obaviti i prikupljanje i dostava). [25]

Kompletan pregled ograničenja u tom problemu je sljedeći: [19]

- Svaka ruta započinje i završava u skladištu;
- Svaki korisnik biva posjećen samo jednom;
- Količina robe u vozilu uvijek mora biti između 0 i maksimalno raspoloživog kapaciteta tog vozila;
- Za svakog korisnika *i* postoji u istoj ruti korisnik o_i, koji treba biti poslužen prije njega;
- Za svakog korisnika *i* postoji u istoj ruti korisnik l_i, koji treba biti poslužen poslije njega.

Iz riječima opisanog koncepta ograničenja, vidljivo je da razmatranje ovoga problema ostvaruje potrebu za uvođenjem nekih novih oznaka u postavljanju i formulaciji zadatka:

$$\min \mathrm{F} = \sum_{i=0}^{n} \sum_{j=0}^{n} w_{ij} \cdot x_{ij} \tag{20}$$

$$\sum_{i=0}^{n} x_{ij} = 1 \qquad \forall\, j = 1, 2, \ldots, n \tag{21}$$

$$\sum_{j=0}^{n} x_{ij} = 1 \qquad \forall\, i = 1, 2, \ldots, n \tag{22}$$

$$\sum_{i=1}^{n} x_{0i} = k \tag{23}$$

$$\sum_{i=1}^{n} x_{i0} = k \tag{24}$$

$$\sum_{i=0}^{n} r_{ij} - q_j = \sum_{i=0}^{n} r_{ji} \qquad \forall\, j = 1, 2, \ldots, n \tag{25}$$

$$\sum_{i=0}^{n} g_{ij} + p_j = \sum_{i=0}^{n} g_{ji} \qquad \forall\, j = 1, 2, \ldots, n \tag{26}$$

$$\sum_{i=1}^{n} g_{0i} = 0 \tag{27}$$

$$\sum_{i=1}^{n} r_{i0} = 0 \tag{28}$$

$$r_{ij} + g_{ij} \leq c \cdot x_{ij} \qquad \forall\, i \in \{0, \dots, n\},\ j \in \{0, \dots, n\} \tag{29}$$

$$x_{ij} \in \{0,1\} \qquad \forall\, i, j \in V \tag{30}$$

$$r_{ij} \geq 0 \qquad \forall\, i \in \{0, \dots, n\},\ j \in \{0, \dots, n\} \tag{31}$$

$$g_{ij} \geq 0 \qquad \forall\, i \in \{0, \dots, n\},\ j \in \{0, \dots, n\} \tag{32}$$

gdje je:

n	broj korisnika
w_{ij}	cijena na luku od korisnika *i* do korisnika *j*
x_{ij}	binarna varijabla/varijabla odluke (ima vrijednost 1 ukoliko vozilo prevozi teret između korisnika *i* i *j*, a u suprotnom poprima vrijednost 0)
k	broj vozila
r_{ij}	količina robe za dostavu na luku između korisnika *i* i *j*
q_i	zahtjev (potražnja) za dostavom od strane korisnika *i*
g_{ij}	količina robe za prikupljanje na luku između korisnika *i* i *j*
p_i	zahtjev (potražnja) za prikupljanjem od strane korisnika *i*
c	kapacitet vozila

Cilj VRPPD-a, opisan formulacijom koja je dana u jednadžbi (20), jest pronalazak *x* ruta s minimalnim troškovima. Ograničenja dana jednadžbama (21) i (22) ukazuju da svaki korisnik mora biti poslužen isključivo jedanput. Ograničenja dana jednadžbama (23) i (24) identificiraju *k* vozila koja realizaciju prijevoza moraju započeti i završiti u skladištu.

Ograničenja u jednadžbama (25) i (26) tiču se očuvanja protočnosti uz izbjegavanje nastanka pod-ruta[14]. Nadalje, ograničenja dana jednadžbom (27) i jednadžbom (28) uvjetuju da vozila započinju obilaske ruta s 0 prikupljenih jedinica tereta, kao i da ih završavaju s 0 jedinica tereta za dostavu. Ograničenje iz jednadžbe (29) označuje maksimalni raspoloživi kapacitet vozila koji je predviđen za posluživanje korisnika, dok ograničenja dana jednadžbama (30), (31) i (32) služe za postavljanje varijabli na odgovarajuće vrijednosti.

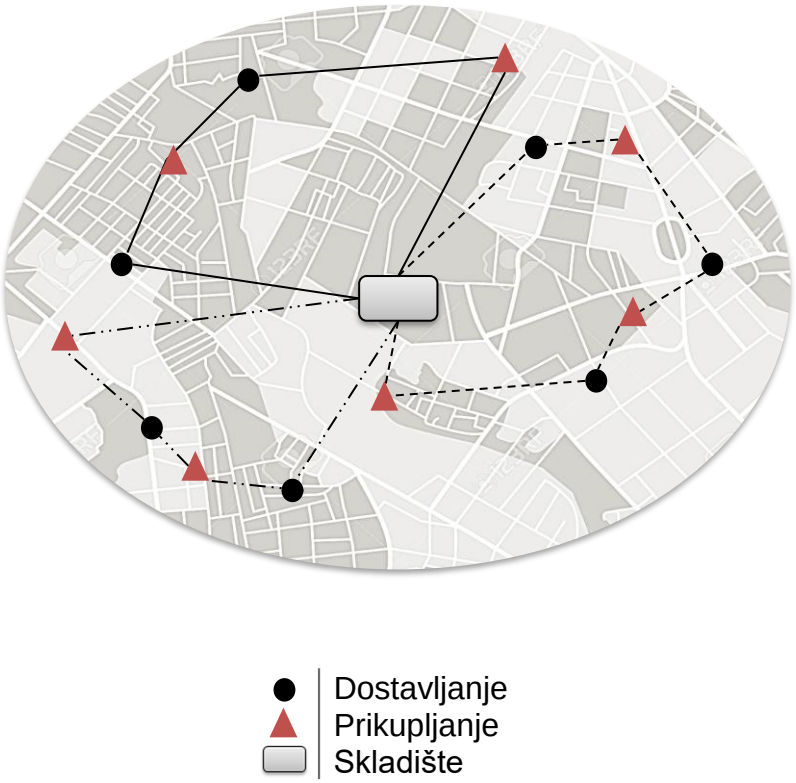
Ovako izvedena formulacija primjer je osnovnog modela VRPPD-a u kojemu se dostavljanje i prikupljanje robe obavlja na istoj lokaciji. Ukoliko se taj model želi proširiti s nešto složenijim oblikom VRPPD-a, u kojemu su lokacije dostavljanja i prikupljanja robe prostorno odvojene, tada je u formulu s ograničenjima potrebno uključiti još dvije dodatne jednadžbe. U jednoj će se uvjetovati da količina robe za prikupljanje mora iznositi 0 na svim dostavljajućim lokacijama, a druga će biti suprotna tome.

Nakon ovih pojašnjenja oko problematike i utvrđivanja osnovnih pravila i smjernica, moguće je riješiti početno zadani primjer VRPPD-a, u kojemu je potrebno opslužiti sve korisnike, bilo da se radi o zahtjevima dostavljanja robe ili o zahtjevima prikupljanja robe.

Pretpostavka je da dostava mora biti izvršena prije posjete lokaciji na kojoj se obavlja prikupljanje robe. Iz tog razloga svaka ruta započinje iteraciju tako što se najprije posjećuje lokacija korisnika sa zahtjevom dostavljanja, nakon čega slijedi odlazak vozila do lokacije korisnika na kojoj je predviđeno prikupljanje robe.

Imajući to na umu, rješenje primjera može se predstaviti s tri novonastale rute koje u svim segmentima udovoljavaju prethodno definiranim ograničenjima VRPPD problema. Ovako konstruirane rute vrlo često se nazivaju pomiješanima. Razlog tomu je što, kako i sam naziv sugerira, lokacije dostavljanja i prikupljanja robe bivaju međusobno ispremiješane pa se duž cijele rute izmjenjuju čas jedna, čas druga (Slika 17).

[14] (engl. *Subtours*)

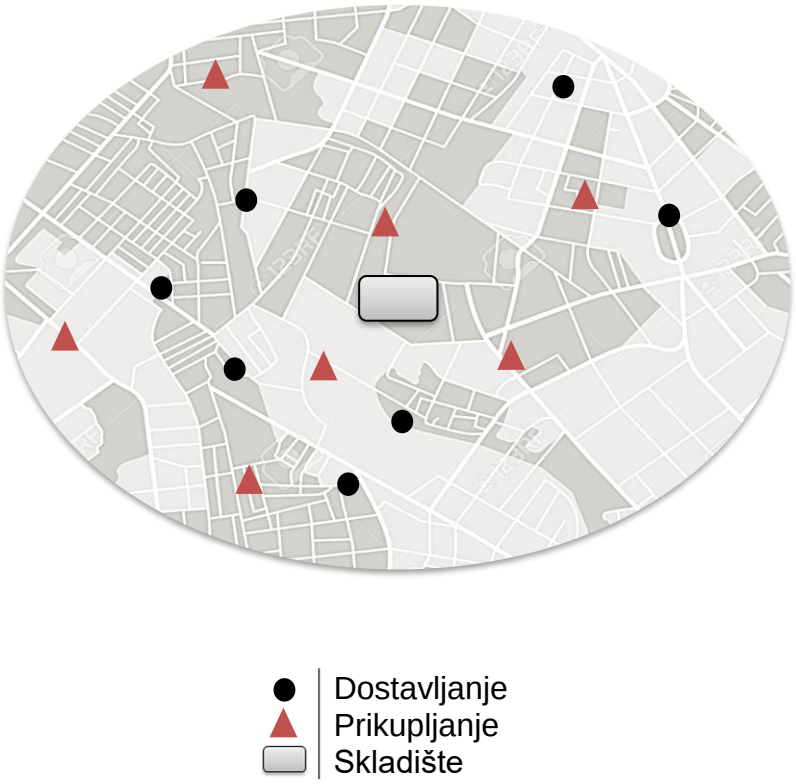


Slika 17. Rješenje primjera VRPPD-a
Izvor: Izradio autor

6.1.5. Problem usmjeravanja vozila s dostavom i povratnim prikupljanjem

VRPB i VRPPD su vrlo slični problemi pa se nerijetko znaju promatrati kroz prizmu jednog podproblema VRP-a, s više mogućih varijanti rješavanja. Ono što ih čini drugačijima i po čemu se međusobno razlikuju, jest redoslijed obilaska lokacija u ruti. Naime, obje rute sadrže dva podskupa zahtjeva, no dok se kod VRPPD-a ti zahtjevi u ruti izmjenjuju, kod VRPB-a su oni striktno odvojeni i ne miješaju se. Konkretno, roba se prikuplja tek u povratku, nakon što se obavi zadnja predviđena dostava i isprazni teretni prostor vozila. [27] To je ujedno i glavna pretpostavka čitavog VRPB problema.

U praksi se on vrlo često pojavljuje kod tvrtki čija dostavna vozila, nakon isporučene robe kupcima, moraju još u centralno skladište dopremiti robu od dobavljača. Pritom valja napomenuti da se vozila ne moraju nužno vraćati istim putem i prikupljati robu s istih lokacija na kojima su ranije boravila prilikom dostavljanja robe (Slika 18). [25]



Slika 18. Primjer VRPB-a
Izvor: Izradio autor

Da bi se uopće mogla osigurati izvedivost ovoga primjera, potrebno je, kao i u prethodnim primjerima, najprije zadovoljiti pretpostavku prema kojoj broj vozila k nije manji od minimalnog broja vozila k_{min} koja su nužna za posluživanje svih korisnika.

Nakon potvrđivanja te pretpostavke, svi se napori posvećuju ka postizanju rješenja VRPB-a, koje se sastoji od pronalaženja x ruta s minimalnim troškovima. To će rješenje biti validno i prihvatljivo samo ukoliko su ispunjeni sljedeći uvjeti: [19]

- Svaka ruta započinje i završava u centralnom skladištu;
- Svako korisnik se posjećuje točno jedanput;
- Zbroj pojedinačnih zahtjeva korisnika ne prelazi kapacitet vozila c, neovisno radi li se o zahtjevima dostavljanja ili o zahtjevima prikupljanja robe;
- U svakoj ruti najprije se ispunjavaju svi zahtjevi za dostavom robe, a potom se pažnja preusmjerava na ispunjavanje zahtjeva prikupljanja robe.

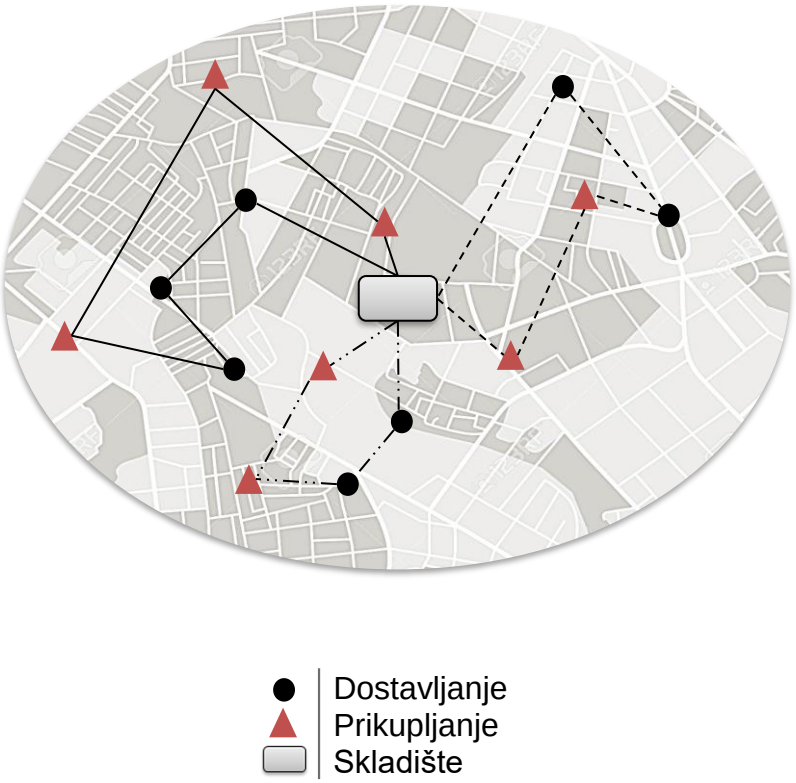
Iz navedenih spoznaja o funkciji cilja i pripadajućim ograničenjima, vrlo se lako može uočiti sličnost s prethodnim problemom. Naime, sva ograničenja iz VRPPD-a postojana su i kod VRPB-a, a funkcija cilja zajednička je i jednom i drugom problemu.

Ipak, ono što VRPB ima, a VRPPD nema, jest ograničenje prednosti posluživanja. Spomenuto se ograničenje mora dodatno uključiti u formulacijske izraze prilikom rješavanja VRPB problema, budući da ono i čini ovaj problem posebnijim u odnosu na druge probleme sa sličnom tematikom.

Stoga, da bi se to ograničenje moglo pridodati u postojeću formulaciju, uvodi se posebna oznaka γ, kojom se označuje udio dostavljene robe u ruti nakon kojega se može početi s prikupljanjem. Oznaka se u konkretnom slučaju postavlja na vrijednost 1 jer se sa zahtjevima prikupljanja započinje tek onda kada su ispunjeni i realizirani svi zahtjevi dostavljanja robe. Nakon što je navedena oznaka definirana i uvedena, ograničenje prvenstva posluživanja poprima sljedeći oblik:

$$r_{ij} + p_{ij} \leq (1 - \gamma) \cdot c \cdot x_{ij} \tag{33}$$

Na osnovu ovog specifičnog ograničenja i svih onih koji su navedeni u prethodnom problemu, postiže se prihvatljivo, ali i ispravno rješenje početno zadanog primjera. Takvo rješenje ispunjava zadanu funkciju cilja i pronalazi tri rute s minimalno nastalim troškovima (Slika 19).

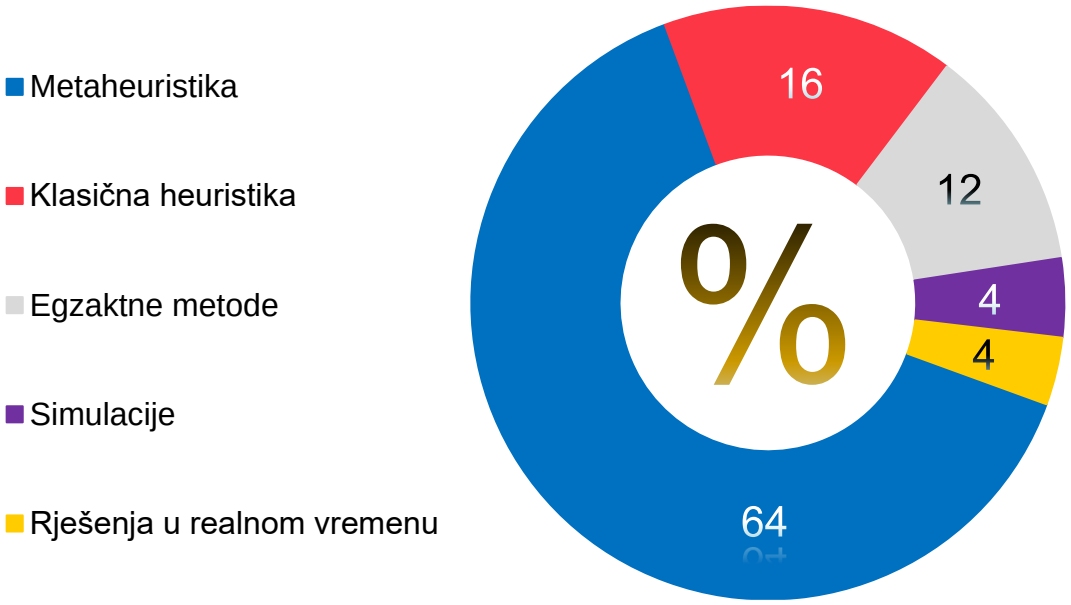


Slika 19. Rješenje primjera VRPB-a
Izvor: Izradio autor

Za pronalaženje rješenja svih dosad navedenih primjera VRP-a, potrebna je odgovarajuća metoda odnosno algoritam. Od kraja pedesetih godina prošlog stoljeća pa sve do danas, proveden je velik broj istraživanja na temu VRP-a. Posljedično s time razvijene su i različite optimizacijske metode za njegovo rješavanje, a ovisno o načinu pronalaska rješenja, te se metode mogu podijeliti na egzaktne, heurističke i metaheurističke. [25]

Egzaktne metode teže točnom rješenju što ih čini sporima, osobito ako se radi o problemu s velikim brojem korisnika. Naime, takve metode rješavanja problema sastoje se u tome da prebroje sva moguća stanja problema, nakon čega se za svako stanje radi izračun cijena, da bi se na kraju odabralo stanje s minimalnom vrijednošću (cijenom, udaljenošću, vremenom, brojem vozila i dr.).

To ih čini teško primjenjivima u realnim problemima pa se zbog toga za rješavanje ovakvih kombinatornih optimizacijskih problema uglavnom koriste heurističke i metaheurističke metode koje daju približno optimalno rješenje u realnom vremenu. Ne čudi stoga da su heurističke i metaheurističke metode najzastupljenije metode u dosadašnjim znanstvenim istraživanjima, vezanima uz problematiku VRP-a (Grafikon 3). [22]

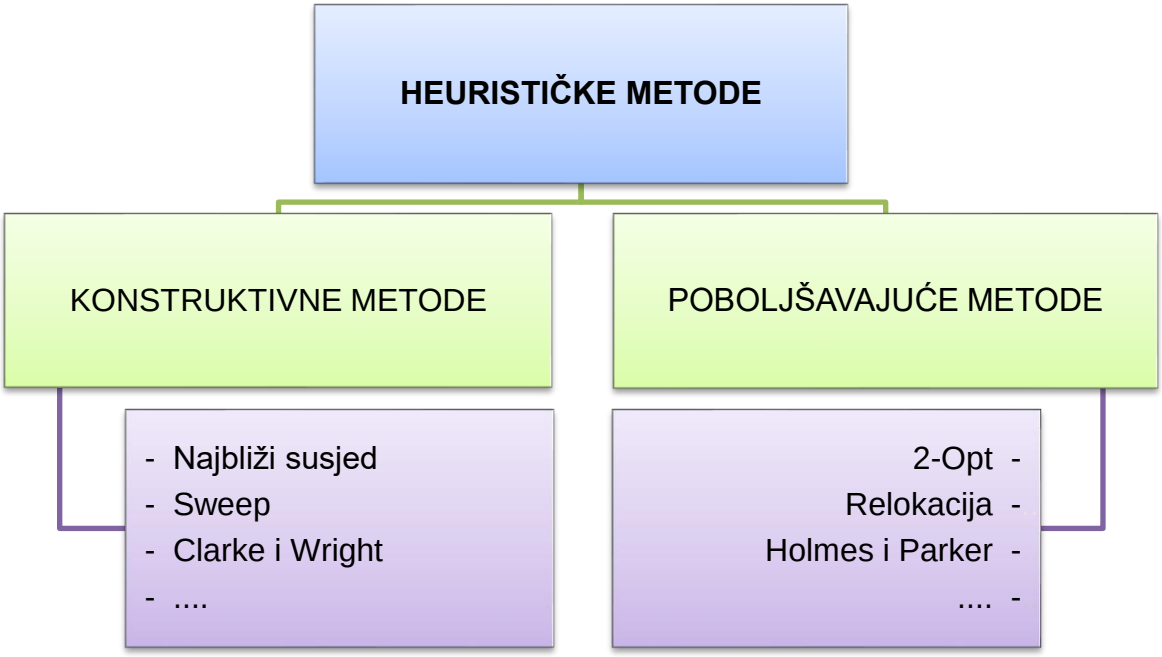


Grafikon 3. Relativna prisutnost optimizacijskih metoda u istraživanjima
Izvor: Izradio autor prema [22]

Metaheurističke metode prednjače u znanstvenoj važnosti te se u njihovo istraživanje ulaže najveći napor. Klasične heurističke, a potom i egzaktne metode pojavljuju se rjeđe, a razlog zbog kojega je to tako ponajprije treba tražiti u njihovim nedostatcima. Prvotne često znaju zapeti tijekom pretraživanja rješenja, a potonje, iako daju optimalno rješenje, čine to u neprihvatljivom vremenu. Simulacije i metode rješavanja problema u realnom vremenu vrlo se rijetko koriste pa stoga usmjeravanje pažnje isključivo na heurističke i metaheurističke metode predstavlja logičan korak u daljnjem istraživanju ovoga problema.

6.2. Heuristički pristup u rješavanju problema usmjeravanja vozila

Heuristički pristup podrazumijeva korištenje iskustva, intuicije i vlastite procjene prilikom rješavanja nekog problema. Za razliku od egzaktnih metoda, heurističke metode ne podrazumijevaju znanje o strukturi ili odnosima unutar modela problema koji se rješava, pa ih stoga odlikuje mogućnost brzog pronalaska rješenja problema. Nadalje, heurističke metode sastoje se od pravila izbora, filtriranja i odbacivanja rješenja, a obično se koriste prilikom postavljanja početnih rješenja, zahvaljujući konstruktivnim algoritmima, koja onda mogu biti nadograđivana i eksploatirana drugim metodama, točnije postupcima poboljšavanja (Slika 20). [19]



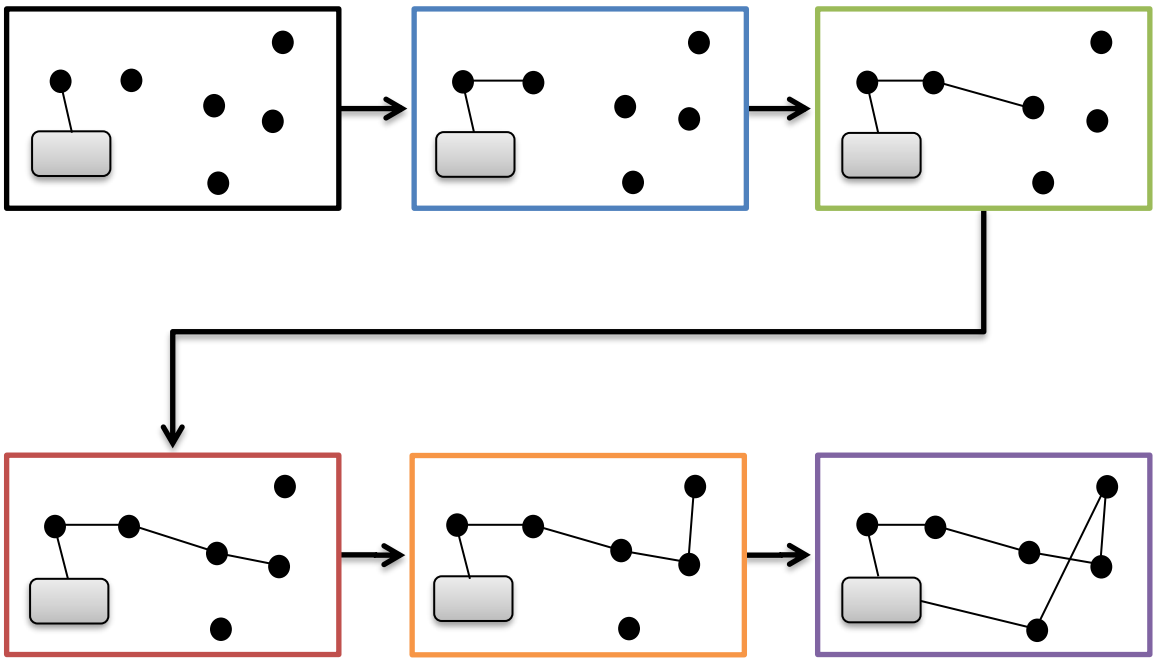
Slika 20. Podjela heurističkih metoda rješavanja optimizacijskih problema
Izvor: Izradio autor

Konstruktivna heuristika postupno izgrađuje rješenje problema, kako bi ono u svojoj krajnjoj upotrebi moglo biti izvedivo. Pritom vodi računa o ukupnom trošku, ali se ne služi nikakvim postupcima poboljšavanja. [28] Karakterizira ju tzv. „pohlepan[15]“ način rada, budući da se u svakom koraku algoritma, rješenje nadograđuje uz minimalan trošak. [25]

[15] (engl. *Greedy*)

6.2.1. Heuristika najbližeg susjeda

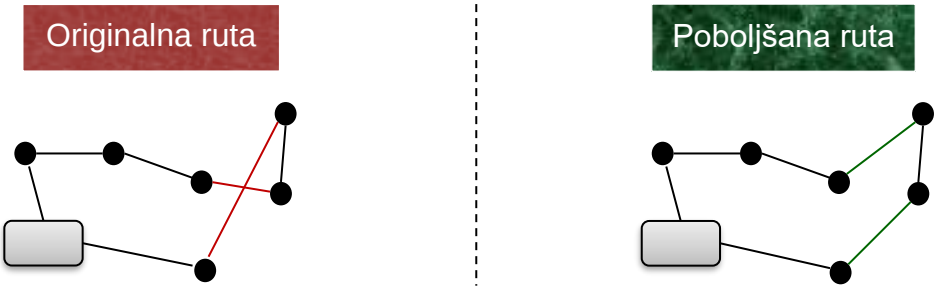
Heuristika najbližeg susjeda[16] je klasičan primjer „pohlepnog“ algoritma, u kojemu se rute konstruiraju serijski, odnosno jedna za drugom, od početka do kraja. U svakoj se iteraciji algoritma u rutu dodaje neposluženi korisnik koji je najbliži trenutnoj lokaciji vozila (Slika 21). [25]



Slika 21. Princip rada u heuristici najbližeg susjeda
Izvor: Izradio autor

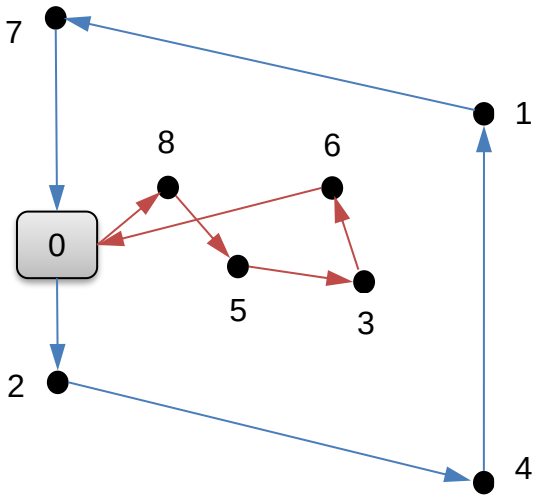
Rješenje ovakvog primjera na prvu izgleda zadovoljavajuće, no ono se još može poboljšati. Za poboljšanja su zadužene poboljšavajuće metode, a jedna od najpoznatijih je 2-Opt metoda (Slika 22). Ona radi na principu iterativnog unaprjeđenja rute, brid po brid. Konkretno, iz rute se uklanjaju dva (2) proizvoljna brida, a potom se u tu istu rutu dodaju dva nova brida kako bi svi korisnici u njoj ponovno mogli biti spojeni. Spajanje se vrši na način da se zadrže svi uvjeti, kako oni koji se tiču obilaska, tako i oni ograničavajući, ukoliko takvi postoje u konkretnom problemu. Dobiveni će se obilazak koristiti samo ako je kraći od početnog, a navedeni se postupak ponavlja dokle god se ne iscrpe sve moguće kombinacije.

[16] (engl. ***N**earest **N**eighbour **H**euristic* – NNH)



Slika 22. Usporedba originalne rute i rute koja je poboljšana 2-Opt metodom
Izvor: Izradio autor

Ukoliko se radi o nekom od podproblema VRP-a koji zahtijeva kapacitativna ograničenja, tada se prilikom dodavanja novog korisnika u rutu, treba ustvrditi je li kapacitet vozila dostatan za njegovo uključivanje. U trenutku kada vozilu ponestane raspoloživog kapaciteta, ruta se zatvara za preostale korisnike, angažira se novo vozilo te se isti postupci ponavljaju dokle god ima korisnika koji nisu posluženi (Slika 23).

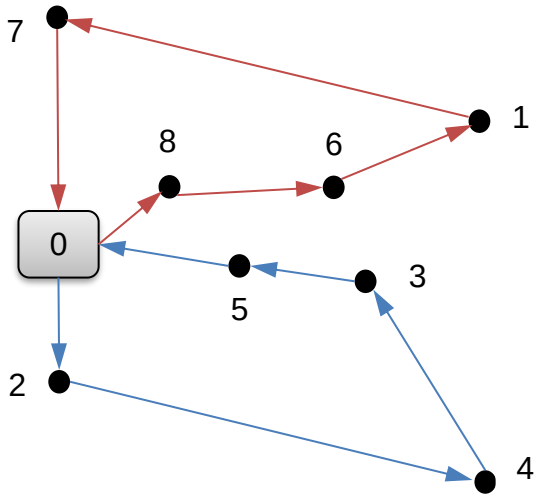


Slika 23. Heuristika najbližeg susjeda s ograničenjem kapaciteta
Izvor: Izradio autor prema [25]

Na slici je prikazano rješenje CVRP problema do kojega se stiglo korištenjem heuristike najbližeg susjeda. Konkretni problem sačinjen je od 8 lokacija (korisnika), pri čemu svaka lokacija ima potražnju za 1 jedinicom tereta. Za opskrbljivanje lokacija pripremljena su dva vozila, od kojih svako vozilo raspolaže s kapacitetom od 4 jedinice tereta. [25]

Prednosti ovog algoritma ogledaju se u jednostavnosti njegove implementacije, brzini te mogućnosti izvedbe stohastičke varijante, koja može generirati više različitih, ali izvedivih rješenja problema. [25] Unatoč navedenim prednostima, ovaj algoritam ima i značajne nedostatke, a neki od njih mogu se uočiti već i sa same slike u kojoj je dano konačno rješenje algoritma. Naime, na slici se jasno može iščitati „pohlepna“ narav algoritma koji gleda samo jedan korak unaprijed te na osnovu toga konstruira rješenje koje čak ni u ovako malenom problemu ne predstavlja optimum.

Dokaz tomu je i crvena ruta *0 – 8 – 5 – 3 – 6 – 0*, koja bi mogla biti kraća da je u drugoj iteraciji umjesto bližeg korisnika *5* odabran korisnik na lokaciji *6*. Osim toga, inzistiranje na odabiru najbližeg korisnika posljedično utječe i na raspodjelu korisnika u samim rutama. Trenutna raspodjela korisnika u rutama nije optimalna, iako zadovoljava uvjete za kapacitetom. Drugačijom raspodjelom moguće je osigurati minimalnu udaljenost prijevoza, a da su pritom i dalje zadovoljeni svi kriteriji ograničenja kapaciteta (Slika 24).

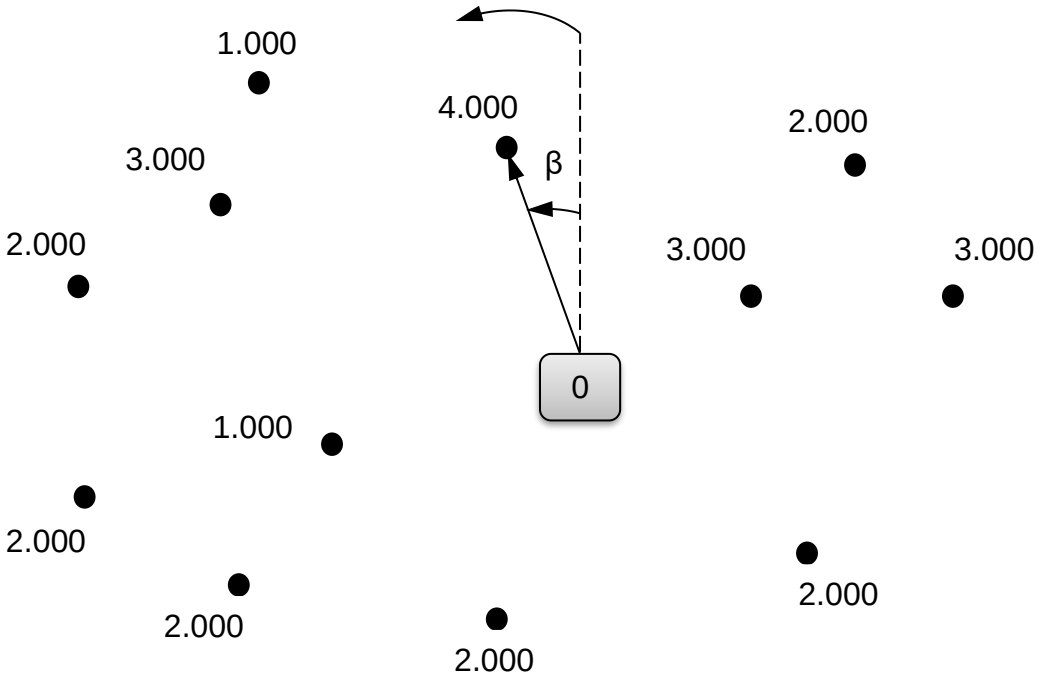


Slika 24. Poboljšanje rješenja dobivenog heuristikom najbližeg susjeda
Izvor: Izradio autor

6.2.2. Sweep algoritam

Razvoj ovog algoritma pripisuje se autorima Gillettu i Milleru koji su ujedno i zaslužni za njegovo ime *Sweep*. [29] Algoritam se ubraja u klasičnu konstruktivnu heuristiku, a sami se pristup rješavanja problema usmjeravanja vozila sastoji od

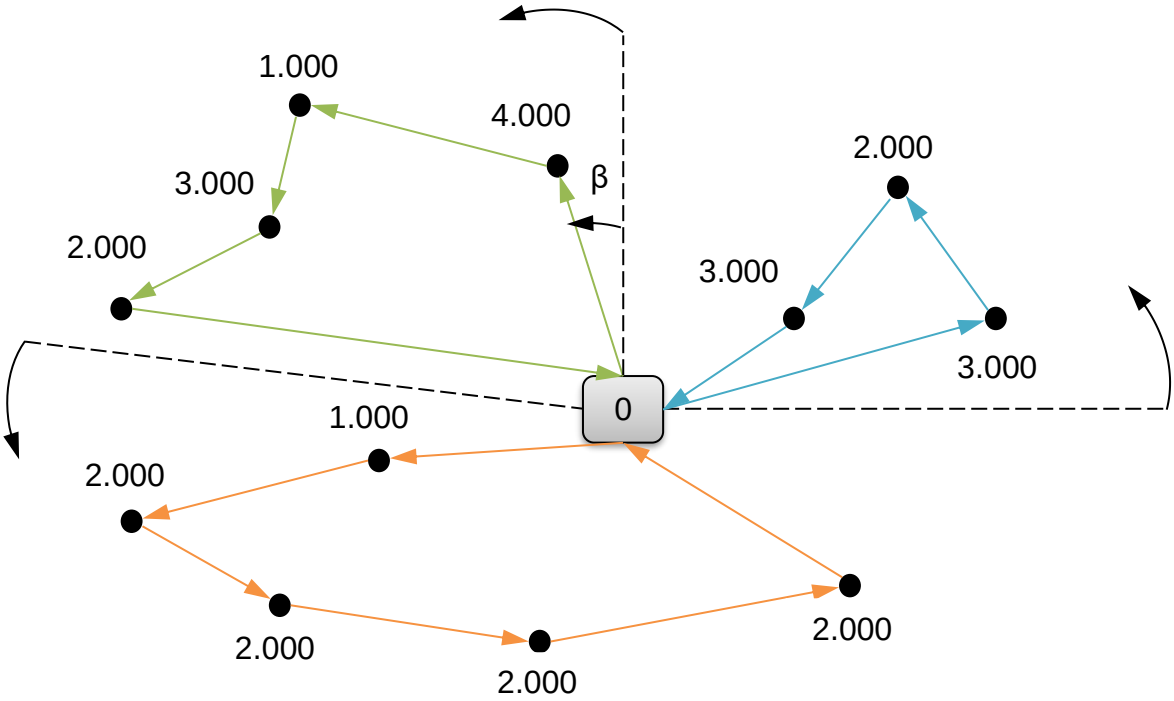
grupiranja korisnika prema kriteriju najmanjeg polarnog kuta *β* u odnosu na zamišljeni pravac koji prolazi kroz skladište i koji se rotira u smjeru kazaljke na sat ili obrnuto od smjera kazaljke na sat (Slika 25).



Slika 25. Početni položaj zamišljenog pravca i smjer rasta polarnog kuta
Izvor: Izradio autor

Na primjeru iz slike prikazan je CVRP problem kojega je potrebno riješiti koristeći se postulatima *Sweep* algoritma. U njemu je svaki korisnik predstavljen s potražnjom koju on sam zahtijeva iz centralnog skladišta, a koja se mjeri u jedinicama tereta. Pritom su kapaciteti svakog pojedinog vozila, koje može biti korišteno u ovome problemu, ograničeni na 10.000 jedinica tereta. Početni zamišljeni pravac sa slike postavlja se u bilo kojem smjeru i od njega kreće grupiranje korisnika u rute.

Rute se, kao i kod heuristike najbližeg susjeda, konstruiraju serijski, na način da se u trenutnu rutu dodaju korisnici s najmanjim polarnim kutom, dokle god aktivno vozilo ima raspoloživog kapaciteta. Onda kada raspoloživi kapacitet više nije dostatan za opskrbu niti jednog od preostalih neposluženih korisnika, ruta se zatvara, aktivno vozilo vraća se u skladište i angažira se novo vozilo. Taj se postupak ponavlja sve dok i posljednji korisnik nije poslužen (Slika 26). [25]



Slika 26. Rješenje primjera Sweep algoritmom
Izvor: Izradio autor

Rješenje sa slike iznjedrilo je tri rute od kojih svaka udovoljava kapacitativnom ograničenju s početka primjera. U zelenoj ruti zbroj zahtjeva od strane korisnika iznosi 10.000 jedinica tereta (4.000 + 1.000 + 3.000 + 2.000), a to je točno onoliko koliko jedno vozilo može i prenijeti. U narančastoj ruti zahtjevi korisnika također ne prelaze ograničenje kapaciteta, budući da njihov zbroj iznosi 9.000 jedinica tereta (1.000 + 2.000 + 2.000 + 2.000 + 2.000), a ista je stvar i s posljednje kreiranom rutom, gdje zahtjevi korisnika, redom 3.000 + 2.000 + 3.000, ne prelaze kapacitet vozila od 10.000 jedinica tereta (8.000 < 10.000).

Ipak, unatoč uspješno riješenom problemu, ovako konstruirano rješenje nije najbolje ukoliko se kod njegovog ocjenjivanja gleda ukupna prijeđena udaljenost. Naime, ovdje se prilikom dodavanja korisnika ne minimizira udaljenost već polarni kut *β*. Zbog toga se nerijetko nakon početnog rješenja u ovaj problem upliću i neke poboljšavajuće metode, poput ranije spomenutog 2-Opt algoritma. Osim njega, postoji i opcija da se rute u potpunosti rekonstruiraju (relociraju). Tada Sweep algoritam poprima karakteristiku dvostupanjskog pristupa, koji se temelji na pravilu *prvo grupiraj, a zatim rutiraj*. [25]

Idući nedostatak ovoga algoritma povezan je s vremenskim pitanjima kao što su vremenska ograničenja (prozori) i ukupno vrijeme koje je provedeno na ruti. U tim i takvim slučajevima, *Sweep* teško obrađuje zadani problem.

S druge pak strane, prednosti *Sweep* algoritma svakako su njegova jednostavnost i brzina rješavanja problema, budući da nema potrebe za ogromnim količinama računalne memorije. Također, za rezultate koji se moraju dobiti u kratkom vremenskom periodu, razina računalne pogreške kod ovoga se algoritma smatra prihvatljivom.

6.2.3. Clarke i Wright algoritam ušteda

Clarke i Wright algoritam (engl. ***C****larke* ***and W****right* – C&W) jedan je od najstarijih, ali i najpoznatijih algoritama za rješavanje VRP problema. Razlog zbog kojega je tako poznat i zastupljen krije se u tome što obično daje vrlo dobre rezultate. [25]

Sami algoritam baziran je na vrlo jednostavnoj ideji, a postupci njegova odvijanja mogu se redom sažeti u četiri glavna koraka, od kojih svaki postupno vodi k približavanju konačnom rješenju: [30]

1. Definiranje matrice udaljenosti;
2. Definiranje matrice uštede[17];
3. Definiranje ruta;
4. Definiranje redoslijeda obilaska u rutama.

Iz prva tri koraka proizlazi koja vozila obilaze koja odredišta, dok se u četvrtom koraku determinira redoslijed obilaska vozila u rutama. Kao dodatni peti korak može se uvesti metoda poboljšavanja, koja ima za cilj provjeriti postoji li takav izgled ruta i redoslijed obilaska u njima, koji će rezultirati još većom uštedom, a samim time i još kraćim prijeđenim putem u transportnoj mreži.

[17] Različiti autori koriste različite termine pa se tako, između ostalog, mogu naći i nazivi *matrica štednje* i *matrica skraćenja.*

Kao i u prethodnim algoritmima, tako se i ovdje primjer rješavanja prikazuje na VRP problemu s ograničenjem kapaciteta (CVRP), a razlog tomu jest taj što je on najzastupljeniji, odnosno s najvećim se postotkom pojavljuje u realnim svakodnevnim izazovima logističkog operatera.

Primjer se sastoji od 6 korisnika (lokacije s indeksima od *1* do *6*) koje je potrebno opskrbiti robom, i jednog centralnog skladišta (lokacija s indeksom *0*) iz kojeg se generiraju rute prema korisnicima. Matrica udaljenosti između skladišta i korisnika, kao i udaljenosti korisnika međusobno, dana je u tablici (Tablica 2).

Tablica 2. Matrica udaljenosti

	0	***1***	***2***	***3***	***4***	***5***	***6***
0	-	20	18	14	16	12	19
1	20	-	22	18	30	26	28
2	18	22	-	32	20	22	21
3	14	18	32	-	20	22	21
4	16	30	20	20	-	30	32
5	12	26	22	22	30	-	26
6	19	28	21	21	32	26	-

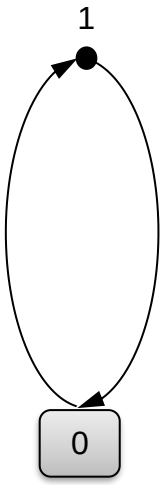
Izvor: Izradio autor

Matrica udaljenosti sastoji se od udaljenosti između svakog para lokacija, uz pretpostavku simetričnosti ($d_{12} = d_{21}$)[18]. Udaljenosti mogu biti unaprijed zadane, ali kada to nije slučaj, onda ih je potrebno samostalno odrediti. Ukoliko se radi o realnoj situaciji, udaljenosti se mogu definirati korištenjem podataka iz raznih javno dostupnih aplikacija koje omogućuju određivanje stvarnih udaljenosti (Google karte, Bing karte i

[18] Asimetrične udaljenosti su rijetkost ($d_{12} \neq d_{21}$). Obično se javljaju zbog regulacije prometa pa se stoga, radi pojednostavljenog računanja, vrlo često zanemaruju. Ipak, valja biti oprezan i imati na umu da je ovo pojednostavljenje dopušteno jedino onda kada moguća odstupanja ne utječu bitno na konačno rješenje.

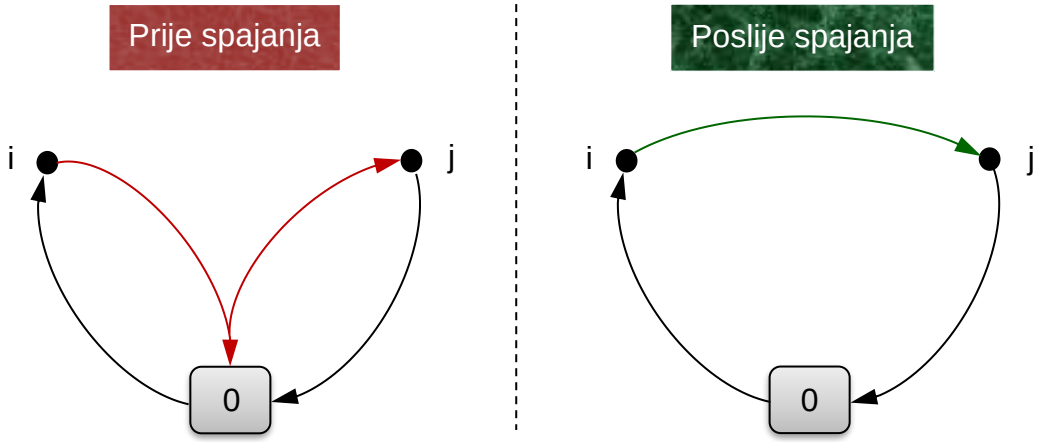
dr.). Udaljenosti također mogu biti izračunate i putem Pitagorinog poučka, onda kada su poznate zemljopisne koordinate korisnika (gradova).

Nakon što su obznanjeni svi podatci u matrici udaljenosti, započinje se s kreiranjem elementarnih ruta. To se radi na način da se kreira ruta za svakog korisnika, dodavanjem lukova između skladišta i korisnika u oba smjera (Slika 27).



Slika 27. Izgled elementarne rute za prvog korisnika
Izvor: Izradio autor

Po završetku kreiranja elementarnih ruta, kreće se s dobivanjem matrice uštede koja predstavlja skraćenje prijevoznog puta. Skraćenje se postiže obilaskom dva korisnika istim vozilom, tj. konsolidacijom (spajanjem) dvaju zahtjeva korisnika na istoj ruti. Spajanje se obavlja brisanjem završnog luka prve rute i početnog luka druge rute te kreiranjem novog luka između korisnika (Slika 28).



Slika 28. Spajanje korisnika u C&W algoritmu
Izvor: Izradio autor

Razlozi ovakvog spajanja isključivo su optimizacijske prirode. Naime, ukoliko vozilo posjećuje korisnike *i* i *j*, svakog ponaosob u zasebnim rutama, tada će ukupna prevaljena udaljenost biti $d_{0i} + d_{i0} + d_{0j} + d_{j0}$, odnosno $2(d_{0i} + d_{oj})$. No, ukoliko vozilo posjeti korisnika *i*, a odmah zatim u nastavku rute posjeti i korisnika *j* pa se tek onda vrati u skladište, tada će prevaljena udaljenost iznositi $d_{0i} + d_{ij} + d_{j0}$. Ukoliko se pokaže da je potonja udaljenost kraća od prvotne, to znači da je moguće ostvariti uštedu u udaljenosti. Ona se računa tako da se od $d_{0i} + d_{i0} + d_{0j} + d_{j0}$ oduzme $d_{0i} + d_{ij} + d_{j0}$. Dakle, za svaki par ruta $(0, \ldots, i, 0)$ i $(0, j, \ldots, 0)$, gdje je $i, j = 1, \ldots, n$ i $i \neq j$, može se izračunati potencijalna ušteda $s_{ij} = d_{0i} + d_{0j} - d_{ij}$, uz uvjet da je kapacitet vozila veći ili jednak ukupnoj potražnji korisnika iz obje rute.

Na osnovu posljednje formule, sve moguće uštede u ovom primjeru dane su u tablici (Tablica 3). One mogu biti pozitivne, jednake nuli ili negativne. Pozitivne će biti uz uvjet da je $d_{0i} + d_{i0} + d_{0j} + d_{j0} > d_{0i} + d_{ij} + d_{j0}$. Jednake nuli bit će onda kada je $d_{0i} + d_{i0} + d_{0j} + d_{j0} = d_{0i} + d_{ij} + d_{j0}$. Negativne će postojati samo ako vrijedi da je $d_{0i} + d_{i0} + d_{0j} + d_{j0} < d_{0i} + d_{ij} + d_{j0}$.

Tablica 3. Matrica ušteda u C&W algoritmu

	1	***2***	***3***	***4***	***5***	***6***
1	-					
2	16	-				
3	16	0	-			
4	6	14	10	-		
5	6	8	4	-2	-	
6	11	16	12	3	5	-

Izvor: Izradio autor

Matrica ušteda je također simetrična, ali su radi bolje preglednosti prikazane samo vrijednosti ispod dijagonale. Nadalje, može se primijetiti kako matrica ušteda i matrica udaljenosti nisu istih dimenzija. Matrica udaljenosti je 7 x 7 matrica, gdje *0* predstavlja centralno skladište, a od *1* do *6* su korisnici. Matrica ušteda je 6 x 6 matrica, i ona služi samo za prikazivanje korisnika od *1* do *6* budući da je centralno skladište *0* sakriveno unutar dobivenih ušteda.

Uštede u matrici uobičajeno su pozitivnog predznaka, veće od ili jednake nuli, a to znači da je ispunjen teorem nejednakosti trokuta[19]. Prema tome, ako udaljenosti zadovoljavaju teorem nejednakosti trokuta, tada će iznos $d_{0i} + d_{i0} + d_{0j} + d_{j0,}$ uvijek biti veći od ili jednak iznosu $d_{0i} + d_{ij} + d_{j0}$, a to posljedično znači da će vrijediti uvjet u kome je $s_{ij} \geq 0$.

Primjerice, ušteda između korisnika *1* i *2* (s_{12}) iznosi 16, a dobivena je prema jedinstvenoj formuli za računanje potencijalnih ušteda ($s_{ij} = d_{0i} + d_{0j} - d_{ij}$), tako što je od zbroja 20 + 18 oduzet broj 22 ($d_{01} + d_{02} - d_{12}$). Ta ušteda je pozitivna i sukladno tome udovoljava teoremu nejednakosti trokuta. Ušteda između korisnika *2* i *3* (s_{23}) iznosi 0, a takav izračun postignut je na način da je od zbroja 18 + 14 oduzet broj 32 ($d_{02} + d_{03} - d_{23}$). Kada ušteda iznosi 0, tada se i dalje podrazumijeva da je teorem

[19] Prema teoremu nejednakosti trokuta, zbroj duljina dviju stranica trokuta, veći je ili jednak duljini preostale stranice.

nejednakosti trokuta zadovoljen, no onda se za njega kaže da je degenerativan. U takvim se slučajevima, radi lakšeg poimanja i zamišljanja realne situacije, može reći da korisnici leže na istome pravcu. Posljednji slučaj uštede je onaj s negativnim predznakom, a upravo je takva ušteda između korisnika *4* i *5* (s_{45}), s iznosom -2. Izračunata je istim postupkom, ali naravno s drugačijim vrijednostima nego na prethodnim primjerima. Ona se ne uzima u obzir budući da po svojoj vrijednosti zapravo ne predstavlja uštedu već trošak, pa s takvim negativnim predznakom ne udovoljava teoremu nejednakosti trokuta. Takav slučaj može se pripisati pogrešci u brojevima kod matrice udaljenosti, budući da oni nisu realistični s aspekta teorema nejednakosti trokuta.

Nadalje, u nastavku rješavanja algoritma, poželjno je sve uštede iz matrice poredati po vrijednostima, od najveće prema najmanjoj, radi lakšeg snalaženja (Tablica 4).

Tablica 4. Uštede u silaznom poretku

Korisnici (i – j)	**Ušteda (s_{ij})**	*Korisnici (i – j)*	**Ušteda (s_{ij})**	*Korisnici (i – j)*	**Ušteda (s_{ij})**
1 – 2	**16▼**	*1 – 6*	**11**	*5 – 6*	**5**
1 – 3	**16**	*3 – 4*	**10**	*3 – 5*	**4**
2 – 6	**16**	*2 – 5*	**8**	*4 – 6*	**3**
2 – 4	**14**	*1 – 4*	**6**	*2 – 3*	**0**
3 – 6	**12**	*1 – 5*	**6**	*4 – 5*	**-2**

Izvor: Izradio autor

Nakon što su uštede poredane, može se krenuti sa spajanjem ruta, no prije toga potrebno je definirati potražnju svih korisnika koji trebaju biti posluženi, kao i kapacitet svih vozila raspoloživih za obavljanje distribucije (Tablica 5).

Tablica 5. Zadana potražnja korisnika i kapacitet vozila

Korisnik	**Potražnja**	
1	**4**	*Kapacitet vozila = 15*
2	**6**	
3	**3**	
4	**5**	
5	**3**	
6	**6**	

Izvor: Izradio autor

Na osnovu danih podataka iz tablice s potražnjom i kapacitetom, moguće je predvidjeti broj vozila, a samim time i broj ruta, koje će biti konstruirane za potrebe izvršenja distribucije prema korisnicima. To se može učiniti na način da se zbroje potražnje svih pojedinih korisnika (4 + 6 + 3 + 5 + 3 + 6) i da se potom taj zbroj podijeli s kapacitetom vozila (15). Rezultat te matematičke operacije iznosi 1,8 te se iz njega može implicitno iščitati kako će za realizaciju prijevoza biti potrebna nepuna 2 vozila. Dva vozila automatski za sobom povlače zaključak o dvije moguće rute u konačnom rješenju problema.

Da bi se takva pretpostavka i obistinila, potrebno ju je matematički potvrditi iterativnim postupcima. U njima se rute kreiraju po kriteriju maksimalne uštede, gdje se dva korisnika spajaju u istu rutu dok god to kapacitet vozila dozvoljava. U trenutku kada se kapacitet vozila iscrpi i postane nedostatan, odabire se sljedeća ruta i spajanje se nastavlja. Postupak završava kada nestane mogućnosti za ostvarenjem novih ušteda.

U prvoj iteraciji, kreće se od najveće uštede (s_{12}) koja iznosi 16 (Tablica 4). Ta ušteda uključuje korisnika *1* i korisnika *2,* što znači da se oni mogu kombinirati u jednu zajedničku rutu, ali samo ukoliko suma njihovih zahtjeva (potražnji) ne prelazi dopušteni kapacitet vozila. Provjera tog uvjeta je ispunjena (4 + 6 < 15) pa se korisnik *1* i korisnik *2* mogu spojiti u jednu rutu, koja nakon spajanja poprima izgled *0 – 1 – 2 – 0*. Ušteda s_{12} se nakon ove iteracije isključuje iz daljnjeg razmatranja.

Iduća najveća ušteda je ona s_{13} te ponovno iznosi 16. Ona uključuje korisnika *1* i korisnika *3*, a kako je korisnik *1* već spojen u rutu *0 – 1 – 2 – 0*, treba provjeriti može li se i korisnik *3* priključiti toj ruti. Provjera opet ovisi o ispunjavanju uvjeta kapaciteta, a sada je potražnjama korisnika *1* i *2,* potrebno dodati potražnju korisnika *3* i usporediti ukupni zbroj s dopuštenim kapacitetom vozila. Potražnja korisnika *3* iznosi 3 i ukoliko se priključi potražnjama korisnika *1* (4) i korisnika *2* (6), kapacitet vozila neće biti prekoračen, a to znači da se korisnik *3* slobodno može uključiti u rutu s korisnicima *1* i *2*, nakon čega će ta ruta poprimiti izgled *0 – 1 – 2 – 3 – 0*. Ušteda s_{13} se nakon toga više ne uzima u razmatranje.

Korisnik *2* i korisnik *6*, sudionici su sljedeće najveće uštede s_{26} koja opet iznosi 16. Korisnik *2* već učestvuje u ruti *0 – 1 – 2 – 3 – 0* pa preostaje da se i korisnik *6* proba priključiti toj ruti. Njegova potražnja iznosi 6, a kada se ta vrijednost nadoda zbroju potražnji postojećih korisnika u ruti, onda se kapacitet vozila znatno premašuje (19 > 15). Takav ishod provjere odbacuje mogućnost priključivanja korisnika *6* u rutu s korisnicima *1*, *2* i *3*.

Zbog istog razloga redom se odbacuju uštede s_{24}, s_{36}, s_{16}, s_{24}, s_{34}, s_{25}, s_{14}, s_{24} i eventualna spajanja koja bi iz njih mogla proizaći. Nakon nekoliko takvih neuspjelih pokušaja spajanja, slijedi ušteda s_{56} koja iznosi 5. Sastavljena je od korisnika *5* i *6*, a pošto se nijedan od ta dva korisnika ne nalazi u nekoj ruti, pristupa se kreiranju nove rute s novim vozilom. Prije samog kreiranja rute, potrebno je još jedino provjeriti uvjet ograničenja kapaciteta. Zbroj potražnji korisnika *5* i *6* je 9 (3 + 6), a to je manje od dopuštenog kapaciteta vozila (15), što znači da nema zapreke za spajanjem ovih dvaju korisnika u jednu rutu. Tako se uz prethodnu rutu *0 – 1 – 2 – 3 – 0* sada nalazi i ruta *0 – 5 – 6 – 0*. Ušteda s_{56} se nakon ove iteracije više ne može uzimati u obzir.

Slijedi ušteda s_{35} koja ima vrijednost 4. a uključuje korisnike *3* i *5*. Ova se ušteda u startu može odbaciti iz jednog vrlo jednostavnog razloga, a to je da korisnici *3* i *5* već pripadaju formiranim rutama. Naime, njihovo bi spajanje rezultiralo spajanjem dviju dosadašnjih ruta u jednu zajedničku, a jasno je i bez računanja kako kapacitet vozila za takvo što nije dostatan.

Nakon neuspjelog pokušaja s uštedom s_{35}, ide se k novoj uštedi s_{46}. Ona iznosi 3, a čine ju korisnici *4* i *6*. Korisnik *6* već je uključen u rutu *0 – 5 – 6 – 0* pa se radi provjera temeljem koje će se ustvrditi može li se toj ruti priključiti i korisnik *4*. Korisnik *4* ima potražnju 5 i ukoliko se ona doda sumi potražnje korisnika *5* i *6* (3 + 6), dobit će se ukupna zajednička suma u iznosu 14, koja je još uvijek manja od dopuštenog kapaciteta vozila (14 < 15). Time je korisnik *4* uspješno pridodan u rutu s korisnicima *5* i *6* pa ruta dobiva novi oblik *0 – 5 – 6 – 4 – 0*. Ovime se završava postupak spajanja korisnika, budući da su svi sada uključeni u nove rute koje se baziraju na efektivnijem iskorištenju prijevoznih elemenata.

Kao konačni zaključak spajanja proizlazi da su provedenim iterativnim postupcima konstruirane dvije rute te da je svakoj od tih dviju ruta dodijeljeno po jedno dostavno vozilo. Time su ujedno potvrđene i početne pretpostavke o broju vozila i ruta:

1. *0 – 1 – 2 – 3 – 0*, s ukupnom potražnjom od 13 jedinica tereta;
2. *0 – 5 – 6 – 4 – 0*, s ukupnom potražnjom od 14 jedinica tereta.

S ovime problem usmjeravanja vozila još uvijek nije u potpunosti riješen jer preostaje još za svaku rutu odrediti redoslijed obilaska korisnika, koji će u konačnici rezultirati najkraćim transportnim relacijama. Redoslijed se obično utvrđuje heuristikom najbližeg susjeda budući da su međusobne udaljenosti korisnika poznate i nalaze se u pripadajućoj matrici. Iz nje se može iščitati da je u ruti *0 – 1 – 2 – 3 – 0*, centralnom skladištu najbliži korisnik *3* (*0 - 3*), a korisniku *3* bliži je korisnik *1* nego korisnik *2* (*0 – 3 – 1*). Još je preostao jedino korisnik 2 pa se on dodaje na kraj rute, prije samog povratka skladištu. Takvim se redoslijedom obilaska ostvaruje novi izgled rute *0 – 3 – 1 – 2 – 0*. Na isti način utvrđuje se i redoslijed obilaska u ruti *0 – 5 – 6 – 4 – 0*, no budući da je on već inicijalno dobro postavljen, ta ruta ostaje nepromijenjenog izgleda. Ovim korakom se završava izvođenje C&W algoritma, a kako bi provjerili je li, i ako je, u kojoj mjeri je točno algoritam poslužio svrsi, potrebno je izračunati ukupni prijeđeni put u novim rutama i usporediti ga s inicijalnim, kada su rute bile tek elementarno postavljenje.

Prijeđeni put u ruti *0 – 3 – 1 – 2 – 0* iznosi 72 (14 + 18 + 22 + 18), dok prijeđeni put u ruti *0 – 5 – 6 – 4 – 0* iznosi 86 (12 + 26 + 32 + 16). Stoga ukupni prijeđeni put u novokonstruiranim rutama iznosi 158 (72 + 86).

Elementarno postavljene rute bile su konstruirane na sljedeće načine: *0 – 1 – 0, 0 – 2 – 0, 0 – 3 – 0, 0 – 4 – 0, 0 – 5 – 0, 0 – 6 – 0*. Ukupni prijeđeni put u njima iznosio je 198 (20 + 20 + 18 + 18 + 14 + 14 + 16 + 16 + 12 + 12 + 19 + 19).

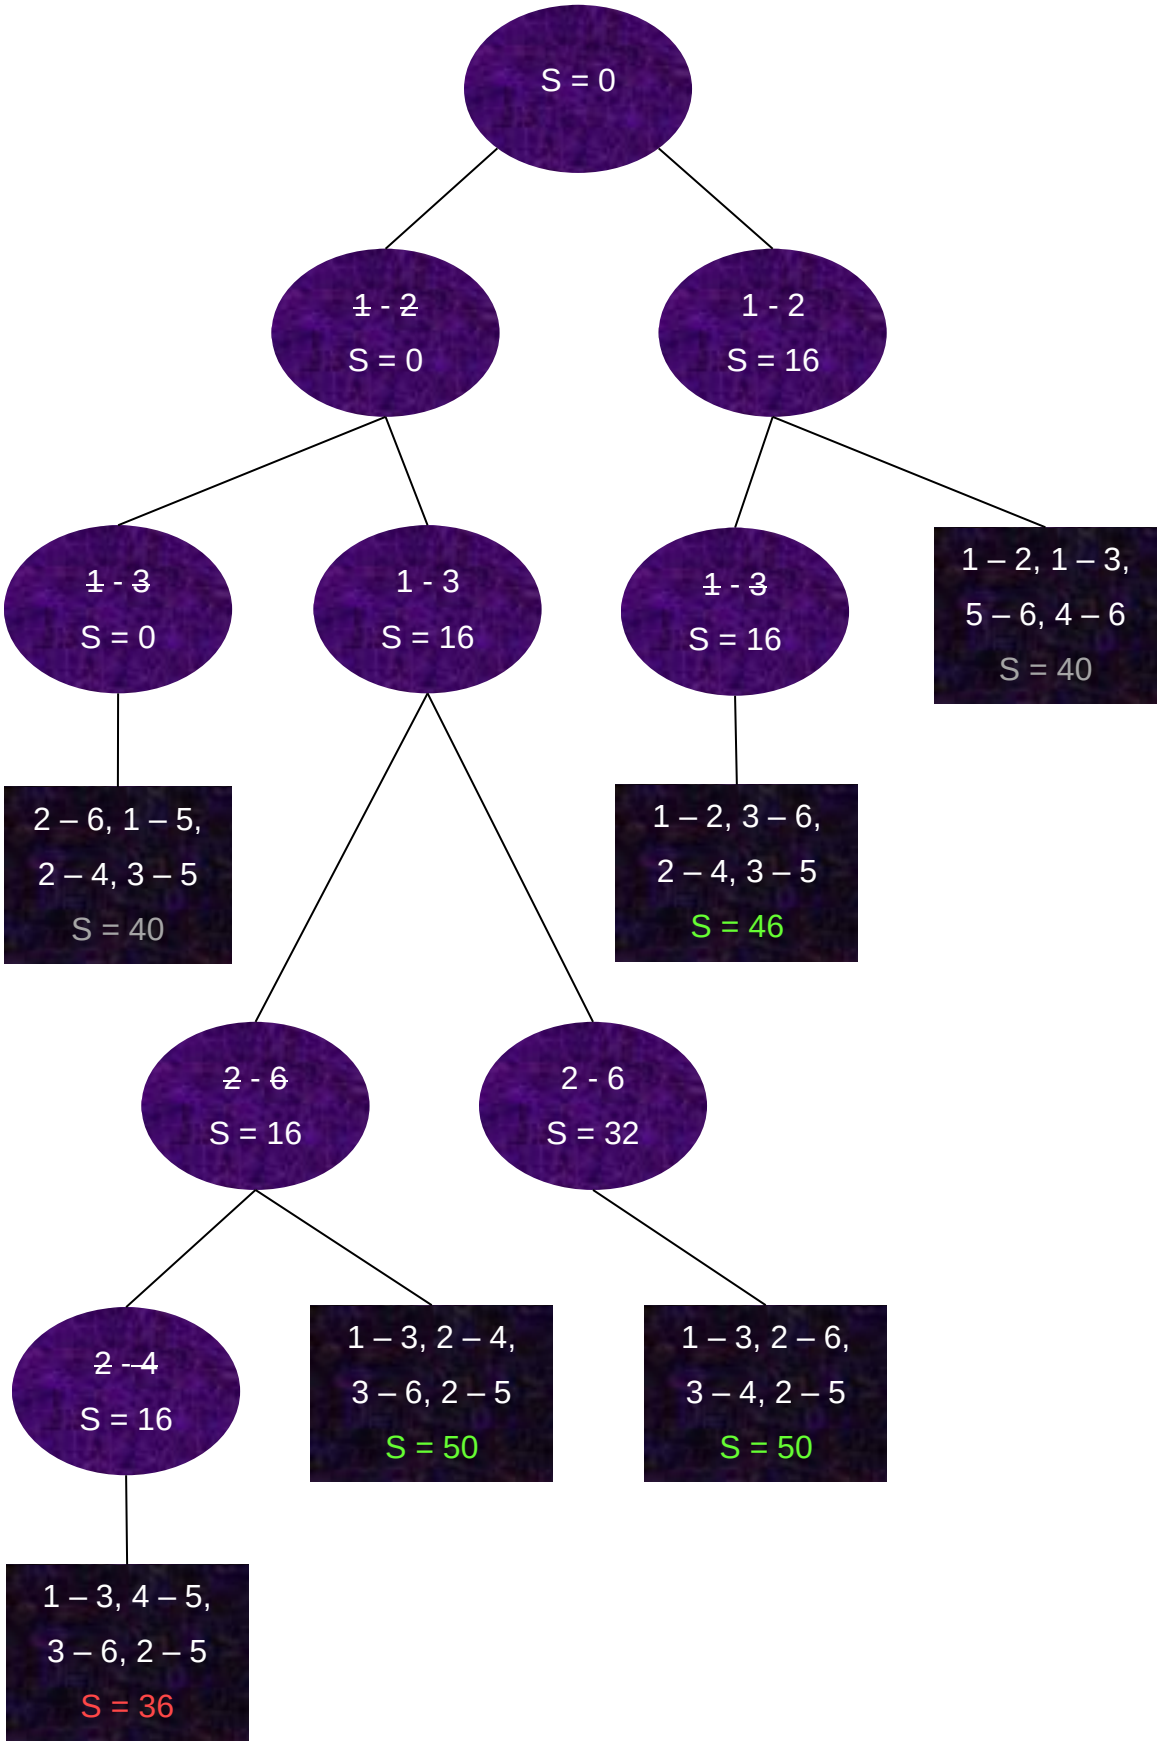
Iz ovih izračuna proizlazi da ukupna ušteda prijeđenog puta iznosi 40 (198 - 158), što je otprilike 20% ukoliko se ušteda gleda kroz prizmu postotaka, budući da je to u praksi vrlo čest način predočavanja pogodnosti. Ako se promatra duži vremenski period i u obzir se uzme da vozila putuju gotovo svaki dan, ta je ušteda vrlo velika i značajna.

Međutim, kako je svrha postojanja logističkog operatera ta da stalno iznova donosi bolja rješenja i značajnija poboljšanja postojećih rezultata, tako se došlo i do metode s kojom ova ušteda može biti još više unaprijeđena.

Naime, C&W je heuristički algoritam što podrazumijeva da je, između ostalog, i „pohlepan“, a to znači da njegovo rješenje nije uvijek i ono optimalno. Njegov problem može se detektirati prilikom spajanja korisnika na osnovu poredanih ušteda, od najveće pa do najmanje. Baš zbog toga što se uštede uzimaju tim redom, postavlja se pitanje može li drugačiji redoslijed uzimanja ušteda rezultirati boljim spajanjem korisnika. Odgovor je da može i u tu svrhu primjenjuje se poboljšavajuća metoda Holmes i Parker (engl. ***H****olmes* ***and P****arker* – H&P).

H&P algoritam je računalno mnogo zahtjevniji od C&W-a. On predstavlja njegovo proširenje, s mnogo više računanja, budući da funkcionira poput granajućeg algoritma koji će s radom prekinuti tek onda kada ispita sve moguće solucije. Naravno, algoritam se može prilagoditi zahtjevima, potrebama i individualnim željama pa njegovo izvođenje može biti prekinuto prije ili kasnije, primjerice onda kada pronađe prvo bolje i kvalitetnije rješenje.

Upravo jedno takvo bolje i kvalitetnije rješenje prethodnog primjera može se vidjeti na slici (Slika 29).



Slika 29. H&P precizirano rješenje primjera
Izvor: Izradio autor

Razlog zbog kojega se može reći da H&P algoritam daje bolje i kvalitetnije rješenje u odnosu na C&W algoritam, jest iznos uštede. U ovome primjeru, H&P algoritmom postiže se ušteda 50, dok se C&W algoritmom postiže ušteda 40. Štoviše, H&P algoritam do uštede 50 može doći u čak dva navrata, odnosno s dvije različite konstrukcije ruta.

U jednoj soluciji rute će poprimiti izgled *0 – 1 – 3 – 6 – 0 i 0 – 5 – 2 – 4 – 0*. Tada će ukupni prijeđeni put iznositi 148, a do spomenute uštede 50 može se doći ukoliko se taj iznos oduzme od 198, koliko iznosi ukupni inicijalni prijeđeni put.

Druga solucija jest kada rute poprime oblik *0 – 1 – 3 – 4 – 0* i *0 – 5 – 2 – 6 – 0*. I u tom će slučaju ukupni prijeđeni put također iznositi 148, što ponovno daje uštedu 50 koju C&W algoritam, izvođenjem svojih iteracija, nije mogao postići.

H&P algoritam funkcionira tako što ne kreće nužno spajati korisnike od najveće poredane uštede iz pripadajuće matrice, već preispituje i druge opcije biranja ušteda. Tako se u ovome primjeru, gdje algoritam uspijeva doći do uštede 50, preskače najveća ušteda s_{12} (na slici je ona precrtana) i kreće se sa spajanjem korisnika od prve iduće uštede s_{13}. Sukladno tome, sve precrtane uštede na slici podrazumijevaju da ih je algoritam privremeno zaobišao, a to matematički znači da im je privremeno postavio vrijednost na nulu te ih nije uzeo u razmatranje.

Unatoč ovim brojnim vidljivim prednostima, korištenje H&P algoritma ne mora uvijek donijeti poboljšanje rezultata. Nekada će to biti slučaj, nekada neće. Nekada će rješenje dobiveno C&W algoritmom biti sasvim dovoljno jer će ujedno biti i optimalno, ali to se ne može znati jer su heuristički algoritmi upravo takvi. Nesavršeni, ali pouzdani, barem po pitanju jednostavnijih optimizacijskih problema.

Za one malo složenije, koji su u praksi zapravo i najčešći, potrebno je nešto puno kompleksnije, ali točnije i savršenije. Takvo nešto može se pronaći u metaheuristici, čiji se postupci rješavanja optimizacijskih problema odlikuju sposobnošću pronalaska visoko kvalitetnih rješenja.

6.3. Metaheuristički programski alat za optimizaciju i planiranje ruta

Metaheuristički pristup smatra se najnovijim pristupom u rješavanju kombinatornih optimizacijskih problema. On predstavlja skup koncepata koji definiraju upotrebljive metode za rješavanje velikog broja različitih problema. [19]

Na tom pristupu dizajniran je i optimizacijski program *VRP Spreadsheet Solver*, koji, uklopljen u Excel tablice, može riješiti više od 64 varijante VRP problema. [31] Među njima su i one, kroz rad već ranije spomenute, s ograničenjima kapaciteta, udaljenosti, vremena, istovremene dostave i prikupljanja te dostave i povratnog prikupljanja.

Program je javno dostupan i besplatan što znači da se može preuzeti putem interneta. [32] Njegova najveća prednost, u odnosu na ostale programske pakete, ogleda se kroz jednostavnu, praktičnu i lako razumljivu upotrebu. Osim toga što je vrlo pristupačan, zahtijeva i manje vremena za razvoj od ostalih programskih rješenja, koja podrazumijevaju kodiranje i korištenje drugih naprednih alata.

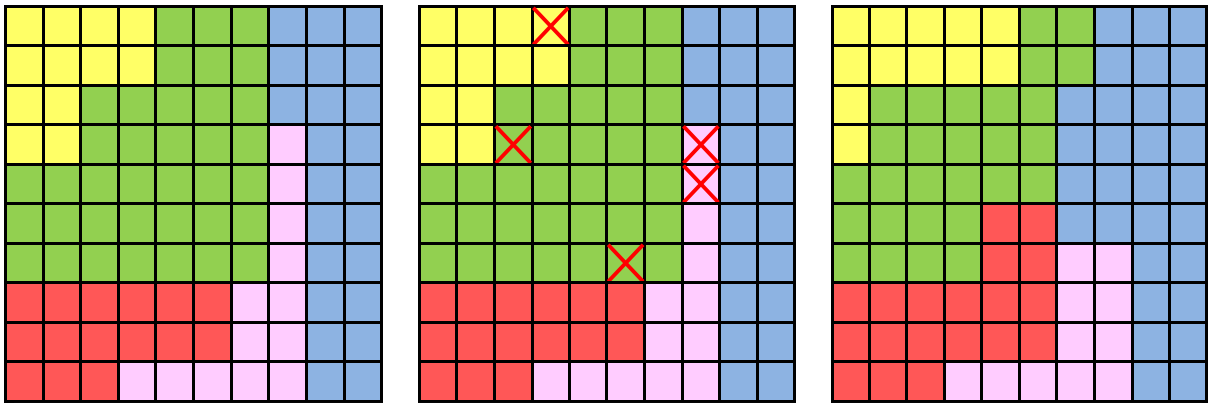
Naime, Excel u sebi već ima ugrađen programski jezik[20] koji pruža osnovne funkcionalnosti, ali i iznimnu fleksibilnost koja je na razini programskog jezika visoke razine. Upravo o toj fleksibilnosti svjedoče i 64 varijante problema koje mogu biti riješene, te do 200 korisnika u njima koji mogu raspoređeni na bilo kojem geografskom području. Ta se brojka korisnika može proširiti ugradnjom posebnih dodataka u program, no to onda za sobom nosi posljedicu usporavanja njegovih radnih funkcija. Po tom pitanju programski jezik Excela ne može se natjecati s programskim jezikom C++. Tome u prilog idu i neka neformalna istraživanja koja otkrivaju da je programski jezik Excela i do 3 puta sporiji od programskog jezika C++, čak i po pitanju osnovnih aritmetičkih operacija. Štoviše, dosadašnja iskustva korištenja programskog jezika u Excelu, navode da je u praksi taj rezultat još porazniji. [31] To ne treba čuditi budući da se oduvijek za veću kvalitetu trebala platiti i određena, obično veća cijena, a ovaj program, treba još jednom napomenuti, je potpuno besplatan.

[20] (engl. ***V****isual* ***B****asic For* ***A****pplications* – VBA)

6.3.1. Implementirani algoritam unutar programskog alata

Budući da je program oplemenjen metaheurističkim pristupom, u njega je implementiran upravo jedan takav algoritam. Radi se o pretraživanju velikog susjedstva[21], odnosno postupku koji je baziran na lokalnom pretraživanju. Njegova strategija svodi se na to da tijekom pretraživanja pokušava obuhvatiti što širi prostor rješenja, a nakon toga detaljnije istražiti samo ona područja koja obećavaju pronalazak kvalitetnih rješenja. Pritom se nije dobro previše zadržavati na određenom području u prostoru rješenja i pretjerano ga istraživati, osobito ako ono ne obećava pronalazak kvalitetnih rješenja, ali isto ga tako nije pametno niti prerano napustiti bez detaljnije analize, iz razloga što se u blizini mogu nalaziti adekvatna tražena rješenja. [25]

Posljedično s time što ovaj algoritam omogućuje pretraživanje puno šireg prostora rješenja, u njegovim se iteracijama privremeno/povremeno prihvaćaju i lošija rješenja. Takav koncept se naziva principom uništavanja i popravljanja[22], a može se vidjeti na slici (Slika 30). Onoga trenutka kada pretraga ne uspije pronaći bolje rješenje od postojećeg, sama se zaustavlja u svojem lokalnom optimumu. [25]



a) Inicijalno rješenje *b) Uništeno* *c) Popravljeno*

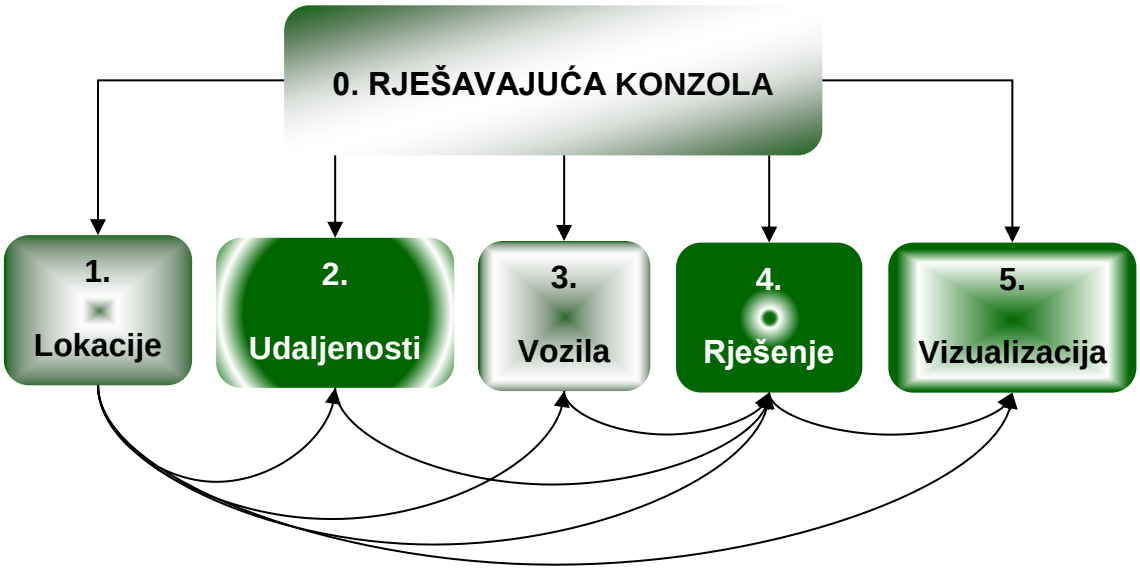
Slika 30. Rezultat operacije uništavanja i popravljanja
Izvor: Izradio autor prema [33]

[21] (engl. ***L**arge **N**eighborhood **S**earch* – LNS)
[22] (engl. ***R**uin **and R**ecreate* – R&R)

Jedna od praktičnih prednosti ovog algoritma ogleda se u mogućnosti jednostavnog prilagođavanja novim ograničenjima. S takvom značajkom, potrebno je modificirati samo postupak popravljanja kojim se korisnici dodaju u rute. Upravo je zbog toga jedan ovakav metaheuristički algoritam konačno i odabran za nositelja pretraživanja prostora rješenja unutar strukture programskog alata.

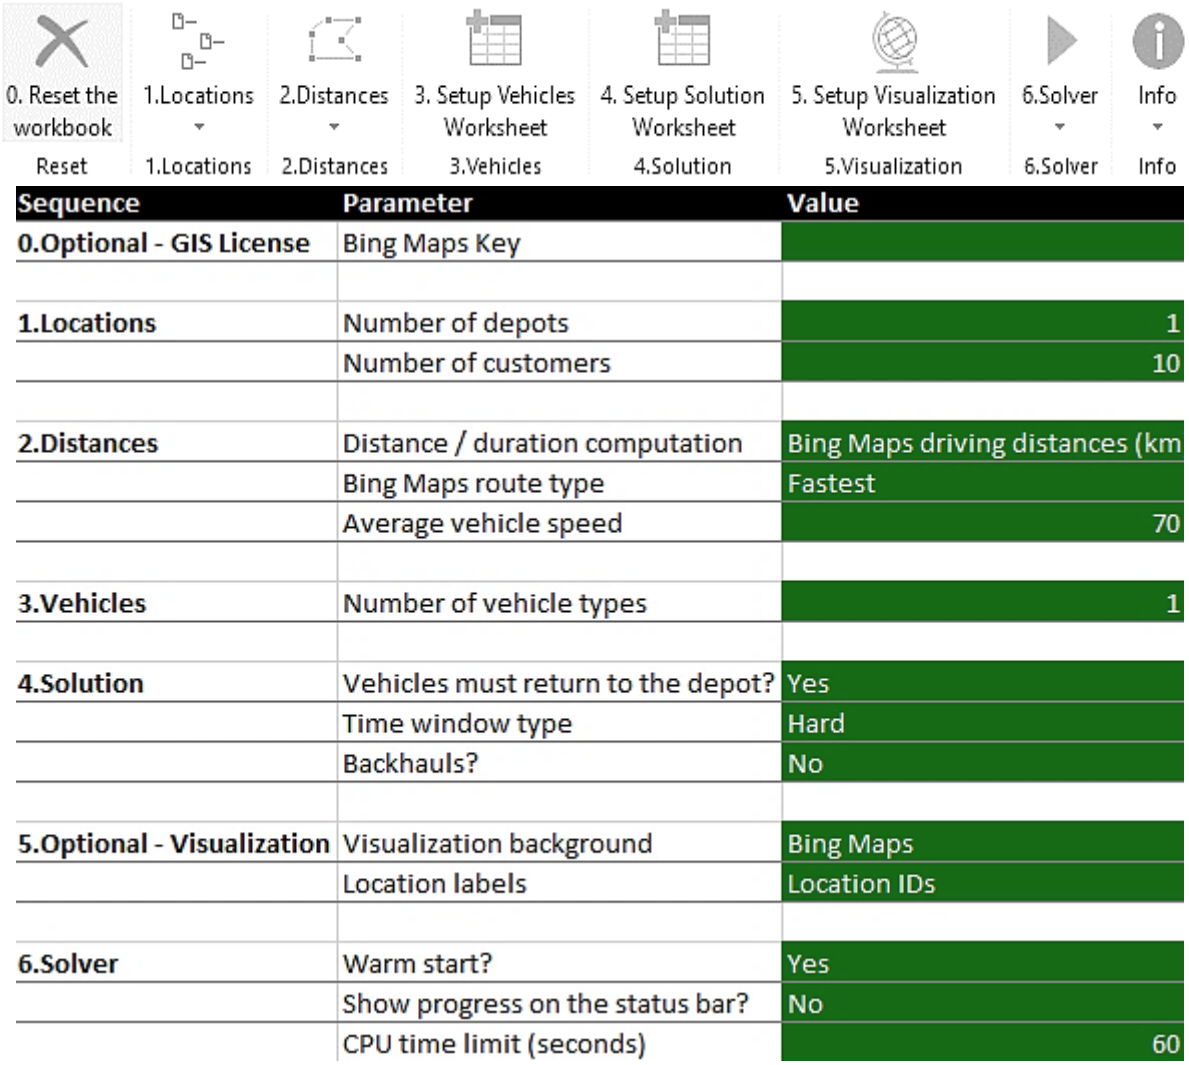
6.3.2. Struktura i okruženje programskog alata

Programski alat u Excelu sastavljen je od proračunskih tablica na nekoliko zasebnih listova, u kojima protok informacija postupno napreduje. Na početku radna knjiga sadrži samo radni list pod nazivom rješavajuća konzola, dok se preostali radni listovi generiraju u slijedu, sukladno indeksima koji označuju njihov redoslijed (Slika 31). Osim redoslijeda, na slici je prikazan i protok podataka između proračunskih tablica, a strelice pritom označuju međusobne ovisnosti radnih listova.



Slika 31. Shema programskog okruženja u Excelu
Izvor: Izradio autor prema [31]

Iz slike se također potvrđuje da je nulti korak ovog programskog alata popunjavanje *radnog lista s rješavajućom konzolom*. Taj list služi za pohranu i davanje informacija preostalim radnim listovima te sadrži različite ulazne parametre, među kojima su najvažniji oni o broju skladišta, korisnika i raspoloživih vrsta vozila (Slika 32). Veličine ovih parametara ovise o težini problema koji se rješava.

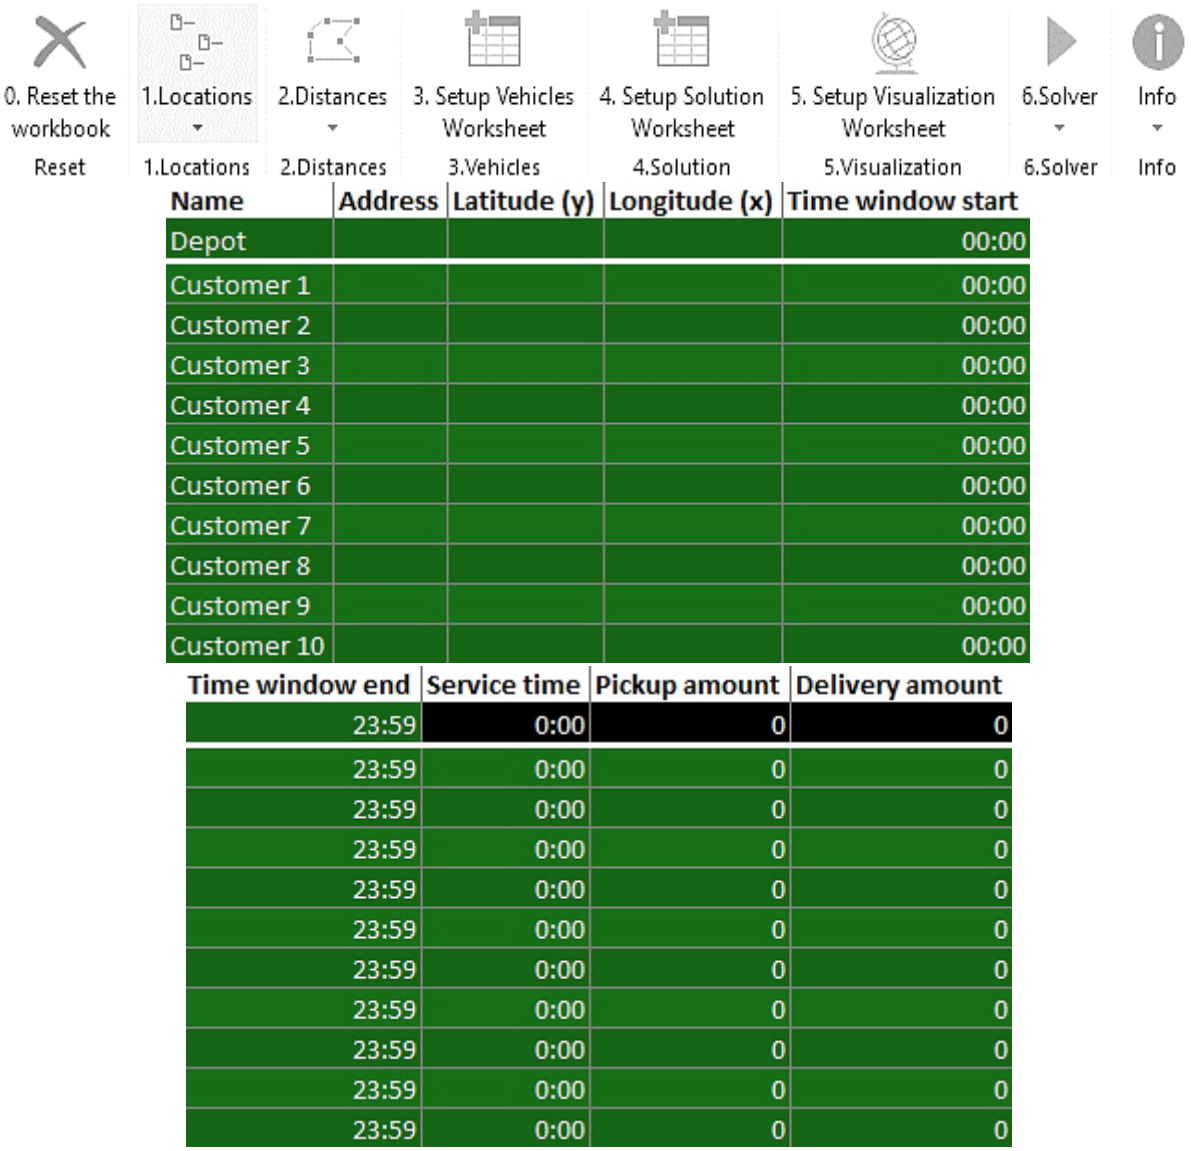


Sequence	Parameter	Value
0.Optional - GIS License	Bing Maps Key	
1.Locations	Number of depots	1
	Number of customers	10
2.Distances	Distance / duration computation	Bing Maps driving distances (km
	Bing Maps route type	Fastest
	Average vehicle speed	70
3.Vehicles	Number of vehicle types	1
4.Solution	Vehicles must return to the depot?	Yes
	Time window type	Hard
	Backhauls?	No
5.Optional - Visualization	Visualization background	Bing Maps
	Location labels	Location IDs
6.Solver	Warm start?	Yes
	Show progress on the status bar?	No
	CPU time limit (seconds)	60

Slika 32. Radni list s rješavajućom konzolom
Izvor: Izradio autor

Nakon radnog lista s rješavajućom konzolom, u kojem su dane tek početne informacije o problemu, na red dolazi i *radni list s lokacijama*, koji sadrži detaljne pojedinosti o skladištima i korisnicima (Slika 33). U tom radnom listu nalaze se njihova imena, adrese, koordinate, vremenski prozori, trajanja posluživanja te zahtjevi za prikupljanjem i/ili dostavljanjem robe.

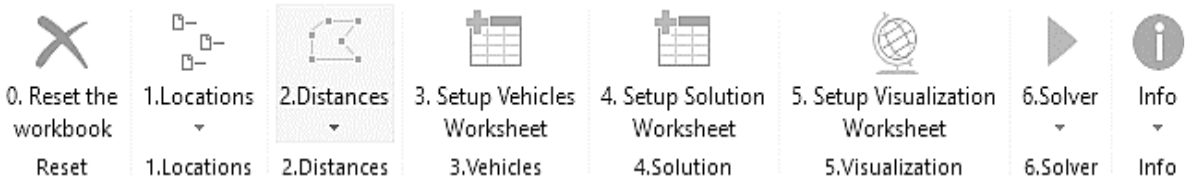
Pritom za koordinate valja napomenuti da se mogu unositi ručno, da se mogu izravno učitavati pomoću kompatibilnog vanjskog izvora ili da se mogu popuniti putem GIS web servisa (engl. ***G****eographic* ***I****nformation* ***S****ystem* – GIS), na temelju prethodno unesenih adresa. Poželjno je također da se uz svaku adresu dopiše i poštanski broj, budući da nejasne adrese mogu dovesti do nedostupnih lokacija.



Name	Address	Latitude (y)	Longitude (x)	Time window start	Time window end	Service time	Pickup amount	Delivery amount
Depot				00:00	23:59	0:00	0	0
Customer 1				00:00	23:59	0:00	0	0
Customer 2				00:00	23:59	0:00	0	0
Customer 3				00:00	23:59	0:00	0	0
Customer 4				00:00	23:59	0:00	0	0
Customer 5				00:00	23:59	0:00	0	0
Customer 6				00:00	23:59	0:00	0	0
Customer 7				00:00	23:59	0:00	0	0
Customer 8				00:00	23:59	0:00	0	0
Customer 9				00:00	23:59	0:00	0	0
Customer 10				00:00	23:59	0:00	0	0

Slika 33. Radni list s lokacijama
Izvor: Izradio autor

Po završetku opisivanja radnog lista s lokacijama slijedi *radni list s udaljenostima*. Osim samih udaljenosti, ovaj radni list sadrži i trajanja putovanja između skladišta i svakog pojedinog korisnika, kao i između svaka dva korisnika međusobno (Slika 34).



From	To	Distance	Duration
Depot	Depot	0,00	0:00
Depot	Customer 1	0,00	0:00
Depot	Customer 2	0,00	0:00
Depot	Customer 3	0,00	0:00
Depot	Customer 4	0,00	0:00
Depot	Customer 5	0,00	0:00
Depot	Customer 6	0,00	0:00
Depot	Customer 7	0,00	0:00
Depot	Customer 8	0,00	0:00
Depot	Customer 9	0,00	0:00
Depot	Customer 10	0,00	0:00

From	To	Distance	Duration
Customer 1	Depot	0,00	0:00
Customer 1	Customer 1	0,00	0:00
Customer 1	Customer 2	0,00	0:00
Customer 1	Customer 3	0,00	0:00
Customer 1	Customer 4	0,00	0:00
Customer 1	Customer 5	0,00	0:00
Customer 1	Customer 6	0,00	0:00
Customer 1	Customer 7	0,00	0:00
Customer 1	Customer 8	0,00	0:00
Customer 1	Customer 9	0,00	0:00
Customer 1	Customer 10	0,00	0:00

From	To	Distance	Duration
Customer 2	Depot	0,00	0:00
Customer 2	Customer 1	0,00	0:00
Customer 2	Customer 2	0,00	0:00
Customer 2	Customer 3	0,00	0:00
Customer 2	Customer 4	0,00	0:00
Customer 2	Customer 5	0,00	0:00
Customer 2	Customer 6	0,00	0:00
Customer 2	Customer 7	0,00	0:00
Customer 2	Customer 8	0,00	0:00
Customer 2	Customer 9	0,00	0:00
Customer 2	Customer 10	0,00	0:00

From	To	Distance	Duration
Customer 3	Depot	0,00	0:00
Customer 3	Customer 1	0,00	0:00
Customer 3	Customer 2	0,00	0:00
Customer 3	Customer 3	0,00	0:00
Customer 3	Customer 4	0,00	0:00
Customer 3	Customer 5	0,00	0:00
Customer 3	Customer 6	0,00	0:00
Customer 3	Customer 7	0,00	0:00
Customer 3	Customer 8	0,00	0:00
Customer 3	Customer 9	0,00	0:00
Customer 3	Customer 10	0,00	0:00

From	To	Distance	Duration
Customer 4	Depot	0,00	0:00
Customer 4	Customer 1	0,00	0:00
Customer 4	Customer 2	0,00	0:00
Customer 4	Customer 3	0,00	0:00
Customer 4	Customer 4	0,00	0:00
Customer 4	Customer 5	0,00	0:00
Customer 4	Customer 6	0,00	0:00
Customer 4	Customer 7	0,00	0:00
Customer 4	Customer 8	0,00	0:00
Customer 4	Customer 9	0,00	0:00
Customer 4	Customer 10	0,00	0:00

From	To	Distance	Duration
Customer 10	Depot	0,00	0:00
Customer 10	Customer 1	0,00	0:00
Customer 10	Customer 2	0,00	0:00
Customer 10	Customer 3	0,00	0:00
Customer 10	Customer 4	0,00	0:00
Customer 10	Customer 5	0,00	0:00
Customer 10	Customer 6	0,00	0:00
Customer 10	Customer 7	0,00	0:00
Customer 10	Customer 8	0,00	0:00
Customer 10	Customer 9	0,00	0:00
Customer 10	Customer 10	0,00	0:00

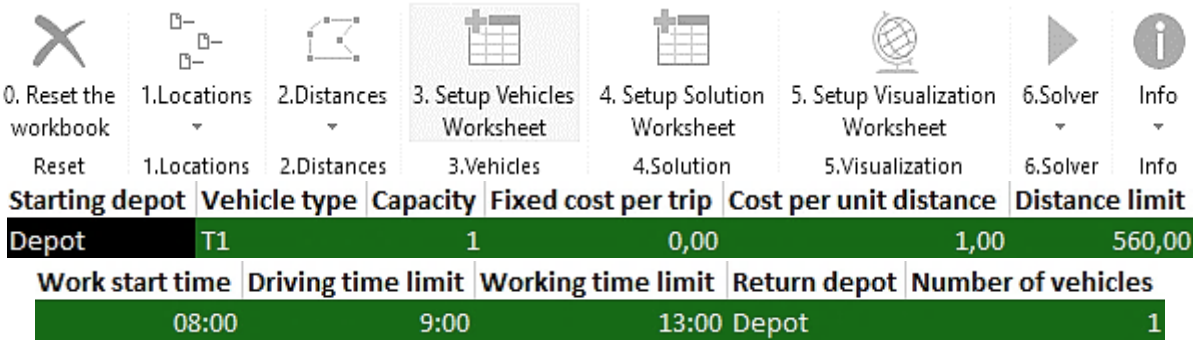
Slika 34. Skraćeni radni list s udaljenostima
Izvor: Izradio autor

Značajan utjecaj na to koliko će iznositi udaljenosti i trajanja putovanja u ovoj proračunskoj tablici, ima odabir parametra koji se nalazi na početnom radnom listu rješavajuće konzole, a tiče se načina kojim će se rute u daljnjim postupcima odabirati (najkraća ili najbrža ruta).

Odabir najkraće rute obično pronalazi one rute koje prolaze gradskim centrima i kao takve podliježu vrlo gustom prometu i strogim ograničenjima. Takve rute predstavljaju bolji izbor kada postoji potreba za obavljanjem gradskih dostava.

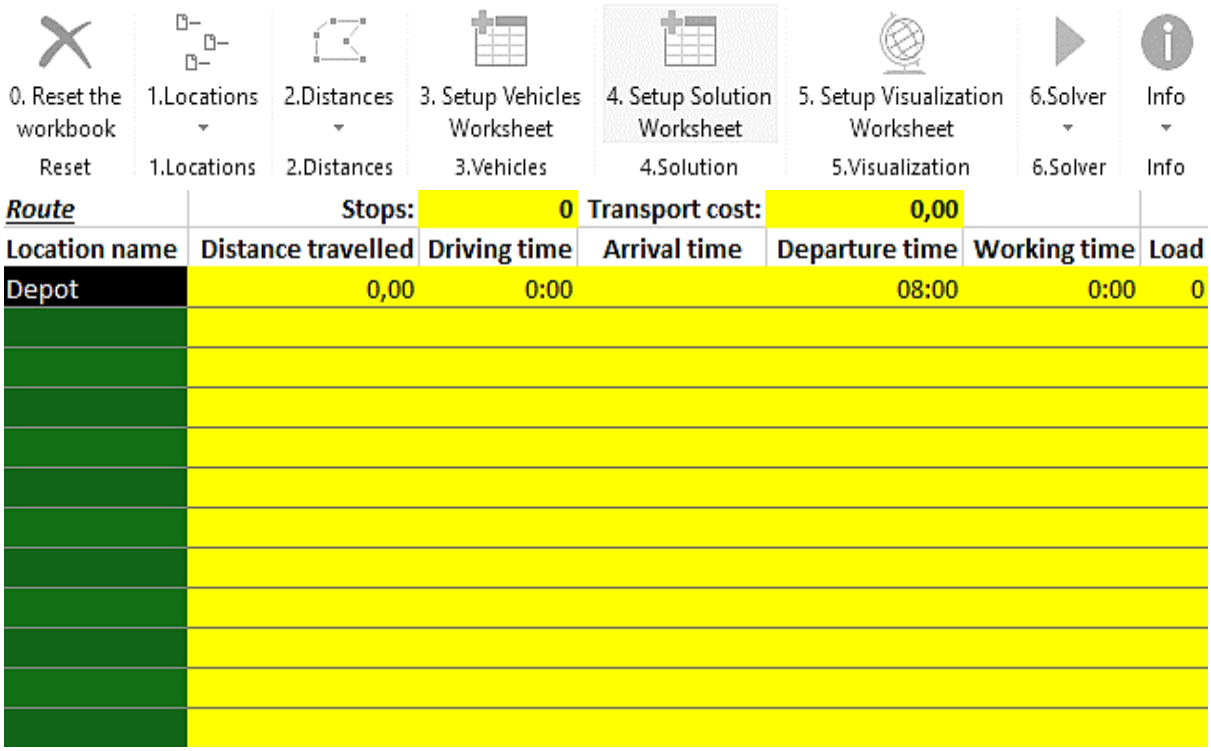
S druge strane, odabirom najbržih ruta ostvaruje se pretpostavka korištenja perifernih prometnica, brzih cesta i autocesta pa su takve rute bolja opcija za operacije s velikim dostavnim udaljenostima.

Nakon definiranja udaljenosti i vremena putovanja, temeljem odabranih najkraćih ili najbržih ruta, slijedi *radni list s vozilima*, u kojem su uključeni razni troškovni i radni parametri. Troškovni parametri sastoje se od fiksnih troškova po putovanju te troškova po jedinici prijeđene udaljenosti. Radni parametri uključuju kapacitet vozila, njegov početak rada, maksimalnu udaljenost koju ne smije prekoračiti te radna vremena koja se vežu uz vozača tog vozila (Slika 35). Spomenuti parametar kapaciteta može odgovarati masenoj ili volumnoj mjernoj jedinici, ovisno o tome koja je mjerna jedinica upisana za količinu robe u radnom listu s lokacijama.



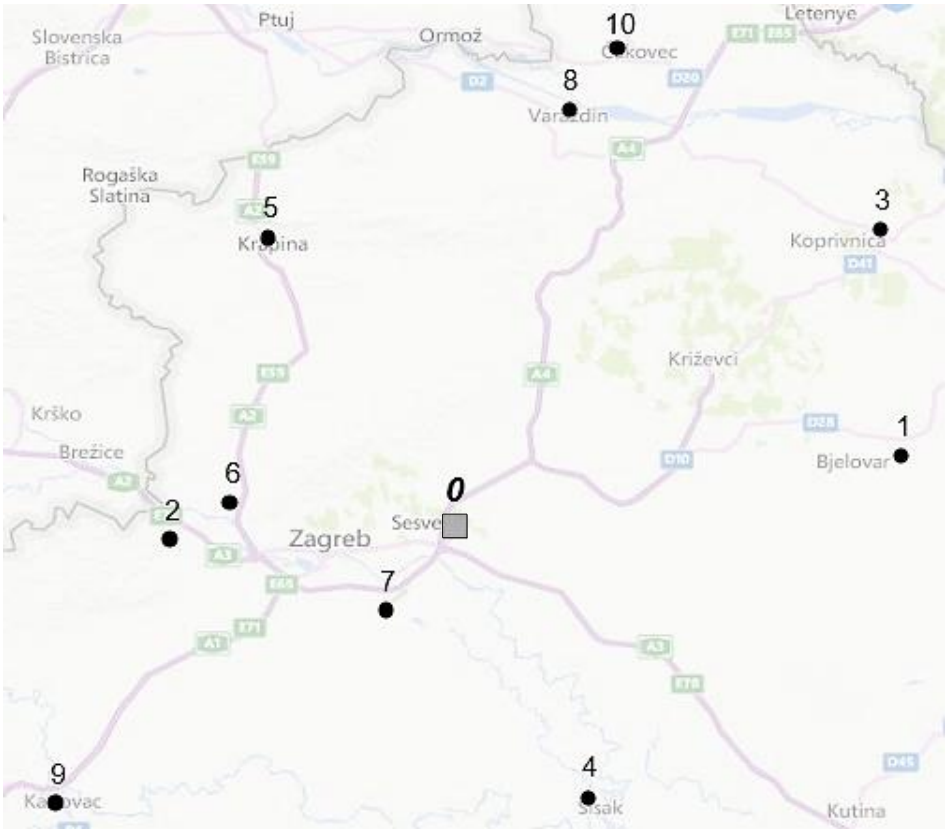
Slika 35. Radni list s vozilima
Izvor: Izradio autor

Za dobivanje rješenja u *radnom listu s rješenjem*, koriste se informacije iz svih prijašnjih radnih listova. Primjerice, iz radnog lista s vozilima koriste se informacije za svako vozilo koje je u njemu specificirano. Nadalje, iz radnog lista s lokacijama dohvaćaju se informacije o vremenu posluživanja, kao i količinama robe za dostavu i/ili prikupljanje. Podatci o udaljenostima i trajanjima putovanja iz radnog lista s udaljenostima, nužni su radi izračunavanja vremena polaska/dolaska te troškova putovanja između korisnika (Slika 36).



Slika 36. Radni list s rješenjem
Izvor: Izradio autor

Iz podataka koji će se generirati u radnom listu s rješenjem, moći će se iščitati rezultati preraspodjele korisnika, ruta i vozila, odnosno koji će korisnik pripasti kojoj ruti i koja će ruta pripasti kojem vozilu. Jednom kada takvo rješenje bude poznato, ono će se i vizualno moći pregledati u posljednjem listu koji nosi naziv *vizualni radni list*. U njemu su rute i lokacije korisnika prikazane grafom rasipanja, uz podršku zemljopisne karte koja je preuzeta iz javnog GIS servisa. Taj se graf, poput svakog grafičkog objekta u Excelu, može oblikovati prema potrebama i željama korisnika programa (Slika 37).



Slika 37. Vizualizacija skladišta i korisnika
Izvor: Izradio autor

Zaključno se može reći da *VRP Spreadsheet Solver*, kao programski alat za optimizaciju i planiranje ruta, svoju primjenu nalazi u stvarnom svijetu i na stvarnim problemima. Iako je prvenstveno predviđen za upotrebu od strane logističkog operatera, poslužit će kao pomoć i svima ostalima koji se suočavaju s problemom usmjeravanja vozila. Zbog toga je njegov potencijal velik i osobit, a posebno se to odnosi na manje i srednje tvrtke koje imaju u cilju postići značajnije uštede u transportnom poslovanju.

Da bi se potencijal ovog programskog alata dokazao i u praksi, za stvarni primjer problema uzeta je transportna mreža logističke tvrtke Quehenberger Logistics GmbH, koja dio svojeg međunarodnog poslovanja obavlja i u Republici Hrvatskoj.

7. OPTIMIZACIJA TRANSPORTNE MREŽE NA PRIMJERU IZ PRAKSE

Logistička tvrtka Quehenberger Logistics GmbH, austrijska je tvrtka s dugom tradicijom koja seže sve do 60-ih godina prošlog stoljeća. U početku je bila vlasništvo Rudija Quehenbergera, po kojemu je i dobila ime, a danas je u privatnom vlasništvu Christiana Fürstallera i Rodolphea Schoettela, kao dio grupacije Augustin Quehenberger Group GmbH. Sjedište joj je u Straßwalchenu, u blizini Salzburga, i trenutno zapošljava oko 2.900 djelatnika, na 85 lokacija, u 18 zemalja svijeta (Slika 38).



Slika 38. Rasprostranjenost tvrtke Quehenberger Logistics GmbH u Europi
Izvor: Prilagodio autor prema [34]

Budući da brojke govore same za sebe, osim prethodno navedenih, vrijedi spomenuti i one koje su zaslužne za ugled tvrtke u poslovnom svijetu, a temelje se na činjeničnom stanju (Tablica 6).

Tablica 6. Indikatori performansi tvrtke Quehenberger Logistics GmbH u 2017.

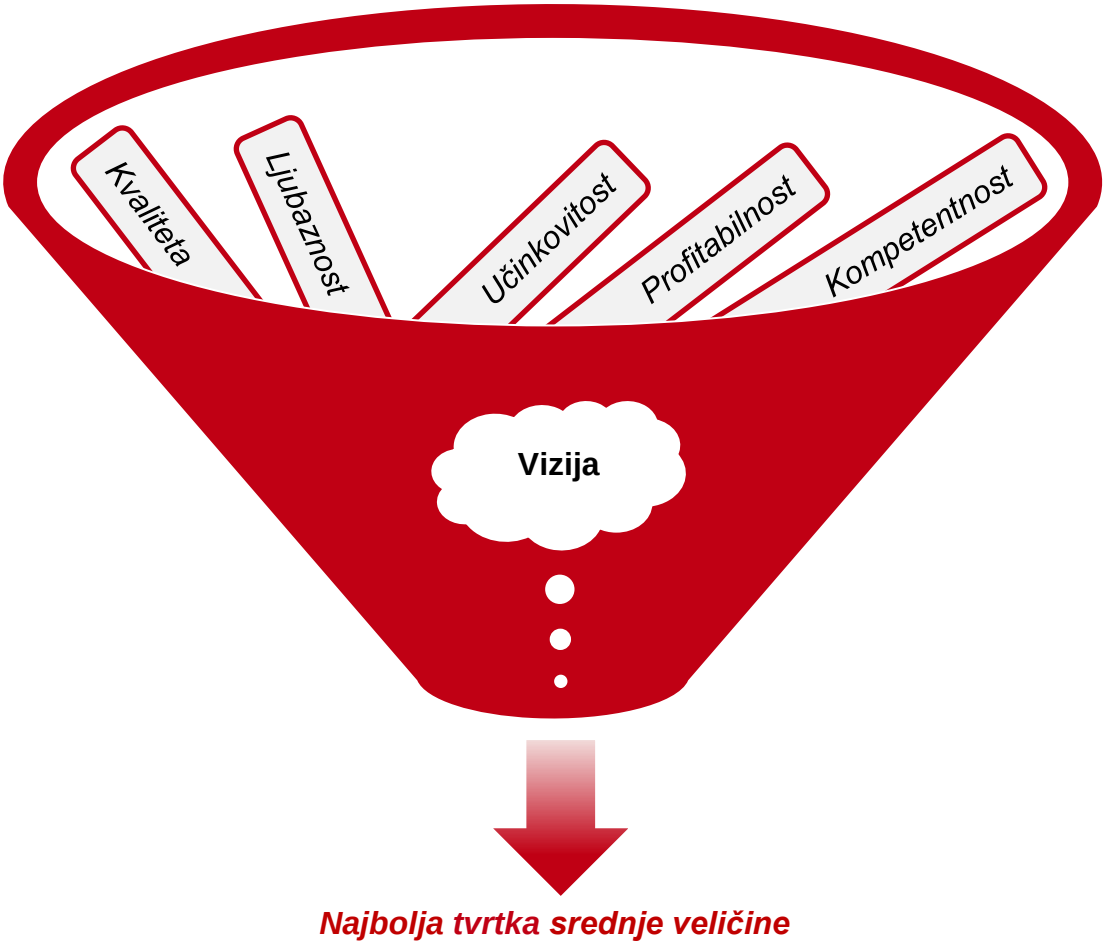
Promet	**450.000.000 EUR**
Rast prometa	>13%
Pošiljke punih kamiona[23] */ Pošiljke nepunih kamiona*[24] */ Intermodalni promet / Željeznički promet / Maloprodaja*	600.000 pošiljaka
Domaći + međunarodni zbirni promet / Zračni + Morski promet / Carinjenje	1.800.000 pošiljaka

Izvor: Izradio autor prema [35]

Ove brojke upućuju na to da se radi se o visokokvalitetnoj tvrtki srednje veličine, a kao takva, ona je fokusirana na one gospodarske grane i regije u kojima je bolja od ostalih. Tome u prilog ide i njena vizija, iz koje se može iščitati da joj je namjera postati najboljom logističkom tvrtkom srednje veličine u Centralnoj i Istočnoj Europi (Slika 39). Uz to, tvrtka želi biti: [36]

- Uvjerljiva po kvaliteti usluge;
- Nenadmašna u efikasnosti;
- Sposobna poslovati s profitabilnošću koja osigurava njenu prosperitetnu budućnost.

[23] (engl. ***F**ull **T**ruck **L**oad* – FTL)
[24] (engl. ***L**ess **T**han **L**oad* – LTL)



Slika 39. Vizija tvrtke Quehenberger Logistics GmbH
Izvor: Izradio autor

Značajnu ulogu u takvom poduhvatu, osobito kada se radi o Istočnoj Europi, ima Quehenberger Hrvatska d.o.o., koja je osnovana 2011. godine te danas ima sjedište u Svetoj Nedelji.

Tvrtka u Hrvatskoj posjeduje sve reference kako bi u zadanom roku Quehenberger grupacije postala nezaobilazan logistički partner svima onima kojima su uspjeh i kvaliteta na samom vrhu prioriteta poslovanja. Tako je, između ostalog, certificirana i prema ISO 9001[25], ISO 14001[26] te BS OHSAS 18001[27] standardima.

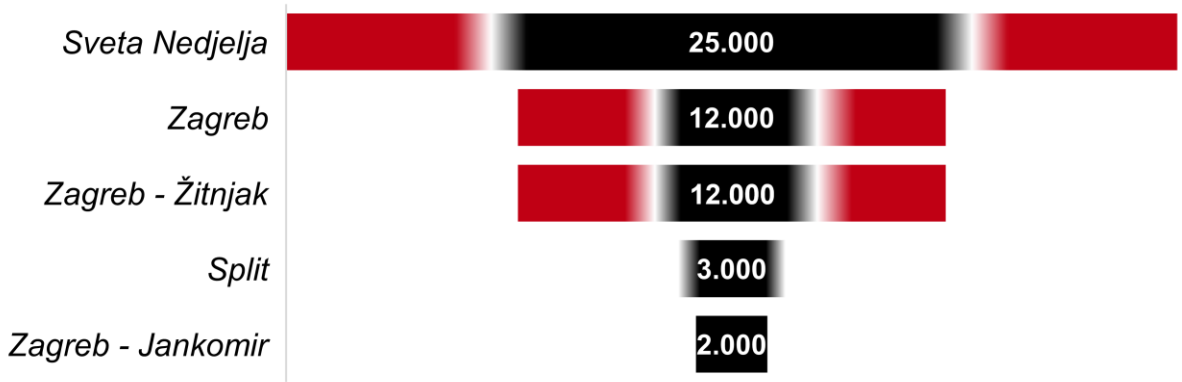
[25] Certifikat kvalitete.
[26] Certifikat okoliša.
[27] Certifikat sigurnosti.

Kako bi se spomenuta vizija grupacije nastavila razvijati, tvrtka je u samom početku zaposlila visokokvalitetan profesionalni kadar, s respektabilnim iskustvom na području logistike. Taj kadar danas broji oko 511 zaposlenika na nekoliko lokacija u Republici Hrvatskoj, točnije od lokacije sjedišta u Svetoj Nedelji, do lokacija područnih ureda u Zagrebu, Splitu, Osijeku i Rijeci (Slika 40).



Slika 40. Sjedište i područni uredi tvrtke Quehenberger Hrvatska d.o.o.
Izvor: Prilagodio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Ukupni skladišni prostori tvrtke u Hrvatskoj rasprostiru se na 69.000 m^2, od čega najveći udjel pripada glavnom skladištu u Svetoj Nedelji gdje je dostupno 25.000 m^2, uz mogućnost proširenja na još dodatnih 15.000 m^2. U Zagrebu je na nekoliko lokacija raspoloživo još ukupno 26.000 m^2, a u Splitu 3000 m^2 (Grafikon 4).



Grafikon 4. Udjeli skladišnog prostora tvrtke Quehenberger Hrvatska d.o.o.
Izvor: Izradio autor

7.1. Analiza transportne mreže

Transportna mreža zbirnih i konsolidiranih pošiljaka tvrtke Quehenberger Hrvatska d.o.o. rasprostranjena je diljem Republike Hrvatske, a okarakterizirana je učinkovitošću, pouzdanošću i jednostavnošću obrade korisničkih zahtjeva. Za to je zaslužna i mreža partnera, koja uz brzu obradu zahtjeva, omogućuje i brzu distribuciju, čime se zaokružuje kompletna pružena usluga (Slika 41).



Slika 41. Mreža partnera tvrtke Quehenberger Hrvatska d.o.o.
Izvor: Prilagodio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Osim prikazanih gradova partnera na slici, Quehenberger Hrvatska d.o.o. ima i svoje kooperante u Erdutu, Tovarniku i Vukovaru, mjestima od posebne važnosti preko čijih se graničnih prijelaza ostvaruje spajanje na Quehenberger Balkansku mrežu.

Upravo je izdvajanje poslova vanjskim kooperantima – *outsourcing*, jedna od ključnih sposobnosti tvrtke. Time se omogućuje da tvrtka, kao partner i suradnik, optimizira logističke procese za svoje korisnike (klijente), tako što svakodnevno korespondira s prijevoznicima i skladištima. Na taj način organizirana je i nacionalna

distribucija, a za potrebe ovoga primjera, iz tvrtkine baze podataka izdvojeni su podatci jedne klasične dnevne distribucije koja obuhvaća sedam (7) ruta, podijeljenih na nekoliko regija, u kojima su uključeni i neki od partnera s prethodne slike (Tablica 7).

Tablica 7. Generalni prikaz podataka za svih sedam ruta

Ruta	*Država dostave*	*Regija*	*Vrsta Vozila*	*Volumen (m^3)*	*Masa (kg)*	*Količina (broj)*
1	Hrvatska	Rijeka 2	Kamion	20,752	2143,19	61
2	Hrvatska	Sjever	Kombi	8,985	975,33	28
3	Hrvatska	Karlovac	Kamion	19,099	2407,565	66
4	Hrvatska	Istra	Kamion	11,171	1586,57	126
5	Hrvatska	Rijeka	Kamion	12,81	1723,57	50
6	Hrvatska	Slavonija	Kamion	17,2	2371,87	1302
7	Hrvatska	Dalmacija	Tegljač	42,39	5997,281	333
			∑	**132,407**	**17205,376**	**1966**

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

U konkretnom primjeru, disponent koji je zadužen za planiranje, organiziranje i usmjeravanje transportnih ruta, u obzir uzima čimbenike kao što su trošak prijevoza, vrijeme dostave, kapacitet vozila, brzina vozila, dužina rute, uvjeti dostave itd.

Njegov zadatak sastoji se u tome da, pored svih navedenih ograničavajućih čimbenika, odredi redoslijed obilaska dostavnih mjesta i put kojim prijevoznik obavlja distribuciju. Ciljevi koji stoje iza tog zadatka ogledaju se u što manjim transportnim troškovima i što većim koeficijentima popunjenosti vozila. Sve to disponent uglavnom obavlja na temelju iskustva, uz pomoć programa za odabir najkraćeg puta – *Optimap*. Na taj način definirani su i podatci u tablicama koje slijede, a koje detaljnije ulaze u pojedinosti svake rute.

Za prvu rutu koja se odnosi na regiju Rijeka 2, detaljni podatci dani su u tablici (Tablica 8). U njoj su navedena mjesta dostave, imena konkretnih primatelja (klijenata/korisnika), njihove adrese, karakteristike same robe (volumen u kubičnim metrima; masa u kilogramima; količina u broju pošiljaka) te redoslijedi obilaska dostavnih mjesta. Na koncu su dane i informacije koje se tiču vozila, točnije njegovog vremenskog zadržavanja u skladištu te transportnog troška[28] kojeg generira.

[28] U transportni trošak dodatno su uključeni iznosi cestarina, mostarina i tunelarina.

Tablica 8. Detaljni prikaz podataka za analizu rute 1 – regija Rijeka 2

Volumen	*Masa*	*Količina*	*Mjesto dostave*	*Primatelj*	*Adresa*	*Redoslijed dostave*
16,588	1687,23	40	Kukuljanovo	Pevec d.d.	Kukuljanovo 361	**2**
0,037	8,04	6	Kukuljanovo	Pevec d.d.	Kukuljanovo 361	**2**
0,936	97	2	Kukuljanovo	Lesnina H. d.o.o.	Kukuljanovo 345	**1**
0,621	74,5	3	Kukuljanovo	Lesnina H. d.o.o.	Kukuljanovo 345	**1**
0,363	45,48	2	Kukuljanovo	Lesnina H. d.o.o.	Kukuljanovo 345	**1**
2,137	221,14	7	Kukuljanovo	Lesnina H. d.o.o.	Kukuljanovo 345	**1**
0,07	9,8	1	Kukuljanovo	Lesnina H. d.o.o.	Kukuljanovo 345	**1**
∑ **20,752**	**2143,19**	**61**				
Trošak transporta: 1922,71 / Vrijeme dolaska u skladište: 3:00 / Početak ukrcaja: 3:30 / Kraj ukrcaja: 4:30						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Polazište, a ujedno i krajnje odredište rute 1, nalazi se u Svetoj Nedelji – glavnom i najvećem skladištu tvrtke Quehenberger Hrvatska d.o.o. Vrijeme dolaska kamiona u skladište je u ranim jutarnjim satima, točnije u 3:00 sata. Početak ukrcaja je u 3:30, a kraj ukrcaja u 4:30 sati. Ukrcajni prostor kamiona iznosi 35 m^3, što je i više nego dovoljno za ukrcaj i transport robe čiji ukupni volumen u ovoj ruti iznosi 20,752 m^3. Zaključno s krajem ukrcaja, kamion započinje svoju distribuciju u ruti 1.

Ruta 1 najjednostavnija je od svih sedam ruta i to iz nekoliko razloga. Glavni razlog je taj što se dostava odvija samo na jednom mjestu, u naselju Kukuljanovo, nedaleko od Rijeke. Na području Kukuljanova nalazi se Industrijska zona u kojoj su smješteni brojni trgovački, poslovni, skladišni te proizvodni prostori. Upravo tamo se roba iz ove rute i dostavlja, što je još jedan od razloga njene jednostavnosti, jer s aspekta transporta, ta zona kotira kao vrlo dobro isprojektirana. To znači da je za dostavu omogućena nužna protočnost te kvalitetna i brza povezanost s važnim transportnim pravcima. U konačnici, primatelja su samo dva pa i to doprinosi čitavoj jednostavnosti ove rute.

Nakon rute 1, slijedi ruta 2. Ona se tiče Sjeverne regije, a svi njeni detaljni podatci prikazani su u tablici čiji je format identičan prethodnoj, ali uz sadržaj koji je personaliziran samo njoj (Tablica 9).

Tablica 9. Detaljni prikaz podataka za analizu rute 2 – regija Sjever

Volumen	Masa	Količina	Mjesto dostave	Primatelj	Adresa	Redoslijed dostave
0,93	110,87	3	Varaždin	Lesnina H. d.o.o.	Gospodarska ul. 37	**1**
0,512	43,63	1	Varaždin	Frigo & Co. d.o.o.	Gospodarska ul. 29A	**3**
1,665	117,62	2	Varaždin	Frigo & Co. d.o.o.	Gospodarska ul. 29A	**3**
0,029	4,6	1	Ludbreg	Frigo & Co. d.o.o.	Ul. Rudolfa Fizira 6	**4**
0,741	49,95	1	Koprivnica	Frigo & Co. d.o.o.	Ul. Frana Galovića 24	**5**
4,433	553,6	12	Koprivnica	Pevec d.d.	Radnička cesta 10	**6**
0,675	95,06	8	Varaždin	Bauhaus d.o.o.	Gospodarska ul. 29	**2**
∑ **8,985**	**975,33**	**28**				
Trošak transporta: 864,22 / Vrijeme dolaska u skladište: 8:00 / Početak ukrcaja: 8:30 / Kraj ukrcaja: 9:00						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Polazišno/odredišno skladište rute 2 nalazi se u Svetoj Nedelji, a kombi do njega dolazi u 8:00 sati. Početak i kraj ukrcaja predviđeni su u 8:30, odnosno 9:00 sati. Kombi raspolaže ukrcajnim prostorom od 20 m^3, čime su zadovoljene potrebe ove rute za ukupnom zapreminom robe od 8,985 m^3.

Sadržajno je ruta 2 nešto malo raznovrsnija u odnosu na rutu 1, a ono što ju izdvaja od ostalih, jest najmanja količina robe koja treba biti dostavljena klijentima. Dostava se vrši u gradove Varaždin, Ludbreg i Koprivnicu, a nakon posjete zadnjem gradu i dostave robe zadnjem primatelju, vozilo se vraća u skladište, čime ova ruta završava.

Iduća ruta je ruta 3, a ona je zadužena za regiju Karlovac. Podatci za rutu 3 prikazani su u identičnom tabličnom formatu kao i kod prethodnih ruta (Tablica 10).

Tablica 10. Detaljni prikaz podataka za analizu rute 3 – regija Karlovac

Volumen	Težina	Količina	Mjesto	Primatelj	Adresa	Redoslijed dostave
0,176	22,005	3	Karlovac	E plus d.o.o.	Prilaz V. Holjevca 12	**2**
12,832	1326,46	29	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
1,367	290	5	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
0,517	55,6	2	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
1,093	232	4	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
0,869	180	3	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
0,177	30,6	8	Karlovac	Pevec d.d.	Ul. Antuna Mihanovića 1A	**1**
2,068	270,9	12	Sisak	Pevec d.d.	Zagrebačka ul. 47	**3**
∑ **19,099**	**2407,57**	**66**				
Trošak transporta: 1228,01 / Vrijeme dolaska u skladište: 8:00 / Početak ukrcaja: 8:30 / Kraj ukrcaja: 9:15						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Ruta 3 započinje i završava distribuciju u skladištu kod Svete Nedelje. Vrijeme dolaska u skladište i početak ukrcaja identični su kao i u prethodnoj ruti, dok je kraj ukrcaja produžen te se predviđa u 9:15 sati. U ovoj ruti ponovno se koristi kamion kapaciteta 35 m^3, koji bez poteškoća može ukrcati robu volumena 19,099 m^3.

Ova je ruta vrlo slična prethodnim dvjema budući da nema veliki broj dostavnih mjesta, odnosno primatelja koje treba posjetiti. Ona s dostavljanjem robe započinje u Karlovcu za dva različita primatelja, a završava se u Sisku kod jednog primatelja. Nakon Siska slijedi povratak prema skladištu u Svetoj Nedelji.

Time je ova ruta zaključena, a iduća na redu je ruta 4 koja se odnosi na distribuciju u regiji Istra. Svi se konkretni podatci vezani uz tu rutu nalaze u tablici (Tablica 11).

Tablica 11. Detaljni prikaz podataka za analizu rute 4 – regija Istra

Volumen	*Težina*	*Količina*	*Mjesto dostave*	*Primatelj*	*Adresa*	*Redoslijed dostave*
1,367	290	5	Pula	Pevec d.d.	Industrijska ul. 15	**1**
0,074	16,08	12	Pula	Pevec d.d.	Industrijska ul. 15	**1**
0,048	8,5	1	Vodnjan	Lesnina H. d.o.o.	Šijanska cesta 60	**2**
0,24	42	2	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
1,935	145,35	3	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
0,109	168,3	17	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
0,032	5,6	1	Vodnjan	Lesnina H. d.o.o.	Šijanska cesta 60	**2**
0,032	5,6	1	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
0,651	60	1	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
0,645	51,5	1	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
1,774	156,9	5	Poreč	Labelle d.o.o.	Creska ul. 34	**3**
0,775	83,4	3	Pula	Pevec d.d.	Industrijska ul. 15	**1**
1,448	300	5	Pula	Pevec d.d.	Industrijska ul. 15	**1**
2,041	253,34	69	Pula	Pevec d.d.	Industrijska ul. 15	**1**
∑ **11,171**	**1586,57**	**126**				
Trošak transporta: 3601,21 / Vrijeme dolaska u skladište: 5:00 / Početak ukrcaja: 5:30 / Kraj ukrcaja: 6:00						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Početak i završetak rute 4 odvija se u skladištu koje se nalazi u Svetoj Nedelji. Kamion dolazi u skladište u 5:00 sati, njegov početak ukrcaja je u 5:30 sati, a kraj se predviđa u 6:00 sati. Ukrcajni prostor kamiona ograničen je na 35 m^3, dok ukupni volumen robe za ovu rutu iznosi 11,171 m^3. Iz toga proizlazi da je ograničenje kapaciteta ispoštovano te se po završetku ukrcaja robe može krenuti s distribucijom.

Ruta 4 s distribucijom započinje u Puli, a zatim slijede gradovi Vodnjan i Poreč. Zadnje obavljena dostava u Poreču znači da se kamion može vratiti odakle je i krenuo na putovanje – u skladište iz Svete Nedelje.

Zaključno s rutom 4 započinje ruta 5, koja se ponovno dotiče Rijeke pa stoga i naziv regije glasi tako. Podatci za tu rutu su, kao i u prethodnim slučajevima, dani u standardiziranoj pripadajućoj tablici (Tablica 12).

Tablica 12. Detaljni prikaz podataka za analizu rute 5 – regija Rijeka

Volumen	Težina	Količina	Mjesto dostave	Primatelj	Adresa	Redoslijed
0,118	14,67	2	Rijeka	E plus d.o.o.	Zvonimirova ul. 3	**1**
8,325	1162,7	27	Rijeka	Pevec d.d.	Škurinjska cesta 9B	**2**
2,251	252,6	5	Krk	Elektro Krk t.o.	Ul. Stjepana Radića 1A	**3**
2,116	293,6	16	Malinska	Trgovina Krk d.d.	Ul. sv. Vid - Miholjice 116	**4**
∑ **12,81**	**1723,57**	**50**				
Trošak transporta: 2484,10 / Vrijeme dolaska u skladište: 7:30 / Početak ukrcaja: 8:00 / Kraj ukrcaja: 8:30						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Polazište/odredište rute 5 identično je prethodnim rutama. Vrijeme dolaska kamiona u skladište je u 7:30 sati, dok je početak ukrcaja predviđen oko 8:00 sati. Kraj ukrcaja, koji ujedno označuje i početak distribucije robe prema primateljima, očekuje se u 8:30 sati. Kamion s ukrcajnim prostorom od 35 m^3 udovoljava ograničenju kapaciteta jer ukupni volumen robe za rutu 5 iznosi 12,81 m^3 (12,81 < 35).

Kao što je već navedeno, ova ruta ponovno ide do Rijeke, ali ovoga puta mora proći samim centrom grada, zbog čega je njena realizacija mnogo zahtjevnija od rute 1, koja se dotiče samo periferije grada. Dodatna otegotna okolnost ove rute je što se nakon dvije dostave u Rijeci, ona nastavlja na otoku Krku, a takva mjesta često znaju biti problematična i nepristupačna. Nakon odrađenih dostava na otoku, vozilo se vraća u glavno skladište i time ruta 5 završava.

Po njenom završetku započinje pretposljednja ruta u ovom primjeru, a to je ruta 6. Ona je usmjerena na Slavonsku regiju te se detaljni podatci o toj ruti i regiji mogu vidjeti u idućoj tablici (Tablica 13).

Tablica 13. Detaljni prikaz podataka za analizu rute 6 – regija Slavonija

Volumen	Težina	Količina	Mjesto dostave	Primatelj	Adresa	Redoslijed dostave
3,153	355,98	1215	Požega	Alles d.o.o.	Industrijska ulica 40	1
0,006	9,9	1	Požega	Alles d.o.o.	Industrijska ulica 40	1
2,854	584	9	Osijek	Fliba d.o.o.	Svilajska ul. 36	3
5,946	701,82	29	Osijek	Fliba d.o.o.	Svilajska ul. 36	3
0,013	1,66	2	Požega	Alles d.o.o.	Industrijska ulica 40	1
3,492	491,81	32	Osijek	Agria d.o.o.	Ul. sv. L. B. Mandića 215	2
1,736	226,7	14	Osijek	Pevec d.d.	Ul. kneza Trpimira 24	4
∑ **17,2**	**2371,87**	**1302**				
Trošak transporta: 3437,81 / Vrijeme dolaska u skladište: 18:00 / Početak ukrcaja: 18:30 / Kraj ukrcaja: 19:30						

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Ruta 6 ima istovjetnu početnu/završnu lokaciju kao i prethodne rute, a to je skladište u Svetoj Nedelji. Vremena dolaska kamiona u skladište, početka ukrcaja i kraja ukrcaja, predviđena su za predvečernje sate. Razlog je taj što se primatelji nalaze na udaljenim lokacijama pa da bi se do njih stiglo unutar radnog vremena, potrebno je krenuti dan ranije.

Zbog toga se u ovoj ruti polazak očekuje večer prije, oko 19:30 sati, nakon što se izvrši ukrcavanje robe u kamion. Kapacitet kamiona od 35 m^3 ispunjava uvjete za transportom budući da ukupni volumen robe iznosi manje od toga, točnije 17,2 m^3. Sama dostava se najprije obavlja na jednoj lokaciji u Požegi, a potom se nastavlja u Osijeku, gdje se poslužuju tri primatelja. Vozilu nakon zadnjeg primatelja slijedi povratak u skladište, čime ruta 6 završava.

Nakon nje, na red dolazi ruta 7, koja je ujedno i posljednja ruta u ovome primjeru. Ona se odnosi na Dalmatinsku regiju, a kao i kod svih dosadašnjih ruta, temeljiti podatci za ovu rutu dani su u tablici koja slijedi (Tablica 14).

Tablica 14. Detaljni prikaz podataka za analizu rute 7 – regija Dalmacija

Volumen	Mjesto	Primatelj	Adresa	Redoslijed
0,964	Split	Andabaka d.o.o.	Kopilica ul. 21A	2
0,806	Split	Andabaka d.o.o.	Kopilica ul. 21A	2
0,906	Split	Andabaka d.o.o.	Kopilica ul. 21A	2
0,386	Split	Andabaka d.o.o.	Kopilica ul. 21A	2
0,096	Split	Brodomerkur d.d. - Dujmovača	Solinska ul. 47	2
0,772	Split	Brodomerkur d.d. - Dujmovača	Solinska ul. 47	2
0,292	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,714	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,114	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,343	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,651	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,048	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,699	Dugopolje	Lesnina H d.o.o.	Ul. sv. Leopolda Mandića 2	2
0,927	Solin	Građa d.d.	Vranjički put 2	2
0,278	Solin	Građa d.d.	Vranjički put 2	2
0,074	Kaštel Sućurac	Pevec d.d.	Put Juke 6	2
0,063	Sinj	Era Commerce d.o.o.	Ul. Miljenka Buljana 6	2
0,652	Sinj	Era Commerce d.o.o.	Ul. Miljenka Buljana 6	2
0,186	Makarska	Era Commerce d.o.o.	Vrgorački put 3	2
0,652	Makarska	Era Commerce d.o.o.	Vrgorački put 3	2
1,612	Makarska	Kingtrade d.o.o.	Dubrovačka ul. 29	2
2,635	Makarska	Pevec d.d.	Put Velikog Brda 1	2
0,059	Šibenik	E plus d.o.o.	Put Vida 6	1
0,326	Šibenik	Era Commerce d.o.o.	Put Razorskih težaka 2	1
1,304	Šibenik	Era Commerce d.o.o.	Put Razorskih težaka 2	1
1,64	Šibenik	Pevec d.d.	Ul. Velimira Škorpika 23	1
0,118	Zadar	E plus d.o.o.	Ul. akcije Maslenica 1	1
0,386	Zadar	Elektrostroj	Ul. Stjepana Radića 5	1
0,292	Zadar	Građa d.d.	Ul. Matijaševa ograda 1	1
0,556	Zadar	Građa d.d.	Ul. Matijaševa ograda 1	1
0,967	Zadar	Građa d.d.	Ul. Matijaševa ograda 1	1
0,074	Zadar	Pevec d.d.	Ul. 159. brigade HV 6	1
1,04	Poličnik	Lesnina H d.o.o.	Murvica jug 16	1
1,22	Poličnik	Lesnina H d.o.o.	Murvica jug 16	1
0,07	Posedarje	Lesnina H d.o.o.	Islam Latinski 2B	1
1,272	Posedarje	Lesnina H d.o.o.	Islam Latinski 2B	1
1,378	Posedarje	Lesnina H d.o.o.	Islam Latinski 2B	1
5,029	Kaštel Sućurac	Fliba d.o.o.	Cesta dr. Franje Tuđmana 7	2
6,168	Kaštel Sućurac	Fliba d.o.o.	Cesta dr. Franje Tuđmana 7	2
1,669	Zadar	Fliba d.o.o.	Ul. 84. gardijske bojne HV Termiti br. 20	1
0,869	Zadar	Pevec d.d.	Ul. 159. brigade HV 6	1
2,829	Zadar	Pevec d.d.	Ul. 159. brigade HV 6	1
1,254	Mlini	Pevec d.d.	Tomislava Macana 12	2
∑ **42,39**				
Trošak transporta: 7180,32 / Vrijeme dolaska u skladište: 21:30 / Početak ukrcaja: 22:00 / Kraj ukrcaja: 23:45				

Izvor: Izradio autor prema podatcima iz tvrtke Quehenberger Hrvatska d.o.o.

Početak i završetak ove rute namijenjen je skladištu u Svetoj Nedelji, kao što je slučaj i sa svih šest prethodnih ruta. Vremena koja se vežu uz skladišne aktivnosti, odvijaju se u kasnim večernjim satima i to dan ranije, a sve kako bi vozilo na dan dostave moglo stići do predviđenih lokacija. Budući da ukupni volumen robe iznosi 42,39 m^3, potrebno je koristiti veće vozilo za dostavu robe. Zbog toga se angažira tegljač kapaciteta 100 m^3, koji može udovoljiti zahtjevima rute.

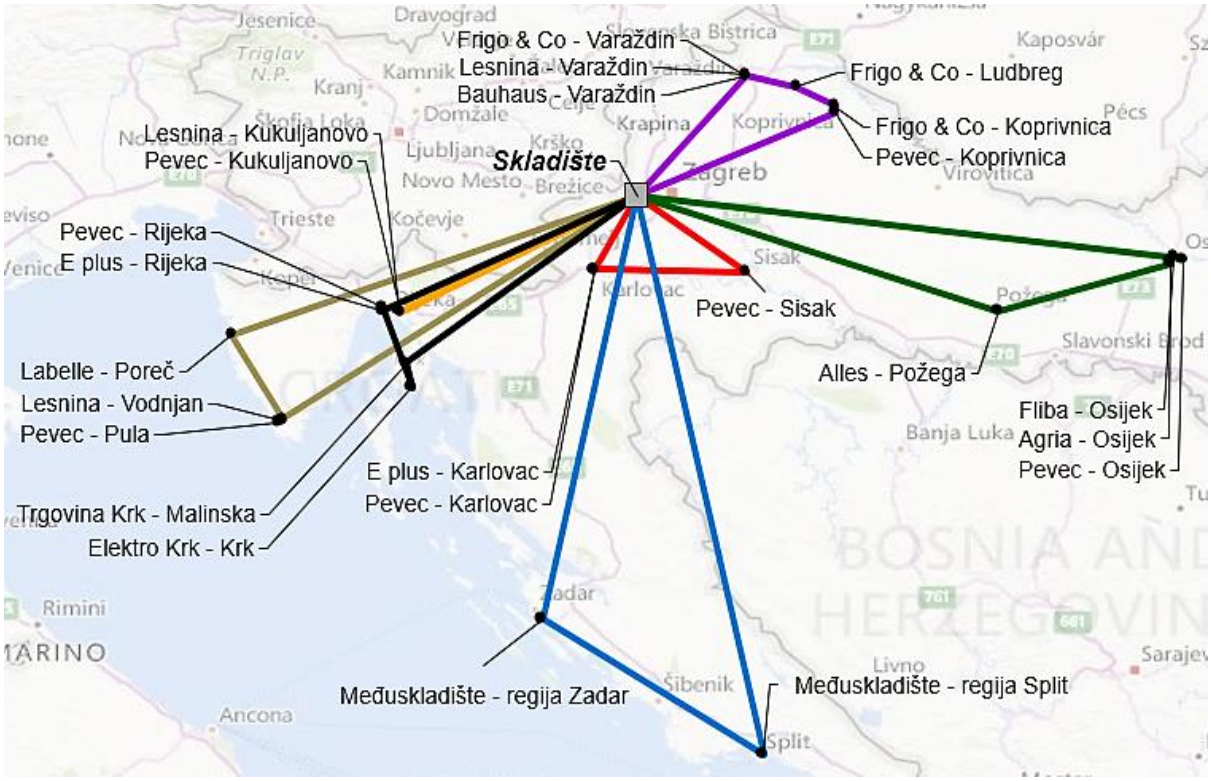
Već iz ovoga se može pretpostaviti da je ruta 7 najkompliciranija i najzahtjevnija ruta, a pogledom na tablicu to se i potvrđuje. Naime, ruta 7 ima najveći broj dostavnih mjesta, najveći broj primatelja i u njoj se dostavlja najveća količina robe.

Zbog svega toga, za tu je rutu odlučeno da bude međuskladišna, a to znači da tegljač dostavlja robu samo do skladišta partnera u Zadarskoj i Splitskoj regiji, nakon čega oni preuzimaju na sebe krajnju dostavu do primatelja, ovisno o tome koje mjesto dostave pripada kojoj regiji.

Sukladno tome su navedeni i redoslijedi dostave u tablici, tako što su u tom stupcu prisutna samo dva broja – jedan (1) i dva (2). S jedan (1) se označuju mjesta dostave koja su bliska Zadarskoj regiji i koja će biti poslužena od strane partnera iz te regije, a s dva (2) se označuju mjesta dostave usko povezana sa Splitskom regijom i njezinim pripadajućim partnerom.

S ovim objašnjenjem ujedno je završena i analiza svih sedam ruta transportne mreže tvrtke Quehenberger Hrvatska d.o.o., te se njihov konačni izgled može vidjeti na slici (Slika 42).

U idućem koraku preostaje istražiti može li se štogod u toj mreži učiniti boljim, učinkovitijim, jednostavnijim i smislenijim. Svrsishodno tome, kako je i ranije najavljeno, primijenjen je optimizacijski program *VRP Spreadsheet Solver*.

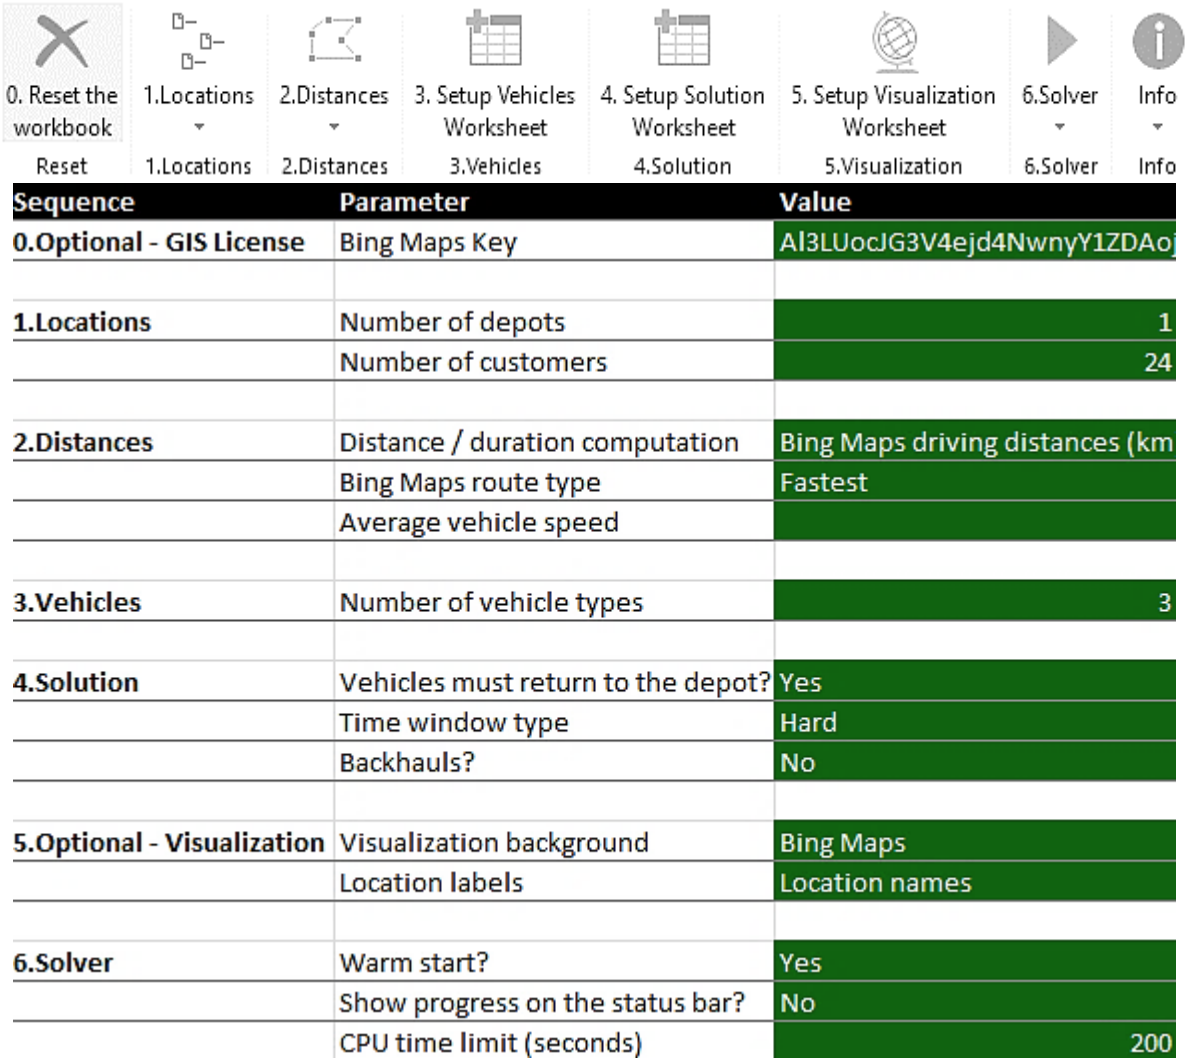


Slika 42. Vizualni pregled svih analiziranih ruta u transportnoj mreži
Izvor: Izradio autor

7.2. Prijedlog elemenata optimiranja transportne mreže

Optimizacijski program *VRP Spreadsheet Solver* uvijek započinje unošenjem podataka u radni list s rješavajućom konzolom. Bez ispunjavanja tog radnog lista nije moguće nastaviti s daljnjim unošenjem konkretnijih podataka o skladištu, korisnicima, vozilima, ograničenjima i drugim elementima. Zbog toga je važno unaprijed znati o kakvom se problemu točno radi i koliki je njegov opseg.

Slika rješavajuće konzole za konkretni primjer sadrži ispunjene sve potrebne parametre (Slika 43). Neki od parametara nisu detaljnije objašnjeni budući da nemaju preveliki značaj za ovaj rad i za rješavanje konkretnog primjera. Ako ipak postoji zanimanje za neke od nespomenutih parametara, sva se detaljnija objašnjenja mogu pronaći u povezanoj literaturi. [31], [37]



Sequence	Parameter	Value
0.Optional - GIS License	Bing Maps Key	Al3LUocJG3V4ejd4NwnyY1ZDAoj
1.Locations	Number of depots	1
	Number of customers	24
2.Distances	Distance / duration computation	Bing Maps driving distances (km
	Bing Maps route type	Fastest
	Average vehicle speed	
3.Vehicles	Number of vehicle types	3
4.Solution	Vehicles must return to the depot?	Yes
	Time window type	Hard
	Backhauls?	No
5.Optional - Visualization	Visualization background	Bing Maps
	Location labels	Location names
6.Solver	Warm start?	Yes
	Show progress on the status bar?	No
	CPU time limit (seconds)	200

Slika 43. Postavljanje početnih parametara u rješavajućoj konzoli
Izvor: Izradio autor

U ovome primjeru, broj skladišta je jedan (1), a broj korisnika 24. Kod broja korisnika potrebno je napomenuti da se svi korisnici iz Zadarske regije ubrajaju pod jednog korisnika koji se naziva „međuskladište – regija Zadar“. Isti je slučaj i s korisnicima iz Splitske regije, oni pripadaju jednom korisniku pod nazivom „međuskladište – regija Split“.

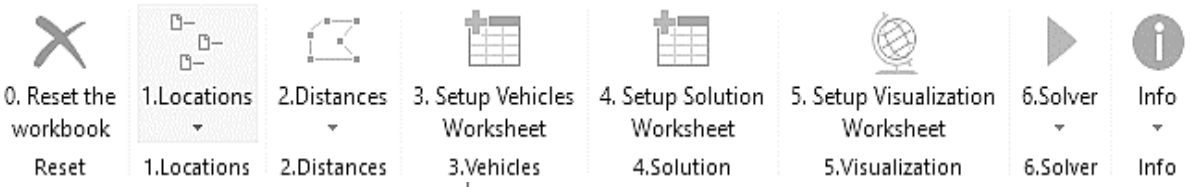
Udaljenosti (u kilometrima) i trajanja putovanja dobivaju se pomoću Bing karata, a pritom se za njihovo dobivanje koriste najbrže umjesto najkraćih ruta. Kada su postavke takve, onda prosječnu brzinu vozila nije potrebno upisivati. Naime, Bing karte omogućuju procjenjivanje vremena putovanja vozila temeljem poznatih ograničenja brzina na ruti.

Nadalje, što se tiče vozila, tu su definirane tri (3) vrste – kombi, kamion i tegljač. Taj je podatak poznat iz prethodno odrađene analize, a iz njega se može zaključiti kako se radi o heterogenom problemu usmjeravanja vozila. Pored toga, definirano je i da se sva vozila moraju vratiti u skladište, da se vremenski prozori za dostavu moraju strogo poštovati, kao i da nema povratnog prikupljanja robe.

Po završetku upisivanja spomenutih parametara, ostaje još tek njih nekoliko, vezanih uz osobne želje i preferencije pojedinca koji popunjava radni list s rješavajućom konzolom.

Nakon što se i to izvrši, izrađuje se novi radni list s lokacijama, koji je u ovome primjeru radi većeg i preglednijeg prikaza podijeljen na dvije slike. U originalu se inače radi o jednoj slici, odnosno jednom radnom listu s jednom tablicom.

Prva slika se tako odnosi na unošenje imena skladišta i korisnika, kao i njihovih detaljnih adresa (Slika 44), dok su na drugoj slici sadržane koordinate skladišta i korisnika, njihovi vremenski prozori, trajanja posluživanja i zahtjevi u pogledu količine robe koja im se dostavlja (Slika 45).

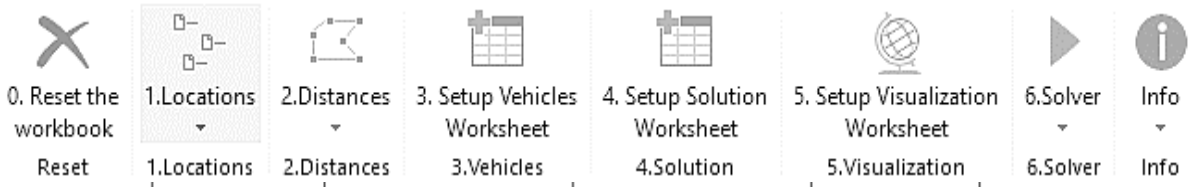


Name	Address
Skladište	Gospodarska ulica 2A, Sveta Nedelja
Pevec - Kukuljanovo	Kukuljanovo 361, Kukuljanovo
Lesnina - Kukuljanovo	Kukuljanovo 345, Kukuljanovo
Lesnina - Varaždin	Gospodarska ulica 37, Varazdin
Bauhaus - Varaždin	Gospodarska ulica 29, Varazdin
Frigo & Co - Varaždin	Gospodarska ulica 29A, Varazdin
Frigo & Co - Ludbreg	Ulica Rudolfa Fizira 6, Ludbreg
Frigo & Co - Koprivnica	Ulica Frana Galovica 24, Koprivnica
Pevec - Koprivnica	Radnicka cesta 10, Koprivnica
E plus - Karlovac	Prilaz Veceslava Holjevca 12, Karlovac
Pevec - Karlovac	Ulica Antuna Mihanovica 1A, Karlovac
Pevec - Sisak	Zagrebacka ulica 47, Sisak
Pevec - Pula	Industrijska ulica 15, Pula
Lesnina - Vodnjan	Sijanska cesta 60, Vodnjan
Labelle - Poreč	Creska ulica 34, Porec
E plus - Rijeka	Zvonimirova ulica 3, Rijeka
Pevec - Rijeka	Skurinjska cesta 9B, Rijeka
Elektro Krk - Krk	Ulica Stjepana Radica 1A, Krk
Trgovina Krk - Malinska	Ulica sveti Vid - Miholjice 116, Malinska
Alles - Požega	Industrijska ulica 40, Pozega
Agria - Osijek	Ulica svetog Leopolda Bogdana Mandica 215, Osijek
Fliba - Osijek	Svilajska ulica 36, Osijek
Pevec - Osijek	Ulica kneza Trpimira 24, Osijek
Međuskladište - regija Zadar	Gazenicka cesta, Zadar
Međuskladište - regija Split	Cesta dr. Franje Tudmana, Kastel Sucurac

Slika 44. Upisivanje podataka u prvi dio radnog lista s lokacijama
Izvor: Izradio autor

U prvom dijelu radnog lista s lokacijama, kroz konkretne tekstualne opise, vidi se ono što je brojevima definirano u početnoj konzoli, a to su imena i adrese svih korisnika, kao i glavnog skladišta. Za adrese je važno da budu točne i po mogućnosti provjerene u Bing kartama, kako ne bi došlo do njihove pogrešne interpretacije.

Vrijedi također upozoriti da nakon što je u rješavajućoj konzoli definiran broj skladišta i korisnika, on se u ovom radnom listu više ne može niti povećavati niti smanjivati i zbog toga je vrlo važno imati unaprijed stvorenu predodžbu problema.



Latitude (y)	Longitude (x)	Time window start	Time window end	Service time	Delivery amount
45,80238	15,77590	08:00	23:59	0:45	0
45,33099	14,50945	08:00	16:00	0:15	16,625
45,33693	14,50563	08:00	16:00	0:15	4,127
46,29406	16,35544	08:00	16:00	0:15	0,93
46,29156	16,35378	08:00	16:00	0:15	0,675
46,29247	16,35258	08:00	16:00	0:15	2,177
46,24787	16,62531	08:00	16:00	0:15	0,029
46,16807	16,83182	08:00	16:00	0:15	0,741
46,14441	16,83445	08:00	16:00	0:15	4,433
45,50591	15,54462	08:00	16:00	0:15	0,176
45,50464	15,54532	08:00	16:00	0:15	16,855
45,49678	16,35515	08:00	16:00	0:15	2,068
44,88797	13,85376	08:00	16:00	0:15	5,705
44,89408	13,88536	08:00	16:00	0:15	0,08
45,24305	13,60575	08:00	16:00	0:15	5,386
45,33773	14,40765	08:00	16:00	0:15	0,118
45,35582	14,41532	08:00	16:00	0:15	8,325
45,02742	14,57278	08:00	16:00	0:15	2,251
45,12784	14,54255	08:00	16:00	0:15	2,116
45,33800	17,70373	08:00	16:00	0:15	3,172
45,53226	18,62729	08:00	16:00	0:15	3,492
45,56234	18,63835	08:00	16:00	0:15	8,8
45,54709	18,69192	08:00	16:00	0:15	1,736
44,09116	15,26933	08:00	16:00	0:30	16,066
43,54202	16,44786	08:00	16:00	0:30	26,324

Slika 45. Upisivanje podataka u drugi dio radnog lista s lokacijama
Izvor: Izradio autor

S koordinatama se započinje drugi radnog lista s lokacijama, a u ovome su primjeru one najprije popunjene putem GIS web servisa, na temelju prethodno unesenih adresa. Budući da se radi o detaljnim adresama gdje je svaki broj ulice bitan, onda je točnost koordinata još dodatno povećana ručnim unosima.

Nadalje, vremenski prozori su za sve korisnike jednaki, a njihova širina dobivena je nakon razgovora s odgovornom osobom iz tvrtke. Na isti način dobiveni su i podatci o trajanjima posluživanja korisnika. Ta su trajanja jednaka za gotovo sve korisnike, osim za posljednja dva koja se odnose na međuskladišta u Zadarskoj i Splitskoj regiji.

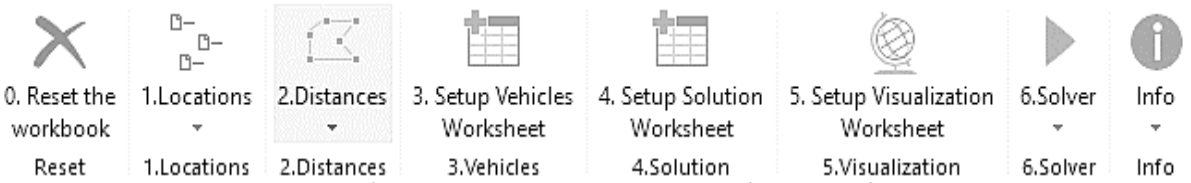
Potreba za takvom promjenom proizlazi iz toga što se u međuskladištima roba vrlo često odmah priprema i slaže za daljnju otpremu pa je zato i vrijeme posluživanja duže nego kod ostalih korisnika, gdje se roba samo iskrcava bez dodatnih aktivnosti.

Posluživanje u glavnom skladištu kod Svete Nedelje također je nešto drugačijeg trajanja, a dobiveno je tako što je izračunato prosječno trajanje ukrcaja iz svih sedam analiziranih ruta.

Na sličan način dobiveni su i podatci o ukupnoj količini robe za dostavu. Neke vrijednosti samo su preuzete iz analiziranih tablica jer se radilo o pojedinačnim narudžbama, dok je druge vrijednosti bilo potrebno zbrojiti jer su se odnosile na više narudžbi za jednu lokaciju. Pritom treba naglasiti kako mjerna jedinica za količinu robe nije specificirana, no koja god ona bila, obavezno se mora podudarati s mjernom jedinicom za kapacitet vozila. Budući da su iz tvrtke dobiveni samo podatci o volumnim kapacitetima vozila, onda se volumen koristi i kao mjerna jedinica za količinu robe.

S time se zaključuje radni list s lokacijama te se izdaje naredba koja kreira novi radni list s udaljenostima. Proračunska tablica iz tog radnog lista prevelika je za cjelokupni prikaz jer se u njoj nalaze udaljenosti i trajanja putovanja između svih 24 korisnika međusobno, kao i udaljenosti i trajanja putovanja između glavnog skladišta i svakog pojedinog korisnika.

Zbog takve složenosti tablice, za ogledni je primjer istaknut samo jedan njezin mali dio koji se odnosi na udaljenosti i trajanja putovanja između glavnog skladišta i svakog pojedinog korisnika (Slika 46), dok su na istom principu bazirane i preostale udaljenosti između svih korisnika međusobno. Za vizualizaciju čitave tablice može poslužiti jedna od prethodnih slika, u kojoj je radni list s udaljenostima prvi puta spominjan u radu (Slika 34).



From	To	Distance	Duration
Skladište	Skladište	0,00	0:00
Skladište	Pevec - Kukuljanovo	158,26	1:36
Skladište	Lesnina - Kukuljanovo	157,76	1:34
Skladište	Lesnina - Varaždin	105,07	1:06
Skladište	Bauhaus - Varaždin	104,78	1:06
Skladište	Frigo & Co - Varaždin	104,67	1:06
Skladište	Frigo & Co - Ludbreg	118,93	1:18
Skladište	Frigo & Co - Koprivnica	120,72	1:36
Skladište	Pevec - Koprivnica	121,46	1:37
Skladište	E plus - Karlovac	54,18	0:37
Skladište	Pevec - Karlovac	54,52	0:38
Skladište	Pevec - Sisak	67,38	0:56
Skladište	Pevec - Pula	268,00	2:52
Skladište	Lesnina - Vodnjan	265,19	2:47
Skladište	Labelle - Poreč	263,65	2:57
Skladište	E plus - Rijeka	166,80	1:42
Skladište	Pevec - Rijeka	165,31	1:41
Skladište	Elektro Krk - Krk	191,89	2:19
Skladište	Trgovina Krk - Malinska	171,87	1:55
Skladište	Alles - Požega	196,63	2:13
Skladište	Agria - Osijek	293,25	2:47
Skladište	Fliba - Osijek	297,27	2:46
Skladište	Pevec - Osijek	302,32	2:49
Skladište	Međuskladište - regija Zadar	295,30	2:51
Skladište	Međuskladište - regija Split	410,25	3:57

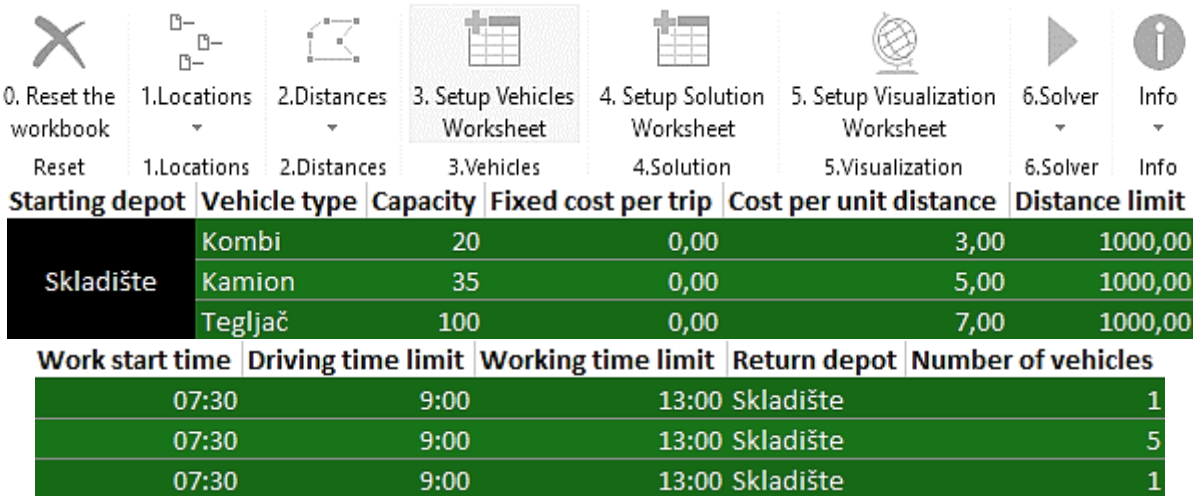
Slika 46. Skraćeni i prilagođeni prikaz dobivenog radnog lista s udaljenostima
Izvor: Izradio autor

Sve udaljenosti izražene su u kilometrima, a valja još napomenuti kako u ovoj proračunskoj tablici nije potrebno ništa upisivati jer se udaljenosti i trajanja putovanja prenose iz Bing karata, na osnovu prethodno upisanih korisnika i njihovih točnih adresa iz radnog lista s lokacijama.

Daljnje optimiranje transportne mreže, u kojem slijedi nastavak radnih listova, dijeli se na dva slučaja. U prvom slučaju prikazan je prijedlog rješenja bez slobode biranja raspoloživog broja vozila po svakoj vrsti. Time je taj slučaj ograničen isključivo na one brojeve za koje se odlučila odgovorna osoba u tvrtki Quehenberger Hrvatska d.o.o. U drugom je slučaju pak omogućena sloboda biranja broja vozila po vrsti koja stoje na raspolaganju za rješavanje konkretnog problema.

7.2.1. Prijedlog rješenja – slučaj 1

Nakon radnog lista s udaljenostima slijedi radni list s vozilima, a u njemu ponovno dolazi do potrebe za popunjavanjem parametara iz proračunske tablice (Slika 47). Veći dio podataka o vozilima također je dobiven putem ostvarenog kontakta s tvrtkom Quehenberger Hrvatska d.o.o.



Starting depot	Vehicle type	Capacity	Fixed cost per trip	Cost per unit distance	Distance limit
Skladište	Kombi	20	0,00	3,00	1000,00
	Kamion	35	0,00	5,00	1000,00
	Tegljač	100	0,00	7,00	1000,00

Work start time	Driving time limit	Working time limit	Return depot	Number of vehicles
07:30	9:00	13:00	Skladište	1
07:30	9:00	13:00	Skladište	5
07:30	9:00	13:00	Skladište	1

Slika 47. Popunjavanje parametara u radnom listu s vozilima – slučaj 1
Izvor: Izradio autor

Vrste vozila utvrđene su prilikom analiziranja transportne mreže tvrtke, a isto tako i njihovi pripadajući kapaciteti te obveza povratka u skladište.

Fiksni troškovi vozila po putovanju uključeni su u cijenu transporta po prijeđenom kilometru pa stoga nisu zasebno upisivani. Ono što nije uključeno u tu cijenu jesu iznosi cestarina, mostarina i tunelarina, iz razloga što oni ovise o konačnom izgledu ruta. Zbog toga su te pristojbe tek naknadno navedene u samom prijedlogu rješenja, budući da su javno obznanjene i lako dostupne. [38]

Nadalje, tvrtka nema posebno definiranih ograničenja po pitanju maksimalne prijeđene udaljenosti vozila pa je stoga u tu rubriku za sve tri vrste vozila upisan proizvoljan broj od 1000 kilometara, budući da ta udaljenost ne može biti prekoračena u konkretnom primjeru.

Osim toga, svim je vozilima određen početak rada u 7:30 sati. To vozilima ostavlja dovoljno vremena da u zadanom intervalu (8:00 – 16:00) posjete dostavna mjesta primatelja. Naravno, u praksi će neka vozila ipak biti primorana krenuti ranije s dostavom, kao što je viđeno u analizi tvrtke. To se posebice odnosi na dostavljanje robe u međuskladišta za Zadarsku i Splitsku regiju jer iako s ovim početkom rada vozila uspijevaju do njih dostaviti robu u zadanom intervalu, treba uzeti u obzir da ta dva međuskladišta nakon primitka robe trebaju tu istu još otpremiti i dostaviti krajnjim korisnicima. Prema tome, ukoliko se dostava od međuskladišta do krajnjih korisnika odvija dan poslije, onda je početak rada u 7:30 sati sasvim zadovoljavajući, no, ako međuskladišta planiraju u istome danu izvršiti tu dostavu, onda će vozilo iz glavnog skladišta u Svetoj Nedelji biti primorano krenuti mnogo ranije. Budući da takvo pomjeranje početka rada vozila unatrag ne utječe na izgled ruta i raspored obilaska u njima, onda je radi jednostavnosti to vrijeme u ovome primjeru određeno jednako za sva vozila.

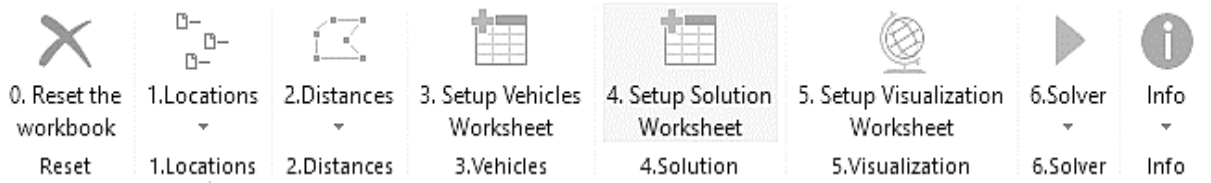
Iduće dvije rubrike u radnom listu s vozilima tiču se vozača, odnosno njihovih ograničenja po pitanju dnevnog vremena vožnje[29] i dnevnog radnog vremena[30]. Ta su pitanja zakonski regulirana pa su sukladno uputama ovdje takva i upisana. Konkretno, dnevno vrijeme vožnje ne smije biti dulje od 9 sati, a iznimno može biti i 10 sati, ali ne više od dva puta u tjednu. Dnevno radno vrijeme iznosi 13 sati unutar perioda od 24 sata i ono se može produžiti do maksimalnih 15 sati, ali također samo dva puta tjedno. Pri tome svakako treba upozoriti da ako vozač ima početak rada između 0:00 i 5:00 sati, on toga dana mora završiti svoje radno vrijeme prije nego što ima više od 10 sati ukupnog rada. [39]

[29] Vrijeme vožnje obuhvaća ukupno vrijeme vožnje između završetka jednog dnevnog razdoblja odmora i početka sljedećeg dnevnog razdoblja odmora.
[30] Radno vrijeme, osim vožnje, obuhvaća i razne druge aktivnosti kao što su nadzor ukrcaja i iskrcaja, osiguranje sigurnosti vozila i robe, ispunjavanje administrativnih formalnosti s policijom, carinom, drugim službama itd.

Na kraju proračunske tablice upisani su i brojevi raspoloživih vozila za svaku od vrsta. Budući da je ovo slučaj s istim brojem vozila po vrsti koja stoje na raspolaganju, te se brojke ne mijenjaju i ostaju identične onim brojkama iza kojih stoji odabir odgovarajuće osobe u tvrtki. Ono što se ipak mijenja je broj i izgled ruta te redoslijed obilaska u njima, a to slijedi u idućem radnom listu – onom s prijedlogom rješenja.

Taj je list sastavljen je od onoliko proračunskih tablica koliko je ruta i kreirano. Za ovaj slučaj predlaže se pet (5) novokreiranih ruta, koje su nastale obradom parametara iz prethodnih radnih listova. U svakoj proračunskoj tablici nalaze se razni podatci o pripadajućoj ruti na koju se tablica odnosi. Između ostalog, tu se mogu vidjeti imena i broj korisnika, prevaljene udaljenosti, vremena vožnje i ukupnog rada vozača, vremena dolaska/odlaska vozila do/od korisnika, količine robe na svakoj lokaciji, ime rute, vrstu vozila u njoj, broj stajanja te trošak transporta uz dodatak taksenih pristojbi.

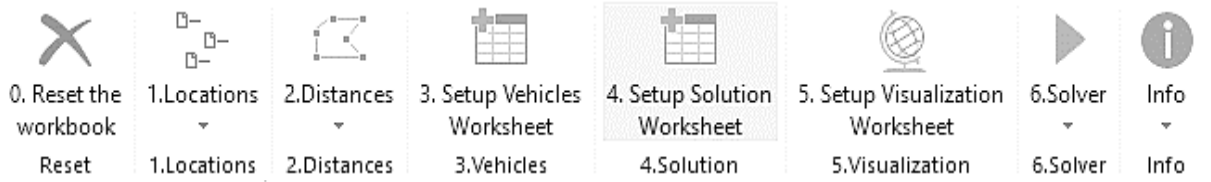
Prva tablica koja sve to obuhvaća, odnosi se na rutu 1 i može se vidjeti na slici (Slika 48).



Route 1 (Kombi)	Stops: 5		Distance cost: 1824, 51			Toll fee: 182,00
Location name	**Distance travelled**	**Driving time**	**Arrival time**	**Departure time**	**Working time**	**Load**
Skladište	0,00	0:00		07:30	0:00	19,3
Agria - Osijek	293,25	2:47	10:17	10:32	3:02	15,8
Pevec - Osijek	300,53	2:58	10:43	10:58	3:28	14
Fliba - Osijek	306,83	3:06	11:06	11:21	3:51	5,24
Alles - Požega	399,40	4:51	13:06	13:21	5:51	2,07
Pevec - Sisak	540,83	6:47	15:17	15:32	8:02	0
Skladište	608,17	7:43	16:28		8:58	0

Slika 48. Detaljni prikaz podataka za novu rutu 1 – slučaj 1
Izvor: Izradio autor

Za rutu 1 predlaže se kombi koji poslužuje pet korisnika vidljivih na slici. Kombi kreće u 7:30 sati, a njegov dolazak kod zadnjeg korisnika predviđen je oko 15:17 sati, čime je zadovoljen vremenski prozor koji nalaže da korisnik bude poslužen između 8:00 i 16:00 sati. Vremena vožnje i ukupnog rada također udovoljavaju ograničenjima koja iznose 9, odnosno 13 sati. Kombi ima ukrcajni prostor od 20 m^3, što udovoljava ukupnom volumenu robe od 19,3 m^3. S time ujedno i završava prijedlog rute 1 te započinje prijedlog rute 2 (Slika 49).

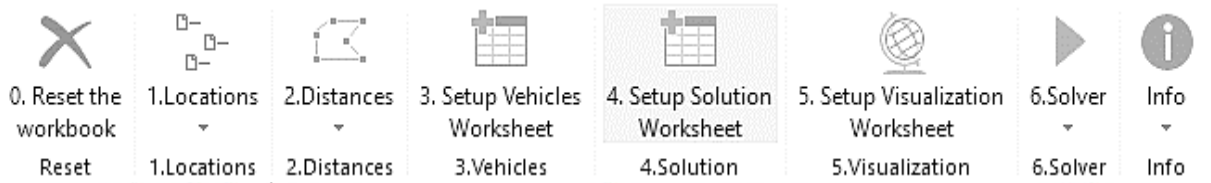


Route 2 (Kamion) **Stops: 8** **Distance cost: 2844,07** **Toll fee: 403,00**

Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	29,7
Lesnina - Kukuljanovo	157,76	1:34	09:04	09:19	1:49	25,6
Pevec - Kukuljanovo	158,63	1:38	09:23	09:38	2:08	8,99
Frigo & Co - Varaždin	395,80	3:59	11:59	12:14	4:44	6,81
Bauhaus - Varaždin	395,91	3:59	12:14	12:29	4:59	6,13
Lesnina - Varaždin	396,31	4:00	12:30	12:45	5:15	5,2
Frigo & Co - Ludbreg	424,31	4:28	13:13	13:28	5:58	5,17
Frigo & Co - Koprivnica	444,05	4:55	13:55	14:10	6:40	4,43
Pevec - Koprivnica	447,24	5:02	14:17	14:32	7:02	0
Skladište	568,81	6:41	16:11		8:41	0

Slika 49. Detaljni prikaz podataka za novu rutu 2 – slučaj 1
Izvor: Izradio autor

Za potrebe rute 2 predlaže se korištenje kamiona koji robu dostavlja do osam korisnika sa slike. Početak rada kamiona predviđen je u 7:30 sati, dok bi kod zadnjeg korisnika trebao stići oko 14:17 sati što znači da je vremenski prozor zadnjeg korisnika, a i svih ostalih prije njega, zadovoljen. Osim toga, zadovoljena su i ograničenja radnog vremena vozača, kao i ograničenja kapaciteta kamiona. Vrijeme vožnje iznosi 6:41 sati, što je manje od dozvoljenih 9 sati, dok radno vrijeme od 8:41 sati ne prelazi dopuštenih 13 sati. Teretni prostor kamiona iznosi 35 m^3 što je dovoljno za ukrcaj robe koju korisnici zahtijevaju, a koja ima volumen od 29,7 m^3. Obrazloženje rute 2 ovime završava, a započinje ono od rute 3 (Slika 50).

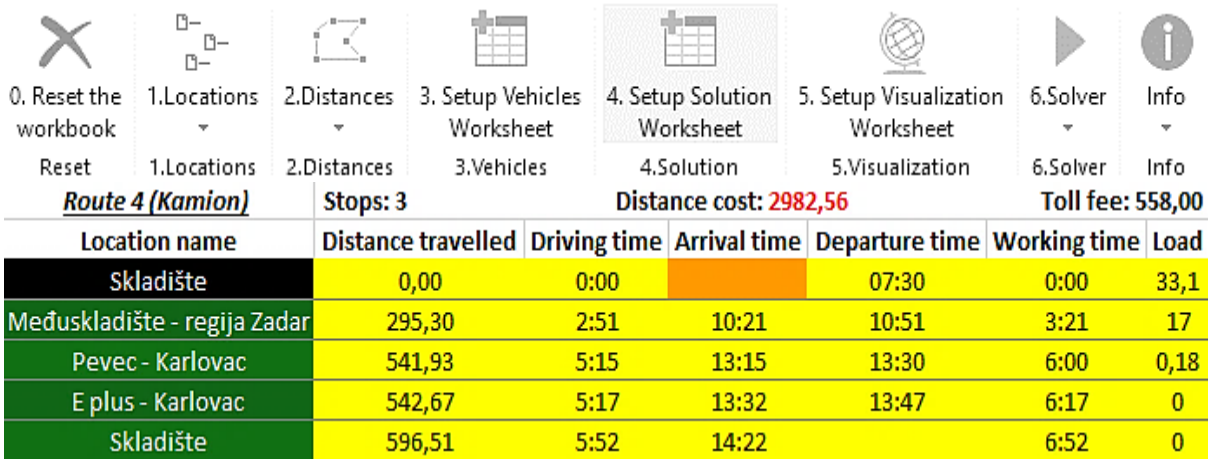


Route 3 (Kamion) **Stops: 7** **Distance cost: 3314,55** **Toll fee: 751,00**

Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	24
Pevec - Rijeka	165,31	1:41	09:11	09:26	1:56	15,7
Lesnina - Vodnjan	268,28	2:56	10:41	10:56	3:26	15,6
Pevec - Pula	271,95	3:04	11:04	11:19	3:49	9,87
Labelle - Poreč	331,71	3:56	12:11	12:26	4:56	4,49
E plus - Rijeka	420,16	5:22	13:52	14:07	6:37	4,37
Trgovina Krk - Malinska	458,60	6:02	14:47	15:02	7:32	2,25
Elektro Krk - Krk	478,93	6:28	15:28	15:43	8:13	0
Skladište	662,91	8:39	17:54		10:24	0

Slika 50. Detaljni prikaz podataka za novu rutu 3 – slučaj 1
Izvor: Izradio autor

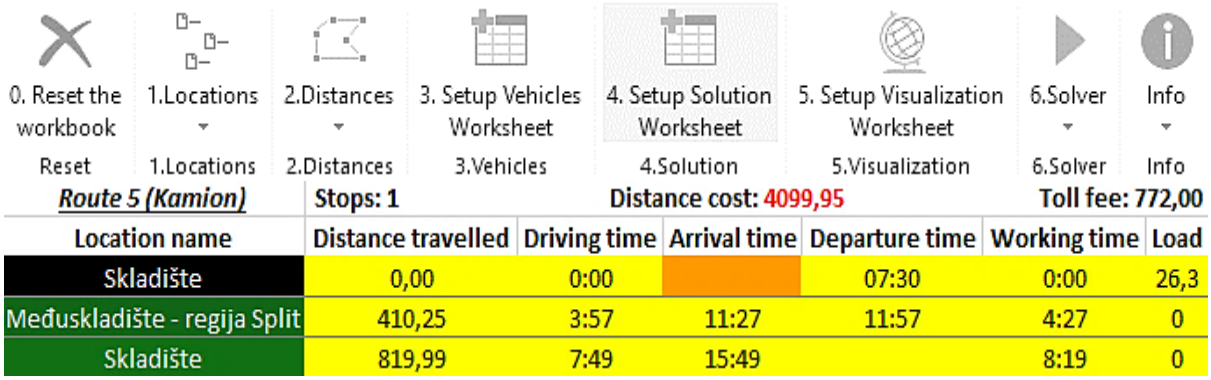
Ruta 3 se prema prijedlogu sastoji od sedam korisnika koje poslužuje kamion kapaciteta 35 m^3. Kamion s tim kapacitetom udovoljava zahtjevima korisnika, čiji ukupni volumen robe iznosi 24 m^3. Nadalje, predlaže se da kamion započne s realizacijom dostave u 7:30 sati kako bi na vrijeme uspio posjetiti i poslužiti sve korisnike, a osobito zadnjeg u ruti do kojeg se previđa dolazak oko 15:28 sati. Time bi se zadovoljila ograničenja vremenskih prozora kod svih 7 korisnika. Uz to, vremena vožnje i ukupnog rada od 8:39 i 10:24 sata, također ne bi prekoračila ograničenja koja se odnose na vozača. Zaključno s ovime iznijet je cjelokupni prijedlog rute 3 pa se može nastaviti i krenuti s prijedlogom rute 4 (Slika 51).



Route 4 (Kamion)	Stops: 3		Distance cost: 2982,56		Toll fee: 558,00	
Location name	**Distance travelled**	**Driving time**	**Arrival time**	**Departure time**	**Working time**	**Load**
Skladište	0,00	0:00		07:30	0:00	33,1
Međuskladište - regija Zadar	295,30	2:51	10:21	10:51	3:21	17
Pevec - Karlovac	541,93	5:15	13:15	13:30	6:00	0,18
E plus - Karlovac	542,67	5:17	13:32	13:47	6:17	0
Skladište	596,51	5:52	14:22		6:52	0

Slika 51. Detaljni prikaz podataka za novu rutu 4 – slučaj 1
Izvor: Izradio autor

Prijedlog rute 4 uključuje tri korisnika koji potražuju robu volumena 33,1 m^3, a za to je potreban kamion s ukrcajnim prostorom od 35 m^3. Polazak kamiona predviđa se u 7:30 sati i tada kamion može udovoljiti svim vremenskim ograničenjima – od vremenskih prozora korisnika, do vremena vožnje i vremena rada vozača. Time je utvrđeno sve oko rute 4 pa ne postoji više prepreka za prikaz posljednje rute 5 (Slika 52).

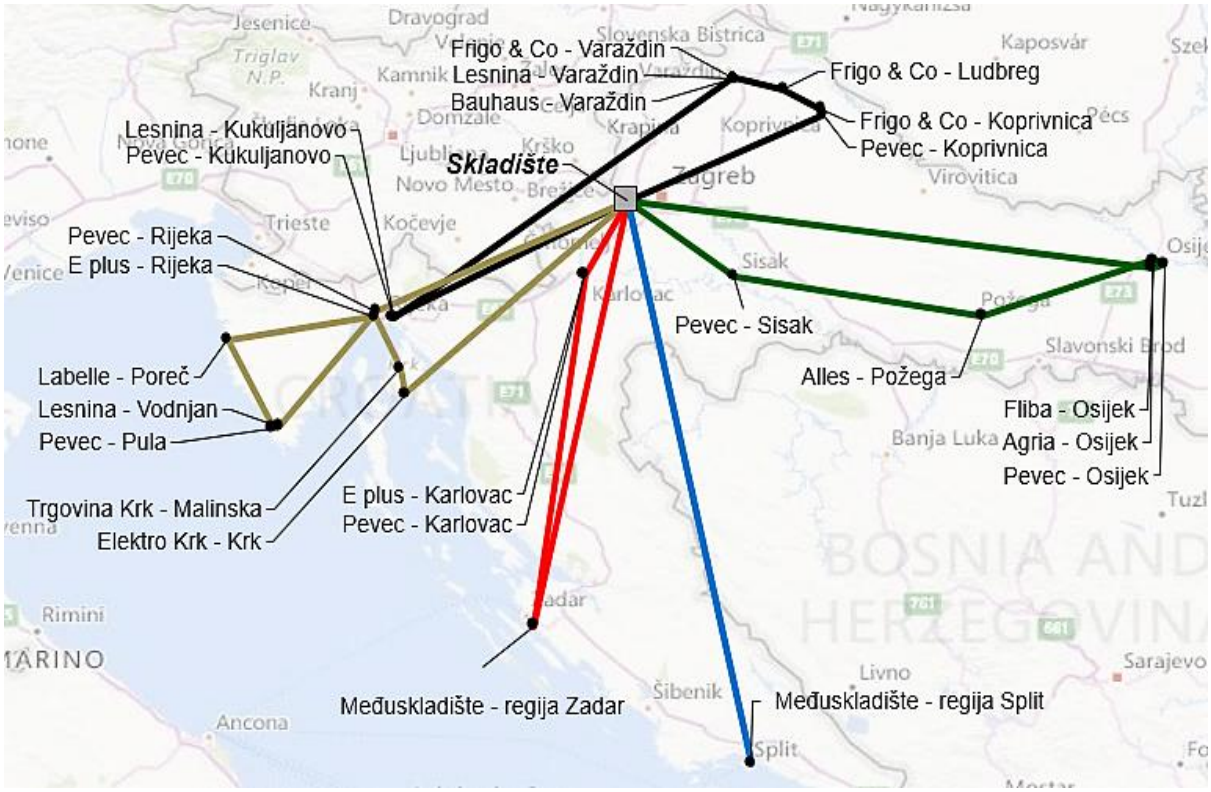


Route 5 (Kamion)	Stops: 1		Distance cost: 4099,95		Toll fee: 772,00	
Location name	**Distance travelled**	**Driving time**	**Arrival time**	**Departure time**	**Working time**	**Load**
Skladište	0,00	0:00		07:30	0:00	26,3
Međuskladište - regija Split	410,25	3:57	11:27	11:57	4:27	0
Skladište	819,99	7:49	15:49		8:19	0

Slika 52. Detaljni prikaz podataka za novu rutu 5 – slučaj 1
Izvor: Izradio autor

Prijedlog rute 5 vezan je uz samo jednog korisnika, točnije međuskladišta za Splitsku regiju. Do njega se dostavlja sva roba koja je predviđena za tu regiju pa ukupni zahtjev ima volumen od 26,3 m^3. Za potrebe transporta te količine robe, predlaže se kamion koji raspolaže s kapacitetom od 35 m^3. Ruta 5, kao i sve prethodne joj, započinje s radom u 7:30 sati. To vrijeme nije fiksno te ono može biti nešto kasnije ili ranije, ovisno o specifičnostima svake rute. Ono što je važno jest da vozilo započne s radom na vrijeme, a sve kako bi se roba u predviđenim vremenskim intervalima i unutar ograničenja za vozače, uspjela dostaviti do svih korisnika, što ovoj ruti uspijeva.

Prijedlog optimiranja transportne mreže tvrtke Quehenberger Hrvatska d.o.o., prema slučaju 1, s ovime je zaključen, a konačni izgled svih predloženih ruta vidljiv je na slici (Slika 53).

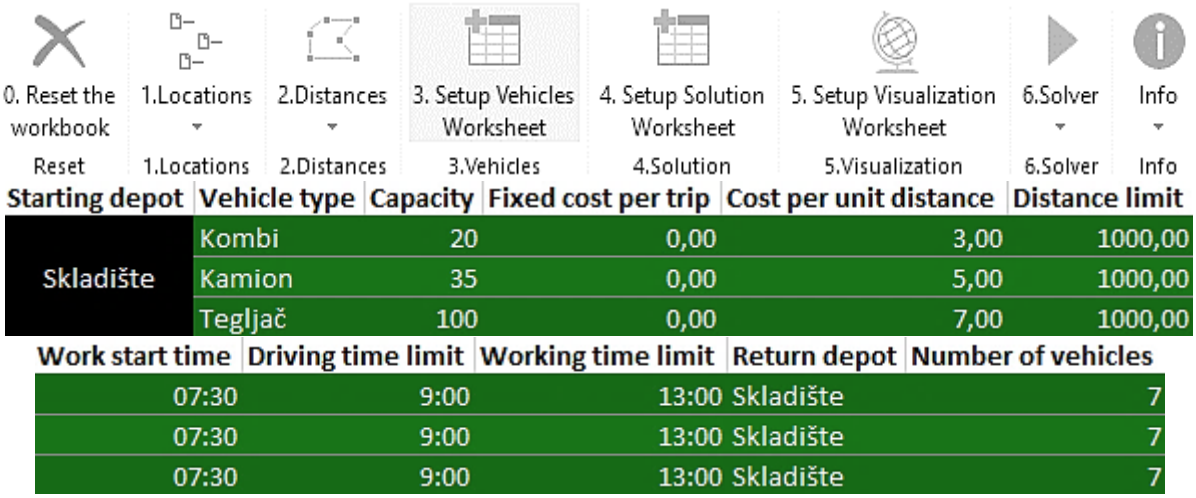


Slika 53. Vizualni pregled svih ruta u prijedlogu rješenja – slučaj 1
Izvor: Izradio autor

Nakon slučaja 1, slijedi slučaj 2, u kojemu je omogućena sloboda biranja broja raspoloživih vozila po vrsti. Takav pristup teži k optimalnom iskorištenju resursa utrošenih na realizaciju distribucije.

7.2.2. Prijedlog rješenja – slučaj 2

Ovaj slučaj započinje s istog mjesta odakle je započeo i slučaj 1, a to je kod popunjavanja radnog lista s vozilima. Razlog tomu je što se oni prethodni radni listovi ni u čemu ne razlikuju između ova dva slučaja. Naime, rješavajuća konzola ostaje važeća, skladište i korisnici nepromijenjeni, a iz toga proizlazi i da udaljenosti bivaju jednake prvotno utvrđenima. Potrebno je stoga promijeniti jedino radni list s vozilima, i to samo jedan dio u proračunskoj tablici koji se odnosi na broj raspoloživih vozila po vrsti (Slika 54).



Starting depot	Vehicle type	Capacity	Fixed cost per trip	Cost per unit distance	Distance limit
Skladište	Kombi	20	0,00	3,00	1000,00
	Kamion	35	0,00	5,00	1000,00
	Tegljač	100	0,00	7,00	1000,00

Work start time	Driving time limit	Working time limit	Return depot	Number of vehicles
07:30	9:00	13:00	Skladište	7
07:30	9:00	13:00	Skladište	7
07:30	9:00	13:00	Skladište	7

Slika 54. Popunjavanje parametara u radnom listu s vozilima – slučaj 2
Izvor: Izradio autor

Broj raspoloživih vozila u ovome je slučaju za svaku vrstu postavljen na sedam. Taj broj upisan je zbog toga što u analizi tvrtke stoji da se dostava obavlja sa sedam vozila budući da postoji sedam ruta. Prema tome, broj sedam po svim vrstama vozila znači da se dostava teoretski može obaviti tako da svih sedam vozila budu ili kombiji ili kamioni ili tegljači. Naravno, u praksi je to vrlo teško izvedivo, a za neke vrste vozila i nemoguće. Primjerice, sedam kombija sa svojim kapacitetom ne mogu poslužiti sedam ruta koje su definirane analizom tvrtke, iako bi to bilo idealno jer je transportni trošak kombija najmanji. Stoga je i napravljena ovakva pretpostavka o broju raspoloživih vozila po vrsti, jer ona omogućuje da se slobodnim kombiniranjem svih triju vrsta vozila pronađe optimalno rješenje, koje će poslužiti kao adekvatni prijedlog poboljšanja postojećeg stanja.

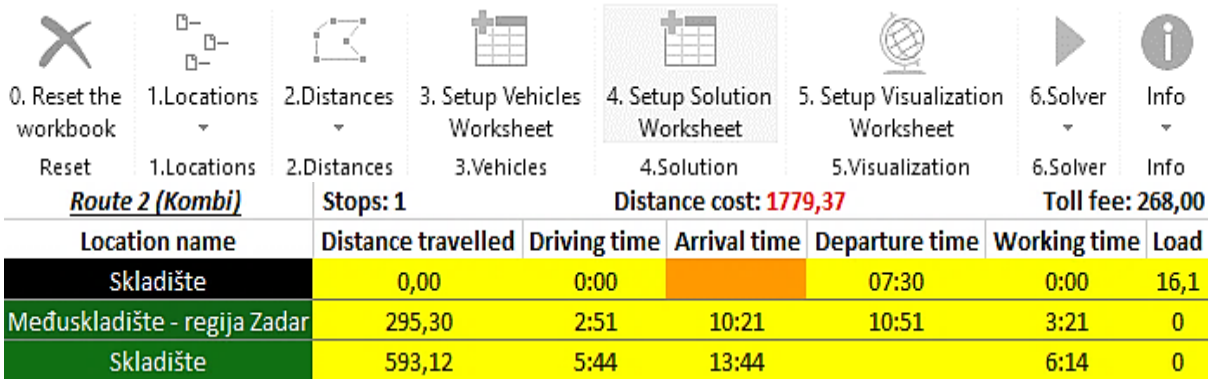
Takav prijedlog ponovno se prikazuje u radnom listu s rješenjem, u kojem proračunske tablice predstavljaju novonastale rute te pružaju dodatan uvid u pojedinosti svake rute. Prva takva proračunska tablica s rješenjem u slučaju 2, može se vidjeti na slici (Slika 55).



Route 1 (Kombi)	Stops: 6		Distance cost: 833, 07			Toll fee: 30,00
Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	8,99
Frigo & Co - Varaždin	104,67	1:06	08:36	08:51	1:21	6,81
Bauhaus - Varaždin	104,78	1:06	08:51	09:06	1:36	6,13
Lesnina - Varaždin	105,19	1:07	09:07	09:22	1:52	5,2
Frigo & Co - Ludbreg	133,18	1:35	09:50	10:05	2:35	5,17
Frigo & Co - Koprivnica	152,93	2:02	10:32	10:47	3:17	4,43
Pevec - Koprivnica	156,11	2:09	10:54	11:09	3:39	0
Skladište	277,69	3:48	12:48		5:18	0

Slika 55. Detaljni prikaz podataka za novu rutu 1 – slučaj 2
Izvor: Izradio autor

Prema prijedlogu, ruta 1 broji šest korisnika čiji ukupni volumen iznosi 8,99 m^3. Za njihovo posluživanje predlaže se upotreba kombija koji raspolaže ukrcajnim prostorom od 20 m^3. Početak njegova rada predviđen je u 7:30 sati, dok se dolazak kod posljednjeg korisnika u ruti očekuje oko 10:54 sata. Iz toga proizlazi da su sva vremenska ograničenja ispoštovana jer će korisnici biti posluženi unutar zadanih vremenskih prozora, a vozač neće imati više od 9 sati vožnje, odnosno 13 radnih sati. S time je razmotren cjelokupni prijedlog rute 1 i može se krenuti s rutom 2 (Slika 56), no prije toga treba još istaknuti jednu zanimljivost rute 1, a to je da ona prema ovom prijedlogu izgleda identično postojećoj ruti 2 iz izbora tvrtke te ih razlikuje jedino redoslijed obilaska korisnika.



Route 2 (Kombi)	Stops: 1		Distance cost: 1779,37			Toll fee: 268,00
Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	16,1
Međuskladište - regija Zadar	295,30	2:51	10:21	10:51	3:21	0
Skladište	593,12	5:44	13:44		6:14	0

Slika 56. Detaljni prikaz podataka za novu rutu 2 – slučaj 2
Izvor: Izradio autor

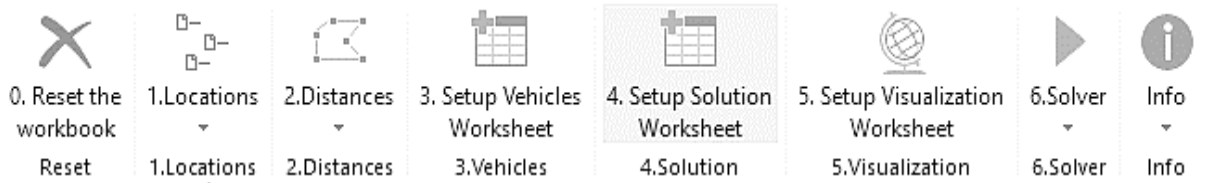
Za rutu 2 predložen je jedan „vidljivi“ korisnik kojemu se roba i dostavlja, a iza njega „sakriveno“ je još 10 krajnjih korisnika koji se nalaze u toj regiji i kojima korisnik iz ove rute prosljeđuje robu. Roba se dostavlja kombijem kapaciteta 20 m^3, kako bi se ispoštovala dana ograničenja. Nakon ovih pojedinosti, slijedi nova ruta 3 (Slika 57).



Route 3 (Kombi)	Stops: 5		Distance cost: 1824,51			Toll fee: 182,00
Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	19,3
Agria - Osijek	293,25	2:47	10:17	10:32	3:02	15,8
Pevec - Osijek	300,53	2:58	10:43	10:58	3:28	14
Fliba - Osijek	306,83	3:06	11:06	11:21	3:51	5,24
Alles - Požega	399,40	4:51	13:06	13:21	5:51	2,07
Pevec - Sisak	540,83	6:47	15:17	15:32	8:02	0
Skladište	608,17	7:43	16:28		8:58	0

Slika 57. Detaljni prikaz podataka za novu rutu 3 – slučaj 2
Izvor: Izradio autor

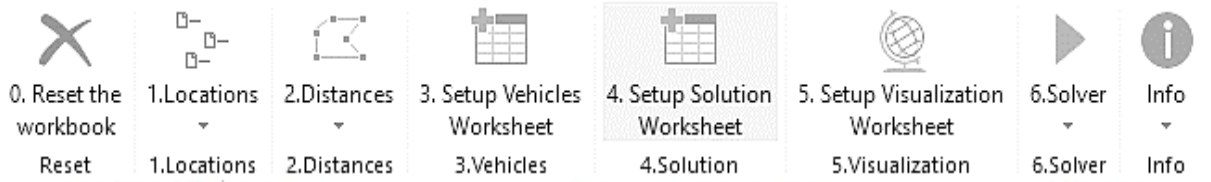
Prijedlog rute 3 identičan je prijedlogu rute 1 iz prvog slučaja. U obje rute korišten je kombi za dostavu, a isto tako kod obje rute kombi započinje s radom u 7:30 sati. Svi ostali parametri analogno tome bivaju identični. Nakon tog saznanja, nema potrebe za dodatnim objašnjenjem rute pa je iduća na redu ruta 4 (Slika 58).



Route 4 (Kombi)	Stops: 2		Distance cost: 327,30		Toll fee: 42,00	
Location name	**Distance travelled**	**Driving time**	**Arrival time**	**Departure time**	**Working time**	**Load**
Skladište	0,00	0:00		07:30	0:00	17
Pevec - Karlovac	54,52	0:38	08:08	08:23	0:53	0,18
E plus - Karlovac	55,26	0:40	08:25	08:40	1:10	0
Skladište	109,10	1:15	09:15		1:45	0

Slika 58. Detaljni prikaz podataka za novu rutu 4 – slučaj 2
Izvor: Izradio autor

U ruti 4 predviđena su dva korisnika s ukupnim volumenom robe od 17 m^3. Zbog toga se predlaže angažiranje kombija koji ima kapacitet od 20 m^3. Nadalje, njegov početak rada prema ovom se prijedlogu planira oko 7:30 sati, tako da se dolazak kod prvog korisnika očekuje malo iza 8:00 sati, nakon što se otvore vremenski prozori za dostavu robe. Sa samo dva korisnika, ova ruta ne dolazi u opasnost od prekoračenja vremenskih ograničenja pa se sukladno tome može krenuti s prijedlogom iduće rute 5 (Slika 59).



Route 5 (Kombi)	Stops: 5		Distance cost: 1761,63		Toll fee: 278,00	
Location name	**Distance travelled**	**Driving time**	**Arrival time**	**Departure time**	**Working time**	**Load**
Skladište	0,00	0:00		07:30	0:00	19,6
Pevec - Rijeka	165,31	1:41	09:11	09:26	1:56	11,3
E plus - Rijeka	169,89	1:51	09:36	09:51	2:21	11,2
Lesnina - Vodnjan	270,51	3:07	11:07	11:22	3:52	11,1
Pevec - Pula	274,18	3:15	11:30	11:45	4:15	5,39
Labelle - Poreč	333,93	4:07	12:37	12:52	5:22	0
Skladište	587,21	7:07	15:52		8:22	0

Slika 59. Detaljni prikaz podataka za novu rutu 5 – slučaj 2
Izvor: Izradio autor

U prijedlogu rute 5 očekuje se skup od pet korisnika, koji sa svojim ukupnim volumenom od 19,6 m^3, popunjavaju gotovo čitavi ukrcajni prostor kombija od 20 m^3. To je ujedno i posljednja ruta u ovome prijedlogu u kojoj se koristi kombi. Za iduće dvije rute predlaže se angažiranje kamiona, a prva takva ruta je ruta 6 (Slika 60).



Route 6 (Kamion) | **Stops: 1** | **Distance cost: 4099,95** | **Toll fee: 772,00**

Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	26,3
Međuskladište - regija Split	410,25	3:57	11:27	11:57	4:27	0
Skladište	819,99	7:49	15:49		8:19	0

Slika 60. Detaljni prikaz podataka za novu rutu 6 – slučaj 2
Izvor: Izradio autor

Prijedlog rute 6 identičan je prijedlogu rute 5 iz prethodnog slučaja. U oba slučaja se za sredstvo transporta koristi kamion, početak rada je u isto vrijeme, a vremenska ograničenja su ispoštovana. Sukladno tome, i u jednom i drugom slučaju, transportni trošak je potpuno isti. Budući da su preostali detalji ove rute već ranije razjašnjeni, nema potrebe za njihovim ponavljanjem pa se može započeti s posljednjim prijedlogom koji se tiče rute 7 (Slika 61).



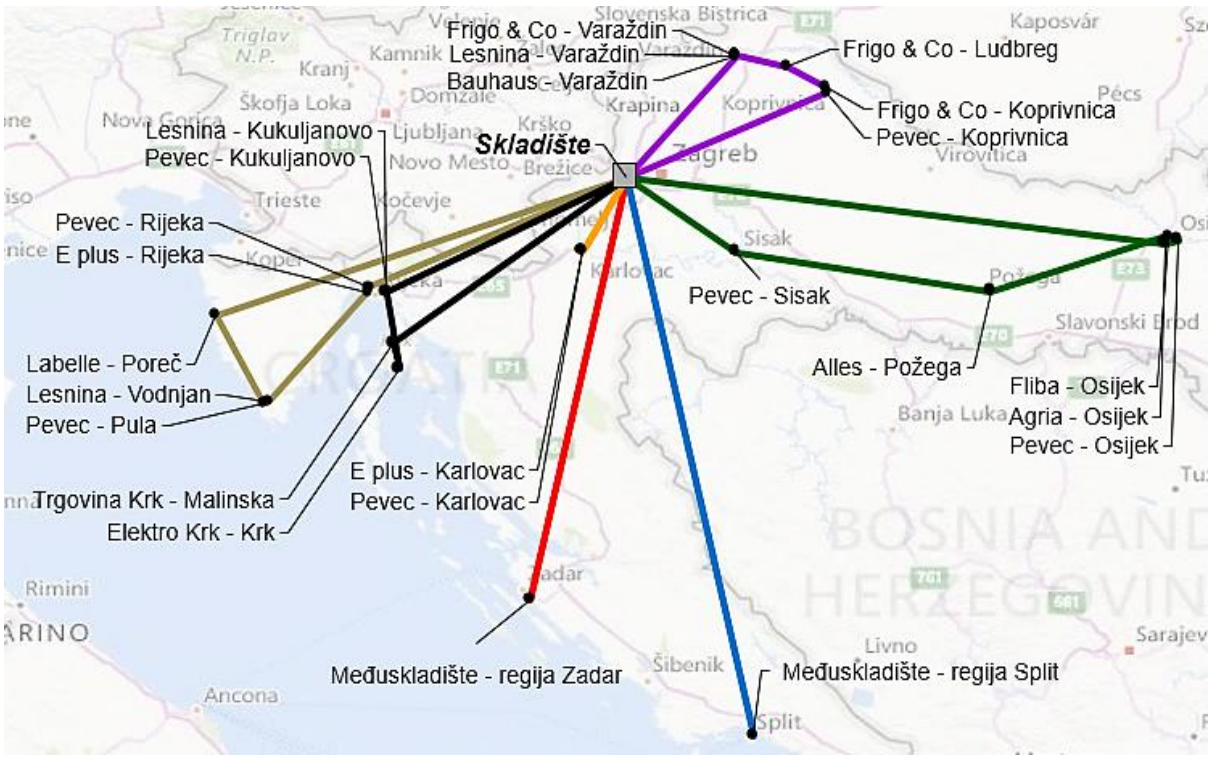
Route 7 (Kamion) | **Stops: 4** | **Distance cost: 1967,72** | **Toll fee: 400,00**

Location name	Distance travelled	Driving time	Arrival time	Departure time	Working time	Load
Skladište	0,00	0:00		07:30	0:00	25,1
Trgovina Krk - Malinska	171,87	1:55	09:25	09:40	2:10	23
Elektro Krk - Krk	192,19	2:21	10:06	10:21	2:51	20,8
Pevec - Kukuljanovo	235,15	3:07	11:07	11:22	3:52	4,13
Lesnina - Kukuljanovo	236,06	3:10	11:25	11:40	4:10	0
Skladište	393,54	4:47	13:17		5:47	0

Slika 61. Detaljni prikaz podataka za novu rutu 7 – slučaj 2
Izvor: Izradio autor

Ruta 7, jednako kao i prethodna ruta 6, predviđa upotrebu kamiona za obavljanje dostave. Ukupni volumen robe, koju korisnici sa slike zahtijevaju, prevelik je u odnosu na kombi pa otuda i proizlazi potreba za kamionom koji raspolaže s većim kapacitetom. Nadalje, početak rada kamiona jednak je svim dosadašnjim, što znači da se predviđa u 7:30 sati. Posljedično s time, zadnji bi korisnik trebao biti posjećen oko 11:25 sati. To govori da su sva vremenska ograničenja uzeta u obzir i da nisu prekršena.

Nakon ovog posljednjeg opisa rute, cjelokupni prijedlog optimiranja transportne mreže tvrtke Quehenberger Hrvatska d.o.o., za slučaj 2, iznijet je na uvid, a njegov se konačni izgled može vizualizirati idućom slikom (Slika 62).



Slika 62. Vizualni pregled svih ruta u prijedlogu rješenja – slučaj 2
Izvor: Izradio autor

Intencija danih slučajeva 1 i 2, je da se prepoznaju eventualni neispunjeni potencijali u transportnoj mreži tvrtke, i na osnovu toga da se daju adekvatni optimizacijski prijedlozi, unatoč specifičnostima u praksi koja se tiču vremenskih, troškovnih, kilometarskih i drugih ograničenja.

Na pitanje je li se u tome zaista i uspjelo, odgovor mogu dati jedino rezultati, a oni se obično prikazuju kroz očekivane učinke onoga što se predlaže. Za problem usmjeravanja vozila, koji čini srž ovog konkretnog primjera, ti očekivani učinci ogledaju se u sljedećem:

- uravnoteženju postojećih ili dizajniranju novih planova ruta, s obzirom na ograničenja i postavljene uvjete;
- smanjenju broja vozila i vozača, potrebnih da se opskrbe svi korisnici;
- povećanju radnih učinkovitosti vozila, nužnih za njihov veći stupanj iskorištenja;
- smanjenju ukupnih transportnih troškova, ovisnih o prijeđenom putu i izboru vozila;
- povećanju kvalitete usluge, odnosno povećanju učinkovitosti opskrbe korisnika.

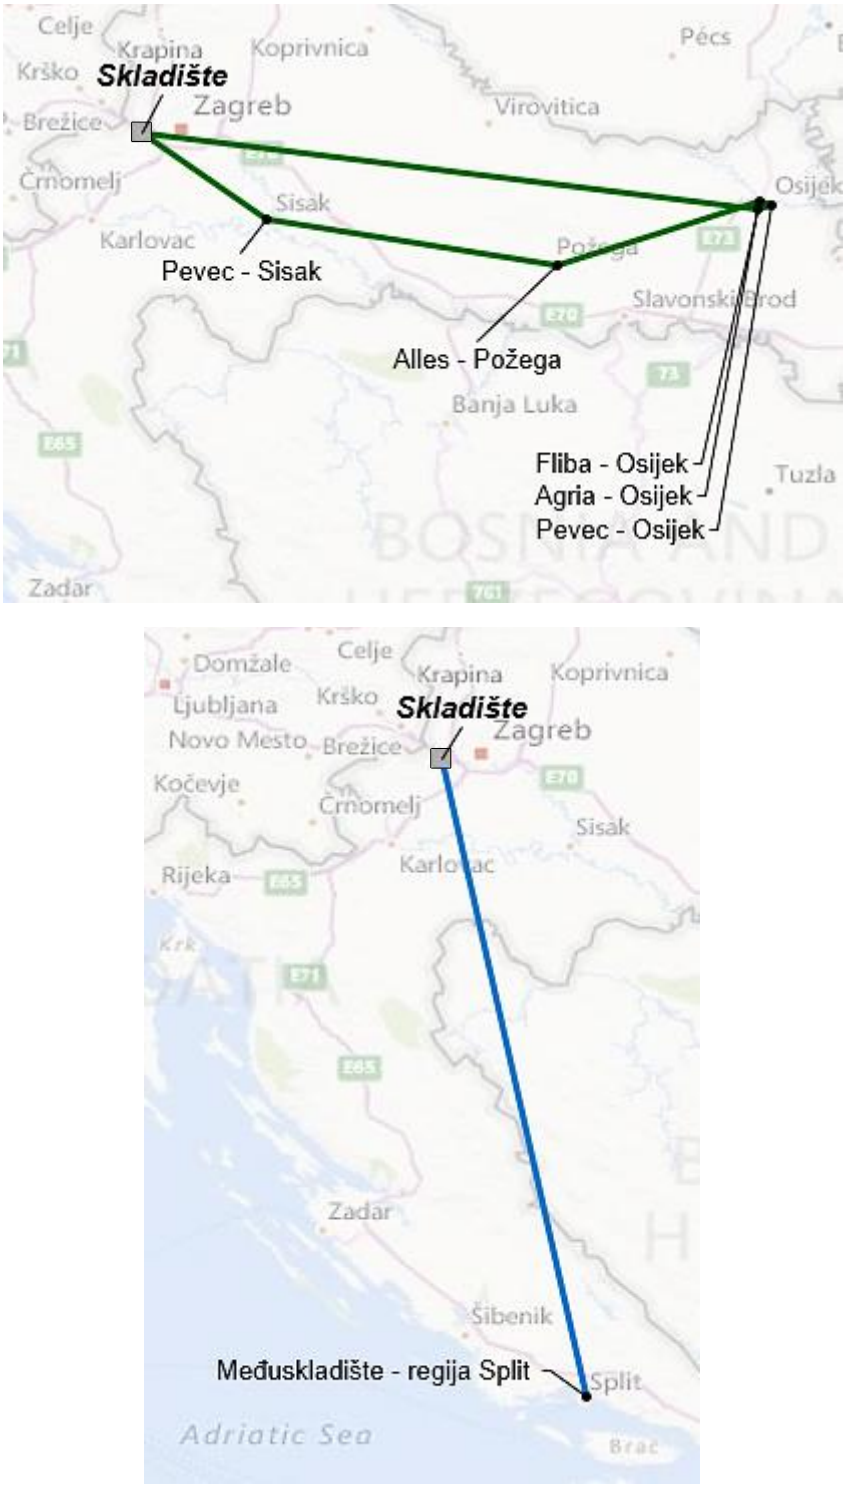
7.3. Prikaz očekivanih učinaka predloženih elemenata optimiranja

Oba iznesena slučaja, zajedno s njihovim prijedlozima rješenja, teže mijenjanju postojećih i dizajniranju novih planova ruta. Tako u odnosu na postojeću transportnu mrežu tvrtke Quehenberger Hrvatska d.o.o., samo prijedlog rješenja iz slučaja 2 ima jednu rutu koja ostaje nepromijenjena po izgledu (Slika 63)



Slika 63. Podudarna ruta između prijedloga rješenja iz slučaja 2 i izbora tvrtke
Izvor: Izradio autor

Što se pak tiče međusobne izjednačenosti prijedloga rješenja iz oba slučaja, tu postoje dvije rute koje su identične (Slika 64).

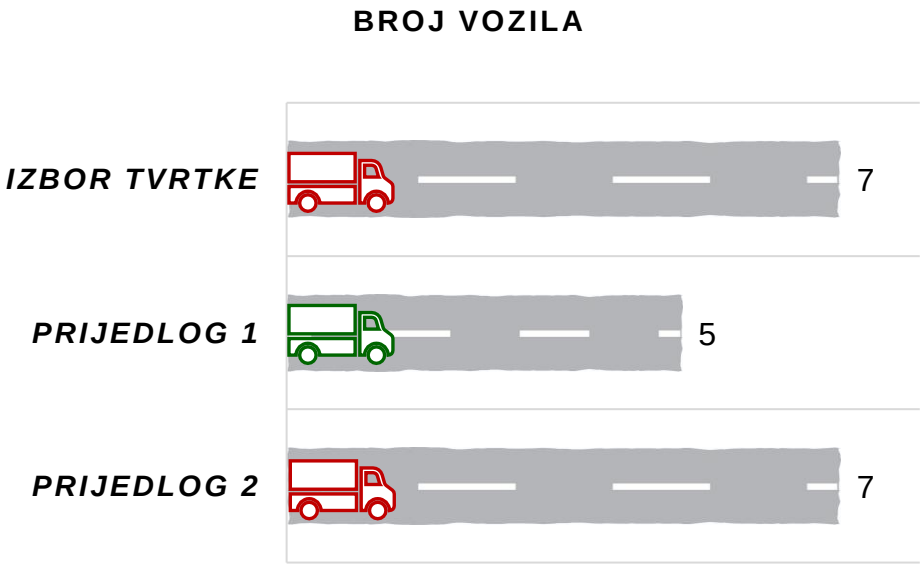


Slika 64. Nepromijenjene rute između dvaju prijedloga rješenja
Izvor: Izradio autor

Prva izjednačena ruta je ona koja prolazi Slavonskom regijom, a druga ruta koja je identična u oba slučaja, odnosno oba iznesena prijedloga rješenja, jest ona koja se tiče dostavljanja robe do međuskladišta u regiji Split.

Ukupan broj ruta iz dva prijedloga rješenja i izbora tvrtke je 19, a kao što se može vidjeti iz priloženih slika, samo su 3 koje se ponavljaju. To dovoljno govori o potrebi njihova redizajniranja prilikom traženja rješenja, ali i benefitima koji iz toga proizlaze.

Primjerice, novim planom ruta često je moguće obaviti isti posao uz manji broj vozila tako da se opterećenja pojedinih vozila ujednače. Promjene po tom pitanju mogu se vidjeti u prijedlogu rješenja iz slučaja 1. U tom je prijedlogu rješenje izvedeno na način da je konstruirano 5 ruta, a to za sobom povlači činjenicu da je potrebno angažirati 5 vozila. Zbog toga prijedlog rješenja iz slučaja 1 nosi sa sobom uštedu broja vozila u odnosu na postojeći izbor tvrtke, ali i prijedlog rješenja iz slučaja 2 (Grafikon 5).



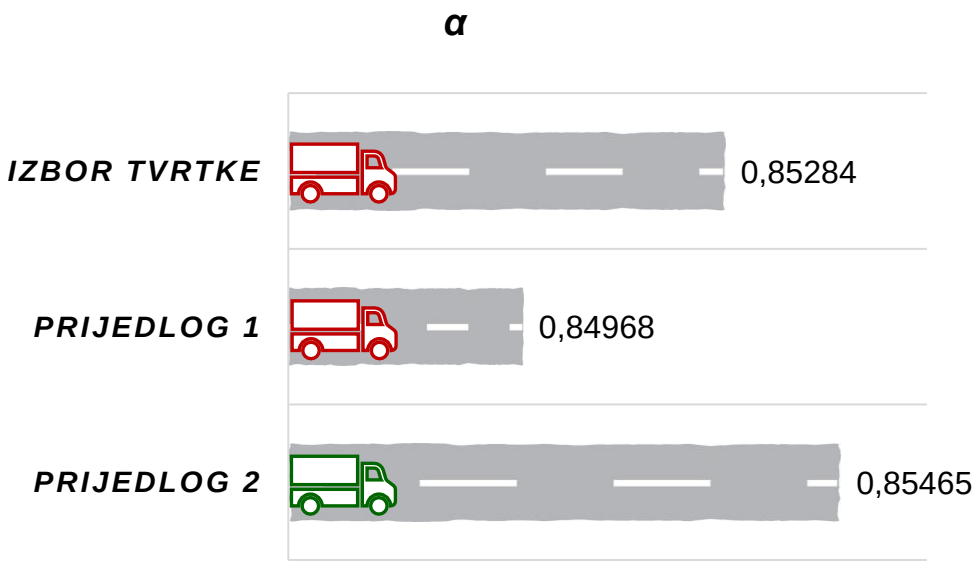
Grafikon 5. Odnos broja vozila između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Smanjenje broja vozila izravno utječe na smanjenje gotovo svih fiksnih troškova, od amortizacije, registracije i osiguranja, pa do režijskih troškova, plaća zaposlenika te raznih drugih pristojbi. Osim toga, smanjuju se i troškovi povezani s povećanom koncentracijom vozila na prometnicama. To se u prvom redu odnosi na eksterne troškove klimatskih promjena, zagađenja zraka, buke, prometnih zagušenja i nesreća.

Nakon broja vozila, za potrebe ocjenjivanja radnih učinkovitosti vozila u rutama, uveden je sustav koeficijenata s kojima je moguće valorizirati stupnjeve iskorištenja vozila u raznim segmentima i kroz razne tehničko-eksploatacijske performanse. Neki od relevantnih koeficijenata za promatrani problem jesu sljedeći:

- Koeficijent iskorištenja vozila u funkciji vožnje – α;
- Koeficijent iskorištenja prijeđenog puta pod opterećenjem – β;
- Koeficijent statičkog opterećenja vozila – γ_s;
- Koeficijent dinamičkog iskorištenja nazivne nosivosti vozila – γ_d.

Koeficijent iskorištenja vozila u funkciji vožnje (α) prati uspješnost angažiranosti vozila, a definira se kao omjer vremena vožnje i ukupnog radnog vremena. U prikazanim rutama, ovaj je koeficijent tek neznatno veći od ostalih kod prijedloga rješenja iz slučaja 2 (Grafikon 6).

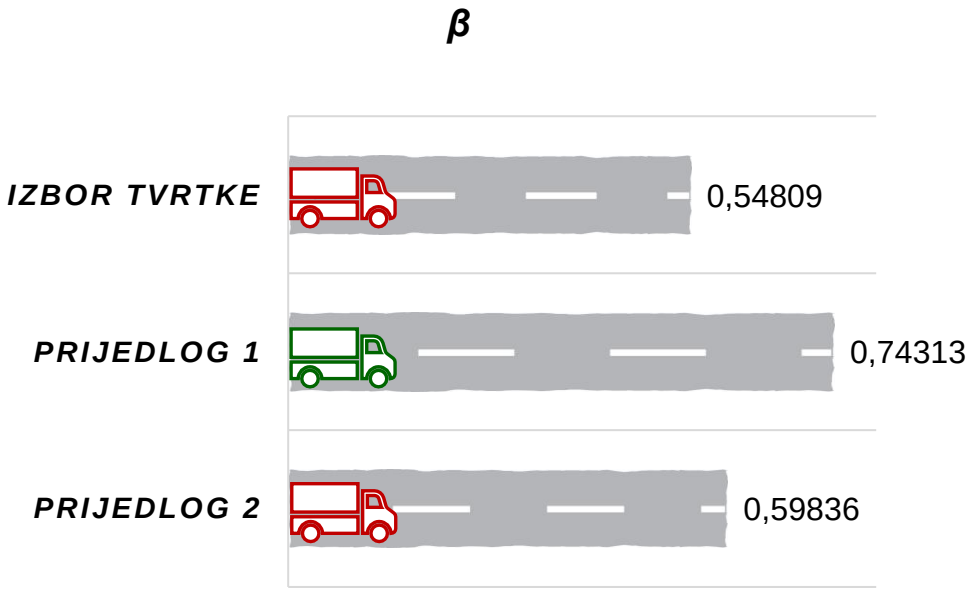


Grafikon 6. Odnos koeficijenta α između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Iz sva tri rezultata može se iščitati da vozila u vožnji provode oko 85% ukupnog radnog vremena. Takav ishod gdje je koeficijent α gotovo jednak za sve tri varijante zapravo je i očekivan. Naime, u rutama iz oba prijedloga rješenja i postojeće mreže tvrtke sudjeluju isti korisnici pa zbog toga vrijeme vožnje i ukupno radno vrijeme imaju vrlo sličan odnos i daju približno jednake rezultate.

Nakon ovako ujednačenih rezultata, slijedi koeficijent u kojemu su rezultati specifični za svaku od tri varijante. Radi se o koeficijentu iskorištenja prijeđenog puta pod opterećenjem (*β)* koji predstavlja odnos prijeđenog puta pod opterećenjem u odnosu na ukupni prijeđeni put. Koeficijentom *β* uglavnom se detektiraju nepoželjni „prazni kilometri“, odnosno kilometri u kojima vozilo nije bilo u službi dostavljanja robe.

Po pitanju ovog koeficijenta najbolje stoji prijedlog rješenja iz slučaja 1. Prijedlog rješenja iz slučaja 2 ima nešto slabiji rezultat, a najlošije kotira postojeći izbor tvrtke (Grafikon 7).



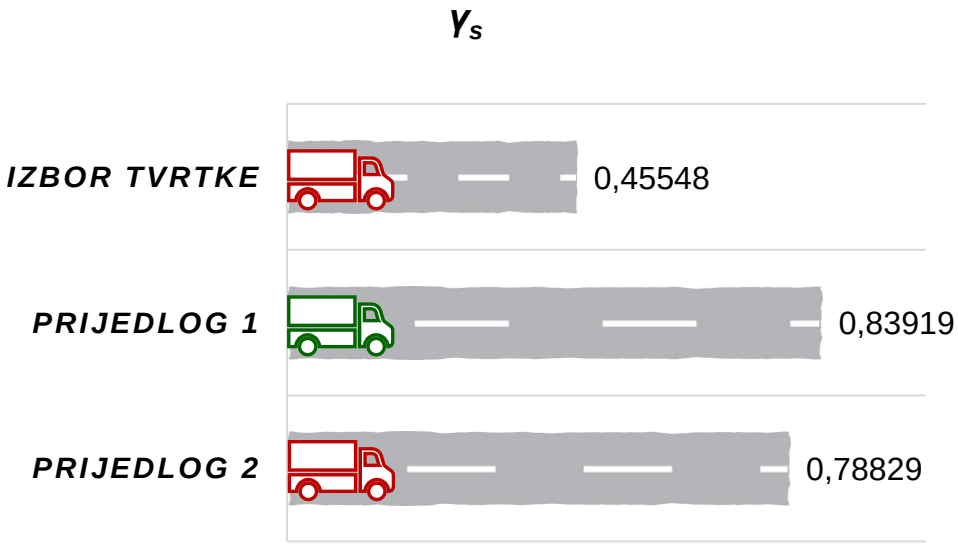
Grafikon 7. Odnos koeficijenta *β* između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Objašnjenje ovakvih rezultata, koji su najpogodniji za prijedlog rješenja iz slučaja 1, krije se u tome što taj prijedlog ima najmanji broj ruta (5), a posljedica toga je da se u njemu najmanje gubi na „praznim kilometrima“. To je zato jer su svi korisnici maksimalno povezani u tih nekoliko ruta pa tako jedna ruta broji 7, a druga čak 8 korisnika, što u konačnici prijeđeni put čini iskorištenijim.

Nadalje, više ili manje iskorištenija mogu biti i vozila, a za to su zaslužni koeficijenti iskorištenja njihove nazivne nosivosti. Prvi od ova dva koeficijenta, koji ujedno daje i oku ugodnije rezultate, jest koeficijent statičnog opterećenja vozila – γ_s. On se dobiva

dijeljenjem stvarnog i nazivnog (mogućeg) opterećenja. Pod stvarnim opterećenjem podrazumijeva se stvarna količina robe u vozilu.

Koeficijent γ_s najbolje je izražen u prijedlozima rješenja iz oba slučaja, osobito u slučaju 1, dok je za postojeći izbor tvrtke on osjetno manji i ukazuje na slabiju iskorištenost nazivne nosivosti vozila u tom rješenju (Grafikon 8).

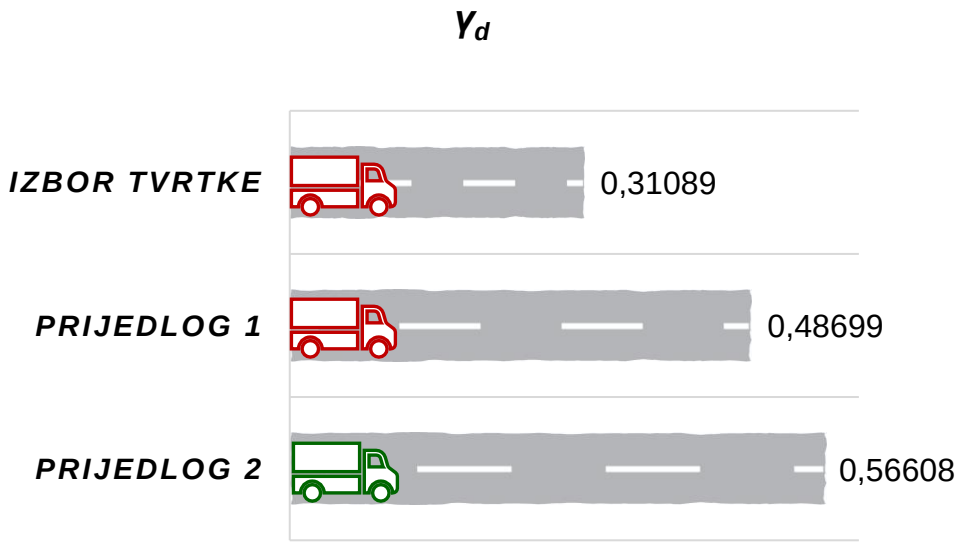


Grafikon 8. Odnos koeficijenta γ_s između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Lošiji rezultat koeficijenta iskorištenja statičnog opterećenja vozila ukazuje na nedovoljnu popunjenost vozila prilikom ukrcavanja robe u glavnom skladištu kod Svete Nedelje. Takav rezultat se mogao očekivati budući da je već sami pogled na analizirane karakteristike vozila i ukrcanu robu to i nagovještavao.

Nadogradnja ovog statičnog koeficijenta pronalazi se u koeficijentu dinamičnog iskorištenja nazivne nosivosti (γ_d) koji nastaje dijeljenjem ostvarenog i mogućeg prometnog učinka. Već je spomenuto da on na prvi pogled prikazuje nešto slabije rezultate od prethodnog koeficijenta, ali to je zato što se vozilo prazni sa svakim iskrcajem robe kod korisnika, čime se postupno smanjuje njegova popunjenost na transportnom putu. Naime, za razliku od statičnog opterećenja koje uključuje samo stvarno prevezenu robu, ovaj koeficijent u obzir uzima i udaljenosti na kojima se roba prevozi, a te udaljenosti onda daju puno veći smisao dobivenim rezultatima.

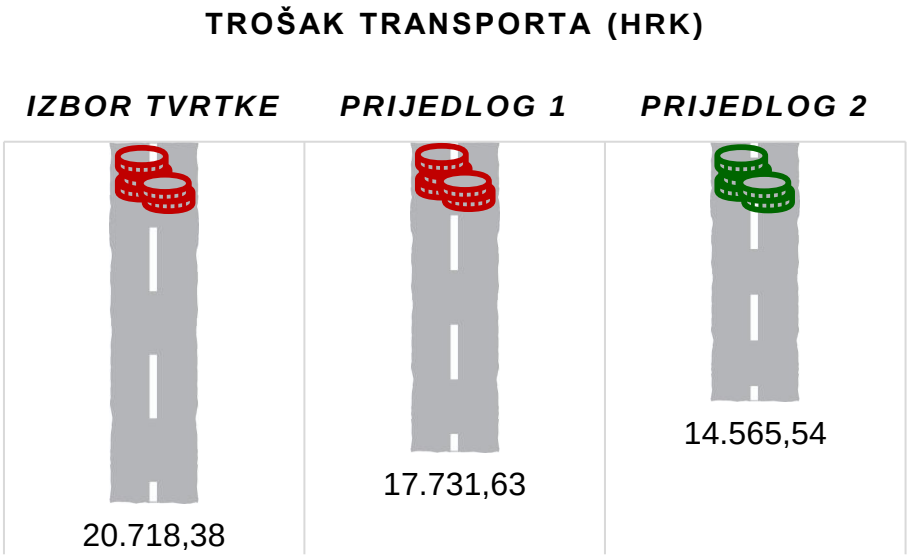
U ocjeni oba prijedloga rješenja i izbora tvrtke ovim koeficijentom, potonji izbor ponovno prednjači sa slabijim rezultatom, dok su uloge oba prijedloga rješenja samo zamijenjene u odnosu na prethodni koeficijent pa tako ovdje najbolji rezultat pruža prijedlog rješenja iz slučaja 2 (Grafikon 9).



Grafikon 9. Odnos koeficijenta γ_d između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Na osnovu rezultata iz ovog i prethodnog grafikona, zaključuje se da nedostatno iskorištenje nazivne nosivosti vozila utječe na gubitak prometnog učinka, a što je transportna udaljenost veća, to je gubitak još značajniji.

Ovime je završen pregled svih koeficijenata, a nakon njih, na red dolazi posljednji kvantitativni ocjenitelj učinka, odnosno onaj koji se tiče smanjenja transportnih troškova (Grafikon 10).



Grafikon 10. Odnos troškova između dvaju prijedloga rješenja i izbora tvrtke
Izvor: Izradio autor

Trošak transporta je od svih dosad navedenih pokazatelja možda i najzvučniji, budući da u ukupnim logističkim troškovima on vrlo često zauzima najveći udjel. Štoviše, kada se govori o optimizaciji transportne mreže, smanjenje transportnog troška vrlo često predstavlja polazišnu točku iz koje se pokušava riješiti određeni problem, budući da se s novčanom mjerljivosti najlakše mogu primijetiti poboljšanja u mreži.

Upravo je to bila misao vodilja prilikom razmatranja potrebe za uvođenjem prijedloga rješenja iz slučaja 2, jer kao što i rezultati sa slike prikazuju, prijedlog rješenja iz slučaja 2 generira najmanji transportni trošak, a za to je zaslužan optimalni broj vozila po vrsti koja stoje na raspolaganju. Time se omogućuje sloboda prilikom kombiniranja ruta pa se tako u prijedlogu rješenja iz slučaja 2 angažira najveći broj kombija, koji ujedno imaju i najmanji trošak po kilometru, dok recimo tegljač koji, usput budi rečeno, ima najveći trošak po kilometru, nije angažiran ni u jednoj ruti. Sve to ide u prilog konačnom rezultatu prijedloga rješenja iz slučaja 2, koji u odnosu na rješenje tvrtke ostvaruje uštedu transportnih troškova od 30%.

Prema ovim rezultatima i prijedlog rješenja iz slučaja 1 također ima manji transportni trošak u odnosu na postojeće rješenje tvrtke. Za razliku od prijedloga rješenja iz slučaja 2, ušteda je ovdje nešto manja te iznosi 14%.

Konačno, ne smije se zaboraviti ni da u očekivane učinke treba ubrojiti i proizvedenu kvalitetu usluge. Ona je s ovim prijedlozima povećana tako što su ispunjeni svi zahtjevi korisnika. Konkretno, dostavljena im je zahtijevana roba, u zahtijevanim količinama, na zahtijevanom mjestu, unutar zahtijevanog vremenskog intervala, a za očekivati je i zahtijevanu (manju) cijenu usluge. Naime, budući da je trošak transporta u predloženim rješenjima smanjen, to ostavlja prostora za prilagodbu cijene koju dogovaraju tvrtka i klijent (korisnik).

S ovime je učinkovitost opskrbe korisnika pomaknuta na viši nivo, a svaka tvrtka treba težiti tome da tako i ostane. Štoviše, kvaliteta usluge se nikada ne bi smjela dovesti u pitanje, jer dobar glas daleko se čuje, a lošiji još dalje.

8. ZAKLJUČAK

Matematičke metode i na njima zasnovani programski alati, služe za rješavanje optimizacijskih problema u kojima se prije svega želi maksimizirati profit odnosno minimizirati trošak. To je centralna okupacija svake tvrtke koja želi poboljšati svoje poslovanje, a posljedično s time mogu se očekivati i poboljšanja nekih perifernih pitanja koja se u ovome radu tiču logističkih procesa, s posebnim naglaskom na one transportne. Sukladno tome, pozitivni učinci mogu se primijetiti i kroz bolji dizajn transportne mreže te drugačiji redoslijed obilaska korisnika u njoj. To nerijetko nosi i potrebu za manjim brojem vozila prilikom dostavljanja robe, što ne znači da će se njihove radne učinkovitosti smanjiti, već upravo suprotno, događa se da im se povećava stupanj iskorištenja, uz značajno smanjenje „praznih kilometara“.

U konačnici, sve navedeno rezultira i kvalitetnijom pruženom uslugom koju korisnici primjećuju i posebno cijene pa se sasvim jasno može zaključiti da transport u logističkim procesima ima važnu ulogu. To je i logično budući da transportni troškovi nerijetko čine i do 50% ukupnih logističkih troškova, iz čega slijedi da poboljšanje transportne efikasnosti znatno utječe na povećanje ukupnih performansi logističkog lanca. Takav značaj transporta u logističkim je krugovima shvaćen ozbiljno i zbog toga postoji veliki broj matematičkih metoda koje se bave isključivo transportnim problemima. Problem usmjeravanja vozila jedan je od njih, a zbog toga što je stalno prisutan u logističkoj svakodnevici, konstantno se istražuju nove metode kako bi se poradilo na njegovom uspješnijem rješavanju. Naime, matematičke metode još uvijek ne omogućuju izračunavanje optimalnih rješenja iznimno složenih pothvata i to je njihov nedostatak. Osim toga, problemi se pojavljuju i kod njihove primjene u rješavanju transportnih problema, budući da takvi problemi zahtijevaju iznimna znanja i vještine o suvremenim metodologijama i tehnologijama znanstvenog istraživanja, a to znači da ih mogu uspješno, učinkovito i racionalno upotrebljavati samo profesionalno kompetentni stručnjaci, kojih je nažalost vrlo malo. Nadalje, čak i kada ljudi nisu problem, upotreba matematičkih metoda vrlo često zahtijeva i adekvatnu obrazovno-znanstvenu infrastrukturu te sve prateće sadržaje s kojima raspolaže iznimno mali, gotovo i zanemariv broj institucija, a upravo bi one trebale biti nositelji takvih pothvata.

Nedostataka ima još, no kako u svemu treba biti pozitivan i isticati ono dobro, tako i ovdje treba reći da su prednosti matematičkih metoda mnogostruko veće, važnije i vrijednije od svih njihovih nedostataka. Općenito je najveća prednost transportno povezanih matematičkih metoda ta što omogućuju rješavanje kompleksno strukturiranih problema realnih transportnih sustava, koji se sastoje od ljudi, infrastrukture, suprastrukture, tokova, tereta, informacija i svega ostalog vezanog uz transport. Konkretno, matematičke metode mogu se implementirati u programske alate i tako omogućiti eksperimentiranje s planiranim idejama, i to na relativno jeftin način te bez neželjenih posljedica. Tako se brže dolazi do očekivanih rezultata, koji se onda mogu lako i jednostavno provjeriti i ocijeniti te se na osnovu toga „bezbolno“ mogu donositi zaključci o tome je li nešto dobro i isplativo za primjenu u realnom sustavu, ili nije.

Vodeći se upravo time i spomenutim mogućnostima koje matematičke metode pružaju, u ovom je radu ispitana isplativost optimizacije transportne mreže tvrtke, a rezultati toga su i više nego zadovoljavajući. Naime, na osnovu podataka koji su prikupljeni i analizirani, izneseni prijedlozi rješenja u svim segmentima i po svim pokazateljima nadmašuju postojeće stanje transportne mreže tvrtke, a to je ujedno bila i svrha rada – na stvarnom primjeru, te uz pomoć i podršku matematičkih metoda i programskog alata, optimizirati transportnu mrežu logističkog operatera.

U praktičnoj primjeni, predložena rješenja treba uzeti kao preporuke koje se po potrebi mogu modificirati u skladu s konkretnim okolnostima, u kojima treba uzeti u obzir dodatne čimbenike koji mogu biti stohastičke prirode (poremećaji u odvijanju prometa, nepravilnosti u preuzimanju, otpremi i prijevozu pošiljaka, neispravnost vozila…) ili netehnološke naravi (posebni zahtjevi komitenata). Osobe koje su odgovorne za konačni izgled ruta u transportnoj mreži tvrtke, imaju uvid u sve te informacije, i na temelju njih mogu izvesti potrebne modifikacije te tako ostvariti željene učinke optimizacije.

POPIS LITERATURE

[1] Jurčić, J., Poletan Jugović, T.: *Logistički špediterski operator kao perspektiva klasičnog špeditera*, Pomorski fakultet, Rijeka, 2006.

[2] Dunković, D.: *Logistički poslovi i konkurentnost vrijednosnog lanca maloprodaje*, Ekonomski fakultet, Zagreb, 2009.

[3] Ivaković, Č., Stanković, R., Šafran, M.: *Špedicija i logistički procesi, Fakultet prometnih znanosti*, Zagreb, 2010.

[4] Zelenika, R.: *Logistički sustavi*, Ekonomski fakultet, Rijeka, 2005.

[5] Comtois, C., Rodrigue, J. P., Slack, B.: *The Geography of Transport System*, Routledge, New York, 2013.

[6] Pupovac, D., Zelenika, R.: *Suvremeno promišljanje osnovnih fenomena logističkoga sustava*, Ekonomski pregled, Zagreb, 2001.

[7] Santosh Kumar, G., Shirisha, P.: *Transportation – the Key Player in Logistics Management*, Journal of Business Management and Social Sciences Research, Mahabubnagar, 2014.

[8] Tseng, Y., Yue, W. L.: *The Role of Transportation in Logistics Chain*, University of South Australia, Adelaide, 2005.

[9] Poletan Jugović, T., Tomić, M.: *Principi konkurentnog poslovanja na tržištu logističko-špediterskih usluga*, Pomorski fakultet, Rijeka, 2015.

[10] Zelenika, R.: *Temelji logističke špedicije*, Ekonomski fakultet, Rijeka, 2005.

[11] Pupovac, D., Radić, D., Zelenika, R.: *Špediter u funkciji logističkoga operatora*, Ekonomski fakultet, Rijeka, 2001.

[12] Harmelink, D., Tompkins, J.: *Distribution management handbook*, McGraw-Hill Education, New York, 1994.

[13] Lumsden, K.: *Fundamentals of Logistics*, Chalmers University of Technology, Gothenburg, 2003.

[14] Drašković, M.: *Evolucija sistemskih logističkih provajdera*, Pomorski fakultet, Kotor, 2008.

[15] Jakubauskas, G., Vasiliauskas, A. V.: *Principle and Benefits of Third Party Logistics Approach when Managing Logistics Supply Chain*, Gediminas Technical University, Vilnius, 2007.

[16] Kolinski, A.: *Logistics Management - Modern Development Trends*, Poznan School of Logistics, Poznań, 2016.

[17] URL: http://www.progressive.com.hr/component/content/article/62-kolumne/5547-sto-uracunati-u-stvarne-logisticke-troskove.html (28.05.2018.)

[18] Abdallah, H.: *Guidelines for Assessing Costs in a Logistics System: An Example of Transport Cost Analysis*, United States Agency for International Development, Arlington, 2004.

[19] Carić, T.: *Unapređenje organizacije transporta primjenom heurističkih metoda*, Fakultet prometnih znanosti, Zagreb, 2004.

[20] Pašagić, H.*: Matematičko modeliranje i teorija grafova*, Fakultet prometnih znanosti, Zagreb, 1998.

[21] Dantzig, G. B., Ramster, J. H.: *The Truck Dispatching Problem*, Institute for Operations Research and the Management Sciences, Linthicum, 1959.

[22] De Jaegere, N., Defraeye, M., Van Nieuwenhuyse, I.: *The Vehicle Routing Problem: State of the Art Classification and Review*, Faculty of Economics and Business, Leuven, 2014.

[23] Toth, P.: *Integer Linear Programming Refining Procedures for Vehicle Routing Problems*, Faculty of Engineering, Bologna, 2010.

[24] Li, S., Niu, B., Gan, X., Wang, Y.: *Vehicle Routing Problem with Time Windows and Simultaneous Delivery and Pickup Service Based on MCPSO*, College od Management, Shenzen, 2012.

[25] Galić, A.: *Rješavanje problema usmjeravanja vozila hibridnim staničnim evolucijskim algoritmom*, Fakultet prometnih znanosti, Zagreb, 2018.

[26] Cabral, L. dos A. F., Ochi, L. S., Subramanian, A.: *An Efficient ILS Heuristic for the Vehicle Routing Problem with Simultaneous Pickup and Delivery*, Universidade Federal Fluminense, Niterói, 2008.

[27] Pisinger, D., Ropke, S.: *A Unified Heuristic for Vehicle Routing Problem with Backhauls*, European Journal of Operational Research, Copenhagen, 2006.

[28] Laporte, G., Semet, F.: *Classical Heuristics for the Capacited VRP*, Society for Industrial and Applied Mathematics, Philadelphia, 2002.

[29] Gillet, B. E., Millller, L. R.: *A Heuristic Algorithm for the Vehicle Dispatch Problem*, Institute for Operations Research and the Management Sciences, Linthicum, 1974.

[30] Chopra, S., Meindl, P.: *Supply Chain Management: Strategy, Planning and Operations*, Pearson Prentice Hall, New Jersey, 2004.

[31] Erdoğan, G.: *An open Source Spreadsheet Solver for Vehicle Routing Problems*, School of Management, Bath, 2017.

[32] URL: http://people.bath.ac.uk/ge277/index.php/vrp-spreadsheet-solver/ (13.07.2018)

[33] Carrizosa, E., Guerrero, V., Romero Morales, D.: *Visualizing Proportions and Dissimilarities by Space-filling Maps: A Large Neighborhood Search Approach*, Computers and Operation Research, Instituto de Matemáticas, Seville, 2016.

[34] URL: https://slideplayer.com/slide/10343314/ (31.07.2018.)

[35] URL: https://www.quehenberger.com/sl/hr/kompanija/cinjenice-i-brojke/ (01.08.2018.)

[36] URL: https://www.quehenberger.com/hr/kompanija/filozofija/vizija/?L=986 (01.08.2018.)

[37] Erdoğan, G.: *User's Manual for VRP Spreadsheet Solver*, School of Management, Bath, 2017.

[38] URL: https://www.hak.hr/info/cestarine/ (29.08.2018.)

[39] Debeljak, S., Gočin, M.: *Radno vrijeme i obvezni odmori mobilnih radnika, vozača, i praktični prikaz evidentiranja njihovih aktivnosti*, Veleučilište u Rijeci, Rijeka, 2016.

POPIS KRATICA

7P	Koncept 7P (engl. ***7P** concept*)
1PL	Prva strana logistike (engl. ***1**st **P**arty **L**ogistics*)
2PL	Druga strana logistike (engl. ***2**nd **P**arty **L**ogistics*)
3PL	Treća strana logistike (engl. ***3**rd **P**arty **L**ogistics*)
4PL	Četvrta strana logistike (engl. ***4**th **P**arty **L**ogistics*)
5PL	Peta strana logistike (engl. ***5**th **P**arty **L**ogistics*)
VRP	Problem usmjeravanja vozila (engl. ***V**ehicle **R**outing **P**roblem*)
CVRP	Problem usmjeravanja vozila s ograničenjem kapaciteta (engl. ***C**apacitated **V**ehicle **R**outing **P**roblem*)
DVRP	Problem usmjeravanja vozila s ograničenjem duljine rute (engl. ***D**istance-constraint **V**ehicle **R**outing **P**roblem*)
VRPTW	Problem usmjeravanja vozila s vremenskim ograničenjem (engl. ***V**ehicle **R**outing **P**roblem with **T**ime **W**indows*)
VRPPD	Problem usmjeravanja vozila s dostavom i prikupljanjem (engl. ***V**ehicle **R**outing **P**roblem with **P**ickup and **D**elivery*)
VRPB	Problem usmjeravanja vozila s dostavom i povratnim prikupljanjem (engl. ***V**ehicle **R**outing **P**roblem with **B**ackhauls*)
TSP	Problem trgovačkog putnika (engl. ***T**ravelling **S**alesman **P**roblem*)
NNH	Heuristika najbližeg susjeda (engl. ***N**earest **N**eighbor **H**euristic*)
2-Opt	2-optimalna (engl. ***2-Opt**imal*)
C&W	Clarke i Wright (engl. ***C**larke **and W**right*)
H&P	Holmes i Parker (engl. ***H**olmes **and P**arker*)
VBA	Programski jezik (engl. ***V**isual **B**asic for **A**pplications*)
LNS	Pretraživanje velikog susjedstva (engl. ***L**arge **N**eighborhood **S**earch*)
R&R	Princip uništavanja i popravljanja (engl. ***R**uin **and R**ecreate*)

GIS	Geografski informacijski sustav (engl. ***G**eographic **I**nformation **S**ystem*)
GmbH	Društvo s ograničenom odgovornošću (njem. ***G**esellschaft **m**it **b**eschränkter **H**aftung*)
EUR	Euro (engl. ***EUR**o*)
FTL	Pošiljka punog kamiona (engl. ***F**ull **T**ruck **L**oad*)
LTL	Pošiljka nepunog kamiona (engl. ***L**ess **T**han **L**oad*)
d.o.o.	**D**ruštvo s **o**graničenom **o**dgovornošću (engl. ***L**imited **L**iability **C**ompany* – LCC)
ISO	Međunarodna organizacija za standardizaciju (engl. ***I**nternational **O**rganization for **S**tandardization*)
BS OHSAS	Sustav upravljanja zdravljem i sigurnošću na radu (engl. ***B**ritish **S**tandard **O**ccupational **H**ealth and **S**afety **A**ssessment **S**eries*)
d.d.	**D**ioničko **d**ruštvo (engl. ***P**ublic **L**imited **C**ompany* – PLC)
ul.	**Ul**ica (engl. ***St**reet* – St)
t.o.	**T**rgovački **o**brt (engl. ***M**anu**f**acturin**g** Business* – MFG)
sv.	**Sv**eti (engl. ***S**aint* – *S*)
HV	**H**rvatska **v**ojska (engl. ***N**ational **A**rmy* – NA)
dr.	**D**oktor (engl. ***D**octor* – *Dr*)
HRK	**Hr**vatska **k**una (engl. *Croatian **K**u**n**a* – *Kn*)

POPIS SLIKA

Slika 1. Hijerarhijski prikaz povezanosti terminoloških pojmova 6
Slika 2. Prikaz varijanti udaljenosti s aspekta transporta i logistike 8
Slika 3. Ključni periodi u razvoju logistike 10
Slika 4. Kompleksnost usluga od 1PL do 5PL operatera 16
Slika 5. Dva često suprotstavljena pokretača transportnih troškova 25
Slika 6. Mjerne jedinice pokretača transportnih troškova 26
Slika 7. Vizualni prikaz problema usmjeravanja vozila i njegovih komponenti 30
Slika 8. Hijerarhijski prikaz podproblema VRP-a 33
Slika 9. Osnovna razlika između TSP-a i VRP-a 34
Slika 10. Primjer CVRP-a 35
Slika 11. Rješenje primjera CVRP-a 38
Slika 12. Primjer DCVRP-a 41
Slika 13. Rješenje primjera DCVRP-a 42
Slika 14. Primjer VRPTW-a 47
Slika 15. Rješenje primjera VRPTW-a 48
Slika 16. Primjer VRPPD-a 49
Slika 17. Rješenje primjera VRPPD-a 53
Slika 18. Primjer VRPB-a 54
Slika 19. Rješenje primjera VRPB-a 56
Slika 20. Podjela heurističkih metoda rješavanja optimizacijskih problema 58
Slika 21. Princip rada u heuristici najbližeg susjeda 59
Slika 22. Usporedba originalne rute i rute koja je poboljšana 2-Opt metodom 60
Slika 23. Heuristika najbližeg susjeda s ograničenjem kapaciteta 60
Slika 24. Poboljšanje rješenja dobivenog heuristikom najbližeg susjeda 61
Slika 25. Početni položaj zamišljenog pravca i smjer rasta polarnog kuta 62
Slika 26. Rješenje primjera Sweep algoritmom 63
Slika 27. Izgled elementarne rute za prvog korisnika 66
Slika 28. Spajanje korisnika u C&W algoritmu 67
Slika 29. H&P precizirano rješenje primjera 74
Slika 30. Rezultat operacije uništavanja i popravljanja 77
Slika 31. Shema programskog okruženja u Excelu 78

Slika 32. Radni list s rješavajućom konzolom 79
Slika 33. Radni list s lokacijama 80
Slika 34. Skraćeni radni list s udaljenostima 81
Slika 35. Radni list s vozilima 82
Slika 36. Radni list s rješenjem 83
Slika 37. Vizualizacija skladišta i korisnika 84
Slika 38. Rasprostranjenost tvrtke Quehenberger Logistics GmbH u Europi 85
Slika 39. Vizija tvrtke Quehenberger Logistics GmbH 87
Slika 40. Sjedište i područni uredi tvrtke Quehenberger Hrvatska d.o.o. 88
Slika 41. Mreža partnera tvrtke Quehenberger Hrvatska d.o.o. 89
Slika 42. Vizualni pregled svih analiziranih ruta u transportnoj mreži 98
Slika 43. Postavljanje početnih parametara u rješavajućoj konzoli 99
Slika 44. Upisivanje podataka u prvi dio radnog lista s lokacijama 101
Slika 45. Upisivanje podataka u drugi dio radnog lista s lokacijama 102
Slika 46. Skraćeni i prilagođeni prikaz dobivenog radnog lista s udaljenostima 104
Slika 47. Popunjavanje parametara u radnom listu s vozilima – slučaj 1 105
Slika 48. Detaljni prikaz podataka za novu rutu 1 – slučaj 1 107
Slika 49. Detaljni prikaz podataka za novu rutu 2 – slučaj 1 108
Slika 50. Detaljni prikaz podataka za novu rutu 3 – slučaj 1 109
Slika 51. Detaljni prikaz podataka za novu rutu 4 – slučaj 1 110
Slika 52. Detaljni prikaz podataka za novu rutu 5 – slučaj 1 110
Slika 53. Vizualni pregled svih ruta u prijedlogu rješenja – slučaj 1 111
Slika 54. Popunjavanje parametara u radnom listu s vozilima – slučaj 2 112
Slika 55. Detaljni prikaz podataka za novu rutu 1 – slučaj 2 113
Slika 56. Detaljni prikaz podataka za novu rutu 2 – slučaj 2 114
Slika 57. Detaljni prikaz podataka za novu rutu 3 – slučaj 2 114
Slika 58. Detaljni prikaz podataka za novu rutu 4 – slučaj 2 115
Slika 59. Detaljni prikaz podataka za novu rutu 5 – slučaj 2 115
Slika 60. Detaljni prikaz podataka za novu rutu 6 – slučaj 2 116
Slika 61. Detaljni prikaz podataka za novu rutu 7 – slučaj 2 116
Slika 62. Vizualni pregled svih ruta u prijedlogu rješenja – slučaj 2 117
Slika 63. Podudarna ruta između prijedloga rješenja iz slučaja 2 i izbora tvrtke 118
Slika 64. Nepromijenjene rute između dvaju prijedloga rješenja 119

POPIS TABLICA

Tablica 1. Dimenzije strategije izdvajanja posla 15
Tablica 2. Matrica udaljenosti 65
Tablica 3. Matrica ušteda u C&W algoritmu 68
Tablica 4. Uštede u silaznom poretku..... 69
Tablica 5. Zadana potražnja korisnika i kapacitet vozila 70
Tablica 6. Indikatori performansi tvrtke Quehenberger Logistics GmbH u 2017..... 86
Tablica 7. Generalni prikaz podataka za svih sedam ruta 90
Tablica 8. Detaljni prikaz podataka za analizu rute 1 – regija Rijeka 2 91
Tablica 9. Detaljni prikaz podataka za analizu rute 2 – regija Sjever..... 92
Tablica 10. Detaljni prikaz podataka za analizu rute 3 – regija Karlovac 92
Tablica 11. Detaljni prikaz podataka za analizu rute 4 – regija Istra..... 93
Tablica 12. Detaljni prikaz podataka za analizu rute 5 – regija Rijeka..... 94
Tablica 13. Detaljni prikaz podataka za analizu rute 6 – regija Slavonija 95
Tablica 14. Detaljni prikaz podataka za analizu rute 7 – regija Dalmacija 96

POPIS GRAFIKONA

Grafikon 1. Prosječni udjel troška transporta u ukupnim logističkim troškovima 23
Grafikon 2. Relativna prisutnost podproblema VRP-a u istraživanjima 33
Grafikon 3. Relativna prisutnost optimizacijskih metoda u istraživanjima..... 57
Grafikon 4. Udjeli skladišnog prostora tvrtke Quehenberger Hrvatska d.o.o. 88
Grafikon 5. Odnos broja vozila između dvaju prijedloga rješenja i izbora tvrtke.... 120
Grafikon 6. Odnos koeficijenta α između dvaju prijedloga rješenja i izbora tvrtke. 121
Grafikon 7. Odnos koeficijenta β između dvaju prijedloga rješenja i izbora tvrtke. 122
Grafikon 8. Odnos koeficijenta γ_s između dvaju prijedloga rješenja i izbora tvrtke 123
Grafikon 9. Odnos koeficijenta γ_d između dvaju prijedloga rješenja i izbora tvrtke 124
Grafikon 10. Odnos troškova između dvaju prijedloga rješenja i izbora tvrtke 125

Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu diplomskog rada pod naslovom **Optimiranje transportne mreže logističkog operatera primjenom matematičkih metoda** na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

U Zagrebu, 5.9.2018

Student/ica:

(potpis)