

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

**Roberto Skoliber**

Zagreb, 2018. godina.

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

Mentori:

Doc. dr. sc. Hrvoje Cajner

Student:

Roberto Skoliber

Zagreb, 2018. godina.

## **IZJAVA**

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

Roberto Skoliber

---

## **ZAHVALA**

*Zahvaljujem se svom mentoru Doc. dr. sc. Hrvoju Cajneru na pruženoj stručnoj pomoći i savjetima prilikom izrade završnog rada.*

*Također, zahvaljujem se poduzećima Tasa d.o.o. i S-Consulting d.o.o. na ukazanoj susretljivosti prilikom prikupljanja podataka bez kojih ovaj rad ne bi bio moguć.*

*Posebno i veliko hvala mojoj obitelji, roditeljima Ani i Stjepanu i sestrama Tanji i Sanji te svim bližnjima i kolegama na bezuvjetnoj podršci i pomoći tijekom studija.*



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



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

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## ZAVRŠNI ZADATAK

Student: **Roberto Skoliber** Mat. br.: 0035202590  
 Naslov rada na hrvatskom jeziku: **Analiza utjecaja značajki vozila na ukupne troškove autoprijevoznčkog poduzeća**  
 Naslov rada na engleskom jeziku: **Analysis of the impact of vehicle characteristics on total cost in a transporting enterprise**


### Opis zadatka:

Utjecaj parametara komponenti u nekom proizvodnom ili uslužnom procesu može biti ključan za isplativost, a time i održivost samog sustava. Posebice se to odnosi na sustave koji pružaju usluge transporta. S obzirom na stroge zahtjeve tržišta i potrebu da usluga prijevoza bude što kvalitetnija i cjenovno povoljnija, prijevoznici i logistički operateri moraju tražiti načine za smanjenje troškova. Veliki dio troškova odnosi se na početnu investiciju, održavanje te eksploataciju. Na temelju dostupnih podataka konkretnog autoprijevoznčkog poduzeća potrebno je prikupiti i statistički analizirati postojeće stanje značajki vozila u voznom parku. Potrebno je kvantitativno izraziti i eksplicitno odrediti povezanost značajki vozila i ukupnih troškova. Temeljem analize rezultata potrebno je formulirati prijedlog poboljšanja u načinu upravljanja voznim parkom.

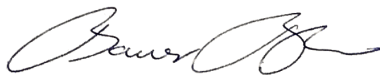
Zadatak zadan:  
 30. studenog 2017.

Rok predaje rada:  
 1. rok: 23. veljače 2018.  
 2. rok (izvanredni): 28. lipnja 2018.  
 3. rok: 21. rujna 2018.

Predviđeni datumi obrane:  
 1. rok: 26.2. - 2.3. 2018.  
 2. rok (izvanredni): 2.7. 2018.  
 3. rok: 24.9. - 28.9. 2018.

Zadatak zadao:  
  
 Dr. sc. Hrvoje Cajner, doc.

Predsjednik Povjerenstva:

  
 Izv. prof. dr. sc. Branko Bauer

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TABLICA.....	V
POPIS KRATICA .....	VI
POPIS OZNAKA .....	VII
SUMMARY .....	VIII
SAŽETAK.....	IX
1. UVOD.....	1
2. PODUZEĆE „TASA d.o.o.“ .....	2
2.1. Područje djelovanja.....	2
2.2. Vizija, misija, ciljevi i strategija .....	3
2.3. Vozni park.....	4
2.4. SWOT analiza .....	8
3. CESTOVNI PROMET I TROŠKOVI.....	11
3.1. Klasifikacija troškova .....	12
3.1.1. Troškovi transporta .....	13
3.1.2. Financijsko izvješće promatranog poduzeća.....	13
3.2. Cestovni promet .....	14
3.2.1. Prednosti cestovnog prometa .....	14
3.2.2. Nedostaci cestovnog prometa .....	14
4. ANALIZA PODATAKA.....	15
4.1. Provjera ujednačenosti vozila .....	15
4.2. Analiza varijanci .....	17
4.2.1. Provjera normalnosti podataka .....	17
4.2.2. ANOVA .....	21
4.3. T-test uparenih uzoraka.....	24
4.3.1. Utjecaj vremenskih prilika na pojavu kvarova .....	24

---

4.3.2.	Utjecaj područja eksploatacije na pojavu kvarova.....	26
4.3.3.	Usporedba vozila marke Volvo.....	28
4.3.3.1.	Usporedba ostvarenog prihoda po kilometru (Volvo) .....	28
4.3.3.2.	Usporedba pojave kvarova (Volvo) .....	29
4.3.4.	Usporedba vozila marke Iveco modela Eurocargo .....	31
4.3.4.1.	Usporedba prihoda po kilometru (Iveco) .....	31
4.3.4.2.	Usporedba pojave kvarova (Iveco) .....	32
4.4.	Korelacijska i regresijska analiza.....	35
4.4.1.	Korelacija između prijeđenih kilometara, kvarova i troškova popravka .....	36
4.4.2.	Regresijska analiza.....	38
4.5.	ABC ili Pareto analiza.....	39
5.	PRIJEDLOG POBOLJŠANJA.....	42
5.1.	Analiza dobivenih rezultata .....	42
5.2.	Načini smanjivanja troškova.....	43
5.3.	Digitalizacija evidencije podataka .....	44
5.3.1.	Desktop aplikacija.....	44
5.3.2.	Uvođenje tehnologije i edukacija djelatnika .....	46
5.4.	Povezivanje na transportnu platformu .....	47
6.	ZAKLJUČAK.....	48
	LITERATURA.....	49
	PRILOZI.....	51

## POPIS SLIKA

Slika 2.1.	Područje djelovanja u međunarodnom transportu.....	2
Slika 2.2.	Vrsta, karakteristike i dimenzije vozila u floti [2].....	4
Slika 2.3.	Vozilo Volvo ČK-430-FF .....	5
Slika 2.4.	Vozilo Volvo ČK-986-GT.....	5
Slika 2.5.	Vozilo Iveco ČK-320-ET .....	6
Slika 2.6.	Vozilo Iveco ČK-325-GD .....	6
Slika 2.7.	Vozilo Mercedes Atego ČK-919-FV .....	7
Slika 2.8.	Vozilo MAN ČK-349-FZ.....	7
Slika 2.9.	Prometno-geografski položaj tvrtke Tasa.....	10
Slika 3.1.	Graf ukupne količine transportirane robe [5].....	11
Slika 3.2.	Fiksni i varijabilni troškovi .....	12
Slika 3.3.	Tortni prikaz troškova transporta .....	13
Slika 3.4.	Bonitetni izvještaj za poduzeće „Tasa d.o.o.“ [8] .....	13
Slika 3.5.	Graf kumulativnih vrijednosti pojedine vrste transporta.....	14
Slika 4.1	Graf prihoda za sva vozila po mjesecima.....	16
Slika 4.2	Graf prihoda po kilometru za sva vozila po mjesecima .....	16
Slika 4.3.	Provjera normalnosti vozila ČK-919-FV .....	18
Slika 4.4.	Provjera normalnosti vozila ČK-986-GT .....	18
Slika 4.5.	Provjera normalnosti vozila ČK-349-FZ.....	19
Slika 4.6.	Provjera normalnosti vozila ČK-430-FF.....	19
Slika 4.7.	Provjera normalnosti vozila ČK-325-GD.....	20
Slika 4.8.	Provjera normalnosti vozila ČK-320-ET .....	20
Slika 4.9.	Prikaz ukupne sume kvadrata odstupanja [10].....	22
Slika 4.10.	Grafički prikaz provedene analize varijanci.....	23
Slika 4.11.	Rezultati provjere normalnosti podataka za kvarove u ljetnim i zimskim mjesecima.....	24
Slika 4.12.	Rezultati t-testa uparenih uzoraka – utjecaj vremenskih prilika .....	25
Slika 4.13.	Box & Whisker prikaz – utjecaj vremenskih prilika.....	25
Slika 4.14.	Rezultat provjere normalnosti za podatke o kvarovima ovisno o mjestu eksploatacije .....	26

---

Slika 4.15. Rezultati t-testa uparenih uzoraka – utjecaj mjesta eksploatacije .....	27
Slika 4.16. Box & Whisker prikaz – utjecaj mjesta eksploatacije.....	27
Slika 4.17. Rezultati t-testa uparenih uzoraka – prihod vozila Volvo .....	28
Slika 4.18. Box & Whisker prikaz – razlike u prihodu vozila Volvo.....	29
Slika 4.19. Rezultati t-testa uparenih uzoraka – broj kvarova kod vozila Volvo .....	30
Slika 4.20. Box & Whisker prikaz – pojava kvarova kod vozila marke Volvo .....	30
Slika 4.21. Rezultat t-testa uparenih uzoraka – prihod po kilometru za vozila Iveco .....	31
Slika 4.22. Box & Whisker prikaz – prihod po kilometru za vozila marke Iveco .....	32
Slika 4.23. Rezultat t-testa uparenih uzoraka – broj kvarova kod vozila marke Iveco .....	33
Slika 4.24. Box & Whisker prikaz – broj kvarova kod vozila Iveco.....	33
Slika 4.25. Rezultat t-testa uparenih uzoraka – troškovi popravka kod vozila marke Iveco...	34
Slika 4.26. Box & Whisker prikaz – troškovi popravka kod vozila marke Iveco .....	34
Slika 4.27. Rezultat analize korelacije.....	36
Slika 4.28. Grafički prikaz rezultata korelacijske analize .....	37
Slika 4.29. Rezultat regresijske analize .....	38
Slika 4.30. Teorijska raspodjela ABC analize [14] .....	39
Slika 4.31. Pareto dijagram ukupnih troškova popravaka .....	41
Slika 4.32. Histogram frekvencija kvarova .....	41
Slika 5.1. Osnovno sučelje desktop aplikacije .....	45
Slika 5.2. Prikaz mogućnosti aplikacije.....	45
Slika 5.3. Primjer praćenja vozila u realnom vremenu [15].....	46
Slika 5.4. TimoCom sučelje [16].....	47



**POPIS TABLICA**

Tablica 2.1.	SWOT analiza.....	8
Tablica 4.1.	Profit po prijeđenom kilometru prema vozilima .....	21
Tablica 4.2.	Tablica analize varijance .....	22
Tablica 4.3.	Podatci o pojavi kvarova ovisno o vremenskim prilikama.....	24
Tablica 4.4.	Podatci o pojavi kvarova – područje eksploatacije.....	26
Tablica 4.5.	Podatci o pojavi kvarova na vozilima marke Volvo.....	29
Tablica 4.6.	Podatci o broju kvarova i troškovima popravka za vozila Iveco.....	32
Tablica 4.7.	Podatci o prijeđenoj udaljenosti, broju kvarova i troškovima popravka .....	36
Tablica 4.8.	ABC analiza.....	40

## **POPIS KRATICA**

SWOT – *Strength, Weakness, Opportunity, Threat* – Snaga, Slabost, Prilika, Prijetnja

ANOVA – *Analysis Of Variance* – Analiza varijance

SKO – Suma kvadrata odstupanja

**POPIS OZNAKA**

<b>Oznaka</b>	<b>Jedinica</b>	<b>Opis</b>
P	kW	Snaga motora
m	t	Nosivost kamiona
$H_0$		Nulta hipoteza
$H_1$		Alternativna hipoteza
$F_0$		Teorijska kumulativna frekvencija
F		Kumulativna frekvencija uzorka
$\mu$		Očekivanje populacije
$\alpha$		Granica značajnosti
$n$		Veličina uzorka
$N$		Broj ukupnih mjerenja svih uzoraka
$k$		Stupanj slobode

## **SUMMARY**

The topic of this bachelor's thesis lays on the gathering and analysis of data collected from a specific transporting enterprise in order to obtain a clear picture of costs caused by particular features of the company's vehicles.

The initial part of the work gives an insight into the company itself, its structure and current state. After getting acquainted with the enterprise and its issues, types of possible costs that occur in every transporting company will be briefly described. As the vehicles get exploited on a daily basis, there is a big possibility that unplanned failures will occur resulting in unexpected repair costs. Further on, the analysis of data was performed, a bigger insight into the types and frequencies of certain failures was given, in order to make the company fully prepared to eliminate failures quicker. This results in a higher efficiency concerning the level of the capacity of the vehicles. In addition, several business improvements were presented, such as the digitalization of data collection through the creation of an application which allows the user to easily enter and save data for further analysis. Finally, general conclusions on the conducted research and analysis results were given.

Key words: transporting enterprise, failure, costs, transporting vehicles, business

## SAŽETAK

Tematika ovog završnog rada odnosi se na prikupljanje i analiziranje podataka prikupljenih od konkretnog autoprijevoznčkog poduzeća s ciljem dobivanja jasne slike troškova uzrokovanih pojedinim značajkama vozila.

U početnom dijelu rada pobliže je opisano samo poduzeće, njegova struktura i trenutno stanje. Nakon upoznavanja s poduzećem i problematikom s kojom se susreće, ukratko su opisane vrste mogućih troškova koji se pojavljuju u poduzećima koja se bave cestovnim transportom robe. Svakodnevna eksploatacija vozila može rezultirati pojavom ne planiranih kvarova i pratećih troškova popravka. U središnjem dijelu rada provedene su analize podataka, detaljnije su opisane vrste i frekvencija pojave pojedinih kvarova, kako bi se kvarovi što spremnije dočekali u vidu bržeg uklanjanja s ciljem efikasnijeg popunjavanja kapaciteta određene vozne jedinice. U završnom dijelu rada, ponuđeno je nekoliko prijedloga poboljšanja poslovanja, poput kreiranja aplikacije za lakši unos i spremanje podataka za daljnju analizu te opći zaključci o provedenom istraživanju i analizi.

Ključne riječi: autoprijevoznčko poduzeće, kvarovi, troškovi, transportne jedinice, poslovanje

## 1. UVOD

Cestovni prijevoz čini poveznicu između proizvodnog poduzeća i krajnjeg korisnika stoga je ključna karika u lancu vrijednosti proizvodnje. Postizanje kvalitetne, brze i cjenovno povoljne usluge postao je uvjet u suvremenom globalnom tržištu gdje su tvrtke, koje se bave uslugom prijevoza, suočene s rastućom konkurencijom i teškom trenutnom ekonomskom situacijom u gospodarstvu. Ulaganjem kontinuiranog napora, poduzetnici pokušavaju doseći maksimalnu razinu usluge kako bi zadržali dosadašnje i privukli nove klijente.

Značajan utjecaj na zadovoljstvo klijenata svakako čini cijena usluge, koju prijevoznici, pritisnuti konkurencijom ne mogu mijenjati. Iz tog razloga tvrtke se moraju okrenuti prema sebi i unutarnjom analizom prikupljenih podataka tražiti moguća poboljšanja u vidu smanjivanja ili potpune eliminacije nepotrebnih troškova. Sustavnim praćenjem i kategoriziranjem vrste kvarova po pojedinim prijevoznim jedinicama, nakon određenog vremenskog intervala, moguće je predvidjeti frekvenciju pojave određene vrste kvarova te visina troškova njihovog uklanjanja. Na temelju tih podataka moguće je znatno olakšati donošenje budućih odluka o upravljanju voznim parkom (prodaja/popravak/kupnja vozne jedinice). Uz troškove popravka, velik udio u ukupnim troškovima poduzeća nose investicijski troškovi, troškovi održavanja te eksploatacije. Kako bi se postigla optimizacija troškova, a time i maksimalan mogući profit, koji bi služio za daljnje širenje i razvijanje poduzeća, prikupljanje podataka i pravilna analiza troškova predstavlja sponu za stvaranje suvremenog, konkurentnog i uspješnog autoprijevozničkog poduzeća.

U okviru ovog završnog rada, na temelju podataka konkretnog autoprijevozničkog poduzeća, statistički će se analizirati postojeće stanje značajki vozila i odrediti povezanost istih s ukupnim troškovima poduzeća te će se na temelju dobivenih rezultata predložiti moguće poboljšanje u upravljanju voznim parkom.

## 2. PODUZEĆE „TASA d.o.o.“

„Tasa d.o.o.“ je poduzeće koje je izraslo od malog privatnog obrta obitelji Skoliber koja je počela s uslugom domaćeg i međunarodnog transporta 1992. godine. U početku se tvrtka bavila automehaničarskim poslovima i proizvodnjom te prijevozom sokova i vode. Organizacijsku strukturu tvrtke čini osmero zaposlenika, od kojih je šestero vozača, računovođa i organizator transporta, ujedno i osnivač tvrtke Stjepan Skoliber.

### 2.1. Područje djelovanja

Kako je u suvremenom tržištu potreba za kvalitetnom, brzom i povoljnom uslugom transporta postala standard, kako bi opstala na takvom tržištu, tvrtka Tasa se uz navedene atribute izrazito oslanja na fleksibilnost, kako bi stalnim i novim klijentima omogućila pravovremenu domaću i međunarodnu uslugu transporta.

Područje djelovanja po planu međunarodnog transporta odvija se u sljedećim zemljama [Slika 2.1.]:

- Austrija
- Bosna i Hercegovina
- Češka
- Italija
- Mađarska
- Poljska
- Slovenija
- Srbija
- Slovačka
- Švicarska



**Slika 2.1. Područje djelovanja u međunarodnom transportu**

Crvenom bojom na [Slika 2.1] označene su države u kojima tvrtka Tasa nudi širok spektar usluga vezanih uz transport, poput prijevoza robe (madraci, namještaj, željezne konstrukcije,...) i njihovo istovarivanje na dogovorenoj lokaciji, te uslugu selidbe iz ili u bilo koju državu označenu na gornjoj slici.

## 2.2. Vizija, misija, ciljevi i strategija

Prema definiciji, strategija je djelokrug rada i smjer kojim se kreće organizacija kroz duže vrijeme, iz čega se definira svrha proizvodne funkcije prema poslovnoj i korporativnoj strategiji [1]. Strategija i misija postavljaju se radi ostvarivanja željenih ciljeva poput održavanja visokog stupnja kvalitete ili fleksibilnosti. Imajući to na umu, Tasa svojim klijentima jamči kvalitetu, učinkovitost i pouzdanost, bez obzira je li odredište u Hrvatskoj ili u inozemstvu. U nastavku će biti riječi o misiji, ciljevima, viziji i strategiji tvrtke Tasa.

- **Misija**

Misija poduzeća je pratiti trendove i biti u mogućnosti brzo reagirati na konstantne promjene, kako bi i u budućnosti bili u stanju, na zahtjevnom globalnom tržištu, pružiti odgovarajuću i kvalitetnu ponudu, koja će osigurati rast i razvoj poslovanja na zadovoljstvo klijenata i zaposlenika poduzeća.

- **Ciljevi**

- Zadovoljenje potreba i očekivanja klijenata
- Visoka kvaliteta usluga
- Ostvarenje i povećanje profita
- Ostvarenje općeg zadovoljstva zaposlenih

- **Vizija**

Vizija poduzeća se odnosi na kontinuirano ostvarivanje svih točaka strategije koja se ne shvaća samo kao dobra taktika za uspjeh, već se prihvaća kao temeljna filozofija poslovanja.


- **Strategija**

- Konstantno obnavljanje voznog parka, te praćenje i opremanje suvremenim tehnologijama, čime se djelatnicima omogućuju kvalitetni i sigurni uvjeti za rad
- Pružanje kvalitetne, raznolike i pravovremene usluge uz održavanje konkurentnih cijena
- Ulaganje u razvoj i širenje ponude na tuzemnom i međunarodnom cestovnom prijevozu roba



### 2.3. Vozni park

Vozni park sastoji se od vozila marki Volvo, Iveco, Mercedes, Man, Citroen i Renault. Imajući na umu brigu o okolišu, sva vozila imaju minimalno EURO IV, EURO V, EEV i EURO VI motore te udovoljavaju visokim europskim ekološkim standardima. Transportne usluge koje nudi tvrtka Tasa odnose se na prijevoz robe sljedećim vrstama vozila te njihovim pripadajućim dimenzijama i karakteristikama prikazanih na [Slika 2.2.].



Slika 2.2. Vrsta, karakteristike i dimenzije vozila u floti [2]

Poduzeće u svojoj floti raspolaže s desetak vozničkih jedinica i sedam priključnih jedinica, odnosno prikolica. U sklopu ovog rada analizirati će se podaci vezani uz šest kamiona u periodu od jedne godine.

Odabrani su kamioni marki Iveco, Volvo, Man i Mercedes te će u nastavku biti opisani i prikazani fotografijom.



**Slika 2.3. Vozilo Volvo ČK-430-FF**

Kamion Volvo kupljen je polovan 2012. godine sa 180 000 prijeđenih kilometara. Ovo vozilo se pretežno koristi na području Slovenije i Austrije.

Specifikacije:

- Volvo
- Godište: 2008.
- Furgon
- Snaga: 180 kW
- Nosivost: 12 t

Specifikacije:

- Volvo
- Godište: 2013.
- Furgon
- Snaga: 180 kW
- Nosivost: 12 t



**Slika 2.4. Vozilo Volvo ČK-986-GT**

Kamion Volvo kupljen je polovan 2015. godine s 115 000 prijeđenih kilometara te su područja eksploatacije ovog vozila pretežno udaljenije zemlje poput Poljske, Češke i Švicarske.



**Slika 2.5. Vozilo Iveco ČK-320-ET**

Kamion Iveco priključen je floti 2009. godine i kupljen je nov. Koristi se za prijevoz robe u Italiji, Sloveniji, Mađarskoj i Hrvatskoj.

Specifikacije:

- Iveco Eurocargo
- Godište: 2009.
- Cerada mali
- Snaga: 135 kW
- Nosivost: 8 t

Specifikacije:

- Iveco Eurocargo
- Godište: 2011.
- Furgon
- Snaga: 180 kW
- Nosivost: 12 t



**Slika 2.6. Vozilo Iveco ČK-325-GD**

Kamion Iveco je polovno vozilo kupljeno 2015. godine s 240 000 prijeđenih kilometara te se koristi za prijevoz robe po Hrvatskoj, Sloveniji i Austriji.



**Slika 2.7. Vozilo Mercedes Atego ČK-919-FV**

Specifikacije:

- Mercedes Atego
- Godište: 2007.
- Furgon
- Snaga: 180 kW
- Nosivost: 12 t

Kamion Mercedes kupljen je kao polovno vozilo u 2012. godini s 240 000 prijeđenih kilometara. Koristi se za prijevoz robe po Austriji, Srbiji i Mađarskoj.

Specifikacije:

- MAN
- Godište: 2009.
- Cerada mali
- Snaga: 135 kW
- Nosivost: 8 t



**Slika 2.8. Vozilo MAN ČK-349-FZ**

Kamion MAN kupljen je nedavno, 2016. godine kao polovno vozilo s 480 000 prijeđenih kilometara te se isključivo koristi za prijevoz robe po Bosni i Hercegovini.

## 2.4. SWOT analiza

SWOT (eng. *Strength, Weakness, Opportunity, Threat* – Snaga, Slabost, Prilika, Prijetnja) analiza se koristi kao dio poslovnog planiranja, analize tržišta, organizacijske promjene ili u bilo kojoj situaciji koja zahtijeva strateško planiranje pri postizanju željenih ciljeva [3]. Ova analiza je vrlo korisna jer se može primijeniti za bilo koju veličinu poslovanja. Budući da analiza uzima u obzir i unutarnje i vanjske čimbenike, daje jasnu priliku za tvrtke da pobliže pogledaju na ono što rade dobro i koje strategije ili operacije moraju promijeniti. U kontekstu prijedloga poboljšanja, nužno je prvo ustvrditi početno stanje, stoga će se u nastavku rada primijeniti SWOT analiza za poduzeće Tasa.

Tablica 2.1. SWOT analiza

Unutarnji čimbenici	
SNAGE (+)	SLABOSTI (-)
<ul style="list-style-type: none"> <li>• Kvalitetni djelatnici s puno iskustva</li> <li>• Fleksibilnost</li> <li>• Većinska suradnja s renomiranim poslovnim partnerom</li> </ul>	<ul style="list-style-type: none"> <li>• Problem uvođenja tehnologije</li> <li>• Nepostojanje sustava za prikupljanje i spremanje podataka</li> </ul>
Vanjski čimbenici	
PRILIKE (+)	PRIJETNJE (-)
<ul style="list-style-type: none"> <li>• Dobar prometno-geografski položaj</li> <li>• Edukacija zaposlenika o novim tehnologijama</li> </ul>	<ul style="list-style-type: none"> <li>• Odlazak kvalificirane radne snage u inozemstvo</li> <li>• Starija životna dob zaposlenika</li> </ul>

- **Snage**

Uspješnost poduzeća uvelike ovisi o djelatnicima i njihovom načinu i pristupanju radu. Stoga su velika snaga poduzeća upravo djelatnici koji svojim iskustvom i znanjem uvelike doprinose brzom i kvalitetnoj usluzi, čineći je financijski konkurentnom na tržištu. Također, prednost malih poduzeća je fleksibilnost, odnosno mogućnost brze prilagodbe zahtjevima klijenta u vidu ponude odgovarajuće transportne jedinice u željeno vrijeme. Bazirajući visok postotak prometa sa samo jednim poslovnim partnerom u teoriji može biti prijetnja opstanku poduzeća zbog lako mogućeg prekida suradnje iz različitih razloga, no u ovom slučaju, upravo suradnja s renomiranim partnerom, osigurava visoko popunjavanje uslužnog kapaciteta te redovnog pritoka novčanih sredstava, čime partnerstvo postaje snaga poduzeća.

- **Slabosti**

Prilikom analize, vrlo se brzo primjećuje velika slabost poduzeća, a to je neadekvatno praćenje i bilježenje podataka. Svi podaci su pisani ručno i spremljeni po registratorima i ostalim oblicima pismene pohrane, te na taj način onemogućuju bilo kakvu brzu analizu postojećeg stanja ili uočavanja problema koji uzrokuje nepotrebne troškove. Nadalje, postoji problem kod eventualnog uvođenja naprednijih tehnologija praćenja podataka zbog dobne strukture zaposlenika, odnosno težeg prihvaćanja i korištenja spomenutih unaprjeđenja.

- **Prilike**

Dakako, uvođenjem edukacije prilagođene djelatnicima, uviđa se prilika za poboljšanjem pružanja usluga i jačanje unutarnjih čimbenika poduzeća, te sveukupno zadovoljstvo zaposlenika. Nadalje, prometno-geografski položaj poduzeća je izrazito povoljan (sjever Hrvatske) zbog svoje blizine državama Europske unije, Sloveniji i Mađarskoj. Iz prikaza na [Slika 2.9.] vidljivo je da poduzeće Tasa leži na dva vrlo bitna prometna koridora:

- Zapadna Europa – Crno more
- Istočna Europa i Baltik – Mediteran



Slika 2.9. Prometno-geografski položaj tvrtke Tasa


- **Prijetnje**

Vanjski čimbenici koji loše utječu na tvrtku je loša ekonomska situacija u Hrvatskoj što uzrokuje kontinuirani odlazak kvalificirane radne snage u inozemstvo, do te mjere da je nemoguće pronaći i zaposliti novog djelatnika, odnosno vozača kamiona. Također, zbog već spomenute dobne strukture djelatnika, u posljednje tri godine, dvoje djelatnika je otišlo u zasluženu mirovinu, što bez regrutiranja nove, mlađe radne snage predstavlja veliku prijetnju za daljnji rad poduzeća.

### 3. CESTOVNI PROMET I TROŠKOVI

Cestovni prijevoz je vrlo čest način prijevoza robe koji koriste dobavljači i tvrtke za isporuku narudžbi. Cijena prometne (prijevozne) usluge prezentira se korisniku u novčanom obliku, a sastoji se od troškova koje ima prijevoznik i određenog viška ovisnog o stanju na prijevoznom tržištu, odnosno o trenutnoj ponudi i potražnji [4].

Kako bi se bolje shvatio obujam cestovnog prometa, na sljedećem dijagramu biti će prikazna ukupna količina prevezenih dobara u Republici Hrvatskoj.



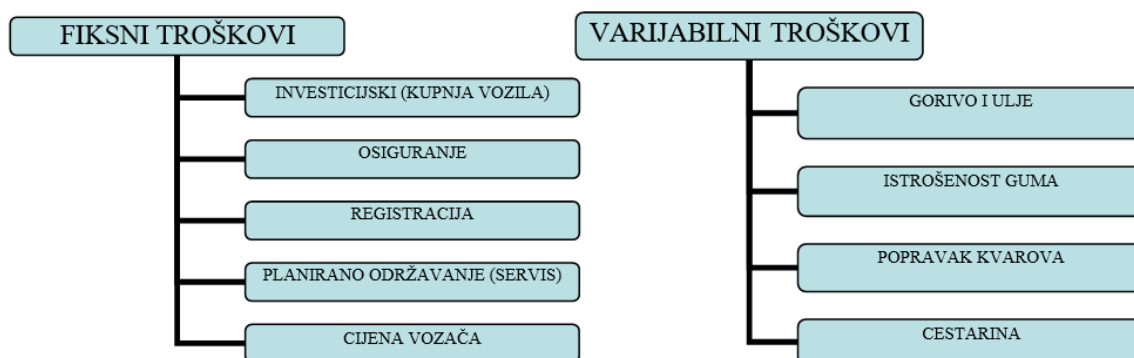
**Slika 3.1. Graf ukupne količine transportirane robe [5]**

Graf [Slika 3.1.] prikazuje ukupnu količinu prevezene robe za period od 2008. do 2016. godine u tisućama tona. Vrlo je lako uočiti da je najveća količina robe bila prevezena 2008. godine i iznosila je 110 tisuća tona te da je nakon toga prisutan opadajući trend u trajanju do 2012. godine koji se može pripisati sveopćoj financijskoj i gospodarskoj krizi koja je potresala globalno gospodarstvo.



### 3.1. Klasifikacija troškova

Profitabilnost poduzeća uvelike ovisi o transportnim troškovima jer čine značajan dio ukupnih troškova poslovanja [6]. Ukupni troškovi se najčešće dijele na dvije vrste, fiksne, na koje ne utječe broj prijeđenih kilometara vozila i varijabilne, koji se mijenjaju s obzirom na prijeđene kilometre vozila prikazane na [Slika 3.2.].



Slika 3.2. Fiksni i varijabilni troškovi

Prilikom računanja troškova prijevoza, uglavnom se uračunava samo trošak goriva, cestarina i neto plaća vozača. Međutim, transportni troškovi su mnogo kompleksniji. Najznačajnija stavka su transportna sredstva i svi oblici održavanja vozila, odnosno amortizacija vozila (kamiona), troškovi registracije, osiguranja, održavanja, ulja i guma i direktni troškovi transporta, maloprije spomenuti troškovi (goriva, cestarine, vozačeve plaće).


Ključnu ulogu u postizanju efikasnosti kod transporta, te u konačnici profitabilnosti poduzeća, igra ekonomija obujma [6]. Prilikom distribucije robe, kako bi se osigurala brza i kvalitetna usluga dostave, te uzimajući u obzir velik broj dostavnih mjesta, potrebno je imati dovoljan broj vozila. Najprisutniji trošak je upravo nedovoljno iskorištenje kapaciteta vozila uzorkovan posjedovanjem velikog broja voznih jedinica prilagođenih pojedinim klijentima i vrsti robe.

### 3.1.1. Troškovi transporta

Transport predstavlja najveći logistički gubitak. Ti gubitci se javljaju uslijed loše organizacije, nedovoljno dobrog planiranja, upravljanja i kontrole odvijanja transportnih procesa te u konačnici i lošeg korištenja transportnih sredstava [7].

Promatrajući ukupne troškove transporta, dominantne su tri kategorije troškova:

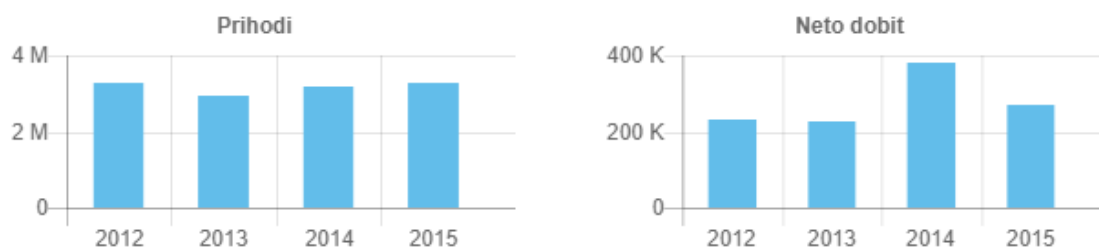
- Troškovi potrošnje energije (45-55%)
- Troškovi održavanja (oko 25%)
- Troškovi radne snage (oko 20%)



Slika 3.3. Tortni prikaz troškova transporta

### 3.1.2. Financijsko izvješće promatranog poduzeća


Usporedimo li podatke o prihodima i neto dobiti poduzeća Tasa na [Slika 3.4.] izraženih u novčanim jedinicama, vidljivo je da troškovi transporta i popravaka itekako utječu na konačnu neto dobit poduzeća, odnosno da uz približno konstantan prihod, neto dobit varira ovisno o spomenutim troškovima.



Slika 3.4. Bonitetni izvještaj za poduzeće „Tasa d.o.o.“ [8]

### 3.2. Cestovni promet

Sveukupni prijevoz robe ostvaruje se korištenjem cesta, mora i/ili plovnih rijeka te željeznica. S ciljem naglaska na važnost cestovnog prometa, prikazati će se podatci ukupnog prijevoza robe prema te tri kategorije na području Europske unije.



**Slika 3.5. Graf kumulativnih vrijednosti pojedine vrste transporta**

Iz prikazanog grafa za period od 2006. do 2015. godine za države članice Europske unije, vidljivo je da se oko 76% sveukupnog prometa robe odvija cestovno [5].

#### 3.2.1. Prednosti cestovnog prometa

Neke od prednosti cestovnog prometa su [9]:

- Isplativ
- Brza dostava
- Pogodan za kratke relacije (domaći i međunarodni prijevoz)
- Pogodan za prijevoz svježih namirnica (voće i povrće)
- Lako praćenje transportnih jedinica
- Olakšana komunikacija s vozačem

#### 3.2.2. Nedostaci cestovnog prometa

Neki od nedostataka cestovnog prometa su [9]:

- Ovisi o zastojsima u prometu
- Transportna jedinica je podložna kvarovima
- Lako moguće oštećenje robe uzrokovano nemarnom vožnjom
- Utjecaj vanjskih vremenskih prilika
- Regulacija prometa može uzrokovati zakašnjenja

## 4. ANALIZA PODATAKA


U današnje vrijeme statistika igra važnu ulogu u svim ljudskim djelatnostima, dok su sposobnost donošenja kvalitetnih zaključaka i interpretacije rezultata neizostavan dio inženjerske i znanstvene prakse. Prilikom prikupljanja podataka iz autoprijevoznčkog poduzeća Tasa, naglasak je bio na podatke vezane uz promet, troškove kategorizirane prema vrsti i broju nastalih kvarova po određenim voznim jedinicama za period od 12 mjeseci, odnosno za 2017. godinu. Svrha ovog rada je analiza utjecaja pojedinih voznih karakteristika vozila na stvaranje troškova uzrokovanih kvarovima, ispitivanje efikasnosti pojedinih vozila te provjeriti postoji li korelacija između vrste vozila, vremenskih uvjeta, područja djelovanja i pojave kvarova.

Statističke metode poput deskriptivne statistike, analize varijanci, ABC analize te korelacije i regresije, biti će korištene s ciljem donošenja zaključaka o promatranoj problematici.

### 4.1. Provjera ujednačenosti vozila


Svaka organizacija teži što ujednačenijem proizvodnim tokom, odnosno teži eliminaciji „uskog grla“ koje predstavlja operaciju s najduljim vremenom trajanja. Na isti način poduzeća koja pružaju transportne usluge mogu koristiti tu sintagmu tako da shvate koje prijevozne jedinice ostvaruju veće troškove, odnosno manji prihod za unaprijed određeni put što može poslužiti kao temelj za daljnje djelovanje.

Kako bi se dobio opći dojam o promatranim podacima, za početak će se prikazati dijagram [Slika 4.1] svih vozila u floti s obzirom na profit koji ostvaruju po mjesecima. Prihodi će biti prikazani u virtualnim novčanim jedinicama. (Prihod = Promet- Ukupni troškovi)



**Slika 4.1 Graf prihoda za sva vozila po mjesecima**

Na ovom naizgled konfuznom dijagramu, vidljivo je da sva vozila održavaju konstantan, ujednačen trend prihoda kroz godinu osim vozila ČK-320-ET, na grafu prikazanog svijetlo plavom bojom, gdje se uočava pad prihoda prema kraju godine. Iz krivulje navedenog vozila, može se pretpostaviti da je ta vozna jedinica bila većim dijelom silazne putanje krivulje, nedostupna za rad, te je zato ostvarila manje prihode. Međutim, takav prikaz podataka ne daje nam stvarno stanje prihoda jer u obzir nije uračunata vrlo bitna stavka, odnosno broj odrađenih prijevoza, tj. prijeđenih kilometara, što je prikazano na [Slika 4.2.].



**Slika 4.2 Graf prihoda po kilometru za sva vozila po mjesecima**

Iz [Slika 4.2.] je vidljivo da prije spomenuto vozilo ČK-320-ET, označeno svijetlo plavom bojom, ipak ostvaruje ujednačen prihod po prijeđenom kilometru, izuzev srpnja i prosinca, gdje se može pretpostaviti da je došlo do većih troškova popravka uzrokovanih pojavom kvara. Također, vidljiv je značajan skok prihoda za vozilo ČK-325-GD, označenog narančastom bojom na dijagramu. Tako velika razlika prihoda u odnosu na preostala vozila može se prepisati prijevozu delikatnije ili skuplje robe, prijevozom dogovorenim u posljednji trenutak, dodatnom uslugom utovarivanja ili istovarivanja, odnosno više plaćenom prijevozu na kraće relacije čime u prvi plan dolazi snaga poduzeća – fleksibilnost.

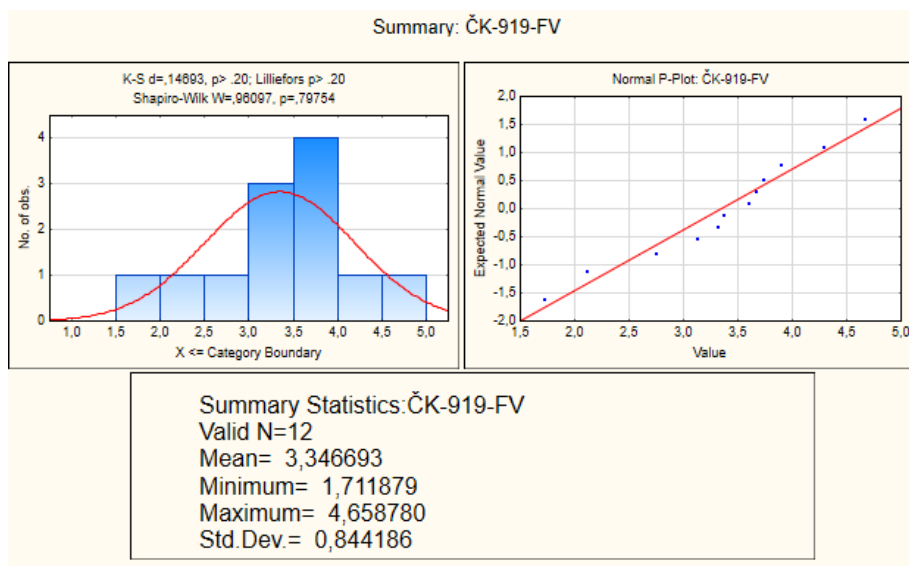
## 4.2. Analiza varijanci

Analiza varijance (ANOVA) je zbirka statističkih modela i njihovih povezanih postupaka za analizu razlika među skupinama. Nadalje, ANOVA je jedna od temeljnih metoda određivanja značajnosti utjecaja promatranih parametara (faktora) na proces [10]. Kako bi se ova metoda mogla primijeniti, potrebno je provjeriti normalnost distribucije promatranih podataka.

### 4.2.1. Provjera normalnosti podataka

Jedna od temeljnih pretpostavka za provedbu analize varijanci je pretpostavka normalnosti promatrane varijable. Ukoliko se podatci pokoravaju normalnoj razdiobi, upotrebom statističkog zaključivanja (eng. *Statistical inference*) moguće je dobivene rezultate iz uzorka primijeniti pri donošenju zaključaka o populaciji. U tu svrhu provjeriti će se normalnost podataka, odnosno ponaša li se prihod po kilometru prema normalnoj razdiobi za svaki kamion posebno. Odluku o normalnosti raspodjele podataka donositi će se s obzirom na vrijednost P parametra. Ukoliko je on veći od 0.05, odnosno vrijednosti  $\alpha$  pogreške, tada se skup podataka smatra normalno distribuiran. Također, za analizu će se koristiti Shapiro-Wilk test. Za analiziranje i dobivanje rezultata koristi se računalni paket *Statistica 2017*.


➤ **Vozilo ČK-919-FV**



**Slika 4.3. Provjera normalnosti vozila ČK-919-FV**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-919-FV ponašaju prema normalnoj razdiobi.

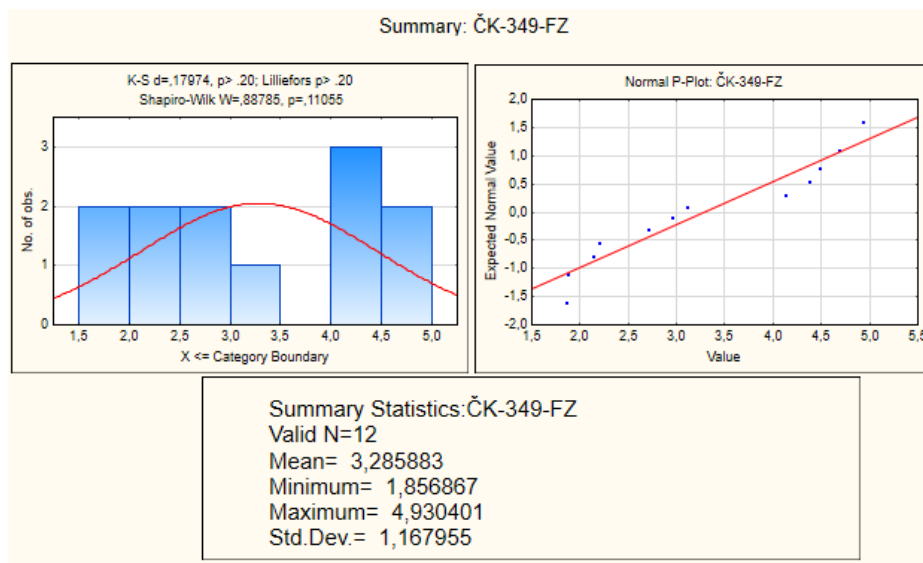
➤ **Vozilo ČK-986-GT**



**Slika 4.4. Provjera normalnosti vozila ČK-986-GT**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-986-GT ponašaju prema normalnoj razdiobi.


➤ **Vozilo ČK-349-FZ**



**Slika 4.5. Provjera normalnosti vozila ČK-349-FZ**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-349-FZ ponašaju prema normalnoj razdiobi.

➤ **Vozilo ČK-430-FF**

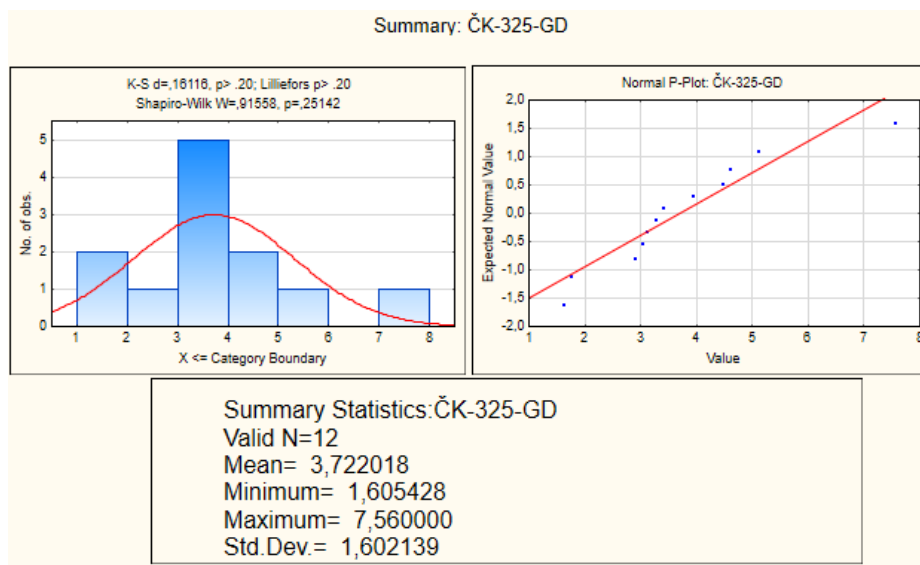


**Slika 4.6. Provjera normalnosti vozila ČK-430-FF**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-430-FF ponašaju prema normalnoj razdiobi.




➤ **Vozilo ČK-325-GD**



**Slika 4.7. Provjera normalnosti vozila ČK-325-GD**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-325-GD ponašaju prema normalnoj razdiobi.

➤ **Vozilo ČK-320-ET**



**Slika 4.8. Provjera normalnosti vozila ČK-320-ET**

Nakon provedene provjere, zaključuje se da se prikupljeni podatci za vozilo ČK-320-ET ponašaju prema normalnoj razdiobi.

Kao rezultat provedene provjere normalnosti podataka dobiva se da je raspodjela profita po kilometru normalno distribuirana čime je potvrđen preduvjet za provođenje analize varijanci.

#### 4.2.2. ANOVA

Analiza varijance je postupak usporedbe više uzoraka pri čemu svaki uzorak predstavlja osnovni skup (populaciju). U tehničkim i proizvodnim uvjetima analiza varijance predstavlja postupak provjere djelovanja promjene stanja nekog faktora na mjerenu vrijednost, odnosno rezultat. Analizom varijance provjeravaju se promjene aritmetičkih sredina uzoraka, čime se potvrđuje ili demantira jednakost očekivanih vrijednosti osnovnog skupa [10]. Za analizu varijance koristiti će se sljedeći podatci prikazani u [Tablica 4.1.].

**Tablica 4.1. Profit po prijeđenom kilometru prema vozilima**

	ČK-919-FV	ČK-986-GT	ČK-430-FF	ČK-349-FZ	ČK-325-GD	ČK-320-ET
Siječanj	2,10	3,29	3,34	4,37	4,45	3,47
Veljača	4,66	1,54	3,37	2,13	3,10	3,59
Ožujak	3,36	2,21	1,37	2,20	7,56	3,14
Travanj	3,66	2,63	3,10	1,88	3,01	2,97
Svibanj	4,28	4,13	1,65	2,95	3,41	1,95
Lipanj	3,73	2,37	5,86	4,48	4,58	2,13
Srpanj	2,75	4,83	4,04	4,12	2,89	-0,20
Kolovoz	3,60	3,50	4,95	1,86	1,61	2,52
Rujan	3,12	5,18	4,10	2,71	5,11	3,09
Listopad	3,90	4,46	4,26	4,93	3,25	1,78
Studeni	3,30	3,36	3,36	3,11	3,94	2,94
Prosinac	1,71	4,29	4,03	4,69	1,75	0,93

Prije provedbe same analize, postaviti će se dvije osnovne hipoteze:  $H_0$  i  $H_1$ .

- $H_0$  :  $\mu_1 = \mu_2 = \mu_3 = \mu_4 = \mu_5 = \mu_6$  – nema značajnih razlika u prihodima između kamiona
- $H_1$  : barem jedan  $\mu_j \neq \mu_{j+k}$  – postoje značajne razlike u prihodima barem jednog kamiona


Ideja analize varijance sastoji se u razdvajanju varijabilnosti mjerenog - varijancom na dva dijela: varijabilnost među uzorcima i varijabilnost unutar uzorka. Ovaj drugi dio varijabilnosti često se naziva rezidualnom varijabilnošću (ostatak) [11].

Nakon provedene analize uz pomoć programskog paketa *Statistica 2017.* i modula *ANOVA*, dobiveni su sljedeći rezultati:

**Tablica 4.2. Tablica analize varijance**

Izvor varijacije	SKO	Stupanj slobode	Srednji kvadrat odstupanja	F <sub>računski</sub>	F <sub>očitano</sub>
Faktor (prihod po km)	14,3521	5	2,8704	1,9706	2,36
Ostatak	96,1358	66	1,4566	-	
Ukupno	110,4879	71	-	-	

Ukupna varijabilnost podataka prikazana je u ćeliji na presjecištu četvrtog retka i drugog stupca i predstavlja ukupnu sumu kvadrata odstupanja ( $SKO_{\text{ukupno}}$ ) [12]. Ukupna suma kvadrata odstupanja rezultat je varijabilnosti između uzoraka (Faktor) i varijabilnosti unutar uzoraka (Ostatak) što se grafički može prikazati prema [Slika 4.9.].



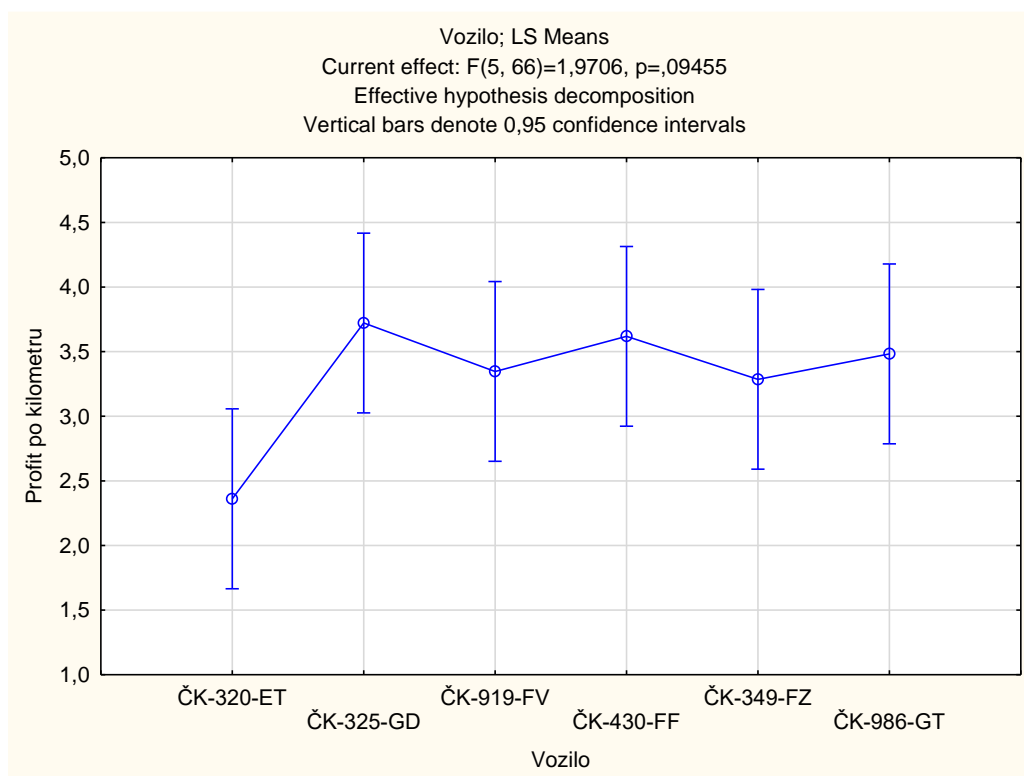
**Slika 4.9. Prikaz ukupne sume kvadrata odstupanja [10]**

Za provjeru hipoteza koristi se F-test na način da se dobivena veličina F koja se ponaša po F razdiobi uspoređi s teorijskom vrijednošću  $F_0$  koja ovisi o broju stupnjeva slobode. Stupnjevi slobode dobivaju uz pomoć broja podataka prema formuli:

- $k_b = n_1 - 1$
- $k_n = n_2 - k_b - 1$

Nulta hipoteza  $H_0$  koja govori da ne postoje značajne razlike između prihoda kamiona prihvaća se ukoliko je izračunata vrijednost  $F$  manja ili jednaka od teorijske  $F_0$  ( $F \leq F_0$ ), a ne prihvaća se ukoliko je  $F > F_0$ , dakako uz određenu vjerojatnost  $\alpha$  [12].

U slučaju usporedbe varijanci šestero kamiona, prihvaća se nulta hipoteza  $H_0$  jer je dobivena računaska vrijednost  $F$  manja od očitane  $F_0$  ( $1,9706 < 2,36$ ). Iz toga slijedi zaključak da nema značajnih razlika u prihodima po kilometru između testiranih vozni jedinica uz vjerojatnost od 95% i da grupe, odnosno kamioni pripadaju istoj populaciji. Grafički prikaz dobivenih rezultata nalazi se na [Slika 4.10.].



**Slika 4.10. Grafički prikaz provedene analize varijanci**

Na [Slika 4.10.] prikazan je dijagram, na kojem su naznačene vrijednosti prihoda po kilometru za svako vozilo. Vidljivo je da kamion ČK-320-ET odskače od ostalih, te bi se dalo naslutiti da postoji značajna razlika između tog vozila i ostalih iz flote, no provedbom F-testa, dokazano je da nema značajnih razlika između varijanci, odnosno da sva vozila pripadaju jednoj populaciji.

### 4.3. T-test uparenih uzoraka

T-distribucija otkrivena je 1908. godine od strane kemičara Williama Sealy Gosseta, zaposlenika Guinness-ove pivovare u Dublinu. Zbog politike pivovare, Gosset je objavio svoje otkriće pod pseudonimom Student [11].

Studentov t-test uparenih uzoraka koristi se za uzorke manje od 30 i uz pretpostavku da su varijance oba osnovna skupa jednake i da su promatrani podatci normalno distribuirani.


#### 4.3.1. Utjecaj vremenskih prilika na pojavu kvarova

Koristeći se t-testom uparenih uzoraka, provjeriti će se imaju li vremenske prilike, odnosno temperature u određenim periodima godine, utjecaj na pojavu kvarova kod voznih jedinica. Podatci koji će se koristiti za testiranje prikazani su na sljedećoj [Tablica 4.3.].

**Tablica 4.3. Podatci o pojavi kvarova ovisno o vremenskim prilikama**

Kamion	Br. kvarova u ljetnim mjesecima	Br. kvarova u zimskim mjesecima
ČK-320-ET	2	9
ČK-325-GD	5	2
ČK-919-FV	4	7
ČK-430-FF	4	5
ČK-349-FZ	5	7
ČK-986-GT	3	4
Suma	23	34

Kako bi se ispunio preduvjet normalnosti podataka za uspješno provođenje t-testa uparenih uzoraka, potrebno je provjeriti dane podatke. Rezultati provjere normalnosti distribucije podataka prikazani su na [Slika 4.11].



**Slika 4.11. Rezultati provjere normalnosti podataka za kvarove u ljetnim i zimskim mjesecima**

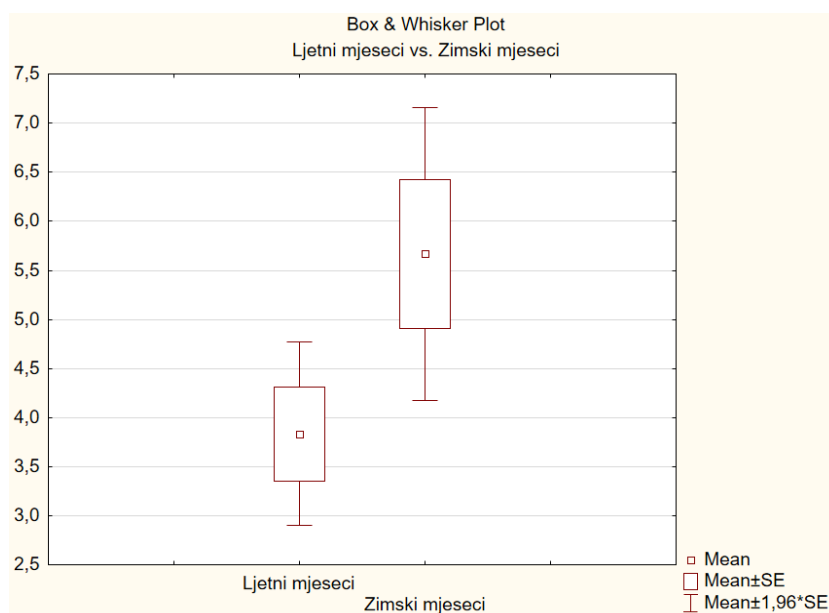
Nakon provedene provjere normalnosti podataka zaključuje se da su promatrani podatci normalno distribuirani te da je time ispunjen preduvjet za provođenje Studentova t-testa.

Prilikom sumiranja svih kvarova kamiona po određenim grupama, iz tablice je vidljivo da se više kvarova pojavilo u zimskim mjesecima. Korištenjem t-testa utvrditi će se jesu li pojave kvarova u ljetnim i zimskim mjesecima značajno različite. Rezultati t-testa uparenih uzoraka prikazani su na [Slika 4.12.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at $p < ,05000$										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
Ljetni mjeseci	3,833333	1,169045								
Zimski mjeseci	5,666667	1,861899	6	-1,833333	2,562551	-1,75245	5	0,140080	-4,52257	0,855899

**Slika 4.12. Rezultati t-testa uparenih uzoraka – utjecaj vremenskih prilika**

Uspoređujući aritmetičke sredine obaju uzoraka (*Mean*), vidljivo je da se u prosjeku u zimskim mjesecima javljaju dva kvara više, no na temelju aritmetičke sredine ne možemo donijeti konačnu odluku o značaju vremenskih prilika na kvarove. Iz tog razloga promatra se P vrijednost. Ukoliko je P vrijednost manja od 0.05, odnosno manja od vrijednosti  $\alpha$  greške, postoje značajne razlike između aritmetičkih sredina uzoraka, a samim time i značajnih razlika u pojavnosti kvarova ovisno o vremenskim prilikama kroz godinu. U ovom slučaju, zaključak je da pojava kvarova ne ovisi značajno o vremenskim prilikama kroz godinu, odnosno o ljetnim i zimskim mjesecima. Za vizualni prikaz dobivenih rezultata za sve analize t-testa uparenih uzoraka koristiti će se Box & Whisker Plot.



**Slika 4.13. Box & Whisker prikaz – utjecaj vremenskih prilika**

Na Box & Whisker dijagramu kvadratić unutar kutije (*Box*) predstavlja aritmetičku sredinu, kutija predstavlja sumu aritmetičke sredine i standardne pogreške, dok brkovi (*Whisker*) predstavljaju područje pojavnivosti s 90-95% sigurnošću. Na prikazanom dijagramu vidljive su razlike kod aritmetičkih sredina, no ne dovoljno da bi bile značajne.

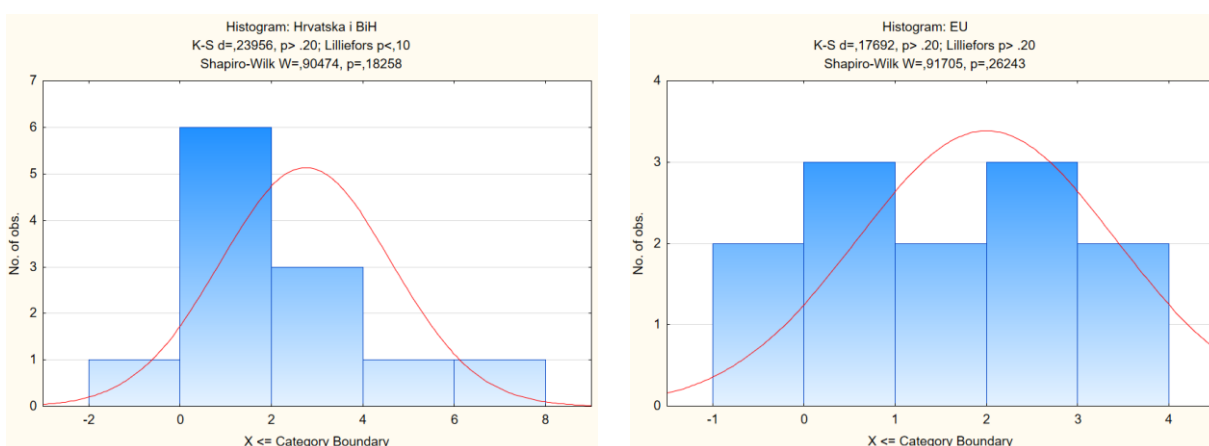
#### 4.3.2. Utjecaj područja eksploatacije na pojavu kvarova

Na isti način korištenjem t-testa uparenih uzoraka provjeriti će se ima li područje eksploatacije voznih jedinica utjecaja na pojavu kvarova kod istih. Kod područja eksploatacije može se uzeti u obzir stanje cesta, postojanje razvijene mreže autocesta, te prometna prohodnost, odnosno učestalost zaustavljanja i kočenja te ponovnog ubrzanja. Kao razliku područja djelovanja uzeta su područja Hrvatske i Bosne i Hercegovine te zemalja Zapadne Europe i Europske unije (Švicarska, Slovenija, Austrija, Italija, Poljska, Češka, Slovačka, Mađarska). Prikupljeni podatci nalaze se u [Tablica 4.4.] raspoređeni po mjesecima.

**Tablica 4.4. Podatci o pojavi kvarova – područje eksploatacije**

Hrvatska i BiH	7	2	2	4	5	0	2	2	3	2	3	1
EU	4	0	4	1	3	2	1	2	3	0	3	1

U svrhu dokazivanja značajnosti područja eksploatacije, izvodi se t-test uparenih uzoraka, no najprije se provjerava adekvatnost podataka, odnosno njihova normalnost.




**Slika 4.14. Rezultat provjere normalnosti za podatke o kvarovima ovisno o mjestu eksploatacije**

Prilikom provjere normalnosti podataka, utvrđeno je da se kvarovi ovisni o mjestu eksploatacije vozila ponašaju po normalnoj distribuciji što pokazuje parametar P koji je iznosom veći od 0.05, odnosno  $\alpha$  greške. Rezultati provedenog t-testa prikazani su na [Slika 4.15.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at p < ,05000										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
Hrvatska i BiH	2,750000	1,864745								
EU	2,000000	1,414214	12	0,750000	1,712255	1,517342	11	0,157382	-0,337915	1,837915

**Slika 4.15. Rezultati t-testa uparenih uzoraka – utjecaj mjesta eksploatacije**

Prilikom usporedbe aritmetičke sredine vrlo lako bi se došlo do zaključka da se na području Hrvatske i BiH pojavljuje više kvarova nego na cestama država Europske unije. Međutim, usporedbom P parametra s vrijednosti 0.05 donosi se zaključak da nema značajnih razlika kod pojavljivosti kvarova kod kamiona korištenih na različitim mjestima eksploatacije. Također treba naglasiti da je uzorak veći, rezultat bi bio precizniji i relevantniji. Grafički prikaz dobivenih rezultata nalazi se na [Slika 4.16.].



**Slika 4.16. Box & Whisker prikaz – utjecaj mjesta eksploatacije**

Na slici je vidljivo da postoje razlike kod srednjih vrijednosti kvarova, no također je vidljivo da te razlike nisu značajne.



### 4.3.3. Usporedba vozila marke Volvo

U suvremenom globalno tržištu, i sve većim širenjem konzumerizma, ljudi i poduzeća posjeduju stvari jednakih marki i istih pretpostavljenih mogućnosti. Dakako, postavlja se pitanje kvalitete i jesu li stvari, u ovom slučaju kamioni, istih marki zapravo jednako kvalitetni i pružaju li željeni izlaz (*Output*). U ovom slučaju usporediti će se vozne jedinice marki Volvo, iste snage motora, maksimalne nosivosti, no različitih godina proizvodnje (2008. i 2013.).


#### 4.3.3.1. Usporedba ostvarenog prihoda po kilometru (Volvo)

Kako bi odredili postoje li značajne razlike između vozila, usporediti će se prihodi ostvareni po prijeđenom kilometru puta. Broj kvarova, odnosno troškovi popravaka imaju indirektan utjecaj na rezultate analize iz razloga što se prihod dobiva oduzimanjem svih troškova od ukupno ostvarenog prometa vozila. Rezultati t-testa vidljivi su na [Slika 4.17.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at $p < .05000$										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
ČK-986-GT	3,482554	1,135186								
ČK-430-FF	3,618523	1,249949	12	-0,135969	1,548794	-0,304113	11	0,766717	-1,12003	0,848089

**Slika 4.17. Rezultati t-testa uparenih uzoraka – prihod vozila Volvo**

Rezultati provedene analize pokazuju da nema prevelike razlike između srednjih vrijednosti prihoda za 2017. godinu između vozila istih voznih karakteristika i različitih godišta. U prilog tome ide i visoka vrijednost P parametra u odnosu na  $\alpha$  vrijednost 0.05. Zaključak ove provjere je da bez obzira na razliku od pet godina u eksploataciji, vozila marke Volvo, istih voznih karakteristika ne ostvaruju značajne razlike u prihodu. U prilog tome ide i grafički prikaz Box & Whisker dijagrama prikazanog na [Slika 4.18.].



**Slika 4.18. Box & Whisker prikaz – razlike u prihodu vozila Volvo**

Prilikom analiziranja grafičkog prikaza značajnosti razlika prihoda kod vozila marke Volvo, vidljivo je da se aritmetičke sredine prihoda po prijeđenom kilometru razlikuju vrlo malo. Također je vidljivo da je kod „mlađeg“ vozila interval očekivanja nešto manji u odnosu na „starije“ vozilo.

#### 4.3.3.2. Usporedba pojave kvarova (Volvo)

Kako bi se odredile razlike između dvaju vozila, pristupa se usporedbi pojave kvarova kroz godinu. S obzirom na rezultat prethodne analize prihoda po kilometru, pretpostavka je da se vozila neće značajno razlikovati s obzirom na broj pojava kvarova.

**Tablica 4.5. Podatci o pojavi kvarova na vozilima marke Volvo**


Mjesec	ČK-986-GT	ČK-430-FF
Siječanj	1	2
Veljača	1	1
Ožujak	0	0
Travanj	0	0
Svibanj	0	1
Lipanj	1	1
Srpanj	0	0
Kolovoz	2	2
Rujan	0	0
Listopad	2	1
Studen	0	1
Prosinac	0	0

Promatrajući podatke iz [Tablica 4.5.] vidljivo je da su se kod „starijeg“ vozila ČK-430-FF pojavila dva kvara više nego kod vozila ČK-986-GT. Rezultati provedenog t-testa nalaze se na [Slika 4.19.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at $p < .05000$										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
ČK-986-GT kvarovi	0,583333	0,792961								
ČK-430-FF kvarovi	0,750000	0,753778	12	-0,166667	0,577350	-1,00000	11	0,338801	-0,533498	0,200164

**Slika 4.19. Rezultati t-testa uparenih uzoraka – broj kvarova kod vozila Volvo**

Analizom rezultata uviđa se razlika kod aritmetičkih sredina od približno 0.2 kvara po vozilu kroz godinu. Dokaz ne postojanja značajnosti razlika između vozila marki Volvo je i iznos P parametra koji iznosi 0.3388, odnosno veći je u odnosu na usporednu veličinu 0.05. Grafički prikaz rezultata testa prikazan je na [Slika 4.20.].



**Slika 4.20. Box & Whisker prikaz – pojava kvarova kod vozila marke Volvo**

Iz dijagrama je vidljiva mala razlika između srednjih veličina uzorka, te se potvrđuje konstatacija o ne postojanju značajne razlike između vozila u smislu pojave kvarova.

Na temelju provedenih analiza zaključuje se da su vozila marke Volvo ujednačena što se tiče prihoda po kilometru i broja pojavljenih kvarova. Dakako, treba naglasiti da je uzorak vrlo mali, te da ova analiza označava dobar početak za daljnje prikupljanje podataka kroz vrijeme i ponovnu usporedbu.

#### 4.3.4. Usporedba vozila marke Iveco modela Eurocargo

Na isti način usporediti će se vozila marke Iveco istog modela Eurocargo. U ovom slučaju vozila nemaju istu snagu i maksimalnu nosivost, odnosno vozilo ČK-320-ET je kupljeno novo 2009. godine sa snagom motora od 135 kW i maksimalnom nosivošću 8 tona, dok je vozilo ČK-325-GD kupljeno 2015. godine pri starosti od četiri godine sa snagom motora 180 kW i maksimalnom nosivošću 12 tona. Ispitati će se razlike u prihodima i broju pojavljenih kvarova.

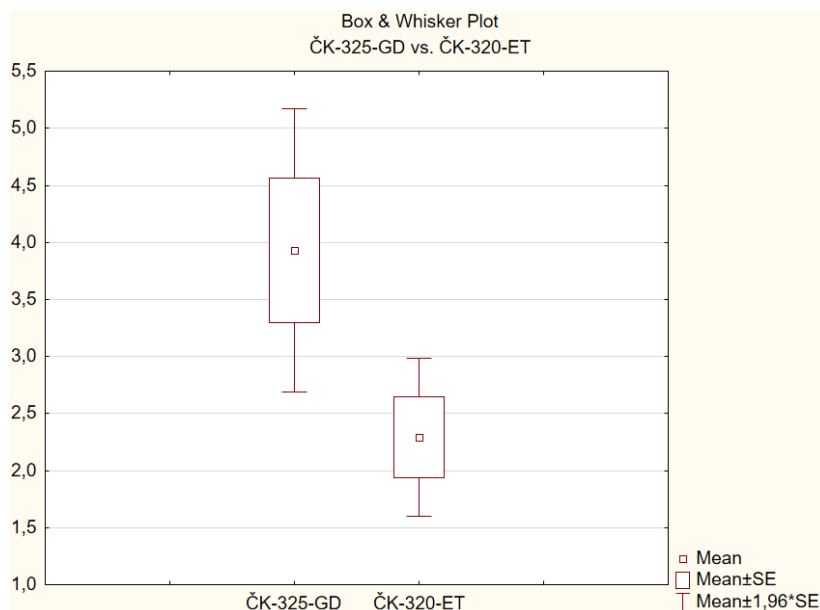
##### 4.3.4.1. Usporedba prihoda po kilometru (Iveco)

Kako bi se odredilo postojanje značajnih razlika u prihodu po kilometru koriste se podaci iz [Tablica 4.1.] te se primjenjuje t-test uparenih uzoraka. Rezultati provedenog testa vidljivi su na [Slika 4.21.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at $p < ,05000$										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
ČK-325-GD	3,930505	2,198698								
ČK-320-ET	2,294644	1,226349	12	1,635861	2,030102	2,791382	11	0,017543	0,345996	2,925726

**Slika 4.21. Rezultat t-testa uparenih uzoraka – prihod po kilometru za vozila Iveco**

Nakon provedenog testa, crvena boja podataka indicira na postojanje značajnih razlika u prihodu po kilometru za vozila marki Iveco. Prilikom usporedbe srednjih vrijednosti, vidljivo je da u prosjeku vozilo ČK-320-ET ostvaruje oko 1.7 novčanih jedinica manje po kilometru od vozila ČK-325-GD. Značajnost razlike dokazuje i vrijednost P parametra koja je manja od granice 0.05. Iz ovog rezultata t-testa zaključuje se da definitivno postoje razlike u prihodima po kilometru između vozila marke Iveco. Međutim, potrebno je u obzir uzeti da zbog veće nosivosti vozilo ČK-325-GD ima mogućnost prijevoza više robe, čime je i sama cijena prijevoza veća, no s povećanjem nosivosti i snage motora, također rastu i eksploatacijski troškovi i troškovi osiguranja te registracije. Značajnost razlike također je vidljiva i na [Slika 4.22.].



**Slika 4.22. Box & Whisker prikaz – prihod po kilometru za vozila marke Iveco**

Iz navedenog dijagrama, vidljivo je da postoji izražena razlika između srednjih vrijednosti prihoda po kilometru. Također je vidljivo i da interval s vjerojatnošću pojave određene količine prihoda od 90 do 95% za kamion ČK-320-ET je na nižim vrijednostima i gotovo nema preklapanja s intervalom kamiona ČK-325-GD čime se potvrđuje značajna razlika u prihodima za vozila marke Iveco.

#### 4.3.4.2. Usporedba pojave kvarova (Iveco)

U sljedećoj tablici prikazani su podatci o broju kvarova na vozilima marke Iveco, te troškovi popravka tih kvarova.

**Tablica 4.6. Podatci o broju kvarova i troškovima popravka za vozila Iveco**


Mjesec	ČK-320-ET	ČK-325-GD	ČK-320-ET	ČK-325-GD
-	Br. kvarova	Br. kvarova	Trošak popravka [N.J.]	Trošak popravka [N.J.]
Siječanj	3	1	1.252,23	515,36
Veljača	2	0	1.164,34	0
Ožujak	0	0	0	0
Travanj	0	0	0	0
Svibanj	1	2	2.732,88	2.495,11
Lipanj	0	0	0	0
Srpanj	1	1	3.782,95	472,21
Kolovoz	0	2	0	1.696,13
Rujan	0	0	0	0
Listopad	0	0	0	0
Studen	1	0	1.389,10	0
Prosinac	3	1	6.865,61	1.568,64

Razlog značajnih razlika u prihodima vozila iste marke potrebno je potražiti u broju kvarova. No, nije svaki kvar isti, odnosno nije cijena svakog popravka ista, stoga će se u svrhu što kvalitetnije analize, u nastavku provjeriti postoje li i značajne razlike kod pojave kvarova i troškova popravka istih, kako bi se pokušao odrediti jedan od razloga značajne razlike u prihodima. Rezultat analize broja kvarova prikazan je na [Slika 4.23.].

T-test for Dependent Samples (Spreadsheet21)										
Marked differences are significant at $p < ,05000$										
Variable	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
ČK-325-GD kvarovi	0,583333	0,792961								
ČK-320-ET kvarovi	0,916667	1,083625	12	-0,333333	1,614330	-0,715282	11	0,489339	-1,35903	0,692363

**Slika 4.23. Rezultat t-testa uparenih uzoraka – broj kvarova kod vozila marke Iveco**

Nakon provedenog testa utvrđeno je da ne postoji značajna razlika kod pojave kvarova kod vozila marke Iveco. Uspoređujući aritmetičke sredine uzoraka, vidljiva je veća vrijednost kod vozila ČK-320-ET, no pojava kvara na tom vozilu nije značajno različita od pojave kvara na vozilu ČK-325-GD. Vizualizacija navedene provjere prikazana je na [Slika 4.24.].



**Slika 4.24. Box & Whisker prikaz – broj kvarova kod vozila Iveco**

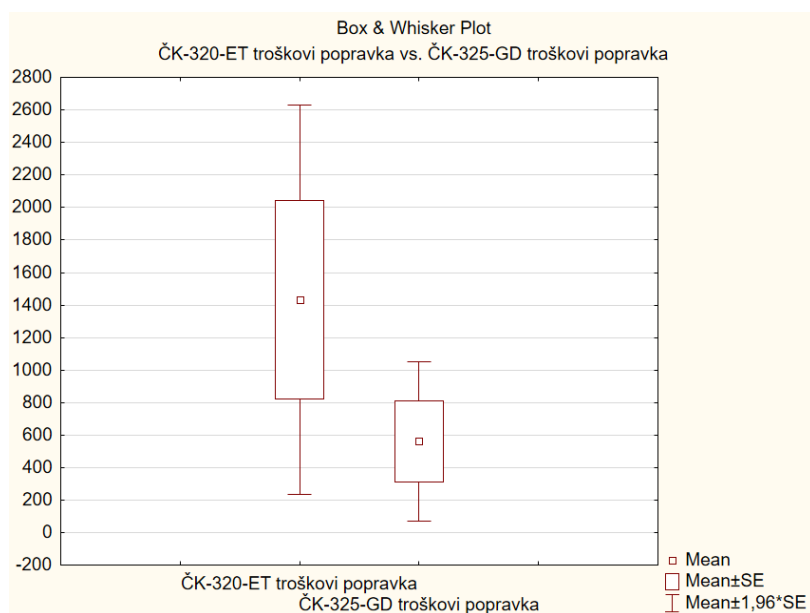
Iz dijagrama je vidljiva razlika između srednjih vrijednosti, te da je varijacija broja kvarova kod vozila ČK-320-ET veća u odnosu na vozilo ČK-325-GD, no zaključak je da nije dovoljno velika razlika da bi bila značajna.

Kako bi dobili što precizniji rezultat analize, slijedi provjera značajnosti razlike kod troškova popravka tih kvarova. Rezultat provedenog testa nalazi se na [Slika 4.25.].

Variable	T-test for Dependent Samples (Spreadsheet21) Marked differences are significant at $p < ,05000$									
	Mean	Std.Dv.	N	Diff.	Std.Dv. Diff.	t	df	p	Confidence -95,000%	Confidence +95,000%
ČK-320-ET troškovi popravka	1432,259	2113,870								
ČK-325-GD troškovi popravka	562,288	866,426	12	869,9717	1826,530	1,649943	11	0,127189	-290,550	2030,494

**Slika 4.25. Rezultat t-testa uparenih uzoraka – troškovi popravka kod vozila marke Iveco**

Iz rezultata provedenog testa uočljiva je velika razlika u prosječnoj cijeni popravka kvara. No s obzirom na frekvenciju pojave kvara, rezultat t-testa je da ne postoji značajna razlika u troškovima popravka nastalih kvarova. Dakako, u obzir treba uzeti raspoloživu količinu podataka, no unatoč tome vidljivo je da je vrijednost P parametra dosta niska, i vrlo blizu granice od 0.05. Bolji prikaz odnosa troškova popravka dobiva se grafičkom vizualizacijom navedenog predmeta analize.



**Slika 4.26. Box & Whisker prikaz – troškovi popravka kod vozila marke Iveco**

Iz priloženog dijagrama vidljiva je razlika aritmetičkih sredina uzoraka (kvadratići unutar kutije) i na prvu izgleda da postoji značajna razlika kod troškova popravaka za ta dva kamiona, no detaljnijom analizom dolazi se do suprotnog zaključka.

Zanimljiva je usporedba između kamiona ČK-320-ET koji je kupljen nov i stariji je samo dvije godine od „suparnika“. Za očekivati je da će vozilo, koje je pod stalnom kontrolom i

redovitim održavanjem za vrijeme cijelog životnog (radnog) vijeka od strane jednog poduzeća, ostvarivati manju pojavu kvarova, ujedno i ostvarivati veće prihode po kilometru, od vozila koje kupljeno polovno. No, također treba uzeti u obzir da dvije-tri godine u svakodnevnoj eksploataciji znači puno u pogledu funkcionalnosti određenih značajki vozila. Provedba ovakve analize je svakako zanimljiva, ujedno bila bi puno preciznija ukoliko bi se posjedovali podaci od početka eksploatacije kamiona od 2009. godine.

#### 4.4. Korelacijska i regresijska analiza

##### ➤ Korelacija

Korelacija je metoda kojom se utvrđuje postoji li među varijablama funkcionalna ovisnost, odnosno to je mjera povezanosti dviju ili više varijabli. Korelacija se iskazuje pomoću Pearson-ovog koeficijenta korelacije  $r$  i može poprimiti vrijednost od  $-1.00$  do  $+1.00$ . Ukoliko je  $r < 0$ , definira negativnu korelaciju, odnosno ako je  $r > 0$ , definira pozitivnu korelaciju [13].

##### ➤ Regresija

Pomoću regresijske analize određuje se oblik krivulje koja najbolje opisuje zadane podatke. Neki od oblika povezanosti varijabli su:

- Linearna povezanost
  - $y = ax + b$
- Krivolinijska povezanost
  - $y = ae^{bx}$
  - $y = a + b \ln(x)$
  - $y = ab^x$

Kod regresijske analize zna se što je uzrok, a što posljedica (zavisna, nezavisna varijabla)[13].

Postoje tri vrste regresijske analize:

- 1) Jednostavna linearna regresija
- 2) Nelinearna regresija (linearizacija)
- 3) Višestruka regresija

U sklopu ove analize, ispitati će se povezanost između prijeđenih kilometara, pojavljenih kvarova i njihovih troškova popravka te oblik nastale krivulje tih podataka.



#### 4.4.1. Korelacija između prijeđenih kilometara, kvarova i troškova popravka

Kako bi se utvrdila eventualna povezanost podataka prikazanih u [Tablica 4.7.] koristiti će se programski paket *Statistica 2017.* i značajka *Correlation matrices.*

**Tablica 4.7. Podatci o prijeđenoj udaljenosti, broju kvarova i troškovima popravka**

Mjeseci	Prijeđena udaljenost km	Broj kvarova	Trošak popravka N.J.
-		-	
Siječanj	36048,8	11	10684,7
Veljača	50182,5	2	1164,34
Ožujak	39653,8	6	9012,12
Travanj	56257,6	4	5154,51
Svibanj	50948,4	7	7882,19
Lipanj	41293,1	4	2424
Srpanj	36331,1	2	4082,41
Kolovoz	39694,7	3	5599,36
Rujan	33979,1	6	9303,49
Listopad	35795,6	2	1499,14
Studeni	40753,1	6	3511,44
Prosinac	36969	4	8009,25

Prilikom provođenja korelacijske analize dobiveni su sljedeći rezultati prikazani na [Slika 4.27.]. Glavni cilj provedbe bio je dokazivanje povezanosti prijeđenog puta i broja pojavljenih kvarova s ukupnim troškovima popravka.


Correlations (Spreadsheet38)	
Marked correlations are significant at p < ,05000	
N=12 (Casewise deletion of missing data)	
Variable	Troškovi popravaka
Prijeđeni kilometri	-0,247983
Kvarovi	0,764429

**Slika 4.27. Rezultat analize korelacije**

Podatak koji smo dobili zove se Pearson-ov koeficijent korelacije. Crvena boja indicira na postojanje povezanosti između dviju varijabli, a predznak govori o pozitivnoj ili negativnoj povezanosti. U ovom slučaju koeficijent korelacije između varijabli Prijeđene udaljenosti i Troškova popravaka iznosi -0,247983 i govori da nema čvrste povezanosti između te dvije varijable.

Međutim, ispitivanjem povezanosti pojave kvarova i troškova kvarova javlja se pozitivna korelacija iznosa 0,764429 iz čega se zaključuje da porastom broja kvarova, rastu i troškovi

popravaka. Dakako, treba imati u vidu da različiti kvarovi izazivaju različite troškove njihove sanacije. Sažetak korelacijske analize prikazan je grafički na [Slika 4.28.].



**Slika 4.28. Grafički prikaz rezultata korelacijske analize**

Na [Slika 4.28.] u gornjem desnom uglu prikazana je deskriptivna statistika s brojem parova podataka  $N$ , srednjom vrijednosti  $Mean$ , standardnom devijacijom  $Std. Dv.$ , i maksimalnom i minimalnom vrijednošću pojedine skupine podataka  $Max.$  i  $Min.$ . Također, prikazan je iznos koeficijenta korelacije te jednadžba i smjer pravca, odnosno kretanja koeficijenta korelacije. Na grafovima iznad i pored prikaza pravca, nalaze se distribucije obiju grupa podataka.

#### 4.4.2. Regresijska analiza

Uz pomoć regresijske analize pokušati će se predvidjeti ponašanje varijable troškova popravka s obzirom na rast broja kvarova. Rezultati provedene analize prikazani su na [Slika 4.29.].


Regression Summary for Dependent Variable: Troškovi popravaka (Spreadsheet38)						
R= ,76442891 R2= ,58435156 Adjusted R2= ,54278671						
F(1,10)=14,059 p<,00379 Std.Error of estimate: 2191,6						
N=12	b*	Std.Err. of b*	b	Std.Err. of b	t(10)	p-value
Intercept			1223,797	1349,662	0,906743	0,385871
Kvarovi	0,764429	0,203875	941,077	250,987	3,749506	0,003787

Slika 4.29. Rezultat regresijske analize

Na [Slika 4.29.] parametar R predstavlja koeficijent korelacije, i govori o povezanosti promatranih varijabli i iznosom je jednak rezultatu dobivenom u prethodnoj analizi. Parametar  $R^2$  opisuje koliko varijance u troškovima popravka se pripisuje varijabli kvarova. Parametar P je iznosom manji od 0.05 i dokazuje postojanje značajne razlike parametra  $R^2$  i nule, odnosno da model ima mogućnost predviđanja iznosa troškova ovisno o broju kvarova. Stupac b predstavlja nestandardiziran koeficijent regresije i govori da za svako jedinično povećanje broja kvarova, troškovi popravka rastu za vrijednost od 941 novčanih jedinica. Parametar  $b^*$  je standardizirani koeficijent regresije i na osnovu njega se određuje postoji li značajna razlika između njega i nule pomoću t-testa i pripadne vjerojatnosti P.

#### 4.5. ABC ili Pareto analiza

Pareto analiza je nastala u 19. stoljeću kada je Vilfred Pareto, talijanski ekonomist uočio da postoji veći broj manje značajnih uzoraka i manji broj značajnijih uzoraka. Ta metoda se koristi kako bi se klasificirali podatci prema važnosti, značajnosti ili učestalosti [14]. Koristeći tu metodu u ovom slučaju odrediti će se značajnost kvarova i troškova njihovog popravka. Teorijska raspodjela razreda A,B i C prikazana je na [Slika 4.30.] gdje u skupinu A ulaze podatci s kumulativnom vrijednosti do 70%, u skupinu B 90-95% i konačno ostatak 5-10% u skupinu C.




Slika 4.30. Teorijska raspodjela ABC analize [14]

U sljedećoj tablici biti će prikazane vrste popravka, ukupni troškovi istih izraženi u novčanim jedinicama te kumulativni zbroj u novčanim jedinicama izražen kao postotak. U skupinu A spadaju kvarovi čiji troškovi ostvaruju 70% ukupnih troškova popravaka, u skupinu B kvarovi koji ostvaruju dodatnih 20% troškova i u skupinu C ostatak od 10% ukupnih troškova popravaka.

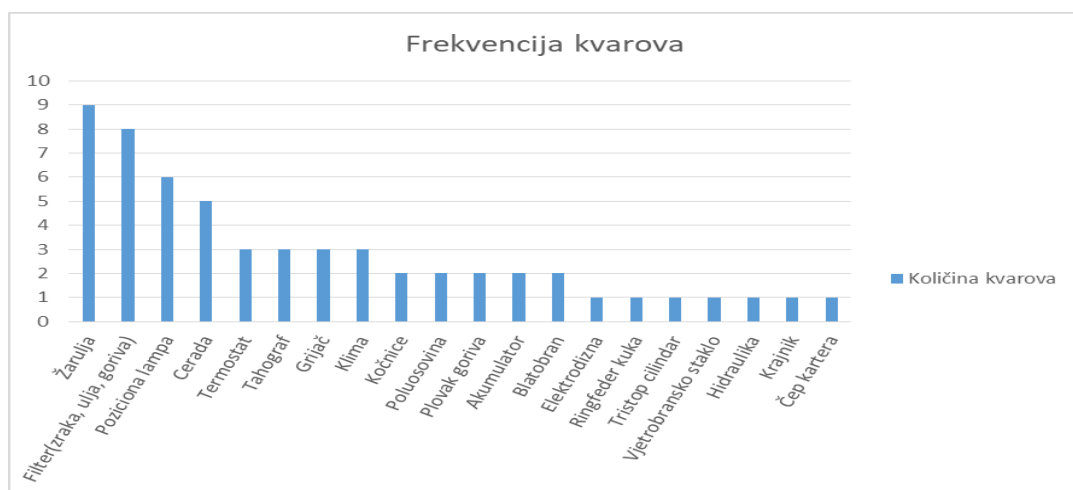
**Tablica 4.8. ABC analiza**

Vrsta popravka	Ukupni trošak	Kumulativno	Kumulativno	Skupina
Kočnice	8029,95	8029,95	12%	A
Poluosovina	7525,04	15554,99	24%	A
Poziciona lampa	6723,6	22278,59	34%	A
Plovak goriva	5465,76	27744,35	43%	A
Termostat	4731,42	32475,77	50%	A
Filter(zraka, ulja, goriva)	4400	36875,77	57%	A
Elektrodizna	3782,95	40658,72	62%	A
Ringfeder kuka	3656,66	44315,38	68%	A
Tahograf	2997	47312,38	73%	B
Akumulator	2865	50177,38	77%	B
Tristop cilindar	2845,5	53022,88	81%	B
Vjetrobansko staklo	2251	55273,88	85%	B
Grijač	1946,64	57220,52	88%	B
Klima	1860	59080,52	91%	C
Blatobran	1741,12	60821,64	93%	C
Hidraulika	1696,3	62517,94	96%	C
Žarulja	834,75	63352,69	97%	C
Krajnik	821,68	64174,37	99%	C
Cerada	781	64955,37	99,7%	C
Čep kartera	175,5	65130,87	100%	C

Prilikom korištenja Pareto analize i crtanja dijagrama, vrlo često se uzima omjer 80-20 kako bi se naglasila važnost značajnijih uzoraka. U nastavku će na [Slika 4.31.] i [Slika 4.32.] biti prikazan Pareto dijagram za ukupne troškove sanacije kvarova i dijagram frekvencije pojave pojedinih kvarova.



Slika 4.31. Pareto dijagram ukupnih troškova popravaka



Slika 4.32. Histogram frekvencija kvarova

Iz prvog dijagrama je vidljivo da kvarovi koji se u pravilu ne pojavljuju često poput kvara na kočnicama, pucanja poluosovine, kvar plovka goriva i kvar termostata, uzrokuju najveću količinu troškova u odnosu na frekvenciju pojave. Stoga je zaključak ove analize da treba posvetiti više pažnje, odnosno češće provoditi aktivnosti održavanja na značajke vozila koje uzrokuju najveći dio troškova popravaka, tj. na značajke koje se nalaze u skupini A kako bi smanjenjem troškova poduzeće povećalo ukupan prihod voznih jedinica po prijeđenom kilometru.

## 5. PRIJEDLOG POBOLJŠANJA

Svako poduzeće teži poboljšanju i sveopćem napretku poslovanja. Nakon provedenih analiza, moguće je izdvojiti najizraženije slabosti poduzeća Tasa i ponuditi prijedloge za unaprjeđenje.

### 5.1. Analiza dobivenih rezultata

Nakon provedene analize povezanosti karakteristika vozila i ukupnih troškova, vrlo čest zaključak je bio da nema značajnih razlika između kamiona unutar flote. No, te rezultate treba uzeti sa zadržkom jer je promatrana količina podataka bila ograničena vremenski na jednu godinu zbog vrlo teškog pristupa podacima i evidentiranju istih uzrokovanih pravilom poduzeća da zbog prevelike količine dokumenata (ručno pisani dokumenti) ne drži dokumentaciju stariju od jedne godine. Usprkos tome, kroz provedena testiranja, jedno vozilo je gotovo uvijek, doduše, dokazano kroz testove ne značajno, odstupalo od ostatka flote. To je vozilo ČK-320-ET marke Iveco koje je kupljeno novo i u eksploataciji je osam godina. Prilikom usporedbe tog vozila s vozilom iste marke, ustanovljeno je da postoje značajne razlike u prihodima koje ostvaruje ta vozila. Mogući razlog tome je povećanje troškova uslijed češće pojavnivosti kvarova, no kako je i dokazano testom, ne postoje značajnije razlike ni u tome kod vozila istih marki. Razlog manjeg prihoda leži u manjoj dostupnosti vozila, odnosno u vremenu koje provodi u automehaničarskoj garaži. Stoga se kao prijedlog poboljšanja nudi, ukoliko postoji tržišna mogućnost za to, prodaja te transportne jedinice i nabava druge, u ovo slučaju provjerene vozne jedinice marke Volvo u istom rangu (snaga, nosivost). Također, prilikom donošenja takve odluke postavlja se pitanje dosad uloženog u kamion i isplativost same prodaje.

## 5.2. Načini smanjivanja troškova

S obzirom na zakon ponude i potražnje, povećanje profita mora se tražiti kroz smanjivanje vlastitih troškova pružanja usluge.

Značajnije uštede moguće je postići na sljedeće načine [7]:

- 1) Pravilan izbor vrste prijevoznog sredstva
- 2) Bolji odabir i planiranje transportnih ruta
- 3) Praćenje transportnih jedinica u realnom vremenu
- 4) Efikasno upravljanje transportnim sredstvima na bazi stvarnih troškova i parametara rada

Izbor vrste transportnog sredstva neposredno ovisi o vrsti, količini, zapremnini, načinu pakiranja robe te udaljenosti transporta. Gledano sa strane ekonomske i tehnološke isplativosti, svako prijevozno sredstvo ima svoje prednosti i ograničenja, stoga je neophodna organizacija prijevoza u skladu s tim. Nadalje, direktan utjecaj na smanjivanje troškova ima pravilno definiranje transportnih relacija i udaljenosti, na kojima se transportno sredstvo najviše isplati, odnosno potrebno je odrediti granicu ili prag rentabilnosti na kojoj vozilo postiže dobit ovisno o tipu, nosivosti i veličini vozila. Postavljanje najisplativijeg rasporeda transportnih zadataka i praćenje vozila u stvarnom vremenu s ciljem fleksibilnog rutiranja vozila omogućava značajne uštede i priliku za ostvarivanjem većeg prometa na način da organizator transporta u realnom vremenu zna lokaciju i popunjenost svakog vozila i omogućuje mu dogovaranje prijevoza robe vozilom koje je izvršilo prethodni nalog i još se nije vratilo natrag. Također, u vidu povećanja prometa sve je popularnija opcija „napravi ili kupi uslugu“ gdje transportna poduzeća međusobno rade usluge ovisno o popunjenosti vlastitih kapaciteta čime se omogućavaju značajne uštede i ekonomično korištenje transportnih sredstava.



### 5.3. Digitalizacija evidencije podataka


Prilikom provedbe SWOT analize, vrlo brzo je na površinu isplivala možda i najveća slabost promatranog poduzeća, a to je zastarjelo evidentiranje podataka gdje se svi podaci relevantni za poslovanje poduzeća bilježe ručno i spremaju u ormar u vidu registratora i fascikala. Takav način prikupljanja podataka oduzima puno vremena te ne ostavlja mogućnost za analizom i uočavanjem trendova koji bi potencijalno mogli indicirati na problem ili gomilanje nepotrebnih troškova. Iz tog razloga, kao prijedlog poboljšanja napravljena je desktop aplikacija prilagođena organizatoru transporta kako bi se ubrzao unos potrebnih podataka i njihovo spremanje u bazu podataka koja se nalazi na računalu. Dodatno unaprjeđenje nudi se u vidu spremanja podataka na oblak (*Cloud*) kako bi se izbjegao potencijalni gubitak podataka uzrokovan kvarom na računalu. U nastavku će biti prikazana izrađena aplikacija i način na koji funkcionira.

#### 5.3.1. Desktop aplikacija

Kako bi se doskočilo zastarjelom načinu bilježenja podataka, kreirana je aplikacija koja omogućava korisniku, odnosno organizatoru prijevoza da nakon svakog uspješno odrađenog prijevoza i sa svim potrebnim dokumentima pred sobom, unese u bazu podataka sve informacije o izvršenoj usluzi prijevoza poput:

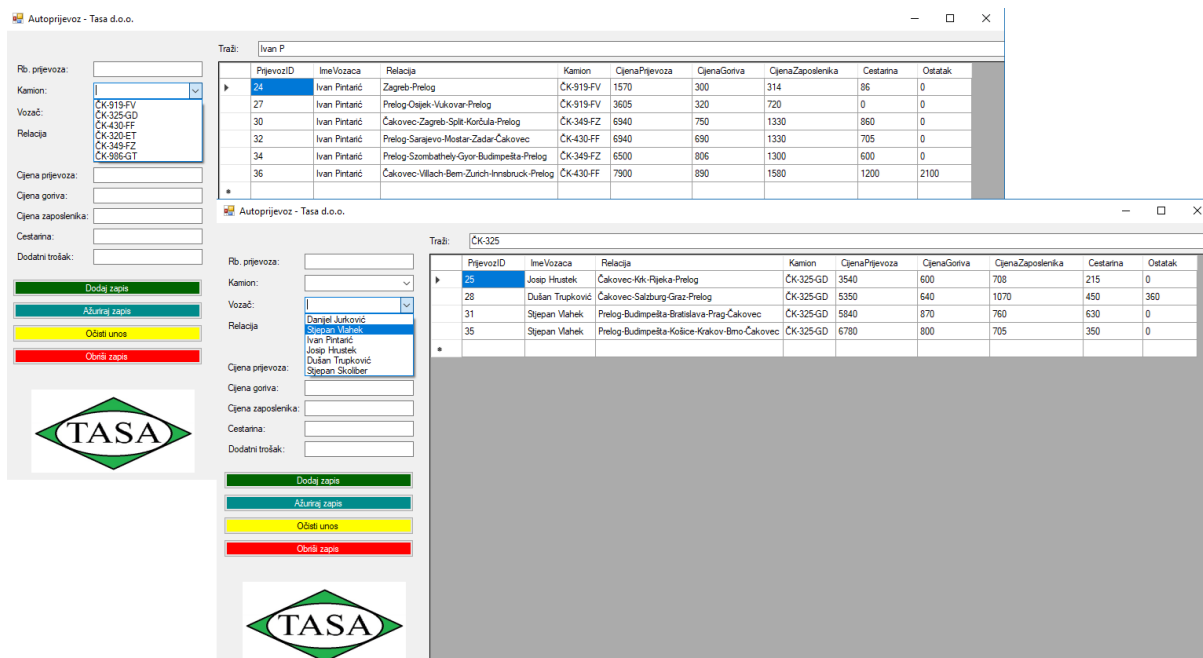
- Imena vozača
- Transportnog vozila
- Relacije
- Cijene prijevoza
- Troška goriva
- Troška cestarine
- Dodatnih troškova

Osnovno sučelje aplikacije prilagođeno poduzeću Tasa, prikazano je na [Slika 5.1.].



Slika 5.1. Osnovno sučelje desktop aplikacije

S ciljem olakšavanja i ubrzavanja unošenja podataka, kategorije *Kamion* i *Vozač* dizajnirane su kao padajući izbornik s mogućnošću dodavanja ili brisanja opcija ukoliko dođe do kupnje ili prodaje vozila, odnosno novog zaposlenja ili odlaska djelatnika. Nadalje, kako bi se olakšao pregled učinka pojedinog vozača ili vozila, korisniku se nudi mogućnost pretraživanja pojmova što je prikazano na [Slika 5.2.].

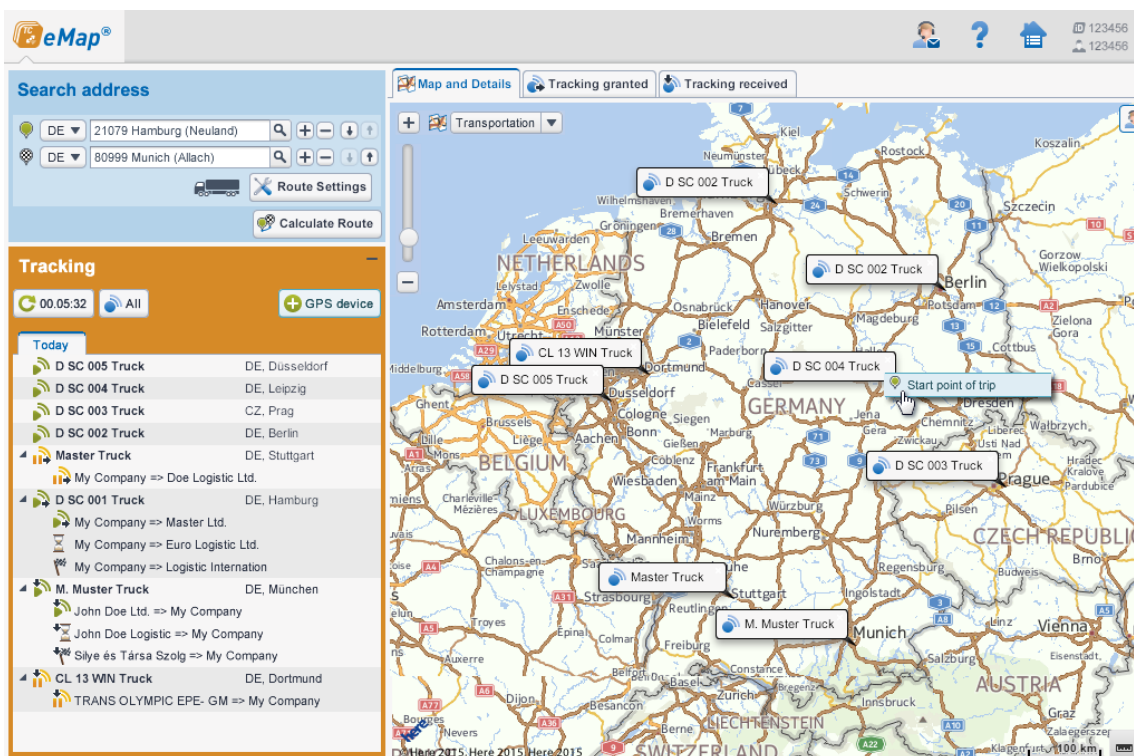


Slika 5.2. Prikaz mogućnosti aplikacije

Ukoliko se dogodi da korisnik pogriješi prilikom upisivanja podataka, nudi mu se mogućnost ažuriranja unesenih podataka ili kompletno brisanje unesenog prijevoza.

### 5.3.2. Uvođenje tehnologije i edukacija djelatnika

Dodatak uvođenju aplikacije za prikupljanje podataka prilagođenu organizatoru prijevoza jest adaptacija aplikacije za vozače. Kupnjom tableta za svako vozilo i edukacijom prema vlastitoj potrebi vozača o upotrebi istog i korištenju adaptirane aplikacije, postigao bi se značajan napredak pri praćenju situacije prilikom usluge transporta u realnom vremenu. Mogućnosti koje se nude, poput komentara vozača o stanju na prometnicama i mogućim kašnjenjima omogućuju organizatoru transporta planiranje alternativne rute kako bi se isporuka izvršila na ugovoreno vrijeme. Također, posjedovanjem tableta u svakom vozilu, izbjegava se dodatan trošak nabave GPS lokatora za praćenje lokacije vozila. Primjer praćenja vozila prikazan je na sljedećoj slici.



Slika 5.3. Primjer praćenja vozila u realnom vremenu [15]

## 5.4. Povezivanje na transportnu platformu

Suvremeni vid popunjavanja kapaciteta ne odnosi se samo na poznanstva i partnerske firme, već se oslanja na priključivanje transportnoj platformi. Konkretni primjer takve platforme jest *TimoCom* koji spaja prijevoznike, špeditere i poduzeća iz područja proizvodnje i trgovine. Na njihovoj burzi prometa dnevno se objavljuje do 750 tisuća međunarodnih ponuda tereta i utovarnih prostora od trenutno 120 tisuća korisnika iz čitave Europe s tendencijom porasta [16]. Sučelje platforme nalazi se na [Slika 5.4.].

Date	Origin	Destination	Carrier	Weight	Volume	Vehicle Type	ADR	Other types possible	Price				
01.11.	GB	AL10 9	St Albans	FR 91660	Méréville	1/1	13.60	24.00	Curtainsider	A	S	-	-
04.11.	GB	BD10 0	Bradford	FR 06000	Nice	1/1	13.60	17.50	Curtainsider	C	S	-	-
28.10.	GB	BD10 0	Bradford	FR 06000	Nice	1/1	13.60	17.50	Curtainsider	C	S	-	-
07.11.	GB	BD10 0	Bradford	FR 06000	Nice	1/1	13.60	17.50	Curtainsider	C	S	-	-
27.10.	GB	BD23	RYLSTONE	FR 59552	LAMBRES-LEZ-DOUAI	1/1	1.00	0.10	Curtainsider	S	-	-	-
25.10.	GB	BL9 0	Bury	FR 27210	Beuzeville	1/1	1.00	2.00	Curtainsider	C	S	-	-
26.10.	GB	CB1 0	Cambridge	FR 45000	Orléans	1/1	0.80	0.40	Curtainsider	A	S	-	-
25.10.	GB	CF10 1	Cardiff	FR 08240	Tally	1/1	13.60	24.00	Curtainsider	C	S	-	-
25.10.	GB	CH9 7	Holywell	FR 02830	Watigny	1/1	4.40	3.00	Curtainsider	C	S	-	-
25.10.	GB	CT1 1	Canterbury	FR 85230	Bouin	1/1	13.60	24.00	Mega	C	S	-	-
25.10.	GB	CT1 1	Canterbury	FR 14500	St-Germain-de-Tallevende-la-Lande-V	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	CV21 1	Rugby	FR 27300	Bernay	1/1	0.80	0.40	Curtainsider	A	C	S	-
26.10.	GB	CV5 6BN	coventry	FR 68100	Mulhouse	1/1	7.70	8.90	Curtainsider	C	S	-	-
25.10.	GB	CV6 1	Coventry	FR 06600	Antibes	1/1	13.60	10.00	Curtainsider	C	S	-	1850 00 EUR
25.10.	GB	DA1 1	Dartford	FR 03350	Cérilly	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	DD11 4	Forfar	FR 69850	Saint-Martin-en-Haut	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	DE1 1	Derby	FR 02250	La Flamengrie	1/1	13.60	24.00	Curtainsider	C	S	-	-
25.10.	GB	DL13 1	Bishop Auckland	FR 57850	Dabo	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	DN41 7	Grimsby	FR 60840	Breuil	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	EN11 9	Hertford	FR 45000	Orléans	1/1	0.80	0.40	Curtainsider	A	S	-	-
25.10.	GB	HR4 0	Hereford	FR 48340	Dégagnac	1/1	1.50	1.60	Curtainsider	C	S	-	-
26.10.	GB	IP10 0	Felkstone	FR 93120	La Courneuve	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	IP10 0	Felkstone	FR 93350	Le Bourget	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	IP10 0	Felkstone	FR 77290	Mitry-Mory	1/1	13.60	24.00	Curtainsider	C	S	-	-
25.10.	GB	IP22 2	Norwich	FR 95500	Gonesse	1/1	13.60	24.00	Curtainsider	C	S	-	-
26.10.	GB	IP22 2	Norwich	FR 95500	Gonesse	1/1	13.60	24.00	Curtainsider	C	S	-	-

Slika 5.4. TimoCom sučelje [16]

Ukoliko je transportna jedinica izvršila uslugu prijevoza i nalazi se primjerice u Salzburgu, bez tzv. *povrata*, odnosno bez ugovorene usluge prijevoza natrag do Hrvatske, taj trošak bi predstavljao NVAT (eng. *Non Value Added Time*), tj. trošak koji klijent nije voljan platiti. U tom slučaju dovoljno je otvoriti platformu prijevoza, upisati podatke o vrsti, tipu, nosivosti i veličini transportne jedinice, mjesto gdje se nalazi i popis ponuđenih prijevoza će se pojaviti korisniku na izbor. Takav način rada znatno pospješuje poslovanje u vidu popunjavanja neiskorištenih kapaciteta.

## 6. ZAKLJUČAK

Kontinuirani napredak i visoka kvaliteta transportne usluge u vidu pravovremene i zadovoljavajuće dostave, cilj je svakog mikro poduzeća jer upravo zbog tih karakteristika opstaju na zahtjevnom i konkurentnom tržištu. Praćenje svakodnevnih aktivnosti i bilježenje podataka sa svrhom kvantitativnog prikaza dobrih i loših komponenti transportnog sustava svakako predstavlja zanimljivo područje za daljnju provedbu analiza i kontinuirani napredak.

Analizirajući podatke prikupljene od poduzeća „Tasa d.o.o.“ cilj je bio dokazati postoje li određene povezanosti između različitih realnih pojava poput kvarova i prijeđenih kilometara te ukupnog prihoda po prijeđenom kilometru. Također, svrha provođenja analize je bila dokazati pripadaju li vozila iz flote istoj populaciji, odnosno može li se od njih očekivati isti izlaz (eng. *Output*). Prilikom analiziranja dobivenih rezultata, jasno je vidljivo da određene tendencije kod pojedinih vozila postoje, no količina podataka kojom se baratalo je bila premala da bi se kroz testove dokazao značajniji međusobni utjecaj varijabli sustava. Korištenjem analize varijanci na temelju prikupljenih podataka o prihodu po prijeđenoj udaljenosti, dokazano je da sva vozila pripadaju istoj populaciji što je zapravo bio i očekivani rezultat obzirom na poznavanje varijabilnih troškova poput goriva i cestarine, te kretanja cijena na tržištu ovisno o karakteristikama prijevoznog sredstva (vrsta, nosivost, veličina). Značajnije odstupanje od populacije javilo bi se ukoliko bi postojali veći neočekivani troškovi popravka i k tome rezultirajući troškovi stajanja, odnosno neiskorištenost vozila. Nadalje, ispitan je utjecaj vremenskih prilika te mjesta eksploatacije na pojavljivost kvarova. Generalni zaključak jest da ti faktori nemaju značajnijeg utjecaja na pojavu kvara što je bilo pomalo neočekivano s obzirom na pretpostavljenu kvalitetu prometnica i podosta velike amplitude vanjskih temperatura kroz godinu. S obzirom na postojanje kamiona istih marki, provedene su usporedbe između vozila marki Volvo i Iveco. Kod Volvo vozila zaključak je da nema razlika u pojavnosti kvarova i prihodima, dok je kod vozila marke Iveco utvrđena značajna razlika u prihodu, no također bez značajnijih razlika u pojavnosti kvarova i njihovih troškova popravka. Mjesta za napredak ovog poduzeća svakako ima i prvi korak prema boljoj budućnosti svakako bi bila digitalizacija i opremanje vozila suvremenim tehnologijama. Prikupljanje i analiziranje podataka iz svakodnevnih aktivnosti svakako predstavlja temelj za razumijevanje procesa transporta i poboljšanje poslovanja autoprijevozničkog poduzeća.

## LITERATURA

- [1] Štefanić, N. 2016. *Proizvodna strategija*. FSB prezentacija (e-učenje). Zagreb. <http://e-ucenje.fsb.hr/course/view.php?id=748> (pristupljeno u siječanju 2018.)
- [2] Kos transporti. <https://www.kostransporti.hr/images/vozni-park3.svg> (pristupljeno u siječnju 2018.)
- [3] Hegedić, M. 2017. *Proizvodni menadžment*. FSB prezentacija (e-učenje). Zagreb. <http://e-ucenje.fsb.hr/course/view.php?id=748> (pristupljeno u siječnju 2018.)
- [4] Debelić, B. 2015. *Troškovi u prometu*. Zagreb. [http://www.pfri.uniri.hr/~debelic/download/ekonomika\\_prometa/predavanja/troskovi\\_u\\_prometu.pdf](http://www.pfri.uniri.hr/~debelic/download/ekonomika_prometa/predavanja/troskovi_u_prometu.pdf) (pristupljeno u veljači 2018.)
- [5] Eurostat. 2018. <http://ec.europa.eu/eurostat/web/transport/data/database> (pristupljeno u veljači 2018.)
- [6] Martinović, M. 2014. *Što uračunati u stvarne logističke troškove*. Zagreb. <http://www.progressive.com.hr/component/content/article/62-kolumne/5547-sto-uracunati-u-stvarne-logisticke-troskove.html> (pristupljeno u veljači 2018.)
- [7] Hrvatski prijevoznik. <https://www.hrvatskiprijevoznik.hr/smanjenje-troskova-u-logistici-kako-racionalizirati-sektor-transporta/> (pristupljeno u veljači 2018.)
- [8] Boniteti. <https://boniteti.croatiabiz.com/subjekt/tasa-doo/79761/799cd> (pristupljeno u veljači 2018.)
- [9] Means and modes of transport. [http://ekool.tktk.ee/failed/H/transport\\_E/advantages\\_and\\_disadvantages\\_of\\_road\\_transport.html](http://ekool.tktk.ee/failed/H/transport_E/advantages_and_disadvantages_of_road_transport.html) (pristupljeno u veljači 2018.)
- [10] Cajner, H. 2016. *Analiza varijance*. FSB prezentacija (e-učenje). Zagreb. <http://e-ucenje.fsb.hr/course/view.php?id=476> (pristupljeno u veljači 2018.)
- [11] Pažin, I. 2014. *Analiza varijance ponovljenih mjerenja*. Diplomski rad. Prirodoslovno-matematički fakultet Sveučilišta u Zagrebu. Zagreb.
- [12] Grubešić, N. 2014. *Karakterizacija procesa uporabom metode regresijske analize i analize varijance*. Diplomski rad. Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu. Zagreb.
- [13] Cajner, H. 2016. *Korelacija i regresija*. FSB prezentacija (e-učenje). Zagreb. <http://e-ucenje.fsb.hr/course/view.php?id=476> (pristupljeno u veljači 2018.)

- 
- [14] Kontrola kvalitete. 2003. *QI alati*. FSB prezentacija. Zagreb.  
[https://www.fsb.unizg.hr/ndt/2003\\_qc\\_QI\\_alati.pdf](https://www.fsb.unizg.hr/ndt/2003_qc_QI_alati.pdf) (pristupljeno u veljači 2018.)
- [15] TimoCom.  
[https://www.timocom.com.hr/STATIC/binary/900000/contentModule/product\\_screens/tcm/en-eMap03.png](https://www.timocom.com.hr/STATIC/binary/900000/contentModule/product_screens/tcm/en-eMap03.png) (pristupljeno u veljači 2018.)
- [16] TimoCom. <https://www.timocom.com/> (pristupljeno u veljači 2018.)

**Napomena:**

Za statističku obradu podataka korišten je programski paket *STATISTICA 2017*.

## **PRILOZI**

- I. CD-R disc
- II. Programski kod aplikacije



## PRILOG II.

```
public void Clear()
{
    textCestarina.Text = "";
    textCijenaZaposlenika.Text = "";
    textCijenaGoriva.Text = "";
    textPrijevozID.Text = "";
    textDodatniTrosak.Text = "";
    textRelacija.Text = "";
    textCijenaPrijevoza.Text = "";
    comboVozac.Text = "";
    comboKamion.Text = "";
}

private void buttonAdd_Click(object sender, EventArgs e)
{
    Prijevoz prijevoz = new Prijevoz();

    //Get a value from input field
    prijevoz.ImeVozaca = comboVozac.Text;
    prijevoz.Kamion = comboKamion.Text;
    prijevoz.Relacija = textRelacija.Text;
    prijevoz.CijenaPrijevoza = textCijenaPrijevoza.Text;
    prijevoz.CijenaGoriva = textCijenaGoriva.Text;
    prijevoz.CijenaZaposlenika = textCijenaZaposlenika.Text;
    prijevoz.Cestarina = textCestarina.Text;
    prijevoz.Ostatak = textDodatniTrosak.Text;
    //insert Data into Database using the method we created before
    bool success = prijevoz.Insert();
    if (success == true)
        //successfully inserted
        {
            MessageBox.Show("Novi prijevoz uspješno zabilježen!");
            Clear();
        }
    else
        {
            MessageBox.Show("Neuspjeli pokušaj, pokušajte ponovo.");
        }
    //Load data on Data Gridview
    DataTable dt = prijevoz.Select();
    dataGrid.DataSource = dt;
}

private void buttonUpdate_Click(object sender, EventArgs e)
{
    Prijevoz prijevoz = new Prijevoz();

    //Get the data from textboxes
    prijevoz.PrijevozID = int.Parse(textPrijevozID.Text);
    prijevoz.ImeVozaca = comboVozac.Text;
    prijevoz.Kamion = comboKamion.Text;
    prijevoz.Relacija = textRelacija.Text;
    prijevoz.CijenaPrijevoza = textCijenaPrijevoza.Text;
    prijevoz.CijenaGoriva = textCijenaGoriva.Text;
    prijevoz.CijenaZaposlenika = textCijenaZaposlenika.Text;
    prijevoz.Cestarina = textCestarina.Text;
    prijevoz.Ostatak = textDodatniTrosak.Text;
    //Update data in data base
}
```

```
bool success = prijevoz.Update();
if (success == true)
{
    //Updated Successfully
    MessageBox.Show("Prijevoz je uspješno izmjenjen!");
    //Load data on Data Gridview
    DataTable dt = prijevoz.Select();
    dataGridView.DataSource = dt;
    //Call clear method
    Clear();
}
else
{
    //Failed to update
    MessageBox.Show("Neuspjela izmjena podataka prijevoza, pokušajte
ponovo!");
}
}
private void buttonClean_Click(object sender, EventArgs e)
{
    Clear();
}

private void buttonDelete_Click(object sender, EventArgs e)
{
    Prijevoz prijevoz = new Prijevoz();

    //Get data from data textbox
    prijevoz.PrijevozID = Convert.ToInt32(textPrijevozID.Text);
    bool success = prijevoz.Delete();
    if (success == true)
    {
        //Successfully Deleted
        MessageBox.Show("Prijevoz je uspješno obrisani!");
        //Load data on Data Gridview
        DataTable dt = prijevoz.Select();
        dataGridView.DataSource = dt;
        //Call clear method
        Clear();
    }
    else
    {
        //Failed to delete
        MessageBox.Show("Neuspjelo brisanje prijevoza, pokušajte ponovo!");
    }
}
}
```