

Univerza
v Ljubljani
Fakulteta
*za gradbeništvo
in geodezijo*



Jamova cesta 2
1000 Ljubljana, Slovenija
<http://www3.fgg.uni-lj.si/>

DRUGG – Digitalni repozitorij UL FGG
<http://drugg.fgg.uni-lj.si/>

V zbirki je izvorna različica doktorske disertacije.

Prosimo, da se pri navajanju sklicujete na bibliografske podatke, kot je navedeno:

University
of Ljubljana
Faculty of
*Civil and Geodetic
Engineering*



Jamova cesta 2
SI – 1000 Ljubljana, Slovenia
<http://www3.fgg.uni-lj.si/en/>

DRUGG – The Digital Repository
<http://drugg.fgg.uni-lj.si/>

This is an original PDF file of doctoral thesis.


When citing, please refer as follows:

Pirc, J. 2015. Algoritem za združevanje prometnih podatkov, pridobljenih iz točkovnih in linijskih meritev za oceno potovalnih časov na avtocestah. = Algorithm combining point and interval detector data to estimate highway travel times. Doctoral dissertation. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo. (Mentor Žura, M., somentor Turk, G.)

<http://drugg.fgg.uni-lj.si>

Univerza
v Ljubljani

Fakulteta za
gradbeništvo in
geodezijo



DOKTORSKI ŠTUDIJSKI
PROGRAM III. STOPNJE
GRAJENO OKOLJE

Kandidat:
JURE PIRC

**ALGORITEM ZA ZDRUŽEVANJE PROMETNIH
PODATKOV, PRIDOBLJENIH IZ TOČKOVNIH IN
LINIJSKIH MERITEV ZA OCENO POTOVALNIH ČASOV NA
AVTOCESTAH**

Doktorska disertacija številka: 19/GO

**ALGORITHM COMBINING POINT AND INTERVAL
DETECTOR DATA TO ESTIMATE HIGHWAY TRAVEL
TIMES**

Doctoral thesis No.: 19/GO

Soglasje k temi doktorske disertacije je dala Komisija za doktorski študij Univerze v Ljubljani
na 41. seji 3. julija 2013.

Za mentorja je bil imenovan izr. prof. dr. Marijan Žura,
za somentorja prof. dr. Goran Turk.

Ljubljana, 6. maj 2015

Univerza
v Ljubljani
Fakulteta za
gradbeništvo in
geodezijo



Komisijo za oceno ustreznosti teme doktorske disertacije v sestavi:

- izr. prof. dr. Marijan Žura,
- doc. dr. Tomaž Maher,
- doc. dr. Peter Lipar,
- prof. dr. Tomaž Tollazzi, UM FG,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 40. seji 24. aprila 2013.

Poročevalce za oceno doktorske disertacije v sestavi:

- doc. dr. Peter Lipar,
- doc. dr. Tomaž Maher,
- prof. dr. Igor Grabec, upok. prof. UL FS,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 17. seji 4. marca 2015.

Komisijo za zagovor doktorske disertacije v sestavi:

- prof. dr. Matjaž Mikoš, predsednik,
- izr. prof. dr. Marijan Žura, mentor,
- prof. dr. Goran Turk, somentor,
- doc. dr. Peter Lipar,
- doc. dr. Tomaž Maher,
- prof. dr. Igor Grabec, upok. prof. UL FS,

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 18. seji 22. aprila 2015.

»Znanje je pomembno. Toda še veliko pomembnejša je njegova koristna uporaba. Ta je odvisna od srca in uma človeka.«

- Dalaj Lama

POPRAVKI

Stran z napako

Vrstica z napako

Namesto

Naj bo

IZJAVA O AVTORSTVU

Podpisani JURE PIRC izjavljam, da sem avtor doktorske disertacije z naslovom:
»ALGORITEM ZA ZDRUŽEVANJE PROMETNIH PODATKOV, PRIDOBLENIH IZ
TOČKOVNIH IN LINIJSKIH MERITEV ZA OCENO POTOVALNIH ČASOV NA
AVTOCESTAH«.

Izjavljam, da je elektronska različica disertacije enaka tiskani različici in dovoljujem njeno
objavo v digitalnem repozitoriju UL FGG.

Ljubljana, 25.4. 2015

(podpis)

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK: 656.1:006.92(043.3)
Avtor: mag. Jure Pirc, univ. dipl. ing. grad.
Mentor: izr. prof. dr. Marijan Žura
Somentor: prof. dr. Goran Turk
Naslov: Algoritem za združevanje prometnih podatkov, pridobljenih iz točkovnih in linijskih meritev za oceno potovalnih časov na avtocestah
Tip dokumenta: Doktorska disertacija
Obseg in oprema: 215 str., 22 pregl., 151 sl., 62 en.
Ključne besede: potovalni čas, merjenje potovalnega časa, ocena potovalnega časa, združevanje podatkov, algoritem za določevanje potovalnega časa

Izvleček

Doktorska disertacija je razdeljena na tri med seboj povezane sklope. Prvi sklop opisuje metodo za določitev reprezentativne vrednosti potovalnega časa na podlagi neposredno linijsko izmerjenih potovalnih časov vozil med dvema točkama. Predlagana metoda, ki temelji na robustni statistiki, je sposobna zaznati in izločiti vozila, katerih podaljšani oz. skrajšani potovalni časi na odseku z vmesnimi priključki nimajo vzroka v prometnih razmerah temveč so posledica individualnega obnašanja posameznih vozil. Metoda je sposobna dobro oceniti potovalni čas osebnih vozil, ki so merodajna za določitev reprezentativne vrednosti potovalnega časa, ker se v prostem prometnem toku gibljejo skoraj brez fizičnih omejitev. Drugi sklop disertacije opisuje metodo za posredno oceno potovalnega časa iz točkovnih meritev hitrosti. Metoda določi, ali je sprememba hitrosti posledica naključnega nihanja zaradi obnašanja voznikov in jo je potrebno zgladiti, ali pa je posledica spremembe prometnega stanja zaradi udarnega vala in jo ne gre gladiti, s čimer zagotovimo hipen odziv algoritma. Po ekstrapolaciji hitrosti na merilniku pripadajoče območje dobimo vrednost potovalnega časa na odseku izvajanja meritve. V tretjem sklopu disertacije je opisan algoritem za združevanje podatkov iz neposredne linijske meritve potovalnega časa, potovalnega časa ocenjenega iz točkovne ekstrapolacije hitrosti ter iz kvalitativne informacije o stopnji prometnega stanja. Namen združevanja podatkov je premostiti prostorsko nenatančnost potovalnega časa pridobljenega iz točkovne ekstrapolacije hitrosti in časovno zakasnelost neposredno izmerjenega potovalnega časa na odseku. Z združevanjem obeh potovalnih časov ter informacije o stopnji prometnega stanja, ki v do sedaj objavljenih študijah ni bila upoštevana, smo dosegli kratkoročno napoved potovalnega časa, ki lahko služi kot koristna informacija vozniku ob vstopu na odsek izvajanja meritve.

BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION

UDC: 656.1:006.92(043.3)
Author: Jure Pirc
Supervisor: assoc. prof. dr. Marijan Žura, Ph.D.
Co-advisor: prof. dr. Goran Turk, Ph.D.
Title: Algorithm combining point and interval detector data to estimate highway travel times
Document type: PhD thesis
Notes: 215 p., 22 tab., 151 fig., 62 eq.
Key words: Travel Time, Travel Time Measurement, Travel Time Estimation, Data Fusion, Travel Time Algorithm

Abstract

The dissertation is divided into three interconnected parts. The first part presents a link travel time estimation algorithm that is based on the use of robust statistic able to exclude the impact of outliers. Outliers in travel time measurements are vehicles whose shortened or extended travel times are not caused by the traffic conditions, but are the result of individual behavior of such vehicle. As the adequate information on travel times is the one of personal cars, the influence of other vehicle categories should be eliminated from the samples which is not feasible with the use of existing link travel time estimation algorithms. The second part of the dissertation presents a method to estimate the value of travel time based on speed extrapolations from point measurements. The method is able to determine whether a speed variation represents a random fluctuation due to individual driver's behavior and should therefore be smoothed or is a consequence of a change in traffic conditions as a result of a shock wave and should therefore be kept as it is in order to provide prompt response of the algorithm. By extrapolating the speed, the value of travel time from point speed measurements is obtained. In the third part of the dissertation, a data fusion algorithm is presented, combining point and interval detector data to estimate highway travel times also taking into account qualitative measurements of traffic flow. The purpose of travel time data fusion from different sources is to overcome on one hand the spatial inaccuracy of indirect travel time estimation from point speed measurements and on the other hand to overcome the information delay of the direct travel time measurements. By combining both data sources, a short-term travel time prediction is achieved, as the input for the travel time information system.

ZAHVALA

Za pomoč pri nastajanju doktorske disertacije se v prvi vrsti zahvaljujem mentorju in somentorju. Hvala mentorju, izr. prof. dr. Marijanu Žuri za vse kritične pripombe in usmeritve med študijem. Najini različni pogledi na tematiko so pogosto pripeljali do novih, boljših rešitev. Hvala somentorju, prof. dr. Goranu Turku, ki je v času izvedbe moje disertacije prevzel mesto prorektorja Univerze v Ljubljani, a kljub temu ostal zvest pomoči študentom. S svojimi dragocenim znanjem, izkušnjami ter idejami s področja statistike mi je pomembno pomagal pri nastanku disertacije in pokazal, da so statistične metode še kako uporabne v prometnem inženirstvu. Hvala tudi akademiku dr. Igorju Grabcu, zaslužnemu profesorju, čigar zanimanje za dinamiko prometnega toka in njegove teoretične ugotovitve so pomagale pri izvedbi algoritma. Zaslužnemu profesorju dr. Simonu Pircu gre zahvala za vse nasvete, ki sem jih od njega prejel v času študija.

Posebna zahvala velja tudi sodelavcem iz podjetja Traffic design d.o.o, Ljubljana, ki so s svojim interdisciplinarnim znanjem v veliki meri pripomogli k uveljavitvi sistemov za nadzor in vodenje prometa na slovenskih avtocestah. Hvala prof. dr. Tomažu Kastelicu, ki mi je po končanem dodiplomskem študiju omogočil, da sem se zaposlil v podjetju, kjer teoretične osnove dobivajo svojo sliko v praktičnih implementacijah. Hvala Blažu Gostiši in Mojci Novak Kastelic, da sta uslišala mojo željo po študiju novih tehnologij in omogočila nakup testne opreme za izvajanje meritev. Hvala Dejan Maksimoviću za vse popoldneve, ki sva jih preživela ob razhroščevanju programske kode. Hvala mag. Robertu Rijavcu za ideje, spodbudo in pomoč, hvala mag. Roku Marsetiču za pomoč pri simulacijah. Hvala kolegom z DARSa, ki so omogočili vgradnjo testne opreme na avtocestni trasi med Vranskim in Blagovico.

Zahvaljujem se tudi Ministrstvu za gospodarski razvoj in tehnologijo ter Ministrstvu za izobraževanje, znanost in šport za dodeljena finančna sredstva, ki so omogočila kakovostno izvedbo študije.

Hvala vsem prijateljem za športna druženja, ki so pomagala zbistriti um med študijskimi seansami. Hvala staršema, ki sta me skozi vsa leta dodiplomskega študija moralno podpirala in mi stala ob strani po svojih najboljših močeh.

Navsezadnje hvala moji Tini za potrpežljivost med vsemi vikendi in popoldnevi, ki sem jih namesto skupnemu druženju z najino Ronjo in kužatom Bonotom posvetil sedenju za računalnikom.

KAZALO VSEBINE

1	UVOD	1
1.1	Opis problematike	1
1.2	Cilji in namen doktorske disertacije.....	3
1.3	Prenos teorije v uporabo	4
1.3.1	Območje testiranja	4
1.3.2	Oprema za izvajanje meritev.....	6
1.4	Obveščanje voznikov o potovalnih časih.....	9
2	POTOVALNI ČAS	12
2.1	Potreba po merjenju potovalnega časa.....	12
2.2	Definicija potovalnega časa	14
3	MERJENJE IN IZRAČUN POTOVALNEGA ČASA.....	21
3.1	Neposredno merjenje potovalnega časa	22
3.1.1	Identifikacija vozila na kontrolnih točkah	23
3.1.2	Sledenje vozil.....	26
3.2	Posredna ocena potovalnega časa	28
4	IZRAČUN POTOVALNEGA ČASA IZ NEPOSREDNIH LINIJSKIH MERITEV 31	
4.1	Pregled obstoječe literature in izvedenih raziskav na temo izračuna potovalnega časa iz neposrednih linijskih meritev	32
4.2	Porazdelitev potovalnih časov	37
4.2.1	Logaritemsko normalna porazdelitev.....	38
4.2.2	Preizkušanje skladnosti empirične porazdelitve z logaritemsko normalno porazdelitvijo	38
4.3	Robustna statistika	40
4.3.1	Osamelci.....	41
4.3.2	Robustna statistika	41

4.3.3	Lokalna stabilnost.....	42
4.3.4	Globalna stabilnost	42
4.3.5	Mere lege	42
4.3.6	Mere razpršenosti	44
4.4	Izračun potovalnega časa.....	48
4.4.1	Izločitev podvojenih vrednosti potovalnega časa.....	48
4.4.2	Izbira časovnega intervala zajema podatkov za pridobitev reprezentativnega vzorca potovalnih časov	49
4.4.3	Določevanje potovalnih časov podnevi.....	55
4.4.4	Določevanje potovalnih časov ponoči.....	59
4.4.5	Opis algoritma za določevanje potovalnih časov iz neposrednih linijskih meritev ..	60
4.4.6	Kalibracija algoritma	62
4.5	Preverjanje delovanja algoritma	63
4.5.1	Preverjanje delovanja algoritma za daljše časovno obdobje	63
4.5.2	Preverjanje delovanja algoritma v času izrednih dogodkov	65
4.6	Primerjava z obstoječimi algoritmi za določevanje potovalnega časa	72
4.6.1	Algoritem za določevanje potovalnih časov TransGuide.....	72
4.6.2	Algoritem za določevanje potovalnih časov Dion in Rakha	73
4.6.3	Algoritem za določevanje potovalnih časov Ma in Koutsopoulos	74
4.6.4	Primerjava algoritmov za določevanje potovalnih časov	75
4.6.5	Ugotovitve	87
5	POSREDNA OCENA POTOVALNEGA ČASA IZ TOČKOVNE EKSTRAPOLACIJE HITROSTI.....	89
5.1	Pregled obstoječe literature in izvedenih raziskav na temo posredne ocene potovalnega časa iz točkovne ekstrapolacije hitrosti.....	91
5.2	Določitev srednje prostorske hitrosti iz točkovnih merilnikov	94
5.2.1	Srednja časovna in srednja prostorska hitrost.....	94
5.2.2	Porazdelitev hitrosti.....	97
5.2.3	Časovni interval zajema podatkov za izračun srednje prostorske hitrosti osebnih vozil	

5.2.4	Izračun srednje prostorske hitrosti osebnih vozil.....	108
5.2.5	Določitev standardnega odklona harmonične sredine	108
5.3	Izračun reprezentativne vrednosti srednje prostorske hitrosti.....	109
5.3.1	Nihanja srednje prostorske hitrosti	109
5.3.2	Glajenje z drsečim povprečjem.....	110
5.3.3	Izračun reprezentativne vrednosti srednje prostorske hitrosti z glajenjem in upoštevanjem nihanj	111
5.3.4	Določitev reprezentativne vrednosti srednje prostorske hitrosti v času nasičenega in zgoščenega prometnega toka	114
5.4	Metode za oceno potovalnega časa na pododseku iz točkovnih meritev hitrosti ..	115
5.4.1	Metode interpolacije in ekstrapolacije hitrosti iz točkovnih merilnikov	116
5.4.2	Primerjava in uporabnost predstavljenih metod interpolacije in ekstrapolacije hitrosti	119
5.4.3	Predlagana metoda ekstrapolacije točkovnih meritev hitrosti na pripadajoč pododsek	120
5.5	Določitev vplivnega območja posameznega merilnega mesta	121
5.6	Ocena potovalnega časa na pododseku iz točkovne ekstrapolacije hitrosti.....	121
5.7	Ocena trenutnega potovalnega časa na odseku iz točkovne ekstrapolacije hitrosti	122
5.8	Primerjava potovalnega časa, ocenjenega s točkovno ekstrapolacije hitrosti z neposredno linijsko izmerjenim potovalnim časom.....	123
5.8.1	Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom	124
5.9	Študija primera.....	126
5.9.1	Območje izvajanja meritve	126
5.9.2	Vplivno območje posameznega merilnega mesta.....	126
5.9.3	Primerjava potovalnega časa, pridobljenega s točkovno ekstrapolacijo hitrosti, z neposredno linijsko izmerjenim potovalnim časom – rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom	128
5.9.4	Ocena trenutnega potovalnega časa na odseku iz točkovne ekstrapolacije hitrosti	135

6	DOLOČITEV TRENUTNEGA POTOVALNEGA ČASA Z ZDRUŽEVANJEM POTOVALNIH ČASOV PRIDOBLENIH IZ NEPOSREDNIH LINIJSKIH MERITEV IN TOČKOVNE EKSTRAPOLCIJE HITROSTI.....	139
6.1	Uvod	139
6.2	Problem časovne zakasnitve.....	140
6.3	Pregled obstoječe literature in izvedenih raziskav	141
6.3.1	Parametrični modeli.....	142
6.3.2	Neparametrični modeli	143
6.3.3	Hibridni modeli.....	145
6.3.4	Ugotovitve na podlagi literature	146
6.4	Splošno o združevanju podatkov iz različnih virov.....	147
6.4.1	Definicije in pomen združevanja podatkov	147
6.4.2	Namen združevanja podatkov	148
6.4.3	Konfiguracija merilnikov pri združevanju podatkov.....	149
6.4.4	Arhitektura združevanja podatkov.....	150
6.4.5	Glavne prednosti in pomanjkljivosti metod za združevanje podatkov	152
6.5	Regresijska analiza	153
6.5.1	Linearna regresija več spremenljivk.....	153
6.5.2	Preverjanje uspešnosti izvedene linearne regresije	155
6.5.3	Interpolacija in ekstrapolacija.....	159
6.6	Učenje algoritma.....	159
6.6.1	Modeliranje prometnega toka s prometno simulacijo	160
6.6.2	Ocenjevanje uspešnosti učenja	162
6.7	Združevanje podatkov iz točkovnih in linijskih meritev za oceno trenutnega potovalnega časa.....	165
6.7.1	Prostorska in časovna poravnava.....	166
6.7.2	Vhodni podatki algoritma za združevanje	167
6.7.3	Metodologija združevanja podatkov	171
6.8	Študija primerov	174
6.8.1	Preverjanje uspešnosti izvedene linearne regresije	175
6.8.2	Okvara tovornega vozila v predoru Trojane.....	178
6.8.3	Prometna nesreča v predoru Trojane	183

6.8.4	Dela na cesti na viaduktu Petelinjek	186
6.8.5	Zapora prehitevalnega pasu v predorih Trojane in Podmilj.....	188
6.8.6	Prometna nesreča v predoru Trojane	190
6.8.7	Delovanje algoritma v razmerah prostega prometnega toka.....	192
6.8.8	Ugotovitve na podlagi analize različnih izrednih dogodkov	193
6.8.9	Delovanje algoritma v primeru izpada enega od virov podatkov	195
7	ZAKLJUČKI.....	196
7.1	Neposredno merjenje potovalnega časa.....	196
7.2	Posredna ocena potovalnega časa	198
7.3	Združevanje podatkov.....	201
8	POVZETEK.....	204
9	SUMMARY.....	208
VIRI	216

KAZALO PREGLEDNIC

Preglednica 4-1: Primer zapisa izmerjenih potovalnih časov, potovalni čas ob upoštevanju omejitve je na območju testiranja 730 sekund.....	32
Preglednica 4-2: Podvajanje meritev iz različnih virov (zaznava istega vozila z dvema različnima tehnologijama).....	48
Preglednica 4-3: Podvajanje meritev iz istega vira (večkratno zaznavanje istega vozila z isto tehnologijo).....	49
Preglednica 4-4: Primerjava delovanja algoritmov (* predlagani algoritem je vzet kot referenčen, vendar ne nujno najboljši)	77
Preglednica 4-5: Nepravilno delovanje algoritma TransGuide v primeru preusmeritve na vzporedno cestno omrežje v času postavitve delovne zapore	82
Preglednica 4-6: Prva sprememba vrednosti potovalnega časa za manj kot 20 % glede na zadnji časovni interval izračuna	82
Preglednica 4-7: Pravilno delovanje predlaganega algoritma v primeru preusmeritve na vzporedno cestno omrežje v času postavitve delovne zapore	83
Preglednica 5-1: Klasifikacija vozil po razredih glede na nemški standard TLS.....	104
Preglednica 5-2: Vplivno območje posameznega merilnega mesta	127
Preglednica 5-3: Povprečni potovalni časi na obravnavanem odseku za obdobje pol leta, pridobljeni s točkovno ekstrapolacijo hitrosti	127
Preglednica 5-4: Razlike med potovalnimi časi pridobljenimi z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za 15. oktober 2013	133
Preglednica 5-5: Razlike med potovalnimi časi pridobljenimi z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za 16. oktober 2013	134
Preglednica 6-1: Primer scenarijev za simulacije.....	161
Preglednica 6-2: Prostorska in časovna poravnava podatkov	167
Preglednica 6-3: Določitev stopnje prometnega stanja	169
Preglednica 6-4: Primer vhodnih podatkov v algoritmu	171
Preglednica 6-5: Vhodni podatki za algoritem združevanja potovalnih časov iz točkovnih (rumeno) in linijskih (oranžno) meritev ter primer podaljšanih potovalnih časov na sedmem pododseku (rdeče). Vsi potovalni časi so v sekundah, PS predstavlja informacijo o prometnem stanju.....	172

Preglednica 6-6: Različni vhodni podatki za učenje algoritma.....	174
Preglednica 6-7: Determinacijski koeficient.....	175
Preglednica 6-8: Standardna napaka regresijskega modela.....	176
Preglednica 6-9: Preglednica ANOVA.....	177
Preglednica 6-10: Določitev vrednosti P	177

LIST OF TABLES

Table 4-1: Travel times recorded on the measurement section, by observing the speed limit the travel time is 730 s.....	32
Table 4-2: Duplication of measurements coming from various technologies.....	48
Table 4-3: Duplication of measurements coming from the same technology.....	49
Table 4-4: Comparison of performance of the algorithms (* proposed algorithm is taken as a reference not necessarily meaning it is the best)	77
Table 4-5: Incorrect response of TransGuide algorithm in case of traffic diversion	82
Table 4-6: TransGuide algorithm is not able to track sudden changes larger than 20 %	82
Table 4-7: Proper response from proposed algorithm in case of traffic diversion	83
Table 5-1: Vehicles' classification based on german standard TLS	104
Table 5-2: Detectors influence area.....	127
Table 5-3: Average travel time on the section for a period of six month, estimated by the extrapolation of point speed measurements.....	127
Table 5-4: Differences between travel times obtained by trajectory reconstruction for October 15, 2013	133
Table 5-5: Differences between travel times obtained by trajectory reconstruction for 16 th October 2013	135
Table 6-1: Traffic simulation scenarios.....	161
Table 6-2: Data for the spatial and temporal alignment	167
Table 6-3: Level of service estimation	169
Table 6-4: An example of algorithm input data	171
Table 6-5: Input data for travel time data fusion algorithm combining travel time estimates based on speed extrapolation (yellow) and direct measurements (orange) and an example of prolonged travel times on 7.th subsection (red). All times are in seconds, PS is information about the level of service.....	172
Table 6-6: Different input data for algorithm learning.....	174
Table 6-7: Determination coefficient	175
Table 6-8: Standard deviation of the regression model.....	176
Table 6-9: ANOVA table	177
Table 6-10: <i>P</i> -value determination.....	178

KAZALO SLIK

Slika 1-1: Primer obveščanja voznikov o potovalnih časih preko grafičnega prikazovalnika spremenljive prometno-informativne signalizacije.....	2
Slika 1-2: Območje testiranja.....	5
Slika 1-3: Kamere za samodejno razpoznavanje registrskih tablic nameščene na portalni konstrukciji nad voziščem.....	7
Slika 1-4: Primer naprav, ki uporabljajo tehnologijo »bluetooth«.....	7
Slika 1-5: Način določevanja potovalnih časov s pomočjo reidentifikacije naslovov »bluetooth« in antena za zaznavanje signala »bluetooth«	8
Slika 1-6: Mikrovalovne tehnologije ter namestitvev mikrovalovnega detektorja nad vozišče ..	9
Slika 1-7: Prikaz prometne vsebine o potovalnem času na shematskem vmesniku SCADA..	10
Slika 1-8: Obveščanje voznikov o potovalnem času v razmerah prostega prometnega toka ..	11
Slika 2-1: Vsakodnevno pojavljanje zastojev na avtocestni mreži je del našega vsakdana	12
Slika 2-2: Nadzorni center za upravljanje sistema za nadzor in vodenje prometa	14
Slika 2-3: Definicije potovalnega časa ter obveščanje voznikov (Soriguera, Rosas in Robusté, 2010)	15
Slika 2-4: Definicija povprečnega dejanskega potovalnega časa vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)	16
Slika 2-5: Definicija povprečnega potovalnega časa po prihodu vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)	17
Slika 2-6: Definicija povprečnega potovalnega časa ob odhodu vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)	18
Slika 2-7: Različne funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom upoštevane pri določevanju potovalnega časa na pododseku (Soriguera in Robusté, 2013)...	19

Slika 2-8: Obveščanje voznikov o potovalnem času preko spremenljive prometno-informativne signalizacije	20
Slika 3-1: Obstoječi sistemi za obveščanje uporabnikov o potovalnih časih	21
Slika 3-2: Aplikacija Potovalni časi	22
Slika 3-3: Določevanje potovalnih časov s sistemom za uparjanje registrskih tablic (Turner in sodelavci, 1998).....	24
Slika 3-4: Preizkušanje komponent sistema za samodejno identifikacijo vozil na severni ljubljanski obvoznici	25
Slika 3-5: Komerčni sistem za sledenje, komunikacijo in nadzor nad vozili (Turner in sodelavci, 1998).....	26
Slika 3-6: Določevanje potovalnega časa s sledenjem signala GPS (Turner in sodelavci, 1998)	27
Slika 3-7: Googlov interaktivni zemljevid s prikazom prometnih razmer na omrežju	28
Slika 3-8: Prikaz silhuete tovornega vozila, osebnega vozila in tovornega vozila s priklopnikom pri prevozu merilnega območja mikrovalovnega detektorja	29
Slika 3-9: Namestitev merilnikov za točkovno merjenje parametrov prometnega toka	30
Slika 4-1: Primerjava metod izločanja osamelcev (Kim in sodelavci, 2012).....	34
Slika 4-2: Porazdelitev potovalnih časov za različna obdobja v tednu	37
Slika 4-3: Porazdelitev potovalnih časov v prostem prometnem toku brez prisotnosti tovornih vozil	38
Slika 4-4: Primerjava med empirično in logaritemsko normalno porazdelitvijo	40
Slika 4-5: Rezultati testa Anderson-Darling in metode hi-kvadrat za primerjavo empirično pridobljene porazdelitve z logaritemsko normalno porazdelitvijo z uporabo programa Mathematica	40
Slika 4-6: Prisotnost osamelcev v meritvah potovalnega časa	41
Slika 4-7: Primerjava drseče mediane in drsečega povprečja	43
Slika 4-8: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa v primeru preusmeritve na vzporedno cestno omrežje	45
Slika 4-9: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa v primeru izrednega dogodka na AC	46
Slika 4-10: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa: jutranja konica v primerjavi s preostalim dnevom.....	47

Slika 4-11: Primerjava obveščanja voznikov s 40. centilom na podlagi $n = 40$ vozil in $t = 5$ minut v primeru zapora voznega pasu v predoru (Trojane) v času dopoldanskih prometnih obremenitev 9. maja 2013 (8:52)	51
Slika 4-12: Število pridobljenih meritev potovalnega časa znotraj petminutnih intervalov podnevi. Majhno število meritev je posledica zgodnje jutranje ure (5:00 - 5:15) prazničnega dne 2. maja 2013	52
Slika 4-13: Število pridobljenih meritev potovalnega časa znotraj petminutnih intervalov ponoči (20:30 - 5:30) za 19 noči meseca maja 2013	53
Slika 4-14: Število pridobljenih meritev potovalnega časa znotraj petnajst minutnih intervalov ponoči (20:30 - 5:30) za 19 noči meseca maja 2013	53
Slika 4-15: Nenadno povečanje prometnega pretoka ter padanje deleža tovornih vozil v jutranji konici 6. maja 2013	54
Slika 4-16: Razmerje med prometnim pretokom in številom zaznanih potovanj v času jutranje konice 6. maja 2013 (število zaznanih potovanj ni neposredno primerljivo s prometnim pretokom zaradi treh vmesnih priključkov)	55
Slika 4-17: Gostota porazdelitve potovalnih časov (zgoraj) ter potovalni časi različnih kategorij vozil (spodaj)	56
Slika 4-18: Vpliv različnih kategorij vozil na mediano potovalnih časov	57
Slika 4-19: 40. centil predstavlja vrednost potovalnega časa za vozila, ki upoštevajo omejitev hitrosti na odseku	58
Slika 4-20: Primerjava drsečega 40. centila in drseče mediane	58
Slika 4-21: Primerjava obveščanja voznikov na podlagi drsečega 40. centila in drseče mediane	59
Slika 4-22: Primerjava obveščanja ponoči na podlagi 40. in 10. centila	60
Slika 4-23: Nihanje obveščanja o potovalnem času za mesec maj 2013	64
Slika 4-24: Primerjava med reprezentativnim potovalnim časom za obveščanje, minimalnim izmerjenim potovalnim časom ter njuno razliko v času izrednega dogodka	66
Slika 4-25: Razlika med potovalnimi časi, o katerih smo voznika obvestili in tistimi, ki so jih vozila dejansko potrebovala za prevoz odseka	67
Slika 4-26: Obvozna pot po regionalni cesti (oranžno) in trasa avtoceste (modro)	68

Slika 4-27: Primer obveščanja voznikov o potovalnih časih preko grafičnega prikazovalnika spremenljive prometno-informativne signalizacije, nameščenim pred izvozom Vransko v smeri Ljubljane.....	68
Slika 4-28: Obveščanje o potovalnih časih med četrtkom 30. maja 2013 in ponedeljkom 3. junija 2013 (1-potovalni časi v času odprte avtoceste, 2-podaljšani potovalni časi ob sobotni jutranji konici, 3-podaljšan potovalni čas v nedeljo opoldne, 4-podaljšan potovalni čas v nedeljo zvečer, 5-zmanjšanje potovalnih časov ob odprtju avtoceste).....	69
Slika 4-29: Izmerjeni potovalni časi in obveščanje o potovalnih časih za obdobje od petka 31. maja do ponedeljka 3. junija 2013.....	70
Slika 4-30: Podaljšanje potovalnih časov ob zaprtju avtoceste (20:00) in preusmeritvi na vzporedno regionalno cesto.....	70
Slika 4-31: Naraščanje potovalnih časov v času aktivacije zapore.....	71
Slika 4-32: Zmanjšanje potovalnih časov ob ponovnem odprtju avtoceste ob 5. uri zjutraj....	71
Slika 4-33: Primerjava obveščanja in surovih podatkov v noči iz 5. na 6. junij 2013.....	72
Slika 4-34: Primerjava določevanja potovalnih časov z različnimi algoritmi (predlagani, TransGuide, Dion in Rakha, Ma and Koutsopoulos) za obdobje dveh mesecev.....	77
Slika 4-35: Robustno delovanje predlaganega algoritma ponoči glede na algoritem Dion in Rakha.....	78
Slika 4-36: Primerjava delovanja algoritmov za obdobje dveh noči (zgoraj) in podrobneje za eno noč (spodaj). Zaradi boljše predstavitve so potovalni časi zaokroženi na zgornjo minuto.	79
Slika 4-37: Primerjava med algoritmi v primeru prometne nesreče, del v predoru in zapore voznega pasu zaradi okvare vozila.....	81
Slika 4-38: Algoritem TransGuide zaradi nenadne spremembe v potovalnih časih, večje od 20 % glede na predhodni časovni interval, le-te ni bil sposoben zaznati – informacija za voznike zato 7 ur ni bila na voljo.....	84
Slika 4-39: Preusmeritev prometa na vzporedno državno cesto.....	84
Slika 4-40: Primerjava delovanja algoritmov v primeru majhnega vzorca v času izrednega dogodka (prva slika) ter v času razmer prostega prometa na praznični dan (druga in tretja slika).....	86
Slika 4-41: Primerjava delovanja algoritmov v primeru zmanjšanja velikosti vzorca za 90 %.....	86

Slika 4-42: Razpršitev potovalnih časov med zastojem. Uporaba drsečega povprečja namesto drsečega centila vodi k do 30 % podaljšanim potovalnim časom.....	87
Slika 4-43: Razpršitev izmerjenih potovalnih časov okoli reprezentativne vrednosti potovalnega časa.....	88
Slika 5-1: Točkovno merjenje karakteristik prometnega toka z mikrovalovnim detektorjem	90
Slika 5-2: Prikaz časa preživetega v gibanju in v zastoju (Turner in sodelavci, 1998)	92
Slika 5-3: Točkovno (levo) in prostorsko (desno) merjenje hitrosti.....	95
Slika 5-4: Časovno-prostorski diagram.....	97
Slika 5-5: Primerjava srednje časovne in srednje prostorske hitrosti (Sever, 2002).....	97
Slika 5-6: Porazdelitev hitrosti vseh vozil na merilnem mestu ter primer hitrosti, za katero ne moremo enolično določiti, kateremu razredu vozil pripada	98
Slika 5-7: Porazdelitve hitrosti vseh vozil na točkovnih merilnih mestih med Vranskim in Blagovico v smeri Ljubljane, kjer je omejitev hitrosti 130 km/h	99
Slika 5-8: Porazdelitve hitrosti vseh vozil na točkovnih merilnih mestih med Vranskim in Blagovico v smeri Ljubljane, kjer je omejitev hitrosti 100 km/h	100
Slika 5-9: Povprečne vrednosti hitrosti vseh vozil na zaporednih merilnih mestih v primerjavi z omejitvijo hitrosti za obdobje med 20. in 30. junijem 2013	101
Slika 5-10: Izmerjene vrednosti hitrosti vseh vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 03D (omejitev hitrosti 130 km/h) za jutranje obdobje.....	102
Slika 5-11: Porazdelitev hitrosti vseh vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 03D (omejitev hitrosti 130 km/h).....	103
Slika 5-12: Porazdelitev hitrosti za različne kategorije vozil na merilnem mestu SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013	104
Slika 5-13: Porazdelitev hitrosti za osebna in tovorna vozila na merilnem mestu SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013	105
Slika 5-14: Porazdelitev hitrosti osebnih vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013	105
Slika 5-15: Porazdelitev hitrosti osebnih vozil na voznem in prehitevalnem pasu posameznih merilnih mest za obdobje med 22. in 23. julijem 2013.....	107
Slika 5-16: Nihanje srednje prostorske hitrosti v zaporednih časovnih intervalih ob pojavu izrednega dogodka	110

Slika 5-17: Glajenje srednje prostorske hitrosti	111
Slika 5-18: Primerjava srednje prostorske, glajene in reprezentativne hitrosti ob pojavu izrednega dogodka (kratkotrajna zapora predora Jasovnik 13. novembra 2013).....	113
Slika 5-19: Povezava med stopnjami prometnega stanja sistema za nadzor in vodenje prometa ter stopnjami pretoka	114
Slika 5-20: Razmere nasičenega (PS 3) oz. zgoščenega prometnega toka (PS 4).....	115
Slika 5-21: Gortočna konstantna ekstrapolacija iz točkovnih merilnikov.....	116
Slika 5-22: Konstantna interpolacija med točkovnimi merilniki z uporabo uteženega povprečja	117
Slika 5-23: Linearna interpolacija med točkovnimi merilniki.....	117
Slika 5-24: Odsekoma konstantna ekstrapolacija iz točkovnih merilnikov - algoritem srednje vrednosti	118
Slika 5-25: Kvadratna interpolacija med točkovnimi merilniki	119
Slika 5-26: Metoda modificirane odsekoma konstantne ekstrapolacije	121
Slika 5-27: Merilnik, merilno mesto in vplivno območje merilnega mesta	121
Slika 5-28: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom (Soriguera in Robusté, 2011).....	125
Slika 5-29: Točkovna merilna mesta na avtocestnem odseku med Vranskim in Blagovico..	126
Slika 5-30: Prostorska poravnava obeh meritev na odseku: območje neposredne linijske meritve potovalnega časa (zgoraj) ter območje točkovne ekstrapolacije hitrosti (spodaj).....	128
Slika 5-31: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času razmer prostega prometnega toka	130
Slika 5-32: Območje postavitve delovne zapore	131
Slika 5-33: Reprezentativna vrednost srednje prostorske hitrosti na merilnem mestu 14D v času trajanja zapore voznega pasu med 15. in 16. oktobrom 2013	131
Slika 5-34: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času zgoščenega prometnega toka zaradi delovne zapore dne 15. oktobra 2013 ob 6:44	133
Slika 5-35: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času zgoščenega prometnega toka zaradi delovne zapore dne 16. oktober 2013 ob 7:05	134

Slika 5-36: Primerjava potovalnega časa določenega iz neposredne linijske meritve in točkovne ekstrapolacije hitrosti v času izrednega dogodka.....	136
Slika 5-37: Lokacija izrednega dogodka pred predorom Jasovnik	136
Slika 5-38: Primerjava med potovalnim časom ob odhodu vozila iz neposredne linijske meritve, trenutnim potovalnim časom iz točkovne ekstrapolacije hitrosti in potovalnim časom ob prihodu vozila iz neposredne linijske meritve	137
Slika 6-1: Nadzorni center sistema za nadzor in vodenje prometa v Ljubljani	140
Slika 6-2: Napaka v oceni potovalnega časa ob uporabi neposredne linijske meritve - problem časovne zakasnitve.....	141
Slika 6-3: Dopolnjujoča konfiguracija merilnikov	149
Slika 6-4: Konkurenčna konfiguracija merilnikov.....	149
Slika 6-5: Zadružna konfiguracija merilnikov	150
Slika 6-6: Centralizirana arhitektura združevanja podatkov.....	150
Slika 6-7: Decentralizirana arhitektura združevanja podatkov	151
Slika 6-8: Porazdeljena arhitektura združevanja podatkov.....	151
Slika 6-9: Predvidene koristi združevanja podatkov glede na število in natančnost merilnikov (Nahin in Pokoski, 1980)	152
Slika 6-10: Izsek iz simulacije	162
Slika 6-11: Prostorska poravnava neposredne linijske meritve (zgoraj) in posredne ocene z ekstrapolacijo (spodaj) med Vranskim in Blagovico.....	166
Slika 6-12: Prostorska poravnava linijske in točkovnih meritev	166
Slika 6-13: Grafični prikaz določitve stopnje prometnega stanja.....	170
Slika 6-14: Algoritem za združevanje podatkov.....	173
Slika 6-15: Standardizirane vrednosti rezidualov	176
Slika 6-16: Nastanek zastoja pred predorom zaradi okvare tovornega vozila v predoru Trojane	178
Slika 6-17: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov	179
Slika 6-18: Primerjava koeficienta korelacije za različne učne množice.....	180
Slika 6-19: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	180
Slika 6-20: Primerjava korena povprečne kvadratne napake (RMSE) za različne učne množice	181

Slika 6-21: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu ter dobro viden vpliv časovne zakasnitve neposredno linijsko določenega potovalnega časa.....	182
Slika 6-22: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov	183
Slika 6-23: Prometna nesreča v predoru Trojane	183
Slika 6-24: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov	184
Slika 6-25: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	184
Slika 6-26: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu	185
Slika 6-27: Zmanjšan vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov	185
Slika 6-28: Dela na preHITEVALNEM pasu	186
Slika 6-29: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov	186
Slika 6-30: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	187
Slika 6-31: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu	187
Slika 6-32: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov	188
Slika 6-33: Dela na VOZnem pasu	188
Slika 6-34: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	189
Slika 6-35: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu	189
Slika 6-36: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov	190
Slika 6-37: Prometna nesreča v predoru Trojane	190
Slika 6-38: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	191

Slika 6-39: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu.....	191
Slika 6-40: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov	192
Slika 6-41: Delovanje predlaganega algoritma v času razmer prostega prometnega toka	193
Slika 6-42: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov	193
Slika 6-43: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov	194
Slika 6-44: Primerjava koeficienta korelacije za različne učne množice.....	194
Slika 6-45: Primerjava korena povprečne kvadratne napake (RMSE) za različne učne množice	195

LIST OF FIGURES

Figure 1-1: Travel time information provided via Variable Message Sign.....	2
Figure 1-2: Test site.....	5
Figure 1-3: Automatic license plate recognition cameras mounted on the structure above the road.....	7
Figure 1-4: Devices using bluetooth technology.....	7
Figure 1-5: Estimating travel times by the use of bluetooth signal and bluetooth antenna.....	8
Figure 1-6: Microwave technologies and microwave detector mounted above the road surface.....	9
Figure 1-7: Variable Message Sign content as shown on SCADA.....	10
Figure 1-8: Travel time information in free flowing traffic.....	11
Figure 2-1: Daily congestion phenomena is part of our every day life.....	12
Figure 2-2: Traffic Control Center as a part of the Traffic Management System.....	14
Figure 2-3: Travel time definitions and drivers' informing (Soriguera, Rosas and Robusté, 2010).....	16
Figure 2-4: True average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013).....	16
Figure 2-5: Arrival based average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013).....	17
Figure 2-6: Departure based average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013).....	18
Figure 2-7: Different trajectories considered in the link travel time definitions (Soriguera in Robusté, 2013).....	19
Figure 2-8: Travel time information provided via Variable Message Sign.....	20
Figure 3-1: Existing travel time information systems.....	21
Figure 3-2: Travel time application.....	22
Figure 3-3: Travel time estimation from license plate recognition (Turner et al., 1998).....	24
Figure 3-4: Testing Automatic Vehicle Identification system.....	25

Figure 3-5: Commercial fleet management system (Turner et al., 1998)	26
Figure 3-6: Travel time estimation from GPS tracking (Turner et al., 1998)	27
Figure 3-7: Google maps interactive traffic layer	28
Figure 3-8: Silhouette of the heavy vehicle, personal car and heavy vehicle with trailer as detected by the microwave detector	29
Figure 3-9: Traffic parameters measurement site	30
Figure 4-1: Different methods for elimination of outliers (Kim et al., 2012).....	34
Figure 4-2: Travel times distribution for different periods during the week	37
Figure 4-3: Travel times distribution during free flow traffic conditions with absence of heavy vehicles.....	38
Figure 4-4: Comparison between empirical and lognormal distribution	40
Figure 4-5: Results of Anderson-Darling test and hi-squared method for comparing empirical and lognormal distribution using Mathematica	40
Figure 4-6: Presence of outliers in travel time measurements	41
Figure 4-7: Comparison between running median and running average	43
Figure 4-8: Comparison between number of measurements, median absolute deviation (MAD) and median during re-routing of traffic on a parallel road.....	45
Figure 4-9: Comparison between number of measurements, median absolute deviation (MAD) and median during incident situation	46
Figure 4-10: Comparison between number of measurements, median absolute deviation (MAD) and median: morning peak period Vs rest of the day	47
Figure 4-11: Comparison between informing the drivers with 40 th percentile based on n = 40 vehicles Vs t= 5 min in case of a lane closure in tunnel Trojane on May 9, 2013 (8:52).....	51
Figure 4-12: Number of travel times measured in 5 min intervals during the day. Low number of measurements is a consequence of a national holiday on May 2, 2013 (5:00 – 5:15)	52
Figure 4-13: Number of travel times measured in 5 min intervals during the 19 nights in May, 2013.....	53
Figure 4-14: Number of travel times measured in 15 min intervals during the 19 nights in May, 2013.....	53
Figure 4-15: A sudden increase in traffic flow and reduced share of heavy vehicles during the morning peak period on May 6, 2013	54

Figure 4-16: Ratio between traffic flow and number of travel times captured during the morning peak period on May 6, 2013 (the number of travel times captured can not be directly compared to traffic flow due to intermediate junctions)	55
Figure 4-17: Probability density function of travel times (above) and travel times of various vehicle categories (below)	56
Figure 4-18: Influence of various categories of vehicles on the median of travel time	57
Figure 4-19: Percentile rank that best describes personal cars driving by the posted speed limit	58
Figure 4-20: Comparison between running 40 th percentile and running median	58
Figure 4-21: Informing the drivers about travel times based on running 40 th percentile Vs running median	59
Figure 4-22: Informing the drivers about travel times based on 40 th percentile Vs 10 th percentile	60
Figure 4-23: Informing the drivers about travel times in the month of May, 2013.....	64
Figure 4-24: Comparison between the representative values of travel time, lowest measured travel times and the difference between both in case of an incident	66
Figure 4-25: Difference between provided travel time information and experienced travel time	67
Figure 4-26: Re-routing during road works via regional road (orange)	68
Figure 4-27: Travel time information provided via Variable Message Sign located in front of Vransko, direction Ljubljana	68
Figure 4-28: Travel times during road works and diversion via regional road over the weekend	69
Figure 4-29: Measured data and the data provided for travel time dissemination from Friday May 31 until Monday June 3, 2013	70
Figure 4-30: Prolonged travel times after closing the highway (8 pm) and traffic diversion to a regional road	70
Figure 4-31: Increase of travel times during the activation of the road closure	71
Figure 4-32: Decrease of travel times after re-opening of the highway at 5 am	71
Figure 4-33: Comparison between measured data and the disseminated travel time data during the night from June 5-6, 2013.....	72

Figure 4-34: Travel time estimation by various algorithms (proposed, TransGuide, Dion and Rakha, Ma and Koutsopoulos) for a period of two months	77
Figure 4-35: Robust travel time estimation by proposed algorithm compared to Dion and Rakha algorithm	78
Figure 4-36: Comparing the performance of the algorithms during free flow conditions for a period of two days (above) and during the night (below). Due to easier representation the travel times estimated by the algorithms are rounded to the upper minute.	79
Figure 4-37: Comparison between algorithms in the case of an accident, road works in the tunnel and lane closure due to heavy vehicle breakdown	81
Figure 4-38: Proper response from the proposed algorithm and inability to track sudden changes in travel times by TransGuide algorithm	84
Figure 4-39: Re-routing via regional road	84
Figure 4-40: Comparison of the algorithms in case of low sampling rates during an event (first figure) and during free flow conditions on a national holiday day (second and third figure) .	86
Figure 4-41: Comparison of the algorithms in case of a reduction of the sample size for 90 %	86
Figure 4-42: Dispersion of travel times during congestion. Using running average instead of running percentile results in up to 30 % longer estimated travel times.	87
Figure 4-43: Dispersion of travel times around the representative value of travel time.....	88
Figure 5-1: Microwave detector measuring traffic flow parameters	90
Figure 5-2: Illustration of running time and stopped delay time (Turner et al., 1998).....	92
Figure 5-3: Spot (left) and linear (right) speed measurement.....	95
Figure 5-4: Time-space diagram	97
Figure 5-5: Comparison of time-mean speed and space-mean speed (Sever, 2002)	97
Figure 5-6: Speed distribution of all vehicles and an example of the speed measurement for which it could not be said to which vehicle's class it belongs	98
Figure 5-7: Speed distribution for different locations with speed limit 130 km/h.....	99
Figure 5-8: Speed distribution for different locations with speed limit 100 km/h.....	100
Figure 5-9: Average speeds on consecutive measurement sites	101
Figure 5-10: Measured speeds on both lanes for the morning peak period on the driving and overtaking lane of the VMS 03D (speed limit 130 km/h) for the morning period	102
Figure 5-11: Speed distribution on both lanes by VMS 03D for speed limit 130 km/h.....	103

Figure 5-12: Speed distribution for different vehicle classes (speed limit 130 km/h) between July 10 - 12, 2013	105
Figure 5-13: Speed distribution for personal cars and heavy vehicles (speed limit 130 km/h) between July 10 - 12, 2013	105
Figure 5-14: Personal cars speed distribution for both lanes (speed limit 130 km/h) between July 10 - 12, 2013	106
Figure 5-15: Personal cars speed distribution for different locations between July 22 - 23, 2013	107
Figure 5-16: Space-mean speed fluctuations over time in case of an incident.....	110
Figure 5-17: Space-mean speed smoothing	111
Figure 5-18: Comparison between space-mean speed, smoothed speed and representative value of speed for an incident situation (short term tunnel closure on November 13, 2013)	113
Figure 5-19: Relationship between traffic state and flow state	114
Figure 5-20: Level of service E (PS 3) and F (PS 4).....	115
Figure 5-21: Upstream constant extrapolation from point detectors.....	116
Figure 5-22: Constant interpolation between point detectors using weighted average.....	117
Figure 5-23: Linear interpolation between detectors.....	117
Figure 5-24: Piecewise constant extrapolation from detectors - midpoint algorithm	118
Figure 5-25: Quadratic interpolation between detectors	119
Figure 5-26: Modified piecewise constant extrapolation	121
Figure 5-27: Detector, measurement site and detectors influence area.....	121
Figure 5-28: Trajectory reconstruction process (Soriguera and Robusté, 2011).....	125
Figure 5-29: Point measurements on the highway section between Vransko and Blagovica	126
Figure 5-30: Measured travel time (above) versus estimated travel time (below): area of coverage.....	128
Figure 5-31: Trajectory reconstruction for free flow traffic.....	130
Figure 5-32: Road works area	131
Figure 5-33: Representative value of space-mean speed on the measurement site 14D during road works between October 15-16, 2013.....	131
Figure 5-34: Trajectory reconstruction for dense traffic due to road works on October 15, 2013 at 6:44	133

Figure 5-35: Trajectory reconstruction for dense traffic due to road works on October 16, 2013 at 7:05.....	134
Figure 5-36: Comparison between measured and estimated travel times in case of an incident	136
Figure 5-37: Location of the incident in front of the tunnel Jasovnik	136
Figure 5-38: Comparison between departure based, instantaneous and arrival based travel times	137
Figure 6-1: Traffic management and control center in Ljubljana	140
Figure 6-2: Error in travel time estimation while using measured travel times - time-lag problem	141
Figure 6-3: Complementary detector configuration.....	149
Figure 6-4: Competitive detector configuration.....	149
Figure 6-5: Cooperative detector configuration.....	150
Figure 6-6: Centralized fusion architecture	150
Figure 6-7: Decentralized fusion architecture.....	151
Figure 6-8: Distributed fusion architecture	151
Figure 6-9: Expected benefits of data fusion in relation to the number and accuracy of detectors (Nahin and Pokoski, 1980).....	152
Figure 6-10: Simulation scenario	162
Figure 6-11: Spatial alignment of measured travel time (above) and travel time estimated from point speed measurements (below)	166
Figure 6-12: Spatial alignment of section and point measurements	166
Figure 6-13: Level of service estimation	170
Figure 6-14: Data fusion algorithm.....	173
Figure 6-15: Standardized residuals.....	176
Figure 6-16: Congestion in front of the tunnel due to heavy vehicle breakdown in tunnel Trojane	178
Figure 6-17: Comparing coefficient of correlation for different data fusion architectures ...	179
Figure 6-18: Comparing coefficient of correlation for different learning sets	180
Figure 6-19: Comparing RMSE for different data fusion architectures	180
Figure 6-20: Comparing RMSE for different learning sets	181

Figure 6-21: Comparing measured travel time with departure based travel time with evident time-lag of the measured travel time	182
Figure 6-22: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources.....	183
Figure 6-23: Accident in tunnel Trojane	183
Figure 6-24: Comparing coefficient of correlation for different data fusion architectures	184
Figure 6-25: Comparing RMSE for different data fusion architectures.....	184
Figure 6-26: Comparing measured travel time with departure based travel time	185
Figure 6-27: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources.....	186
Figure 6-28: Road works on left lane	186
Figure 6-29: Comparing coefficient of correlation for different data fusion architectures	186
Figure 6-30: Comparing RMSE for different data fusion architectures.....	187
Figure 6-31: Comparing measured travel time with departure based travel time	187
Figure 6-32: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources.....	188
Figure 6-33: Road works on right lane.....	188
Figure 6-34: Comparing RMSE for different data fusion architectures.....	189
Figure 6-35: Comparing measured travel time with departure based travel time	189
Figure 6-36: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources.....	190
Figure 6-37: Accident in Trojane tunnel	190
Figure 6-38: Comparing RMSE for different data fusion architectures.....	191
Figure 6-39: Comparing measured travel time with departure based travel time	191
Figure 6-40: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources.....	192
Figure 6-41: Performance of the proposed algorithm during free-flow conditions	193
Figure 6-42: Comparing coefficient of correlation for different data fusion architectures	193
Figure 6-43: Comparing RMSE for different data fusion architectures.....	194
Figure 6-44: Comparing coefficient of correlation for different learning sets	194
Figure 6-45: Comparing RMSE for different learning sets.....	195

OKRAJŠAVE

ABC	Avtomatsko Brezgotovinsko Cestninjenje
DARS	Družba za Avtoceste v Republiki Sloveniji
GPS	Global Positioning System je globalni sistem pozicioniranja
HCM	Highway Capacity Manual je ameriški priročnik za kapacitetne analize
ITS	Inteligentni Transportni Sistemi
MAC naslov	Media Access Control naslov je identifikacijska številka naprave bluetooth
PIC	Prometno-Informacijski Center
PS	Prometno Stanje
RDS-TMC	Radio Data System - Traffic Message Channel je tehnologija za prenos prometno-potovalnih informacij preko radijskih signalov za informiranje uporabnikov na območju mreže avtocest in državnih cest
SCADA	Supervisory Control And Data Acquisition je skupno ime za sisteme, ki so namenjeni nadzoru in krmiljenju različnih tehnoloških procesov z računalnikom
SNVP	Sistem za Nadzor in Vodenje Prometa
SPIS	Spremenljiva Prometno-Informativna Signalizacija
TLS	Technische Lieferbedingungen für Streckenstationen so nemški standardi za periferno obcestno opremo

SLOVAR STROKOVNIH BESED IN TUJK

agregacija	združitev, spojitev, kopičenje
algoritem	navodilo, ki določa vrsto in zaporedje operacij v računskem postopku
analitičen	nanašajoč se na analizo
analogen	podoben
aproksimacija	približna ocena
Bluetooth	varna brezžična tehnologija za povezovanje različnih digitalnih elektronskih naprav na razdalji do nekaj metrov, imenovana tudi modri zob
centil	točka, ki deli statistično populacijo na enake dele
detekcija	zaznava
determinacija	določitev
disperzija	razpršenost oz. variacija
ekstrapolacija	prenos vrednosti podatkov, spoznanj iz znanega dela česa v neznani del
empiričen	ki temelji predvsem na čutnem dožemanju, opazovanju, izkustven
evalvacija	ocena, ovrednotenje
evolucija	postopno spreminjanje česa, razvoj
faktor	kar deluje, vpliva na kaj ali povzroča določeno dogajanje
fuzija	združitev
hierarhija	razvrstitev po položaju, funkcijah, pomembnosti
hipoteza	nedokazana, zgolj verjetna trditev, domneva
homogen	enovit, enoten
integracija	združevanje, povezovanje posameznih enot, delov v večjo celoto
interpolacija	računanje vrednosti funkcije v kaki točki na intervalu, če so znane njene vrednosti na koncih intervala
interpretacija	razlaga, tolmačenje
interval	čas med koncem in ponovnim nastopom kakega pojava, premor
iteracija	računanje, pri katerem se ponavlja vstavljanje približnega rezultata, da se s tem približuje pravemu rezultatu
kalibracija	umerjanje
klasifikacija	razvrstitev, razporeditev česa glede na enake ali podobne lastnosti
kognitiven	spoznaven
kompenzirati	nadomestiti, nadoknaditi
komplementaren	dopolnilen
konfiguracija	izoblikovanost, oblikovitost
kooperativen	zadružen
korelacija	medsebojna odvisnost, soodvisnost
metodologija	skupek metod, ki se uporabljajo pri raziskovanju
mediana	vrednost nekega zaporedja števil, ki razdeli števila, razvrščena po velikosti, na dve enaki polovici po številu elementov

mikrovalovni detektor	točkovni merilnik, ki z uporabo radarske, ultrazvočne in infrardeče
modifikacija	komponente meri karakteristike prometnega toka
osamelci	sprememba, preoblikovanje, prilagoditev
parameter	vrednost opazovanja, ki bistveno odstopa od vzorca večine ostalih opazovanj
prom. tok »stop&go«	konstanta ali spremenljivo število, ki ima v določeni funkcijski povezavi viden pomen
recipročen	stanje v času zgoščenega prometnega toka, ko vozila del časa mirujejo, del časa pa se premikajo z nizkimi hitrostmi
redukcija	v tem primeru mišljeno kot recipročna (obratna) vrednost ulomka
redundanca	zmanjšanje, omejitvev
referenčen	identično podvajanje sredstev
regresija	nanašajoč se na referenco
reidentifikacija	odnos med odvisno in neodvisnimi spremenljivkami
rekonstrukcija	identifikacija istega objekta na dveh zaporednih lokacijah
reprezentativen	iz posameznega podatka na podlagi sklepanja predstaviti si kako celoto
robustna statistika	ki v najvišji meri posreduje lastnosti, značilnosti koga, česa
stohastičen	statistična metoda, ki uporablja cenilke, na katere ne vpliva prisotnost osamelcev
trend	naključen, slučajni
variabilnost	značilnost pojava glede na spreminjanje v daljšem časovnem obdobju
varianca	spremenljivost, nestalnost
	povprečna vrednost kvadratov odklonov spremenljivk od aritmetične sredine

1 UVOD

»Najuspešnejši človek je tisti, ki ima na voljo najboljše informacije.«

- Benjamin Disraeli

1.1 Opis problematike

Gospodarski razvoj in sodoben način življenja ljudi, ki iz različnih vzrokov spodbuja mobilnost, nezadržno vplivata na prometno rast motornega cestnega prometa in število potovanj. Kljub intenzivni gradnji in posodabljanju cestne infrastrukture ni mogoče v vsakem trenutku zagotoviti prostega prometnega toka. V preteklosti se je problematiko reševalo z gradnjo nove cestne infrastrukture ali pa z razširitvijo obstoječih prometnih povezav. Iz prostorskih in ekonomskih razlogov ter neugodnih vplivov na okolje tega ni smiselno početi v nedogled.

Upravljanje prometa danes predstavlja zelo aktualno temo. Zaradi ekspanzivnega razvoja na vseh področjih v zadnjih letih se je prometna aktivnost na cestah povečala do fizičnih meja. Uspešno vodenje prometa in upravljanje prometnih sistemov sta postala ključ do uspešnega upravljanja cestne mreže v domeni posameznega upravljavca, ki hkrati zagotavljata optimizirano uporabo dane infrastrukture.

V razvitih državah poskušamo problem prevelikih prometnih obremenitev rešiti z razvojem in uvedbo inteligentnih transportnih sistemov (ITS), s katerimi je omogočena optimalna izkoriščenost obstoječega cestnega omrežja. Razvoj novih tehnologij omogoča nove načine komuniciranja in zbiranja karakteristik prometnega toka z uporabo različnih tehnologij ITS. Pri vodenju prometa je bilo že večkrat dokazano, da lahko s sistemi ITS izboljšamo izkoriščenost cestnega omrežja, zagotovimo večjo prometno varnost in boljšo informiranost voznikov, kar ima za posledico optimalno izbiro poti pri prevozu potnikov in tovora. Vse navedeno zahteva sistematično in pravočasno obveščanje udeležencev v prometu o dogodkih, ki vplivajo na njihovo mobilnost.

Za voznike, cestne operaterje in prometne inženirje predstavlja podatek o potovalnem času najbolj uporabno informacijo pri načrtovanju potovanja (Palen, 1997). Informacija o predvidenem potovalnem času vzdolž avtocestnega odseka z zgoščenim prometnim stanjem je za voznike najbolj uporabna prometna informacija, na podlagi katere lahko optimizirajo in prilagodijo svoje potovanje (Bar-Gera, 2007). Informacija o potovalnem času pa ni pomembna le za voznike, temveč tudi za upravljavce avtocestnega omrežja, ker predstavlja kvantitativno osnovo za oceno uspešnosti odvijanja prometnega toka na prometnem omrežju in je zato kazalec uspešnosti prometnih strategij, uporabljamo pa jo lahko tudi kot zanesljiv kazalec nastanka zastojev (Berta and Török, 2010). Potovalni čas bo v prihodnje vsekakor postal ključni vhodni podatek modernih sistemov za nadzor in vodenje prometa.



Slika 1-1: Primer obveščanja voznikov o potovalnih časih preko grafičnega prikazovalnika spremenljive prometno-informativne signalizacije

Figure 1-1: Travel time information provided via Variable Message Sign

V splošnem obstajata dve možnosti ocene potovalnega časa na odseku avtoceste: prva možnost je neposredno merjenje, druga možnost pa posredna ocena (Yeon in sodelavci, 2008). Neposredno meritev predstavlja merjenje časa, ki ga izbrano vozilo potrebuje za prevoz od točke A do točke B. Čas potovanja med dvema točkama lahko izmerimo z reidentifikacijo vozila na teh dveh točkah. Alternativa neposredni meritvi je posredna ocena potovalnega časa iz izmerjenih spremenljivk prometnega toka, kot sta hitrost in pretok, pridobljenih iz točkovnih merilcev in njihovi ekstrapolaciji na pripadajoč odsek izvajanja meritve. Tako pri neposrednem merjenju, kot tudi pri posredni oceni, se pojavijo težave v samem postopku določanja potovalnega časa.

Neposredno izmerjeni potovalni čas je meritev izvedena na podlagi funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v prostoru in času, pri čemer je za izvedbo meritve potrebno, da vozilo dokonča svoje potovanje. Po drugi strani je posredna ocena ponavadi pridobljena na podlagi točkovne meritve, ki jo nato ekstrapoliramo v prostor in tako ni pridobljena na podlagi funkcijske zveze med opravljeno potjo vozila in njegovim potovalnim časom. Glavni namen sistema obveščanja uporabnikov o potovalnih časih je vozniku napovedati, koliko časa bo potreboval za prevoz odseka, na katerega vstopa. Sistem podajanja informacije o potovalnih časih, delujoč v trenutnem času, mora tako vozniku ponuditi informacijo o času potovanja na izbranem odseku v prihodnosti. Zaradi velikega števila faktorjev, ki vplivajo na obnašanje prometnega toka je v realnih okoliščinah to lahko zelo zahtevna naloga.

Najpreprostejša metoda za merjenje potovalnih časov na določenem odseku avtoceste je identifikacija vozila na začetni in končni točki izbranega odseka in meritev časa, ki ga je vozilo potrebovalo za prevoz omenjenega odseka. Vendar samodejna identifikacija vozila ni trivialna naloga: vsaj do današnjih dni ni bila. Merjenje potovalnih časov je bilo v preteklosti zaradi pomanjkanja ustreznih tehnologij zelo zamudno ter drago, obenem pa vzorci zajema niso predstavljali zadostne količine informacij in reprezentativnega vzorca, ki bi cestnim operaterjem omogočal podajanje prometno-potovalnih informacij v trenutnem času. Z na novo pridobljenimi znanji s področja telekomunikacij, mikrovalovnih tehnologij ter strojnega vida je prepoznavanje karakteristik objektov v prostem prometnem toku postalo izvedljivo. Dela, za katera je bilo v pionirskih časih raziskovanja prometa potrebna velika ekipa ljudi, rezultati pa so bili znani šele po naknadni analizi, sedaj v opravlja visoko zmogljiva računalniška oprema z uporabo telekomunikacijskih poti, ki omogočajo prenos informacij na poljubno centralno lokacijo. Potovalni časi, izmerjeni s sistemom reidentifikacije vozila na dveh zaporednih točkah, vsebujejo določeno časovno zakasnitev glede na dejanski potovalni čas voznika, ki na odsek šele vstopa. V primeru uporabe neposredno izmerjenega potovalnega časa, pridobljenega z reidentifikacijo vozila, moramo upoštevati napako, ki je posledica časovne zakasnitve, kar je problematično predvsem v času nastajanja zastojev.

Prednost meritev, pridobljenih iz točkovnih merilnikov, je možnost določitve resničnega potovalnega časa s pomočjo virtualne meritve za posamezno vozilo, še preden le-ta konča svoje potovanje. Tako na eni strani neposredno izmerjen potovalni čas predstavlja natančno informacijo s časovno zakasnitvijo, na drugi strani pa posredna ocena iz točkovnih meritev hitrosti predstavlja takojšnjo informacijo z manjšo prostorsko natančnostjo.

Situacija v kateri imamo na voljo različne tehnologije za pridobivanje prometnih podatkov, razne algoritme z različnimi natančnostmi, različno prostorsko vplivno območje posameznega merilnika podatkov in različne časovne okvire, predstavlja ugodno okolje za vzpostavitev sistema združevanja podatkov. Vse predhodno opisano vodi k ideji o dopolnjevanju obeh merjenj in razvoju metodologije ter algoritma za združevanje podatkov, ki bo združil lastnosti posamezne meritve v kombinacijo z večjo natančnostjo.

1.2 Cilji in namen doktorske disertacije

Cilj doktorske disertacije je bil razviti algoritem za sprotno določevanje potovalnih časov, ki bi bil sposoben vozniku nuditi kar se da dobro informacijo o potovalnem času na avtocestnem odseku. Prvi cilj disertacije je bil razviti algoritem za določevanje potovalnega časa iz neposredne linijske meritve ter algoritma, ki na podlagi točkovnih meritev hitrosti in njihove ekstrapolacije v prostor določa potovalne čase na pododsekih. Drugi cilj disertacije pa je bil razviti algoritem za določevanje potovalnih časov, ki združuje ugodne lastnosti neposredno izmerjenega potovalnega časa in potovalnega časa, ocenjenega iz točkovnih meritev hitrosti. Prednost neposredno izmerjenega potovalnega časa je njegova prostorska natančnost, medtem ko ugodno lastnost posredne ocene iz točkovne meritve hitrosti predstavlja časovna neposrednost.

Namen doktorske disertacije je bil razvoj algoritma za določitev reprezentativne vrednosti potovalnega časa, ki deluje v realnem času. Podatek o potovalnem času služi kot vhodni podatek sistema za obveščanje uporabnikov o potovalnih časih na avtocestnem odseku.

Osnovna hipoteza je bila, da je s pomočjo združevanja točkovnih in neposrednih linijskih meritev možno pridobiti natančnejšo in zanesljivejšo oceno vrednosti potovalnega časa na odseku, kot iz posamezne meritve (bodisi linijske, bodisi točkovne). Metodologija je premostila nekatere omejitve določevanja potovalnega časa iz enega samega vira podatkov, ki so posledica omejenega prostorskega pokrivanja točkovnih detektorjev ter zamude pri obveščanju vsled neposrednih linijskih merenj.

Oceno potovalnih časov smo izvedli z združevanjem prometnih podatkov iz različnih točkovnih (mikrovalovni detektorji) in linijskih (reidentifikacija registrskih tablic in naslovov »bluetooth«) merilnikov. Algoritem za združevanje podatkov se je v preizkusni fazi kot podmodul vgradil v sistem za nadzor in vodenje prometa na avtocestnem odseku med Vranskim in Blagovico, po vzpostavitvi opreme na širšem območju pa bo lahko služil tudi za podajanje informacij o potovalnih časih in zamudah na avtocestnem omrežju Slovenije. Na osnovi ocenjenih potovalnih časov se bo izvajalo obveščanje voznikov o potovalnih časih in zamudah na cestnem omrežju preko grafičnih prikazovalnikov spremenljive prometno-informativne signalizacije (grafični prikazovalniki SPIS na avtocestah) ter preko različnih medijev v vozilih (RDS-TMC, navigacija), preko spletnih objav ter preko prometno-informacijskega centra (PIC). Sistem bo s svojo operativnostjo pripomogel k bistvenemu izboljšanju izkoriščenosti obstoječe cestne infrastrukture, večji informiranosti uporabnikov cestnega omrežja, povečanju prometne varnosti, zmanjšanju zamud, manjši onesnaženosti in s tem povezanim zmanjšanju negativnih vplivov na okolje.

Glavni poudarek doktorske disertacije je bil na razvoju algoritma za oceno potovalnih časov na avtocestnem omrežju z združevanjem točkovnih in linijskih meritev. Njegov osnovni namen je združitev ugodnih lastnosti posamezne meritve v kombinacijo z večjo natančnostjo. Za uspešno združevanje točkovnih in linijskih meritev je bil razvit algoritem, ki v trenutnem času dinamično združuje podatke iz točkovnih merilnikov in sistema za reidentifikacijo vozil ter jih z uporabljenim metodo združevanja podatkov aplicira na trenutno časovno obdobje. Tak sistem, ki bi obratoval v realnem času, po avtorjevem vedenju še ne obstaja. V svetu je bilo izvedenih kar nekaj študij, ki se ukvarjajo s problematiko združevanja podatkov iz različnih virov, večina od njih pa jih je žal ostala le na papirju.

1.3 Prenos teorije v uporabo

»V teoriji sta tako teorija kot praksa enaki. V praksi nista.«

- Albert Einstein

Pri vsaki študiji je zaželeno teoretične ugotovitve podkrepiti s podatki iz terena. V ta namen smo teoretična dognanja preizkusili v realnih okoliščinah s pilotskim sistemom za določevanje potovalnih časov, nameščenim na odseku med Vranskim in Blagovico.

1.3.1 Območje testiranja

Odsek avtoceste A1 čez Trojane med Vranskim in Blagovico, kot del V. Pan evropskega koridorja med Barcelono (Španija) in Kijevom (Ukrajina), predstavlja enega od prometno najbolj obremenjenih avtocestnih odsekov v Republiki Sloveniji. Na 22 km višinsko zelo

razgibane trase s prisotnostjo štirih predorov in velikega števila objektov kot so nadvozi, viadukti in mostovi, je promet voden z modernim sistemom za nadzor in vodenje prometa. 50 mikrovalovnih detektorjev, 32 video detekcijskih kamer, 35 video nadzornih kamer, 5 cestno-vremenskih postaj, sistema za merjenje potovalnih časov z uporabo reidentifikacije registrskih tablic in naslovov »bluetooth«, ter 24 grafičnih prikazovalnikov spremenljive prometno-informativne signalizacije predstavlja ugodno področje za preizkušanje različnih računskih orodij in novih tehnologij.

Na podeželski avtocesti, speljani po gričevnatem terenu, prevladuje tranzitni promet, sestavljen predvsem iz tovornih vozil, ki prevažajo tovor med novimi članicami evropske unije. Povprečni letni dnevni pretok na odseku znaša približno 40.000 vozil; kar 30 % od teh so tovorna vozila, ki imajo bistven vpliv na določevanje potovalnih časov. Delež tovornih vozil se ponoči poveča na 80 %.

Območje testiranja s svojo zahtevno traso in nameščeno opremo zagotavlja velik nabor podatkov tako za razmere prostega prometnega toka kot tudi za različne izredne dogodke (nesreče, neugodne vremenske razmere, zapore ceste, preusmeritve prometa...), ki se razvijejo v zastoje. Baza podatkov različnih dogodkov se sprti posodablja, kar omogoča preizkušanje izboljšav v prometnem okolju.



Slika 1-2: Območje testiranja

Figure 1-2: Test site

Na avtocestnem odseku med Vranskim in Blagovico je bil postavljen pilotski sistem za neposredno merjenje potovalnih časov s pomočjo reidentifikacije registrskih tablic in naslovov »bluetooth«. Odsek dolžine 22 km je specifičen predvsem zaradi tega, ker na delu odseka višinsko zelo razgibane trase s pogostimi objekti kot so predori in viadukti velja omejitev hitrosti 100 km/h (70 % dolžine trase), na preostalem delu odseka pa je omejitev hitrosti 130 km/h (30 % dolžine trase).

Na obeh krajnih točkah odseka je bila na obstoječi infrastrukturi sistema za nadzor in vodenje prometa (portali SPIS) postavljena oprema za samodejno razpoznavanje registrskih tablic ter oprema za samodejno zaznavanje naslovov »bluetooth«. Podatki s terena se prenašajo preko optičnega komunikacijskega omrežja do centralnega dela sistema, razvitega za potrebe izračunavanja potovalnih časov. Centralni del sistema je nameščen v regionalnem nadzornem centru Vransko, ki upravlja s prometom na tem delu avtoceste A1.

1.3.2 Oprema za izvajanje meritev

V nadaljevanju je predstavljena oprema, s katero smo merili oz. ocenjevali potovalne čase. Uporabnost algoritma za oceno potovalnih časov pa ni omejena le na opremo, predstavljeno v nadaljevanju, temveč omogoča združevanje podatkov, pridobljenih z drugačno opremo pod pogojem, da so zagotovljene neposredne linijske meritve ter posredna ocena potovalnega časa.

1.3.2.1 Sistem za samodejno razpoznavanje registrskih tablic

Sistem za samodejno razpoznavanje registrskih tablic predstavlja metodo, ki na podlagi optičnega razpoznavanja znakov na sliki prepozna registrsko tablico posameznega vozila. Slike so v sistemu zajete s kamero, ki je nameščena nad vsakim voznim pasom. Pri tem infrardeča bliskavica zagotovi optimalno sliko za razpoznavanje pri hitrostih prostega prometnega toka do 200 km/h. Slika se nato pretvori v ustrezno obliko, primerno za nadaljnjo obdelavo. Z namenom varovanja osebnih podatkov se podatki z registrske tablice prevedejo s posebnim kodirnim algoritmom, kar zagotavlja takojšen izbris podatkov o opazovanem vozilu, sistem pa v nadaljevanju upravlja s kodiranim nizom znakov.

Sistem za samodejno razpoznavanje registrskih tablic tvorijo:

- kamera za zajem slike prednje ali zadnje registrske tablice,
- infrardeča bliskavica, ki je nemoteča za voznika in osvetli sliko ter omogoča nemoteno delovanje podnevi in ponoči,
- zajemalnik slike, ki sproži kamero, da zajame sliko,
- prožilnik, ki je lahko programski ali fizični in se sproži ob prevozu vozila,
- procesorja za obdelavo slike,
- vhodni in izhodni signali med zunanji priključenimi napravami,
- komunikacijski del za povezavo z nadzornim računalnikom na centralni lokaciji,
- napajalna infrastruktura ter
- centralni del z bazo podatkov za zbiranje podatkov, njihovo obdelavo in shranjevanje.



Slika 1-3: Kamere za samodejno razpoznavanje registrskih tablic nameščene na portalni konstrukciji nad voziščem

Figure 1-3: Automatic license plate recognition cameras mounted on the structure above the road

Kamera za razpoznavanje registrskih tablic razpozna registrske tablice mimo vozečih vozil in jih šifrira po posebnem ključu. S tem dobimo kodiran niz znakov, s čimer se izbriše sled za oznako avtomobila. Kodirana informacija se pošlje na centralni strežnik, kjer programska oprema shrani podatke o prevozu prve lokacije. Programska oprema v centru nato neprestano preverja prisotnost te kodirane informacije na sosednjih lokacijah in tako išče ustrezen par. Ko je par poiskan, s primerjavo vstopnega in izstopnega časa (uri na sosednjih lokacijah morata biti sinhronizirani) ter znano razdaljo, zelo natančno izračunamo potovalni čas med tema dvema lokacijama. Vzorčna množica meritev na posamezni relaciji nato omogoča določitev dejanskega potovalnega časa na omenjeni relaciji v določenem časovnem intervalu.

1.3.2.2 Sistem za zaznavanje naslovov »bluetooth«

»Bluetooth« ali modri zob je varna brezžična tehnologija za povezovanje različnih digitalnih elektronskih naprav na medsebojnih razdaljah do nekaj metrov. »Bluetooth« je doživel največji razmah predvsem z uporabo mobilnih telefonov, navigacijskih naprav ter naprav za prostoročno telefoniranje. Za širok razmah tehnologije je pomembna tudi skrb za varovanje podatkov, ki je vgrajena v sam standard.



Slika 1-4: Primer naprav, ki uporabljajo tehnologijo »bluetooth«


Figure 1-4: Devices using bluetooth technology

Vsaka naprava, ki uporablja tehnologijo »bluetooth«, ima svojo identifikacijsko številko t.i. naslov MAC (Media Access Control), ki se v sistemu pretvori v anonimno številko. S tem se izbriše odnos med lastnikom in podatkom za obdelavo. Naslov MAC določi proizvajalec naprave, na voljo pa ni nobene centralne baze podatkov, iz katere bi se dalo ugotoviti kdo je

proizvajalec oziroma uporabnik posameznega naslova MAC. Temu naslovu je dodana časovna oznaka, ki služi za nadaljnjo obdelavo.

Antene »bluetooth«, nameščene ob vozišču, zaznavajo ter identificirajo naprave »bluetooth«: mobilne telefone, navigacijske naprave, sisteme GPS in ostale naprave v vozilih, ki se z drugimi povezujejo preko tehnologije »bluetooth«. Ko vozilo, opremljeno z napravo »bluetooth« potuje po določeni trajektoriji, ga lahko na različnih zaporednih lokacijah anonimno zaznamo ter shranimo njegov naslov MAC, čas prehoda ter lokacijo. S pridobljenimi podatki iz vsaj dveh senzorjev dobimo podatke o potovalnih časih, prometnih pretokih, hitrostih, izvoru in cilju potovanja ter motnjah v prometnem toku.

Ko vozilo z aktivno napravo »bluetooth« prevozi prvo lokacijo s postavljeno anteno »bluetooth«, le-ta prebere njegov naslov MAC skupaj s časom in lokacijo zaznave. Informacija se pošlje na centralni strežnik, kjer programska oprema shrani podatke o prevozu prve lokacije. Programska oprema v centru nato neprestano preverja prisotnost tega naslova MAC na ostalih lokacijah in tako išče par. Ko je par poiskan, s primerjanjem vstopnega in izstopnega časa ter znano razdaljo izračunamo potovalni čas med tema dvema točkama.



Slika 1-5: Način določevanja potovalnih časov s pomočjo reidentifikacije naslovov »bluetooth« in antena za zaznavanje signala »bluetooth«

Figure 1-5: Estimating travel times by the use of bluetooth signal and bluetooth antenna


1.3.2.3 Mikrovalovni detektorji za merjenje parametrov prometnega toka

Mikrovalovni detektorji spadajo v skupino točkovnih merilnikov za merjenje parametrov prometnega toka. Mikrovalovni detektorji nameščeni na avtocestah omogočajo zajem prometnih količin s pomočjo Dopplerjevega radarja, ki izmeri hitrost, ultrazvočnega detektorja, ki posname profil vozila in s tem omogoči klasifikacijo ter izvora infrardeče svetlobe, ki določi smer gibanja vozila.

Mikrovalovni detektorji omogočajo:

- štetje vozil,
- merjenje hitrosti posameznega vozila,
- klasifikacijo vozila v enega izmed petih preddefiniranih razredov,
- zaznavanje zaustavljenega vozila in zasedenosti vozišča,
- merjenje časovnega razmika med vozili,

- zaznavanje vozil, ki vozijo v napačno smer.



Slika 1-6: Mikrovalovne tehnologije ter namestitvev mikrovalovnega detektorja nad vozišče
Figure 1-6: Microwave technologies and microwave detector mounted above the road surface

Mikrovalovni detektorji zagotavljajo naslednjo natančnost oz. nenatančnost detekcije:

- štetje vozil: $\pm 3 \%$
- hitrost: $\pm 3 \%$ ($> 100 \text{ km/h}$)
 $\pm 3 \text{ km/h}$ ($\leq 100 \text{ km/h}$)
- klasifikacija: v prostem prometnem toku glede na nemški standard TLS. Natančnost klasifikacije je nekoliko slabša v primeru prometnega toka »stop & go«.

1.4 Obveščanje voznikov o potovalnih časih

Reprezentativno vrednost potovalnega časa izračunamo z algoritmom, predstavljenim v naslednjih poglavjih. Izračunana vrednost je zaokrožena na sekundo natančno. Izračunana vrednost na sekundo natančno pa za voznika nima pravega pomena. Voznike o potovalnem času obveščamo z minutno natančnostjo, saj vrednosti, natančnejše od minute, zaradi dojemanja potovalnega časa niso smiselne.

Izračunane vrednosti potovalnega časa moramo zato zaokrožiti. V prvi fazi moramo za vsak odsek izvajanja meritve določiti potovalni čas na odseku v razmerah prostega prometnega toka. To je potovalni čas, ki ga za prevoz odseka v razmerah prostega prometnega toka potrebuje vozilo, ki vozi skladno z omejitvijo hitrosti. V kolikor za določeno obdobje izračunamo reprezentativni potovalni čas, ki je nižji od potovalnega časa v prostem prometnem toku, moramo le-tega zaokrožiti na vrednost potovalnega časa v prostem prometnem toku. Voznikov praviloma ne smemo obveščati o potovalnem času, ki je nižji od tistega pri upoštevanju omejitvi hitrosti. Zaokroževanje potovalnih časov izvedemo na zgornjo minuto.

Med glavne naloge sistema za določevanje potovalnih časov sodi posredovanje informacije končnemu uporabniku – vozniku. Še tako kompleksen sistem za izračunavanje potovalnih časov je brez pomena, če nima dovršenega načina podajanja informacij uporabnikom. Da je prometno-potovalna informacija učinkovita, mora biti kratka, jedrnata, kvantificirati mora dogodek ter ga pravilno nasloviti uporabniku. Informacija o potovalnem času zadošča prvim trem pogojem, medtem ko je pravilno naslavljanje v domeni informacijske tehnologije.



Slika 1-7: Prikaz prometne vsebine o potovalnem času na shematskem vmesniku SCADA
Figure 1-7: Variable Message Sign content as shown on SCADA

Uporaba informacij o potovalnem času med samim potovanjem lahko bistveno izboljša potovanje tako posameznemu vozniku kot tudi celotnemu prometnemu toku. Glede na informacijo o vrednosti potovalnega časa na izbrani relaciji oz. do izbranega cilja se lahko voznik odloči za alternativno pot, ki ima krajši potovalni čas in s tem pravočasno prispe na svoj cilj. Tudi v primeru, ko alternativne poti ni na voljo, že sama informacija o podaljšanem potovalnem času blagodejno vpliva na človeka ter zmanjša stres zaradi nepoznavanja časa možnega zastoja.

Najbolj primerna infrastruktura za podajanje informacije o potovalnih časih so grafični prikazovalniki spremenljive prometno-informativne signalizacije (SPIS). Znaki so namenjeni obveščanju voznikov o različnih izrednih dogodkih ter tudi vodenju prometa. Ker so znaki nameščeni nad vozišče, so vidni vsem voznikom. S primerno izbiro alfanumeričnih znakov in standardnih oznak je informacija lahko zelo preprosta in hitro dojemljiva. Podajanje informacije o potovalnih časih preko SPIS je po izkušnjah iz tujine priporočeno predvsem v času prometnih konic. V primeru izrednega dogodka ima obveščanje o izrednem dogodku prednost pred obveščanjem o potovalnem času.

Poleg tega moramo upoštevati tudi dejstvo, da so izmerjeni podatki o potovalnih časih izračunani iz meritev vozil, ki so pred kratkim prevozila določen avtocestni odsek in imajo zato zakasnjene značaj. Kljub temu, da metode natančne napovedi potovalnih časov še ni na voljo, izkušnje iz tujine kažejo, da je na podlagi raziskav o odzivu voznikov prikaz tovrstnih podatkov smiseln.



Slika 1-8: Obveščanje voznikov o potovalnem času v razmerah prostega prometnega toka
Figure 1-8: Travel time information in free flowing traffic

2 POTOVALNI ČAS

»Razum lahko odgovori na vprašanje, toda domišljija ga mora postaviti.«

- Ralph Gerard

2.1 Potreba po merjenju potovalnega časa

Mobilnost v današnjem času predstavlja sinonim za ekonomsko aktivnost in razvitost. Zmožnost povečane mobilnosti znotraj posamezne gospodarske regije poveča njeno konkurenčnost ter vsem, tudi tistim bolj dislociranim, zagotavlja enake možnosti za razvoj. Da pa mobilnost zagotavlja predhodno omenjene prednosti, je potrebno dobro razvito cestno omrežje in smotrno upravljanje prometnih tokov. Slaba razvitost prometne infrastrukture in odsotnost aktivnega upravljanja prometnih tokov lahko za neko regijo tako učinkujeta neproduktivno, kar namesto potencialnih prednosti območja pomeni povečanje stroškov. Stroški, čeprav se jih večina ne zaveda in se pri nas trenutno še ne vrednotijo v zadostni meri, nastanejo predvsem zaradi vsakodnevnih zastojev. Kot sta prikazala Pirc in Pretnar (2010) na primeru resničnega izrednega dogodka na ljubljanski severni obvoznici, lahko nepravilno in nestrokovno vodenje prometnih tokov pomeni nepredstavljljive zamude na celotnem prometnem omrežju in visok izpad prihodkov, kar je nemalokrat prezrto tako od upravljavca cestnega omrežja kot tudi na nivoju državnih inštitucij.



Slika 2-1: Vsakodnevno pojavljanje zastojev na avtocestni mreži je del našega vsakdana
Figure 2-1: Daily congestion phenomena is part of our every day life

Zastoji predstavljajo del našega vsakdana in so neizogibni. Do njih v veliki meri pride zaradi premajhne kapacitete avtocestnega odseka, saj navkljub intenzivni gradnji in posodabljanju cestne infrastrukture v preteklosti, danes ni več mogoče v vsakem trenutku zagotoviti prostega

prometnega toka. V preteklosti se je problematika reševala z gradnjo nove cestne infrastrukture ali z razširitvijo obstoječih prometnih povezav, kar pa danes zaradi prostorskih in ekonomskih razlogov ter neugodnih vplivov na okolje ni več mogoče. Vse predhodno opisano vodi k potrebi po dobrem konceptu upravljanja prometnih tokov: poznati in kvantificirati je potrebno stopnjo prenasičenosti cestne mreže z namenom omejitve njenih škodljivih vplivov na prometni tok.

Na večini mestnih območij širom sveta je omrežje prenasičeno. Poleg tega je kljub trenutnemu obdobju recesije še vedno opazna rast motoriziranega prometa (DRSC, 2012). Vse od odprtja avtocestnega odseka preko Trojan (odsek Vransko-Trojane leta 2002 in odsek Trojane-Blagovica leta 2005) je opaženo konstantno večanje tranzitnega prometa na območju glavne slovenske prometne žile A1. Ker širjenje cestnega omrežja zaradi predhodno opisanih vzrokov ni mogoče, bo potrebno večjo pozornost posvetiti upravljanju prometnih tokov z obstoječimi in na novo nameščenimi inteligentnimi transportnimi sistemi: sem spadajo tudi sistemi za nadzor in vodenje prometa (SNVP), ki so že nameščeni na nekaterih najbolj kritičnih odsekih slovenskega avtocestnega križa.

Sistem za nadzor in vodenje prometa na avtocestah je inteligentni transportni sistem, ki omogoča na izbranem avtocestnem odseku vzpostavitev optimalnih prometnih razmer glede na trenutno in predvideno stanje na cesti (Pirc, 2008). V sistemu se nepretrgoma vrši zbiranje in obdelava prometnih in vremenskih podatkov ter podatkov o izrednih dogodkih, na osnovi katerih se izvaja nadzor nad trenutnim stanjem na cesti. V kritičnih situacijah na cesti se v sistemu izvajajo ročni in samodejni (prednastavljeni) ukrepi vodenja prometa in informiranja uporabnikov avtocest. Delovanje sistema za nadzor in vodenje prometa na avtocestah omogoča več komponent, ki so med seboj povezane v hierarhično strukturo. Osnovni cilji sistema za nadzor in vodenje prometa na avtocestah so zagotovitev večje izkoriščenosti kapacitete avtocestnega omrežja, večja prometna varnost v kritičnih situacijah na cesti, večje udobje in ekonomičnost potovanja ljudi in blaga ter manjša obremenitev okolja. Za zagotovitev pravih ukrepov vodenja prometa se v sistemu v zbirajo in obdelujejo prometni in vremenski podatki ter podatki o izrednih dogodkih na podlagi katerih se izvaja vodenje prometa in informiranje uporabnikov avtocest ob povečanju prometnih obremenitev, v primeru neugodnih vremenskih razmer ali ob pojavu različnih izrednih dogodkov (prometna nesreča, delo na cesti, vožnja v napačno smer, nastanek kolone zaustavljenih vozil). Z namenom zagotavljanja optimalnih prometnih razmer na avtocestnem odseku je bil v sklopu vzpostavitve sistema za nadzor in vodenje prometa razvit prometni model, ki na podlagi vhodnih prometnih parametrov, izmerjenih na terenu z mikrovalovnimi detektorji in video detekcijskimi kamerami, glede na razmere v prometnem toku izračunava prometna stanja. Za homogeniziranje prometnega toka v času konic se voznike preko grafičnih prikazovalnikov spremenljive prometno-informativne signalizacije s hitrostnimi omejitvami obvešča o trenutnem stanju na cesti in posledično vodi prometni tok.

Prometno-potovalne informacije predstavljajo ključni element obveščenosti voznikov. Obveščanje uporabnikov avtocest in podajanje prometno-potovalnih informacij trenutno poteka preko spremenljive prometno-informativne signalizacije (SPIS) ter Prometno-Informacijskega Centra (PIC), ki informacije voznikom posreduje preko različnih medijev (radio, internet, mobilne aplikacije...).



Slika 2-2: Nadzorni center za upravljanje sistema za nadzor in vodenje prometa
Figure 2-2: Traffic Control Center as a part of the Traffic Management System

Podatek o potovalnem času in zamudi na potovanju tako za voznike, cestne operaterje in inženirje prometa predstavlja najbolj uporabno tako kvalitativno kot kvantitativno informacijo pri načrtovanju potovanja (Palen, 1997). V nasprotju z nekaterimi drugimi prometnimi karakteristikami, je ta podatek razumljiv širši javnosti, saj omogoča hitro in jasno dojetje stanja na cestni mreži. Informacija o predvidenem potovalnem času vzdolž avtocestnega odseka z zgoščenim prometnim stanjem je najbolj uporabna prometna informacija za voznike, na podlagi katere lahko izboljšajo in prilagodijo svoje potovanje (potovati ali ne potovati, najboljši čas za izvedbo poti, izbira poti in prometnega sredstva). Informacija o potovalnem času pa ni pomembna le za voznike, temveč tudi za upravljavce avtocestnega omrežja, saj le-ta predstavlja kvantitativno vrednost za oceno uspešnosti odvijanja prometnega toka na prometnem omrežju in je hkrati merilo uspešnosti prometnih strategij, uporabljamo pa jo lahko tudi kot zanesljivo opozorilo o nastanku zastojev. Naloga upravljavca avtocestnega omrežja pa ni le posredovanje informacije o potovalnih časih, temveč tudi pregled in nadzor nad njegovo razpršenostjo in porazdelitvijo, ki bistveno vpliva na primerne ukrepe vodenja prometa.

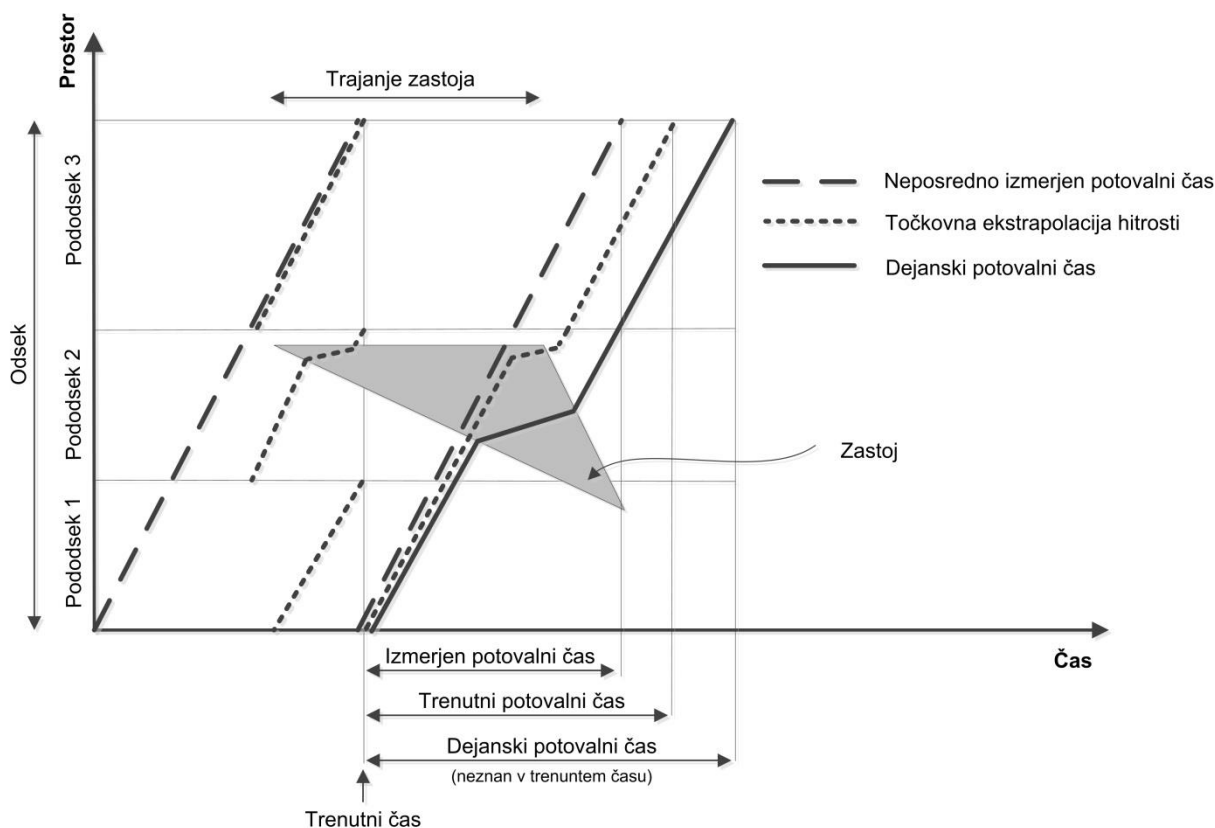
Vozniki so navajeni na vsakodnevno pojavljanje zastojev in zato zamude upoštevajo pri načrtovanju svojega potovanja. Kar je za voznika bolj neprijetno so nepredvidljiva pojavljanja zastojev, kjer pride do nepredvidljivega podaljšanja potovanja. Za voznika je zato zelo pomembno, da je ažurno in zanesljivo obveščen, koliko časa bo njegovo potovanje trajalo. Za zagotovitev zanesljive informacije o bodočem potovalnem času pa moramo najprej izmeriti trenutni potovalni čas na določenem odseku.

Potovalni čas bo v prihodnje vsekakor postal ključni vhodni podatek modernih sistemov za nadzor in vodenje prometa. Zagotavljanje informacije o potovalnih časih zato sodi med osnovne naloge upravljavcev avtocestnega omrežja.

2.2 Definicija potovalnega časa

Potovalni čas je čas, ki ga vozilo potrebuje za potovanje med dvema stacionarnima točkama. Določimo ga lahko z neposredno meritvijo (izmerjeni potovalni čas), kar predstavlja informacijo o preteklem, že izmerjenem potovalnem času, ter zato predstavlja informacijo z določeno zamudo. Nasprotno z neposredno meritvijo predstavlja določitev trenutnega potovalnega časa s posredno oceno (prostorska ekstrapolacija točkovne meritve hitrosti), ki je sestavljena iz trenutnih potovalnih časov na posameznih pododsekih. V primeru posredne ocene velja predpostavka, da bodo prometne razmere do naslednje posodobitve informacije ostale nespremenjene. Ocena trenutnega potovalnega časa je v splošnem boljša ocena napovedanega potovalnega časa za voznika, ki v danem trenutku vstopa na avtocestni odsek kot izmerjen potovalni čas.


Slika 2-3 prikazuje primer različnih definicij potovalnega časa in zamude pri obveščanju v primeru nastanka zastoja (Soriguera, Rosas in Robusté, 2010). V kolikor na odseku pride do zastoja, je opazna napaka pri uporabi izmerjenega potovalnega časa iz predhodnega časovnega intervala za celotni odsek. V kolikor za obveščanje voznikov uporabimo trenutni potovalni čas, sestavljen iz potovalnih časov na posameznih pododsekih v zadnjem časovnem intervalu, je ta informacija že bolj natančna, vendar na splošno vsebuje napako, ki je posledica predvidevanja, da prometne razmere ostanejo nespremenjene do naslednje posodobitve informacije. Na sliki je namenoma prikazan robni primer, kjer izmerjen potovalni čas ne zazna nastanka zastoja, medtem, ko ga potovalni časi, izmerjeni na posameznem pododseku, zaznajo. V takih primerih je tudi najbolj opazna razlika med izmerjenim in trenutnim potovalnim časom.



Slika 2-3: Definicije potovalnega časa ter obveščanje voznikov (Soriguera, Rosas in Robusté, 2010)

Figure 2-3: Travel time definitions and drivers' informing (Soriguera, Rosas and Robusté, 2010)

V kolikor želimo določiti povprečni dejanski potovalni čas na pododseku, dve kontrolni točki na gortočni (x_{j-1}) in doltočni (x_j) lokaciji nista dovolj, saj v tem primeru ni mogoče dejansko zaznati in identificirati vseh vozil, ki so v trenutnem časovnem intervalu p na pododseku. Povprečni dejanski potovalni čas zajema le zadnje meritve s pododseka in ga zato imenujemo tudi trenutni potovalni čas.




Slika 2-4: Definicija povprečnega dejanskega potovalnega časa vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)

Figure 2-4: True average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013)

Povprečnega dejanskega potovalnega časa ne smemo zamenjati s povprečnim potovalnim časom po prihodu vozil, ki je definiran kot povprečni potovalni čas na pododseku j vseh tistih vozil, ki so doltočno vozlišče x_j dosegla v časovnem intervalu p . Povprečni potovalni čas po prihodu vozil v realnih okoliščinah izmerimo z eno od metod reidentifikacije vozil (sistem za reidentifikacijo registrskih tablic, naslovov »bluetooth«, medijev za elektronsko cestninjenje...). Ker je to v večini trenutno obstoječih sistemov po svetu za merjenje potovalnega časa najbolj uporabljen način izvajanja meritve, temu času rečemo tudi izmerjen potovalni čas.

Povprečni potovalni čas po prihodu vozil upošteva le funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom tistih vozil, ki so potovanje na pododseku že končala. Zato vsebuje določeno časovno zakasnitev, saj so se v vmesnem času lahko razmere na začetku pododseka že spremenile.

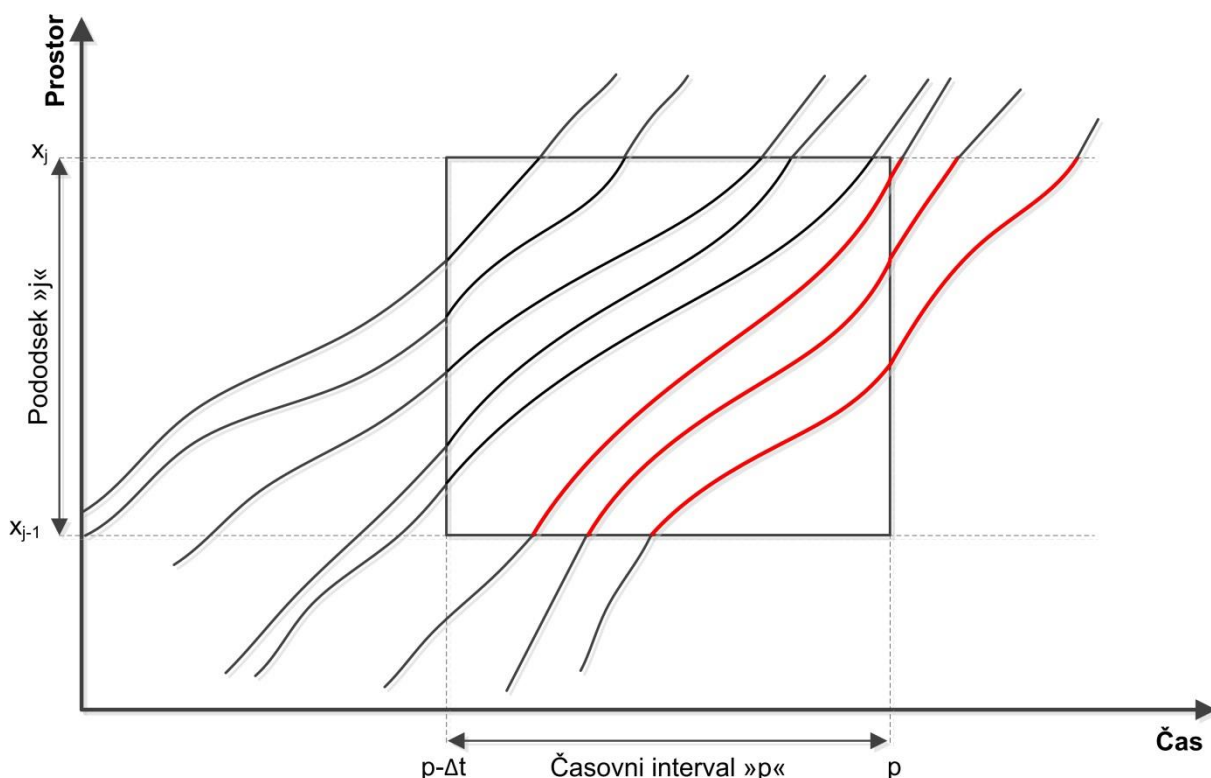


Slika 2-5: Definicija povprečnega potovalnega časa po prihodu vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)

Figure 2-5: Arrival based average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013)

Skladno z omenjenim lahko definiramo tudi povprečni potovalni čas ob odhodu vozil, ki je definiran kot povprečni potovalni čas na pododseku j vseh tistih vozil, ki so gortočno vozlišče x_{j-1} zapustila v časovnem intervalu p .

Za pravilno napoved povprečnega potovalnega časa ob odhodu vozil za svojo pravilno napoved potrebujemo podatke iz prihodnosti, zato ga je v trenutnem času nemogoče natančno določiti. Izračunamo ga lahko v »off-line« načinu, ko imamo na voljo bazo podatkov, ki vsebuje tudi bodočo informacijo glede na trenutni čas. Povprečni potovalni čas ob odhodu vozil bi bil v realnih okoliščinah približno enak povprečnemu potovalnemu času po prihodu vozil, premaknjemem za en časovni interval v prihodnost.



Slika 2-6: Definicija povprečnega potovalnega časa ob odhodu vozil v diagramu funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom: z rdečo so označeni deli funkcijske zveze, upoštevani pri definiciji povprečnega potovalnega časa (Soriguera in Robusté, 2013)

Figure 2-6: Departure based average travel time definition in a trajectories diagram: in red are parts of the vehicles' trajectories considered in the average travel time definitions (Soriguera and Robusté, 2013)

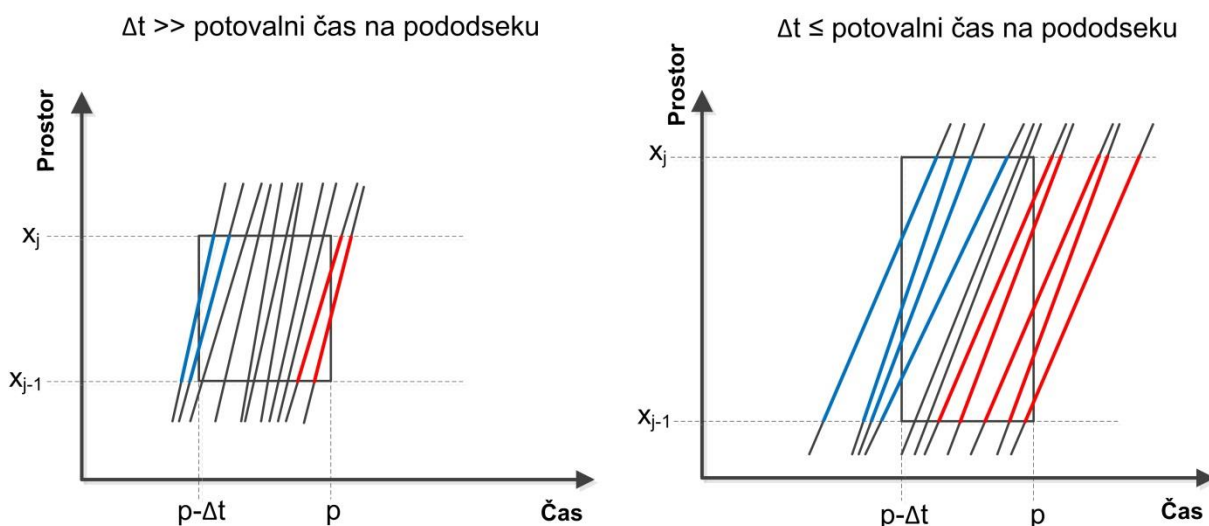
Razlika med predhodno omenjenimi povprečnimi potovalnimi časi je glede izbire delov funkcijskih zvez med opravljeno potjo vozil in njihovim potovalnim časom, ki ta povprečni potovalni čas določajo. Povprečni dejanski potovalni čas je edini, ki upošteva vse in samo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom zajete v trenutnem prostorsko-časovnem območju. Povprečni potovalni čas ob odhodu vozil in povprečni potovalni čas po prihodu vozil namreč upoštevata tudi dele funkcijskih zvez, ki se nahajajo izven trenutnega prostorsko-časovnega območja. Velikost razlike med temi potovalnimi časi je v največji meri odvisna od relativne razlike med trajanjem intervala osveževanja Δt in dejanskimi potovalnimi časi. Čim daljši so dejanski potovalni časi v primerjavi z intervalom osveževanja, tem večja je razlika v skupini vozil, ki jo upoštevamo pri posamezni definiciji potovalnega časa. Δt je parameter, ki ga nastavimo v sistemu za merjenje potovalnih časov in s katerim določimo periodo osveževanja informacije o potovalnem času oz. periodo izračuna. Najmanjša vrednost Δt ima lahko vrednost enako kot cikel osveževanja agregiranih podatkov iz točkovnih merilnikov, vsekakor pa ne sme biti bistveno daljši, saj v tem primeru preveč zgladi variacije/nihanja potovalnega časa znotraj časovnega intervala. Krajša vrednost Δt prav tako pripomore k ustreznemu osveževanju informacije o potovalnem času.

V primerih, ko je potovalni čas na pododseku opazno daljši od Δt , do česar pride ponavadi na dolgih pododsekih ali v primeru zgoščenega prometnega toka, upoštevane funkcijske zveze

med opravljeno potjo vozil in njihovim potovalnim časom pri izračunu povprečnega potovalnega časa, pripadajo različnim skupinam vozil (Slika 2-7 desno). V realnih okoliščinah lahko pride celo do robnega primera, ko nobena od funkcijskih zvez ni skupna vsem definicijam, kar v primeru zgoščenega prometnega toka ni bistveno, saj imajo vsa vozila podobne vozne lastnosti in so zato vse funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom podobne. V primeru prehoda med prometnimi stanji, npr. iz zgoščenega v prosti prometni tok ali obratno, lahko različne definicije vodijo do bistveno drugačnih rezultatov povprečnega potovalnega časa na pododseku. Tu je pomembno katero od definicij privzamemo za izračun.

V nasprotnem primeru v situacijah, ko je potovalni čas na pododseku bistveno krajši od Δt (kratki avtocestni pododseki, gosta namestitve merilnih mest), pa je število funkcijskih zvez, ki bi bile upoštevane le v eni izmed definicij, zelo majhno v primerjavi s skupnimi funkcijskimi zvezami med opravljeno potjo vozil in njihovim potovalnim časom (Slika 2-7 levo). To posledično pomeni, da vse definicije podajo zelo podobne rezultate povprečnega potovalnega časa.

Slika 2-7 z modro označuje funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, ki so upoštevane pri povprečnem potovalnem času po prihodu vozil ne pa pri povprečnem potovalnem času ob odhodu vozil. Z rdečo so, nasprotno predhodnemu, označene funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, ki so upoštevane pri povprečnem potovalnem času ob odhodu vozil ne pa pri povprečnem potovalnem času po prihodu vozil. S črno so označene skupne funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom.



Slika 2-7: Različne funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom upoštevane pri določevanju potovalnega časa na pododseku (Soriguera in Robusté, 2013)

Figure 2-7: Different trajectories considered in the link travel time definitions (Soriguera in Robusté, 2013)

Kot predhodno omenjeno je v realnih okoliščinah iz dveh kontrolnih točk dokaj težko dobiti povprečni dejanski potovalni čas. Potovalni čas lahko približno določimo tako, da združimo

vse povprečne potovalne čase vozil, ki so v časovnem intervalu p prispeli na doltočno kontrolno točko (to je povprečni potovalni čas po prihodu vozil) in povprečne potovalne čase vozil, ki so v časovnem intervalu p začeli potovanje iz gortočne kontrole točke (to je povprečen potovalni čas ob odhodu vozil). S tem pridobimo vse funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, kar v bistvu predstavlja unijo množic, kot prikazuje Slika 2-7, leva slika. Čim večji je presek obeh množic (čim večje je skupno število funkcijskih zvez), tem boljša je aproksimacija povprečnega dejanskega potovalnega časa in proces konvergira k popolni oceni, ki je dosežena tedaj, ko so vse funkcijske zveze skupne. V primerih, ko skupne funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom ne obstajajo, povprečni potovalni čas po prihodu vozil predstavlja zelo slab približek povprečnega dejanskega potovalnega časa.

V sistemu za obveščanje voznikov o potovalnih časih ne posredujejo pravilne informacije za voznika niti povprečni dejanski potovalni čas niti povprečni potovalni čas po prihodu vozil za časovni interval p . Voznika zanima pričakovani potovalni čas, torej potovalni čas ob odhodu vozila za časovni interval $p+1$, ki mu lahko rečemo tudi predvideni potovalni čas. Zatorej za oceno povprečnega potovalnega časa ob odhodu vozil potrebujemo napoved ne le za časovno obdobje enako potovalnemu času posameznega vozila, temveč za časovno obdobje tega potovalnega časa z dodanim Δt . Za zagotovitev kar se da natančne napovedi se je potrebno izogibati dolgim časovnim intervalom Δt , saj le-ti lahko v primeru prehoda med različnimi prometnimi stanji znotraj časovnega intervala Δt vodijo do napačne napovedi.



Slika 2-8: Obveščanje voznikov o potovalnem času preko spremenljive prometno-informativne signalizacije

Figure 2-8: Travel time information provided via Variable Message Sign

3 MERJENJE IN IZRAČUN POTOVALNEGA ČASA

»Privzemimo, kar je uporabno in odstranimo, kar ni.«

- Bruce Lee

Potreba po merjenju prometnih podatkov se je pojavila sočasno s popularizacijo motornega prometa. V začetku je bilo merjenje karakteristik prometnega toka omejeno na merjenje prometnega pretoka (štetje vozil) z namenom ugotavljanja izkoriščenosti posamezne prometnice za potrebe prometnega planiranja. Ne dolgo zatem se je pojavila potreba po merjenju hitrosti, iz katere je bil razviden nivo usluge posamezne prometnice. Te podatki so se večinoma zbirali statično. Komunikacijske tehnologije v preteklosti namreč niso omogočale prenosa podatkov na centralno lokacijo in njihovo obdelavo v trenutnem času. Razvoj modernih sistemov za nadzor in vodenje prometa (SNVP), ki so se na naših avtocestah uveljavili od leta 2004 dalje, je sledil trendom v razvoju komunikacijskih in računalniških tehnologij in tako omogočil zbiranje in obdelavo podatkov ter obveščanje uporabnikov avtocest v trenutnem času. Z vgradnjo modernih merilnikov za merjenje karakteristik prometnega toka, povečano dostopnostjo podatkov na centralni lokaciji in naraščajočo močjo procesiranja, je prometnim inženirjem dandanes na voljo ogromno število podatkov o karakteristikah prometnega toka.

Kljub temu, da potovalni čas predstavlja eno izmed osnovnih karakteristik prometnega toka (Berechman, 2003), ga je bilo do pred nedavnim z razumnimi stroški zelo težko natančno izmeriti na večjem vzorcu prometnega toka. Potovalni čas predstavlja ključni vhodni podatek današnjih modernih sistemov za nadzor in vodenje prometa (Markovič in sodelavci, 2010), kljub temu pa na avtocestnem omrežju Slovenije, do sedaj še ni bilo izvedenih konkretnih meritev in aktivnosti za ta namen. Pomembnost informacije o potovalnem času na določenem odseku avtoceste je v njegovi široki razpoznavnosti in preprostem tolmačenju tako za voznike, za katere je informacija preprosto razumljiva, omogoča vozniku, da se odloči kdaj, kje in s čim bo svoje potovanje izpeljal, kot tudi za upravljavce avtocestnega omrežja saj je dober pokazatelj nivoja usluge. Zapoznel razcvet sistemov za podajanje informacije o potovalnem času v svetu lahko pripišemo težavam pri sistematičnem neposrednem merjenju potovalnih časov in le vprašanje časa je bilo, kdaj bo nesluten razvoj naše družbe, ponudil ustrezno tehnologijo za merjenje potovalnega časa.

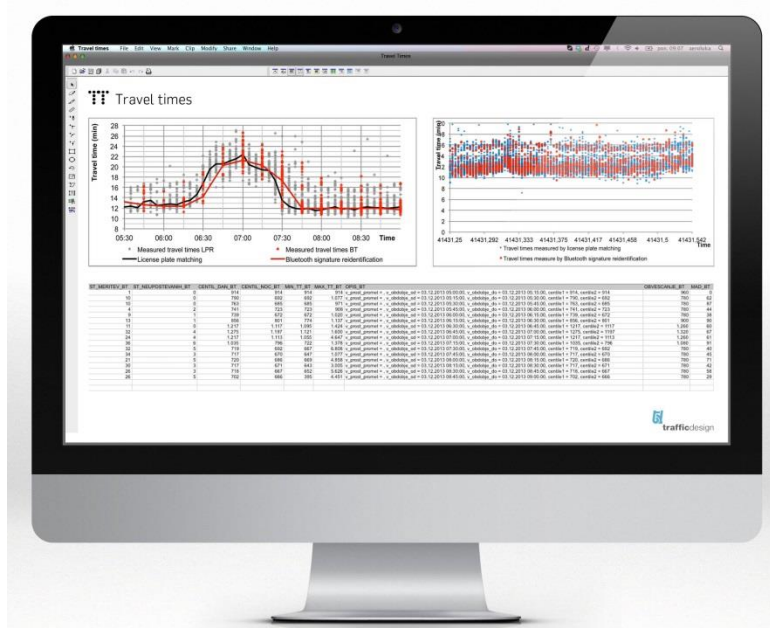


Slika 3-1: Obstoječi sistemi za obveščanje uporabnikov o potovalnih časih
Figure 3-1: Existing travel time information systems

V splošnem obstajata dva načina določanja potovalnega časa na odseku ceste: neposredno merjenje in posredna ocena (Yeon in sodelavci, 2008). Neposredno merjenje potovalnega časa

temelji na merjenju časovnega intervala, ki ga za prevoz odseka med dvema točkama potrebuje točno določeno vozilo. Alternativa temu je posredna ocena potovalnega časa iz osnovnih karakteristik prometnega toka kot sta pretok in hitrost, ki jih pridobimo iz točkovnih merilnikov prometnega toka z uporabo primerne algoritma.

Z upoštevanjem dejstva, da informacija o potovalnem času predstavlja ključno informacijo tako za voznike kot tudi za upravljavce, mora zagotovitev le-te na čim širši (vsaj) avtocestni mreži postati glavna prioriteta avtocestnega upravljavca. Kljub zavedanju tega, je bilo v Sloveniji na to temo storjenega malo ali skoraj nič predvsem zaradi tradicionalnega mišljenja na temo zagotavljanja prometnih podatkov, saj so bili le-ti v preteklosti uporabni le za načrtovanje vzdrževanja in planiranja novih cestnih povezav.



Slika 3-2: Aplikacija Potovalni časi
Figure 3-2: Travel time application

3.1 Neposredno merjenje potovalnega časa

Potovalni čas za vozila, ki potujejo na avtocestnem odseku, lahko neposredno izmerimo. Ena izmed glavnih prednosti neposredno izmerjenega potovalnega časa je njegova prostorska ponazoritev: meritev vključuje vse dejavnike, ki so vplivali na vozilo med njegovim potovanjem. To predstavlja glavno razliko med neposrednim merjenjem in posredno oceno.

Neposredno izmerjen potovalni čas izmerimo s pomočjo reidentifikacije vozila na dveh zaporednih kontrolnih točkah ali pa na podlagi sledenja temu vozilu. Pri reidentifikaciji vozila odsek izvajanja meritve določajo kontrolne točke, pri sledenju vozila pa lahko dobimo potovalni čas za poljubno relacijo. Obstajajo različne metode pridobivanja podatkov o potovalnem času, v grobem jih delimo na metode reidentifikacije vozil na zaporednih točkah (reidentifikacija registrskih tablic, medijev za elektronsko cestninjenje, naslovov »bluetooth«) ter na metode sledenja vozil preko GPS signala.

Praktični problemi (Li and Rose, 2011; Yildirimoglu and Geroliminis, 2013) pri neposrednem merjenju potovalnih časov zajemajo predvsem pridobitev reprezentativnega vzorca meritev v primeru uporabe tehnologije, katere penetracija ne zajema velikega vzorca, določitev osamelcev to je vozil, katerih potovalni čas je bistveno krajši oz. daljši od srednje vrednosti in njihov vzrok ni vezan na prometne razmere na danem odseku temveč je posledica individualnega obnašanja vozila ter največjo hibo metode neposrednega merjenja za uporabo v sistemih obveščanja voznikov, to je časovna zakasnitev informacije. Informacija o neposredno izmerjenem potovalnem času je namreč na voljo šele, ko vozilo prevozi odsek izvajanja meritve. Zakasnitev informacije za voznika, ki vstopa na odsek meritve je ravno tolikšna, kolikor je opazovano vozilo potrebovalo, da je prevozilo odsek. Ta zakasnitev informacije v razmerah prostega prometnega toka nima bistvenega pomena, je pa lahko pomembna v času spreminjajočih se prometnih razmer v času nastanka ali razpustitve zastoja ter v primeru relativno dolgih odsekov izvajanja meritve.

Pri neposrednem merjenju predstavlja potovalni čas individualno lastnost posameznega vozila. Za zagotovitev reprezentativnega vzorca na določenem odseku moramo zato izvesti meritve na večjem številu vozil znotraj prometnega toka, pri čemer je potrebna uporaba primerne tehnološke rešitve, ki zagotovi dovolj velik vzorec izmerjenih vozil ter uporaba primerne statističnega algoritma, ki izloči osamelce.

Za neposredno merjenje potovalnega časa obstajata dve različni metodi: identifikacija vozila na kontrolnih točkah ter sledenje trajektoriji vozila na njegovi poti.

3.1.1 Identifikacija vozila na kontrolnih točkah

Določevanje potovalnega časa z reidentifikacijo vozila na kontrolnih točkah temelji na identifikaciji vozila na začetni in končni točki odseka in natančni določitvi trenutka, ko je vozilo ti dve točki prevozilo (Soriguera in sodelavci, 2010). Iz obeh podatkov dobimo podatek o potovalnem času. Za zagotovitev natančnosti določitve potovalnega časa je potrebna sinhronizacija ure na začetni in končni točki izvedbe meritve. Hkratna korist izvedbe individualnih meritev potovalnega časa je tudi podatek o izvoru in cilju potovanja, kar je uporabno predvsem kot vhodni podatek prometnim študijam.


Meritev potovalnega časa v tem primeru predstavlja informacijo o potovalnem času točno določenega vozila, zato mora vozilo to potovanje končati, preden je informacija na voljo. Ta časovna zakasnelost predstavlja določeno zamudo, saj ni neposredno primerna za obveščanje voznikov, ki na odsek šele vstopajo. Ta vrsta meritve se imenuje potovalni čas po prihodu vozila.

Potovalne čase z reidentifikacijo vozil na kontrolnih točkah lahko izmerimo le med dvema točkama, kjer je nameščena oprema za identifikacijo posameznih lastnosti vozila. Vmesne ali delne meritve niso možne. Iz tega je razvidno, da sta število kontrolnih točk in njihova prostorska razporeditev pomembna za izvedbo in časovno zakasnelost meritve. V primeru goste razporeditve kontrolnih točk efekt časovne zakasnitve nima bistvenega vpliva na rezultat, saj so odseki kratki in informacija časovno ne odstopa bistveno od novih razmer. Gosta razporeditev pa predstavlja znatno višje stroške namestitve in vzdrževanja opreme. V realnih okoliščinah moramo poiskati ravnovesje. Pri iskanju ravnovesja moramo poleg števila

kontrolnih točk upoštevati tudi njihovo razporeditev, ki je predvsem odvisna od vzorcev prometnega toka na tem odseku. Turner (1998) navaja kot primerno razporeditev kontrolnih točk na medsebojni razdalji 2 km na mestnih avtocestah ter 8 km na podeželskih avtocestah, kjer uvozi in izvozi niso tako pogosti.

V realnih okoliščinah se pojavljajo tudi drugi problemi. Eden izmed njih je izločanje zavajajočih podatkov-osamelcev. Gre za potovalne čase, ki zaradi različnih vzrokov odstopajo od pravih in realnih, bodisi gre za vozila, ki so se ustavila na počivališču ali za primer motoristov, ki ob nastanku zastoja prehitvejo kolono. Za pravilno določitev potovalnega časa na določenem odseku moramo upoštevati le tiste podatke, ki odražajo prometne razmere na tem odseku, ne pa tudi tistih katerih vzrok je individualno obnašanje posameznega vozila. V primeru dovolj velikega števila meritev je identifikacija osamelcev mogoča z uporabo robustnih statističnih algoritmov.

Za merjenje potovalnih časov se na avtocestah uporabljajo različne tehnologije: sistem za razpoznavanje registrskih tablic s procesiranjem video slike in njihovo reidentifikacijo, sistem za reidentifikacijo naslovov »bluetooth«, reidentifikacija medijev za elektronsko cestninjenje (npr. tablic ABC) ter tudi reidentifikacija fizičnih lastnosti vozil s pomočjo analize video slike in določevanje potovalnih časov v zaprtem cestninskem sistemu z uporabo tradicionalnih cestninskih listkov. Pri nekaterih od teh tehnologij (npr. reidentifikacija registrskih tablic) moramo posebno skrb posvetiti tudi varstvu osebnih podatkov, saj je določeno registrsko tablico vozila mogoče neposredno povezati z lastnikom vozila.



Slika 3-3: Določevanje potovalnih časov s sistemom za uparjanje registrskih tablic (Turner in sodelavci, 1998)

Figure 3-3: Travel time estimation from license plate recognition (Turner et al., 1998)

Število pravih reidentifikacij, ključnih za pridobitev reprezentativnega vzorca, je v veliki meri odvisno od uporabljene tehnologije za identifikacijo. Poleg nedelovanja opreme, kar se kljub vložnemu trudu z izvedbo preventivnega investicijskega vzdrževanja občasno dogaja, ima velik vpliv na število identifikacij tudi penetracija posamezne tehnologije. V primeru določevanja potovalnih časov s sistemom reidentifikacije registrskih tablic ali v primeru zaprtega cestninskega sistema je delež zajetih/identificiranih vozil zelo visok. V primeru merjenja potovalnih časov s sistemom za reidentifikacijo naslovov »bluetooth« ali s sledenjem

medijev za elektronsko cestninjenje je stopnja identifikacije odvisna od števila voznikov, ki dotično tehnologijo uporabljajo, torej od stopnje penetracije posamezne tehnologije.



Slika 3-4: Preizkušanje komponent sistema za samodejno identifikacijo vozil na severni ljubljanski obvoznici

Figure 3-4: Testing Automatic Vehicle Identification system


Poudariti moramo, da število izvedenih meritev ni enako številu identifikacij temveč številu uspešnih reidentifikacij na zaporednih kontrolnih točkah. V primeru dobrega pokritja kontrolne točke oziroma nadzora vseh pasov ter ob predpostavki, da med kontrolnima točkama ni uvozov ali izvozov, je število identifikacij skoraj enako številu reidentifikacij ne glede na uporabljeno tehnologijo. V primeru vmesnih uvozov ali izvozov, število potovanj, ki jih nismo uspeli reidentificirati sovpada s številom uvozov oz. izvozov na tem odseku, kar nam omogoča tudi izdelavo izvorno-ciljnih matrik. Splošno pravilo je, da v primeru podeželskih avtocest, kjer prevladuje tranzitni promet, zadošča manjše število kontrolnih točk na večji razdalji. V primeru le delnega pokrivanja kontrolne točke (npr. samo nadzor voznega pasu) pa se soočamo z dvema vrstama problemov: prvi je uhajanje vozil, saj vozila v splošnem ne vozijo nujno po istih pasovih, predvsem če gre za bolj obremenjene avtocestne odseke. Drugi problem na katerega naletimo, je ob nadzoru samo voznega pasu, da z veliko verjetnostjo zaznavamo predvsem počasnejša vozila, saj jih hitrejša prehitevajo po prehitevalnem pasu. V omenjenih problemih je število reidentificiranih potovanj bistveno nižje od števila identificiranih vozil. Torej je potrebno čim boljše pokrivanje posamezne kontrolne točke.

3.1.2 Sledenje vozil

Druga skupina metod za neposredno merjenje potovalnega časa deluje na principu sledenja vozil. V tem primeru vzorčna vozila beležijo svoj položaj v vnaprej definiranih časovnih korakih, zato za izvedbo meritev ni potrebna nobena infrastrukturna merilna oprema, prav tako ni nobenih kontrolnih točk. Vzorčna vozila tako postanejo aktivni senzorji in izračunavajo potovalni čas s sprotnim sledenjem trajektorije gibanja vozila.

V preteklosti se je za namene sledenja vozil uporabljalo namenska vzorčna vozila, ki so v različnih časovnih razmikih vozila po avtocestnem odseku le z namenom pridobivanja podatkov o potovalnem času. Da bi dobili zanesljivo informacijo o stanju v prometnem toku bi za aplikacijo implementirano v resničnem svetu morala vzorčna vozila voziti zelo pogosto, kar bi ob zmožnostih današnjih tehnologij predstavljalo drago in ne preveč posrečeno rešitev. Omenjena tradicionalna metoda je zato uporabna le v primeru posameznih specifičnih študij.


Z razvojem modernih inteligentnih transportnih sistemov in popularizacijo sistemov za globalno pozicioniranje (GPS) je postalo vsako vozilo z nameščeno omenjeno tehnologijo (npr. v obliki navigacijske naprave) potencialno vzorčno vozilo. Z združevanjem različnih tehnologij, kot so sistem za globalno pozicioniranje (GPS), GPRS prenos podatkov preko omrežja mobilne telefonije GSM in interneta za globalni dostop do podatkov, so na voljo komercialni sistemi za določanje položaja vozila. V splošnem so sistemi sledenja vozil namenjeni različnim transportnim upravljavcem flot vozil, ki želijo v vsakem trenutku natančno vedeti, kje se nahajajo njihova vozila in kaj se z njimi dogaja (upravljavcem javnega mestnega prometa, lastnikom voznih parkov, taksi službam, kurirskim službam, izposojevalnicam vozil, reševalnim in intervencijskim službam, vojski, ipd.). Sistem je sestavljen iz mobilne enote, ki se nahaja v vozilu, ter iz nadzornega centra, preko katerega spremljamo posamezno vozilo. Pri temu se moramo zavedati vplivov, ki jih imajo vozne lastnosti posamezne flote vozil na izmerjene parametre kakor je npr. vozna dinamika avtobusa z vmesnimi postanki.



Slika 3-5: Komercialni sistem za sledenje, komunikacijo in nadzor nad vozili (Turner in sodelavci, 1998)

Figure 3-5: Commercial fleet management system (Turner et al., 1998)


V bodoče bo, predvsem ob upoštevanju trenutnega trenda uporabe pametnih telefonov, vsak voznik lahko postal prostovoljec, ki bo sodeloval pri pridobivanju podatkov. Ta hitro rastoča in široko uporabna metoda bo širše uporabna takrat, ko bo penetracija pametnih telefonov in naklonjenost voznikov k posredovanju podatkov tretjim osebam dosegla tako mejo, da bodo za vse prometne povezave v kratkih časovnih razmikih na voljo podatki o potovalnih časih.



Slika 3-6: Določevanje potovalnega časa s sledenjem signala GPS (Turner in sodelavci, 1998)

Figure 3-6: Travel time estimation from GPS tracking (Turner et al., 1998)

Spletna ustanova Google ponuja uporabnikom zemljevide (Google maps), prosto dostopen strežnik z geografskimi podatki in zemljevidi, kjer z vklopom dodatne funkcionalnosti lociranja, vsak pametni telefon anonimno pošilja podatke o uporabnikovi hitrosti in lokaciji centralnemu strežniku. S kombiniranjem velikega števila podatkov o hitrostih različnih uporabnikov z vklopljeno funkcionalnostjo se tako ustvari kompleksna slika prometnih razmer na določenem območju. Google kontinuirano zbira omenjene podatke in jih posreduje voznikom nazaj brezplačno v obliki interaktivnih zemljevidov s prikazom stanja na omrežju.



Slika 3-7: Googlov interaktivni zemljevid s prikazom prometnih razmer na omrežju
Figure 3-7: Google maps interactive traffic layer


3.2 Posredna ocena potovalnega časa

Alternativo neposrednemu merjenju predstavlja posredna ocena potovalnega časa na odseku kjer s točkovnimi merilniki kakor so mikrovalovni detektorji in induktivne zanke na preseku ceste znotraj odseka merimo osnovne karakteristike prometnega toka kot so hitrost in pretok ter jih z uporabo primerne algoritma ekstrapoliramo na celoten pripadajoč odsek. V tem primeru celotno območje za katerega želimo oceniti potovalni čas, razdelimo na pododseke, pri čemer vsako merilno mesto definira lastnosti pripadajočega pododseka. Tu predpostavimo, da so točkovno izmerjeni parametri prometnega toka konstantni na celotnem pododseku, kar posledično zahteva dokaj gosto postavitve točkovnih merilnikov. V primeru redke postavitve točkovnih merilnikov se namreč lahko v primeru hitro spreminjajočih se prometnih razmer zgodi, da se prometne karakteristike znotraj odseka spremenijo, kar pa točkovni detektor ni sposoben dovolj hitro zaznati. Ker je v realnih okoliščinah zaradi neracionalnosti pogosto težko zadostiti temu pogoju, je potrebno uporabiti druge metode, s katerimi omogočimo sledenje prostorskemu razvoju parametrov prometnega toka znotraj pododseka s točkovnimi merilniki. Problem pri uporabi induktivnih zank predstavlja tudi pomanjkanje zanesljivosti pri merjenju hitrosti, kar pa je pri mikrovalovnih detektorjih v sled njihove natančnosti neproblematično. Za določitev potovalnega časa na daljšem odseku tako seštejemo potovalne čase posameznih pododsekov. Tako dobljen potovalni čas imenujemo trenutni potovalni čas. Njegova glavna značilnost je upoštevanje samo zadnjih podatkov, ki so na voljo ob predpostavki, da se prometne razmere na posameznem pododseku do naslednje posodobitve informacije ne bodo spremenile. Glavna prednost pri uporabi trenutnega potovalnega časa je torej njegova časovna neposrednost, s katero odraža najnovejše informacije na odseku. V večini primerov je ravno trenutni potovalni čas najboljša ocena evolucije potovalnega časa za prihodnje obdobje vozniku, ki vstopa na odsek izvajanja meritve. Pri temu se moramo zavedati, da trenutni

potovalni čas predstavlja virtualno meritev, ki ne sovпада z dejansko trajektorijo vozila, od katere ta potovalni čas prihaja.

Prostorska posplošitev točkovnih meritev hitrosti na celoten pripadajoči odsek predstavlja alternativo neposrednemu merjenju potovalnih časov na odseku avtoceste. Kljub enostavnosti in natančnosti meritev, pridobljenih z eno od metod neposrednega merjenja, pa trenutno stanje že vgrajene opreme v sklopu sistemov za nadzor in vodenje prometa narekuje istočasno uporabo točkovnih merilnikov parametrov prometnega toka za oceno potovalnih časov.

V literaturi sta omenjena dva načina za oceno potovalnega časa iz točkovnih merilnikov. Prvi pristop govori o uporabi točkovnih merilnikov (v konkretnem primeru induktivnih zank, ki pa jih po funkcionalnosti lahko zamenjamo tudi mikrovalovni detektorji, uporabljenimi na slovenskih avtocestah) z namenom identifikacije fizičnih lastnosti določenega vozila ali skupine vozil na zaporednih lokacijah. Ko je vozilo enkrat reidentificirano na zaporednih lokacijah, lahko neposredno določimo potovalni čas. Razlike med posameznimi metodami so v načinu identifikacije lastnosti vozila. Coifman in sodelavci (2002b, 2003 in 2007) so za reidentifikacijo vozil uporabili njihovo dolžino, Lucas in sodelavci (2004) so za merjenje potovalnega časa reidentificirali lastnosti strukture prometnega toka, medtem ko sta Abdulhai in Tabib (2003) za zaznavanje in reidentifikacijo vozil uporabila elektromagnetne lastnosti vozila pri prevozu znančnega detektorja. Metoda reidentifikacije lastnosti prometnega toka deluje optimalno le v primeru prostega prometnega toka, saj se v času nastanka zastojev ali tudi vmesnih priključkov lastnosti udeleženih vozil spremenijo.



Slika 3-8: Prikaz silhuete tovornega vozila, osebnega vozila in tovornega vozila s priklopnikom pri prevozu merilnega območja mikrovalovnega detektorja
Figure 3-8: Silhouette of the heavy vehicle, personal car and heavy vehicle with trailer as detected by the microwave detector

Drug pogosteje uporabljen, dokaj preprost in bolj intuitiven način za oceno potovalnega časa je prostorska posplošitev točkovnih meritev hitrosti na celoten pripadajoč odsek. V tem algoritmu je upoštevana hipoteza, da so točkovno izmerjene karakteristike prometnega toka reprezentativne za celotni pripadajoči odsek. Zaradi preprostosti meritve in široke uporabnosti točkovnih detektorjev v svetu, je ta način zelo pogosto uporabljen in razširjen pri različnih cestnih upravljavcih.



Slika 3-9: Namestitev merilnikov za točkovno merjenje parametrov prometnega toka
Figure 3-9: Traffic parameters measurement site

4 IZRAČUN POTOVALNEGA ČASA IZ NEPOSREDNIH LINIJSKIH MERITEV

»Z opazovanjem primerov lahko razpoznamo metodo.«

- Descartes

V zadnjih letih je z razvojem na različnih tehnoloških področjih kot so telekomunikacije, komunikacije in strojni vid prišlo do razmaha tehnologij, ki nam na enostaven in cenovno dostopen način omogočajo zaznavanje različnih fizičnih lastnosti vozil. Z razvojem in pocenitvijo sistemov, ki na podlagi strojnega vida razpoznajo določene lastnosti vozila kot npr. razpoznavanje registrskih tablic ali pa identificirajo brezžične signale kot npr. antene »bluetooth« smo zmožni enolično označiti posamezno vozilo. Če isto vozilo zaznamo tudi na drugi lokaciji nam to omogoča neposreden izračun potovalnega časa, ki ga je za prevoz razdalje med dvema zaporednima točkama identifikacije potrebovalo vozilo. Tako dobimo potovalni čas določenega vozila, informacija o potovalnem času pa je na voljo, ko vozilo konča potovanje. To predstavlja določeno zamudo in zato ta informacija ni neposredno primerna za obveščanje voznikov, ki na odsek vstopajo. Ta vrsta meritve se imenuje potovalni čas po prihodu vozila. Prednost neposredno izmerjenega potovalnega časa je vključitev vseh dejavnikov, ki so med potovanjem vplivali na vozilo.

Delež prometnega toka, ki smo ga sposobni zaznati, je odvisen od penetracije posamezne tehnologije. V kolikor uporabljamo tehnologijo, ki je sposobna beležiti fizične karakteristike, prisotne na vseh vozilih kot npr. branje registrskih tablic, lahko pridobimo precej obsežen vzorec meritev. Nasprotno temu tehnologije, ki beležijo karakteristike z nizko stopnjo penetracije kot npr. sledenje naslovov »bluetooth«, zagotavljajo precej manjši vzorec.

Čim večji delež prometnega toka zajamemo, s tem večjo gotovostjo lahko delamo zaključke o lastnostih prometnega toka. Velik delež vozil pomeni tudi prisotnost podatkov, katerih nerazumno kratki oz. dolgi potovalni časi nimajo vzroka v lastnostih prometnega toka temveč predstavljajo individualno obnašanje posameznega vozila (Yildirimoglu and Geroliminis, 2013). Takim vozilom pravimo osamelci, njihove potovalne čase pa moramo v nadaljnji obdelavi izločiti z uporabo statističnih metod. Na podlagi večjega števila meritev tako določimo reprezentativno vrednost potovalnega časa za dano časovno obdobje ter pripadajoč odsek izvajanja meritve.

Za neposredno merjenje potovalnega časa v splošnem obstajata dve različni metodi: reidentifikacija vozila na kontrolnih točkah ter sledenje trajektoriji vozila na njegovi poti. V nadaljevanju je opisana metoda določevanja potovalnih časov z reidentifikacijo vozila na kontrolnih točkah. Potovalne čase smo neposredno izmerili s sistemom reidentifikacije registrskih tablic in naslovov »bluetooth«.

Preglednica 4-1: Primer zapisa izmerjenih potovalnih časov, potovalni čas ob upoštevanju omejitve je na območju testiranja 730 sekund

Table 4-1: Travel times recorded on the measurement section, by observing the speed limit the travel time is 730 s

ID_POTOVANJA	ID_TIP_NAPRAVE	CAS_ZACETEK	CAS_KONEC	CAS_POTOVANJA	HITROST_POVPRECJE
79625	1	19.3.2013 10:33:31	19.3.2013 10:45:14	703	113
79618	1	19.3.2013 10:31:50	19.3.2013 10:44:59	789	101
79617	1	19.3.2013 10:31:04	19.3.2013 10:44:56	832	95
79616	1	19.3.2013 10:29:58	19.3.2013 10:44:53	895	89
79612	1	19.3.2013 10:32:57	19.3.2013 10:44:37	700	113
79611	1	19.3.2013 10:29:02	19.3.2013 10:44:32	930	85
79609	1	19.3.2013 10:33:16	19.3.2013 10:44:22	666	119
79603	1	19.3.2013 10:30:37	19.3.2013 10:44:21	824	96
79604	1	19.3.2013 10:31:33	19.3.2013 10:44:20	767	104
79601	1	19.3.2013 10:32:00	19.3.2013 10:44:18	738	108
79599	1	19.3.2013 10:32:10	19.3.2013 10:44:16	726	109
79583	1	19.3.2013 10:28:59	19.3.2013 10:43:38	879	90
79582	1	19.3.2013 10:29:53	19.3.2013 10:43:34	821	97

4.1 Pregled obstoječe literature in izvedenih raziskav na temo izračuna potovalnega časa iz neposrednih linijskih meritev

V literaturi najdemo vrsto študij na temo izračuna potovalnega časa iz neposrednih linijskih meritev. Več avtorjev se je ukvarjalo s problemom, kako izločiti osamelce, t.j. vozila katerih podaljšan oz. skrajšan potovalni čas nima vzroka v prometnih razmerah na odseku temveč je posledica individualnega obnašanja vozila kot npr. počitek na počivališču oz. motor, ki prehiteva kolono zaustavljenih vozil.

Quayle in sodelavci (2010) so za določitev območja upoštevanja potovalnega časa uporabili metodo drseče standardne deviacije. Za izbrano število zaporednih časovnih intervalov so izračunali povprečno vrednost potovalnega časa in njegovo standardno deviacijo. V kolikor je potovalni čas v trenutnem časovnem intervalu za več kakor vnaprej določeno število standardnih deviacij nad povprečjem, se ga obravnava kot osamelca in se ga zato izloči. Metoda drseče standardne deviacije predpostavi medsebojno neodvisnost in normalno porazdelitev potovalnih časov.

Haghani in sodelavci (2010) so predlagali dvostopenjski algoritem za izločanje potovalnih časov, ki predstavljajo osamelce. Prvi korak temelji na histogramu potovalnih časov, kjer so dejansko uporabili hitrosti namesto potovalnih časov, pridobljenih iz sledenja naslovov »bluetooth«. Histogram je zglajen na podlagi izračuna povprečja časovno zaporednih histogramov, pri čemer so uporabili zadnjih osem zaporednih intervalov. Zglajen histogram tako predstavlja oceno porazdelitve hitrosti na določenem odseku ceste. Osamelci so definirani kot vrednosti hitrosti, ki padejo pod oz. nad spodnjo in zgornjo mejo. Namen metode je določiti in izločiti potovalne čase, ki so posledica različnih potovanj npr. podatki o potovalnih časih, ki so nastali na dveh različnih potovanjih. Drugi korak izločanja je podoben algoritmu drseče standardne deviacije, ki so ga predlagali Quayle in sodelavci (2010).

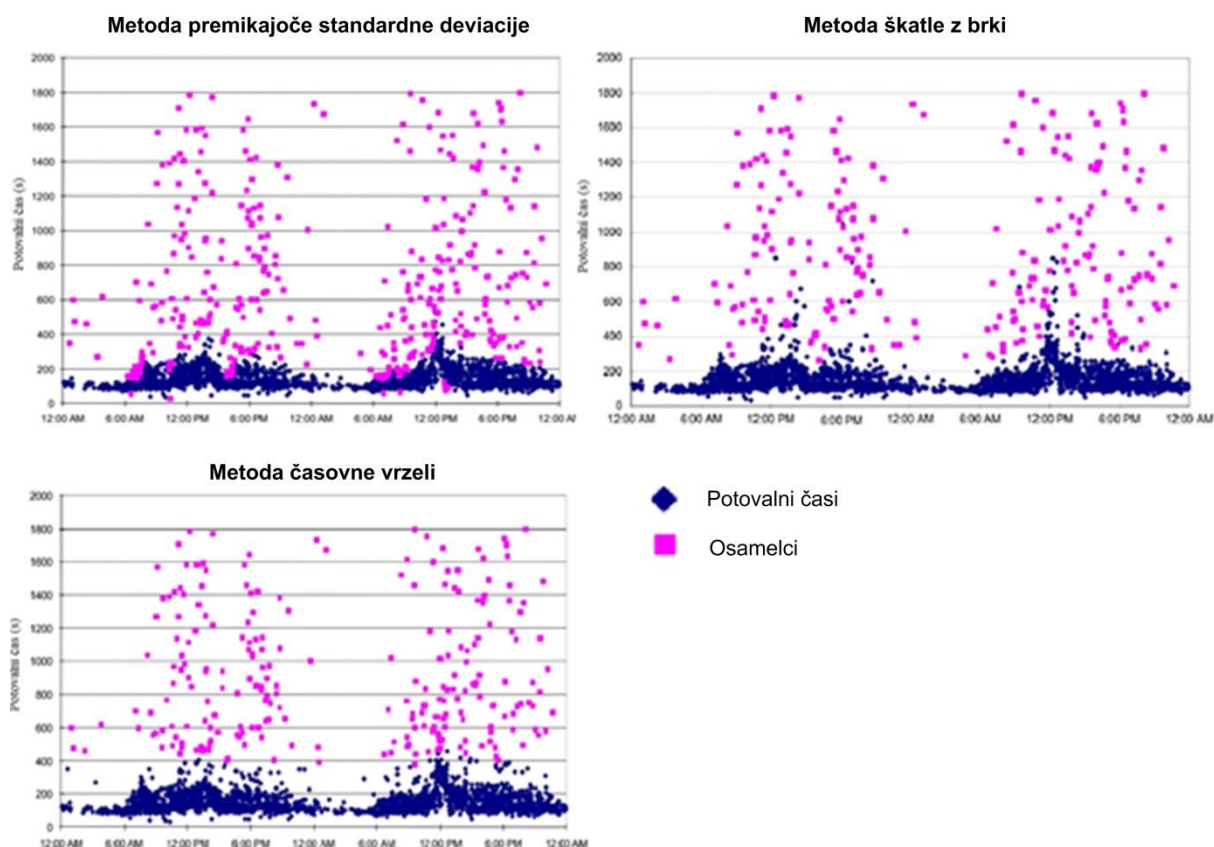
Algoritem izločanja podatkov, ki sta ga predlagala Puckett and Vickich (2010), primerja vsako na novo izračunano vrsto potovalnih časov s predhodnim povprečjem. Če le-ta odstopa za več kot prag meritve (npr. 25 %) od prejšnjega povprečja, potem je ta vrednost označena kot neveljavna in je izločena. Avtorja ugotavljata, da je metoda uporabna predvsem na obremenjenih avtocestah, ki nimajo velikih odstopanj hitrosti od omejitve hitrosti. Uporabnost metode je vprašljiva v času velikih spreminjanj prometnega toka, saj v primeru hitrih sprememb v času nastanka ali razpustitve zastoja vrednosti označi kot neveljavne in jih zavrže, čeprav gre v tem primeru za spremembo prometnega stanja in ne za osamelce.

Dion in Rakha (2006) sta želela zagotoviti, da je algoritem izločanja podatkov uporaben tako v razmerah prostega kot tudi zgoščenega prometnega toka, torej v primeru stabilnih prometnih razmer, kjer nihanje povprečja ni izrazito ter tudi v primeru nestabilnih prometnih razmer, katerih posledica so velika nihanja povprečne vrednosti potovalnega časa. Ukvarjala sta se tudi z uporabnostjo algoritma pri majhnem številu podatkov, pridobljenih iz vira samodejne identifikacije vozil, manjšem od enega procenta. Nov algoritem izločanja podatkov, ki sta ga predlagala Dion in Rakha (2006) uporablja dinamično spreminjajoče se območje veljavnosti, ki na podlagi števila meritev v danem časovnem intervalu, števila meritev v prejšnjem časovnem intervalu ter na podlagi zaporednih meritev izven območja veljavnosti, določi veljavne potovalne čase.

Zaradi velikih nihanj v izmerjenih potovalnih časih, ki predstavljajo težave pri uporabi algoritma Dion in Rakha, sta avtorja Ma in Koutsopoulos (2010) predlagala nadgradnjo algoritma, ki namesto povprečne vrednosti za določitev intervala zaupanja za prihodnji časovni interval uporabi mediano. Avtorja izbiro parametrov in mejnih vrednosti algoritma prepuščata uporabniku, kar omogoča prilagoditev delovanja algoritma različnim razmeram.

Kim in sodelavci (2012) so v svoji študiji semaforizirane cestne mreže preverili tri različne metode izločanja osamelcev v potovalnih časih na mestni cestni mreži: metodo drseče standardne deviacije, metodo škatle z brki ter metodo časovne vrzeli. Pri vseh treh metodah so testiranje izvajali na vzorcu zadnjih 100 vozil. Metoda drseče standardne deviacije upošteva kot veljavne vse meritve, ki so znotraj standardne deviacije, pomnožene z nekim faktorjem odmaknjene v pozitivno in negativno stran od povprečne vrednosti vzorca. Za zagotovitev 95 % obojestranskega intervala zaupanja je ta faktor 1,96. Metoda škatle z brki definira časovno območje dolžine L , ki leži med 25. in 75. centilom vzorca izmerjenih potovalnih časov in vse potovalne čase, ki so pod spodnjo mejo 25. centila oz. nad zgornjo mejo 75. centila označi kot osamelce. Metoda časovne vrzeli temelji na empiričnih dognanjih, njen namen pa je določiti podaljšane potovalne čase, ki so osamelci. Temelji na določitvi časovne vrzeli med upoštevanimi podatki in osamelci, ko ni na voljo nobenih podatkov. Za namene testiranja so Kim in sodelavci (2012) vzeli časovno vrzel velikosti 0,5 pomnoženo z mediano potovalnega časa. Metoda drseče standardne deviacije se izkaže za zelo primerno pri določevanju dolgih potovalnih časov, ki predstavljajo osamelce. Ker potovalni časi zaradi vmesnega semaforiziranega križišča niso normalno porazdeljeni, ta metoda ne izloči kratkih potovalnih časov, saj v primeru, ko povprečni vrednosti vzorca odštejemo standardno deviacijo, pomnoženo s faktorjem, dobimo negativno vrednost oz. vrednost blizu ničle. Na drugi strani imata metoda škatle z brki ter metoda časovne vrzeli podobne negativne lastnosti: metoda škatle z brki se počasi odziva na podaljšane potovalne čase, ki so posledica zgoščevanja prometa v času nastanka zastoja, ter so zato ti potovalni časi mišljeni kot osamelci in so zato izločeni.

Tako metoda škatle z brki kot tudi metoda časovne vrzeli v primeru velikega števila osamelcev nekatere od teh upoštevata v izračunu. Predlagana metoda s strani Kim in sodelavcev (2012) temelji na kombinaciji drseče standardne deviacije in fiksni spodnji meji še upoštevanih potovalnih časov. Metoda drseče standardne deviacije se je po njihovi analizi izkazala kot najboljša pri identificiranju osamelcev z dolgimi potovalnimi časi, ker pa ni sposobna zaznati pretirano kratkih potovalnih časov, je uporabljena spodnja meja še upoštevanih potovalnih časov določena s potovalnim časom pri dvakratnem prekoračenju hitrostne omejitve. Kim in sodelavci (2012) so v svoji študiji preverili tudi tri različne metode napovedi potovalnega časa na mestnem koridorju: metodo drsečih sredin brez prekrivanja zaporednih časovnih intervalov, metodo drsečih sredin s prekrivanjem zaporednih časovnih intervalov ter Kalmanov filter. Za najbolj uspešno se je izkazala metoda drsečih sredin brez prekrivanja časovnih intervalov z uporabo enominutnega časovnega intervala. V primerjavi s petminutnim časovnim intervalom so ugotovili, da se v primeru uporabe enominutnega časovnega intervala metoda hitreje odziva na nenadne spremembe v potovalnem času, ki jih petminutni časovni interval zgladi.



Slika 4-1: Primerjava metod izločanja osamelcev (Kim in sodelavci, 2012)
Figure 4-1: Different methods for elimination of outliers (Kim et al., 2012)

V že nameščenih sistemih za obveščanje voznikov o potovalnih časih deluje precej algoritmov za določevanje potovalnega časa. Eden izmed njih je algoritem TransGuide, razvit na inštitutu Southwest Research, ki potovalne čase na odseku med zaporednimi lokacijami samodejno identifikacije vozil določa z uporabo metode drsečega povprečja, ki samodejno izloči vse potovalne čase, ki za več kot prag meritve odstopajo od definiranega merodajnega potovalnega časa na tem odseku. Potovalni čas na odseku računa z metodo drsečih povprečij, pri čemer

uporablja časovni okvir zajema ter prag meritve za izločanje osamelcev. Časovni okvir zajema se uporablja za določitev časovnega okvirja, ki ga upoštevamo pri izračunu potovalnega časa. V primeru, ko je časovni okvir 5 minut, za izračun potovalnega časa upoštevamo le podatke o avtomobilih, ki so v zadnjih 5 minutah prispeli na doltočni odsek. Prag meritve se uporablja za izločitev osamelcev, to je vozil, ki so zaradi različnih vzrokov, neodvisnih od razmer v prometnem toku kakor npr. postanek na počivališču, bencinskem servisu, za potovanje potrebovala več časa kot ostali prometni tok. V primeru, da je prag meritve nastavljen na 20 % to pomeni, da vsi potovalni časi, ki za več kot 20 % odstopajo od potovalnega časa, določenega v prejšnji časovni iteraciji, niso vključeni v izračun.

TransGuidu podoben algoritem je algoritem TransStar, prav tako razvit na inštitutu Southwest Research. Algoritem temelji na zgoraj opisanih enačbah, njegova edina razlika napram algoritmu TransGuide pa je, da se trenutni potovalni čas posodobi vsakič, ko sistem po zaznavi medija za elektronsko cestninjenje na dveh zaporednih lokacijah izračuna novo vrednost potovalnega časa. Tu torej ne gre za posodabljanje na konstanten časovni interval temveč ob prehodu in določitvi para z vsakega novega vozila. Tudi ta algoritem uporablja prag meritve za izločanje osamelcev, pri čemer pa je časovni okvir zajema običajno veliko krajši (okoli 30 sekund).

Tretji iz družine podobnih algoritmov je algoritem Transmit, katerega delovanje je podobno predhodno omenjenima z razliko, da namesto uporabe drsečega povprečja ta algoritem uporablja konstantne 15-minutne intervale zajema podatkov. Za vsak časovni interval k , sistem zbere vzorec n_k individualnih potovalnih časov, na podlagi katerih nato izračuna trenutni povprečni potovalni čas tt_{ABk} za ta časovni interval po naslednji enačbi:

$$tt_{ABk} = \frac{\sum_{i=1}^{n_k} (t_{Bi} - t_{Ai})}{n_k} \quad (4-1)$$

Spodnja enačba je nato uporabljena za glajenje ocenjenega potovalnega časa z upoštevanjem preteklih podatkov za enak 15-minutni interval v prejšnjem tednu, dnevu oz. glede na specifično situacijo, s čimer dobimo posodobljen povprečni potovalni čas. Proces glajenja se izvede z uporabo robustnega algoritma eksponentnega glajenja. Robustnost algoritma je povezana z uporabo faktorja $\alpha = 0.10$, v kolikor na odseku ni nesreče in vrednost faktorja $\alpha = 0$, v kolikor je na odseku nesreča. Eksponentno glajenje zagotavlja, da podatki v času nesreč niso zajeti v drsečem povprečju in tako baza zgodovinskih podatkov zajema le značilne neponavljajoče primere zastojev.

$$tth''_{ABk} = (\alpha) \cdot tth_{ABk} + (1 - \alpha) \cdot tth''_{ABk-1} \quad (4-2)$$

pri čemer je:

tth''_{ABk} = zglajen zgodovinski podatek o potovalnem času za trenutni časovni interval k ,

tth_{ABk} = zgodovinski potovalni čas za k -ti časovni interval,

tth''_{ABk-1} = zglajen zgodovinski podatek o potovalnem času za predhodni časovni interval $k-1$.

Barceló in sodelavci (2010) so razvili vrsto metod za izločanje podatkov o potovalnih časih, pridobljenih s sledenjem naslovov »bluetooth«. Njihova metoda določa spodnjo mejo še

upoštevanih potovalnih časov v prostem prometnem toku, s čimer so izločene pretirano visoke hitrosti. Sistem na podlagi skupne povprečne hitrosti vozil spreminja trenutno spodnjo mejno vrednost še upoštevane potovalnega časa. Barceló in sodelavci (2010) so za napoved potovalnih časov in določitev osamelcev uporabili Kalmanov filter.

Za določitev anomalij potovalnega časa se v literaturi omenjajo različne statistične metode, ki jih lahko delimo na parametrične in neparametrične (Chandola in sodelavci, 2009). Parametrična metoda je način, v katerem odvisnost opišemo z uporabo parametrov. Parametrične statistične metode za določitev anomalij določijo osamelce ob predpostavki, da zbrani potovalni časi pripadajo neki porazdelitvi. V tem primeru se parametri predvidene ali znane porazdelitve določijo iz podatkov o potovalnih časih, ki so na voljo. Osamelci se določijo na podlagi določitve verjetnosti (intervala zaupanja) predvidene porazdelitve.

Avstrijski raziskovalci Schneider in sodelavci (2009) so izločili osamelce v potovalnih časih, pridobljenih iz sistema elektronskega cestninjenja, z uporabo dveh metod: metodo škatle z brki in izločanje vrednosti z . Metoda škatle z brki identificira osamelce na podlagi kvartilnih vrednosti distribucije. Škatla z brki je diagram, ki se v opisni statistiki pogosto uporablja za grafično ponazoritev skupin številčnih podatkov ter njihovih povzetkov s povzetki prikazanimi s petimi števili: najmanjša vrednost (minimum vzorca), prvi kvartil (q_1), mediana (q_2), tretji kvartil (q_3) in največja vrednost (maksimum vzorca). Metoda škatle z brki spada med neparametrične metode. Izločanje vrednosti z pa identificira osamelce na podlagi primerjave določenega podatka z ostalimi podatki. Vrednost z (tudi standardna vrednost) je statistični kazalec položaja posamezne statistične enote v statistični populaciji glede na aritmetično sredino. Definirana je kot razlika vrednosti konkretne enote in aritmetične sredine populacije v razmerju s standardnim odklonom.

V skupini parametričnih statističnih metod je tudi metoda regresije. Linearno oz. nelinearno regresijo običajno uporabimo pri časovnih vrstah ob predpostavki, da ta časovna vrsta sledi specifičnemu naključnemu (stohastičnemu procesu). Naključni (stohastični ali slučajni) procesi so pojavi, ki se spreminjajo s časom ali krajem v skladu z zakoni verjetnosti. V realnih okoliščinah se pri modeliranju časovnih procesov pogosto srečujemo z metodo drsečega povprečja in avtoregresivnim modelom, pri katerem je izhodna spremenljivka linearno odvisna od svojih predhodnih vrednosti. Vsaka od obeh ima svojo matematično formulacijo in po določitvi parametrov modela stohastičnega procesa lahko določimo interval zaupanja. Skupno obema je predpostavka, da povprečna vrednost potovalnega časa ostane konstantna v času. Te metode so uporabne pri potovalnih časih v obdobjih, ko je povprečna vrednost potovalnega časa konstantna.

Neparametrične statistične metode za določitev anomalij se ne zanašajo na predpostavke o verjetnostnih porazdelitvah podatkov. Ena izmed najbolj znanih metod ima za osnovo histogram. Tu so podatki porazdeljeni v posamezen stolpec, tem stolpcem pa se dodeli ocena, ki ponavadi temelji na stopnji ponavljanja. Osamelce določimo na podlagi njihove stopnje ponavljanja (frekvence).

Kim in sodelavci (2012) so izpostavili tudi problematiko odvisnosti med posameznimi meritvami potovalnega časa, ki so najbolj opazne v primeru zgoščenega prometnega toka. Ker večina statističnih metod temelji na velikih vzorcih slučajno porazdeljenih spremenljivk in

njihovi normalni porazdelitvi, je lahko ta statistični pristop vprašljiv v razmerah zgoščenega prometnega toka, v času, ko zaradi korelacije med vozili njihovi potovalni časi niso neodvisni.

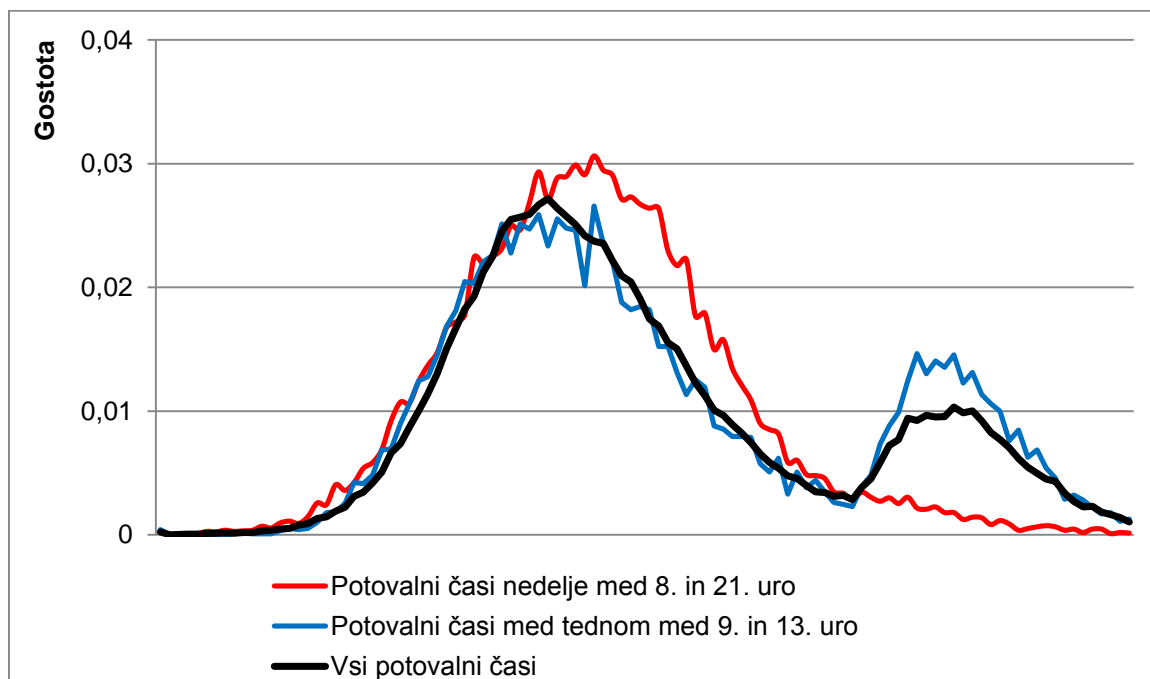
Večini predhodno omenjenim raziskavam je skupno to, da so uporabile predpostavko o normalni porazdelitvi potovalnega časa ter so reprezentativno vrednost potovalnega časa izračunale s klasičnimi statističnimi metodami.

4.2 Porazdelitev potovalnih časov

Analiza neposredno linijsko izmerjenih potovalnih časov, pridobljenih v obdobju 12 dni meseca aprila 2013, je bila opravljena na vzorcu približno 112.000 meritev. Ker zaradi konfiguracije trase in voznih omejitev tovorna vozila za prevoz odseka potrebujejo bistveno več časa kot osebna vozila je za določitev osnovne porazdelitve vzeto obdobje, ko za tovorna vozila velja prepoved vožnje (nedelje med 8. in 21. uro). Struktura prometnega toka je zelo odvisna od dneva v tednu in posamezne ure znotraj dneva, zato so prikazane ločene porazdelitve za posamezna obdobja.

Pri obdelavi velikega števila podatkov iz populacije se v raziskavah pogosto uporabi predpostavka o normalni porazdelitvi podatkov. V kolikor bi za porazdelitev potovalnih časov uporabili predpostavko o normalni porazdelitvi, bi z uporabo statistik vezanih na normalno porazdelitev (povprečje, standardna deviacija) dobili rezultate, ki nepravilno okarakterizirajo obnašanje potovalnih časov.

Iz grafa gostote porazdelitve potovalnih časov za obdobje med tednom, ko so v prometnem toku prisotna tako osebna kot tovorna vozila, sta dobro vidna dva ekstrema, pri čemer prvi pripada osebnim vozilom drugi pa tovornim vozilom.

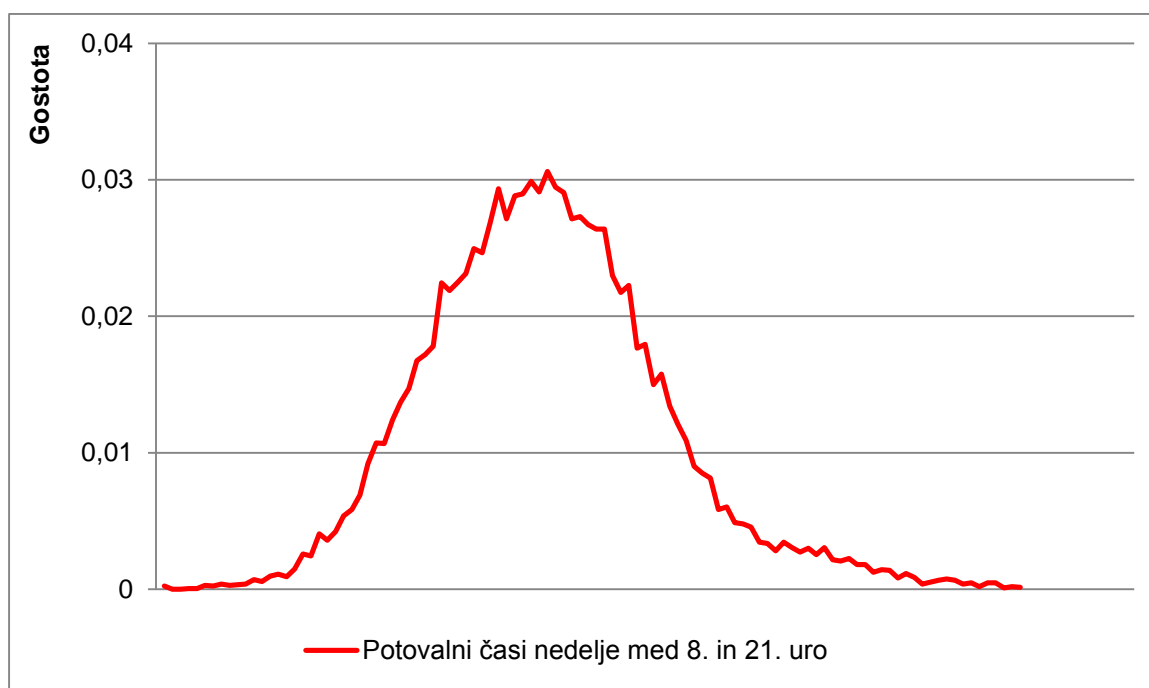


Slika 4-2: Porazdelitev potovalnih časov za različna obdobja v tednu
Figure 4-2: Travel times distribution for different periods during the week

4.2.1 Logaritemsko normalna porazdelitev

Logaritemsko normalna porazdelitev je zvezna verjetnostna porazdelitev slučajne spremenljivke, katere logaritem je normalno porazdeljen. Porazdelitev je dvoparameterska ter asimetrična. Slučajna spremenljivka, ki je logaritemsko normalno porazdeljena, lahko zavzame samo pozitivne vrednosti.

Iz porazdelitve potovalnih časov v prostem prometnem toku v obdobju, ko na odseku ni tovornih vozil, se da razbrati, da se potovalni časi porazdeljujejo logaritemsko normalno, pri čemer je dobro vidna značilna zamaknjenost v desno. Ta zamik v desno je posledica dejstva, da vrednosti potovalnih časov običajno ne zavzemajo vrednosti manjših od tistih doseženih v razmerah prostega prometnega toka, medtem, ko do podaljšanih potovalnih časov pogosto pride predvsem v primeru vmesnega postanka vozila ali v času nastajanja zastojev.



Slika 4-3: Porazdelitev potovalnih časov v prostem prometnem toku brez prisotnosti tovornih vozil

Figure 4-3: Travel times distribution during free flow traffic conditions with absence of heavy vehicles

4.2.2 Preizkušanje skladnosti empirične porazdelitve z logaritemsko normalno porazdelitvijo

Potem, ko smo na podlagi podatkov empirične porazdelitve ocenili predvideno ustrezno porazdelitev, je to izbiro potrebno še preveriti. V literaturi najdemo različne teste za preverjanje predpostavke ali se empirično pridobljeni podatki prilegajo teoretični porazdelitvi.

4.2.2.1 Test hi-kvadrat

Test hi-kvadrat lahko uporabimo pri preizkušanju ali sta dve spremenljivki odvisni ali ne. Rezultate meritev razporedimo po razredih. Test primerja opazovane frekvence empiričnega dogodka v vzorcu s teoretično določenimi frekvencami.

Test hi-kvadrat pogosto uporabljamo pri preizkušanju ali vzorec ustreza predpostavljeni porazdelitvi.

4.2.2.2 Test Kolmogorov-Smirnov

Test Kolmogorov-Smirnov je test, ki se uporablja za primerjavo enakosti zveznih enodimenzionalnih verjetnostnih porazdelitev. Test je neparametričen, kar pomeni, da je preizkušanje ničelne hipoteze neodvisno od porazdelitvene funkcije. V realnih okoliščinah ga ponavadi uporabljamo za primerjavo empirično dobljene verjetnostne porazdelitve z neko referenčno verjetnostno porazdelitvijo. Statistika Kolmogorov-Smirnov določi medsebojne odmike med empirično porazdelitveno funkcijo in porazdelitveno funkcijo referenčne porazdelitve.

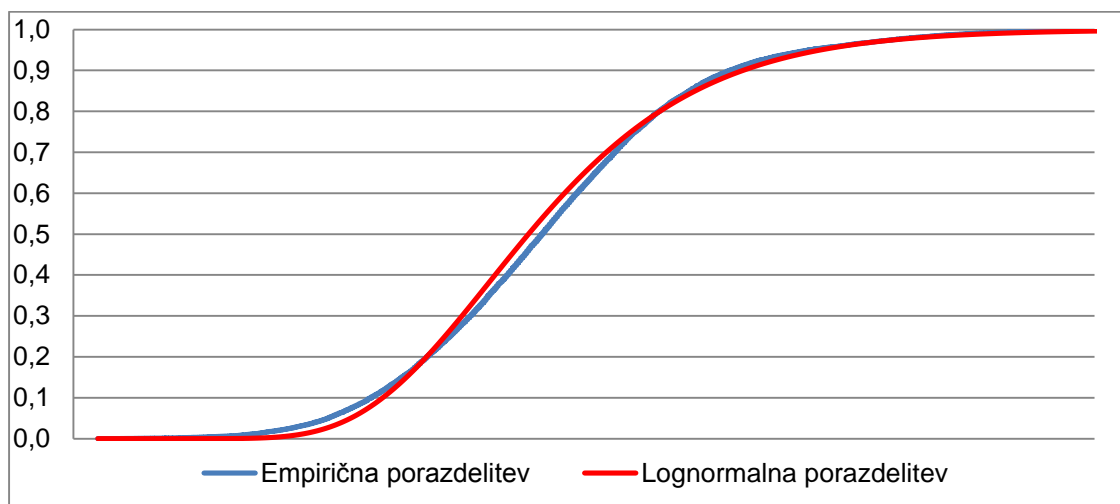
Statistiko določimo tako, da poiščemo največjo absolutno razliko med empirično in referenčno porazdelitveno funkcijo in v kolikor je statistika večja od mejne vrednosti pri določenem tveganju α , potem moramo ničelno hipotezo zavrniti in lahko s tveganjem α sklepamo, da porazdelitev ni takšna, kot smo jo definirali v ničelni domnevi.

Prednost testa Kolmogorov-Smirnov pred testom hi-kvadrat je izrazita v primeru majhnih vzorcev, ki jih težko razvrstimo v razrede.

4.2.2.3 Test Anderson-Darling

Nekatere pomanjkljivosti testa Kolmogorov-Smirnov odpravlja test Anderson-Darling, ki je posebna različica testa Kolmogorov-Smirnov. Test se ne osredotoči le na iskanje maksimalnega odstopanja temveč upošteva vse obravnavane vrednosti. Prav tako ima test večji poudarek na obeh koncih porazdelitve, kjer se v večini primerov nahajajo osamelci. Tudi test Anderson-Darling se lahko uporabi za majhne velikosti vzorcev. Mejne vrednosti testa so odvisne od velikosti vzorca in izbrane stopnje zaupanja.

V primeru, ko je rezultat testa vrednost p manjši od podane mejne vrednosti, testirano porazdelitev zavrnemo s tveganjem α . Tako kot pri testu Kolmogorov-Smirnov tudi za test Anderson-Darling velja, da čim večja kot je vrednost testa p , večje je ujemanje med empirično in teoretično porazdelitvijo.



Slika 4-4: Primerjava med empirično in logaritemsko normalno porazdelitvijo
Figure 4-4: Comparison between empirical and lognormal distribution

4.2.2.4 Rezultati testov

Pri uporabi programa Excel za izvedbo testa Kolmogorov-Smirnov za empirično pridobljeno porazdelitev v primerjavi z logaritemsko normalno porazdelitvijo, smo pri velikost vzorca nekaj manj kot 22.000 vozil pri rezultatu naleteli na izredno majhno vrednost p , na podlagi katere bi lahko s faktorjem $\alpha = 5\%$ zavrnili ničelno hipotezo, ki pravi, da so empirično pridobljeni podatki porazdeljeni logaritemsko normalno. Tako majhna vrednost p je posledica velikega števila prostostnih stopenj, zaradi katere test Kolmogorov-Smirnov zavrne ničelno hipotezo z upoštevanim tveganjem.

V kolikor vzorec podatkov zmanjšamo na red velikosti 100 podatkov, dobimo dobro prileganje empirične porazdelitve k logaritemsko normalni porazdelitvi, pri čemer s tveganjem $\alpha = 5\%$ ne moremo trditi, da se empirično pridobljena porazdelitev ne porazdeljuje logaritemsko normalno. Preveritev ničelne hipoteze smo izvedli s programom Mathematica ter primerjali rezultate testa (vrednost p) Anderson-Darling ter metode hi-kvadrat.

```
datal = RandomSample[data, 100];
```

```
Print["Lognormal distribution"]
```

```
dist = EstimatedDistribution[datal, LogNormalDistribution[a, b]]
```

```
LN = DistributionFitTest[datal, dist, "HypothesisTestData"];
```

```
LN["TestDataTable", All]
```

	Statistic	P-Value
Anderson-Darling	0.243219	0.973821
Cramér-von Mises	0.0313483	0.971532
Pearson χ^2	5.82	0.924882

Slika 4-5: Rezultati testa Anderson-Darling in metode hi-kvadrat za primerjavo empirično pridobljene porazdelitve z logaritemsko normalno porazdelitvijo z uporabo programa Mathematica

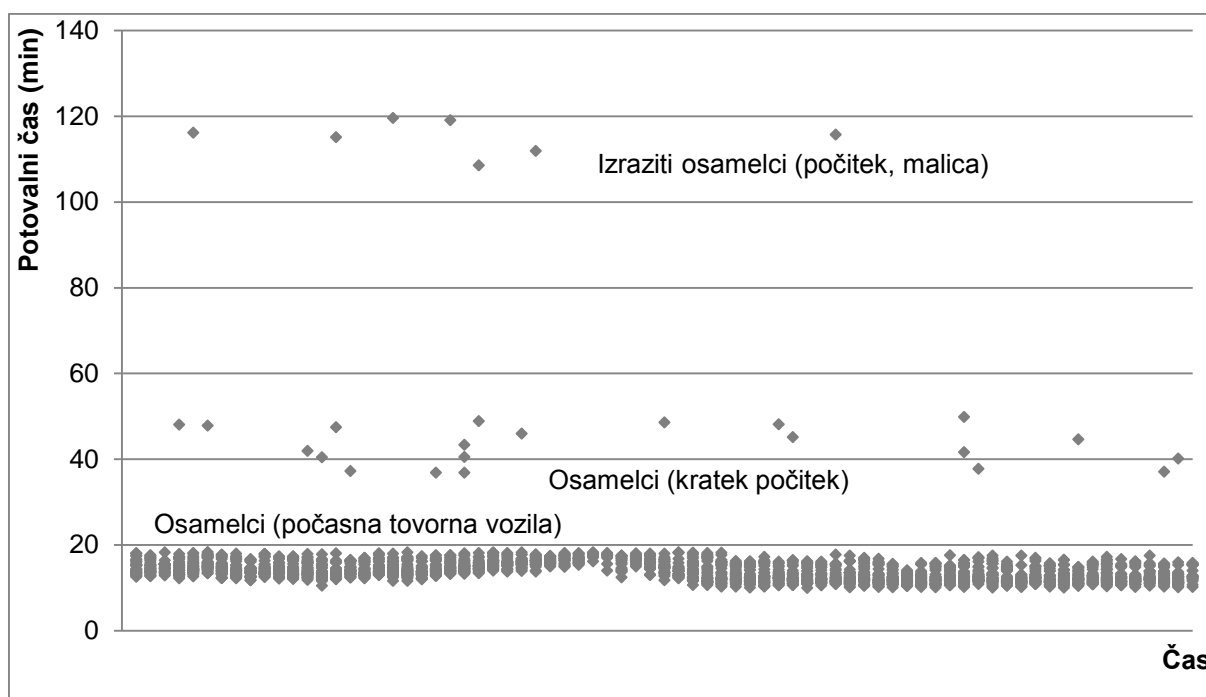
Figure 4-5: Results of Anderson-Darling test and hi-squared method for comparing empirical and lognormal distribution using Mathematica

4.3 Robustna statistika

4.3.1 Osamelci

Osamelec predstavlja podatek, ki bistveno odstopa od večine ostalih podatkov v statističnem vzorcu. Pri izračunu potovalnih časov kot osamelce štejemo potovalne čase, katerih skrajšan oz. podaljšan potovalni čas ni posledica prometnih razmer, temveč individualnega obnašanja posameznega vozila.

Prisotnost osamelcev v podatkih ima neugoden vpliv na določitev reprezentativne vrednosti potovalnega časa.



Slika 4-6: Prisotnost osamelcev v meritvah potovalnega časa
Figure 4-6: Presence of outliers in travel time measurements

V realnih okoliščinah se zato vedno pogosteje uporabljajo tako imenovani robustni modeli in robustna statistika, katerih namen je določiti in izločiti osamelce.

4.3.2 Robustna statistika

Robustna statistika predstavlja alternativen pristop standardnim statističnim metodam, njen namen pa je določitev cenilk, na katere prisotnost osamelcev ne vpliva. Uporaba robustnih statističnih metod omogoča samodejno zaznavanje, označitev in eliminacijo osamelcev. Robustna statistika je uporabna predvsem pri naključnih spremenljivkah, ki niso porazdeljene normalno in pri katerih bi velika odstopanja od srednje vrednosti pri uporabi klasičnih statističnih metod pomenila velike spremembe v rezultatih. Z uporabo robustne statistike dobimo zanesljive rezultate cenilk tudi pri velikih odstopanjih posameznih vrednosti (osamelcev) v porazdelitvi.

Osnovni lastnosti za merjenje robustnosti sta lokalna in globalna stabilnost.

4.3.3 Lokalna stabilnost

Lokalna stabilnost nam pove, kako in koliko posamezni element vzorca vpliva na statistiko. Lokalno stabilnost opišemo z vplivno funkcijo (ang. influence function, *IF*), ki meri vpliv posameznega opazovanja na teoretično predvideno porazdelitev. Vplivna funkcija nam pove, kako se obnaša cenilka v primeru spremembe enega podatka v vzorcu. Želena lastnost robustne statistike je omejena vplivna funkcija, kar pomeni, da je vpliv posameznega opazovanja, ne glede na njegovo velikost, omejen. Neomejene vplivne funkcije dovolijo, da se vpliv kontaminiranih opazovanj povečuje ne glede na to, kako odstopajoča so, kar pomeni, da zelo izstopajoči osamelci lahko popolnoma pokvarijo oceno.

4.3.4 Globalna stabilnost

Globalna stabilnost predstavlja najmanjše število (delež) elementov neskončnih vrednosti, ki so potrebni, da statistika postane neskončna. Globalno stabilnost merimo s točko preloma cenilke (ang. breakdown point), ki predstavlja delež osamelih podatkov, ki jih cenilka lahko upošteva, ne da bi ti imeli velik vpliv na rezultat. Večja kot je vrednost točke preloma cenilke, bolj robustna je. Zgornja meja točke preloma predstavlja vrednost 50 %, saj v primeru, da je več kot polovica meritev kontaminiranih, ni več mogoče razlikovati med pravilnimi in kontaminiranimi podatki. Za razliko od lokalne stabilnosti, ki je lokalna mera, točka preloma meri globalno odpornost.

Zgornjo točko preloma vrednosti 0.5 predstavlja mediana, medtem ko ima povprečna vrednost točko preloma pri vrednosti 0, saj posamezen osamelec v vzorcu lahko bistveno spremeni povprečno vrednost. Analogno temu sta mediana absolutnega odklona in interkvartilni razmik robustni meri statistične razpršenosti, medtem ko standardni odklon ni robustna mera.

Tako so najbolj uporabne robustne metode, ki združujejo visoko vrednost točke preloma in omejeno vplivno funkcijo.

4.3.5 Mere lege

Mere lege so vrednosti, ki opisujejo lego v porazdelitvi. Najpogosteje uporabljena lega mere je srednja vrednost, ki se nanaša na osrednjo težnjo niza podatkov. Sredin, ki jih je mogoče izbrati kot mero srednje vrednosti, je v opisni statistiki mnogo, najbolj poznana sredina je povprečje, ki pa ni robustna mera lege, saj že eno samo opazovanje lahko povsem spremeni povprečno vrednost. Za robustno statistiko zelo uporabna mera lege je mediana, ki je zelo odporna na osamelce.

4.3.5.1 Mediana

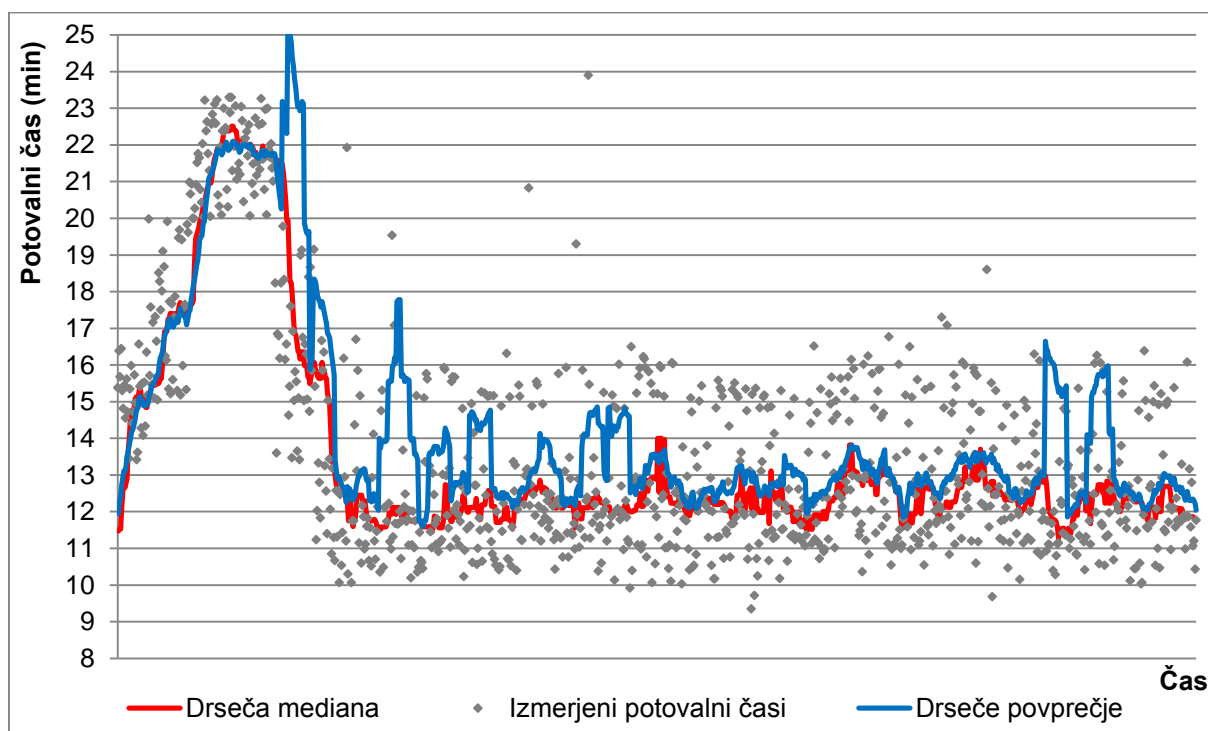
Mediana v statistiki predstavlja vrednost nekega zaporedja števil, ki razdeli števila, razvrščena po velikosti, na dve enaki polovici po številu elementov. Prednost mediane pred aritmetično sredino je, da osamelci manj vplivajo na njeno vrednost. Mediana ima pomembno vlogo v robustni statistiki, saj glede na osamelce predstavlja najbolj neobčutljivo statistiko, predvsem v primerjavi s povprečno vrednostjo. Mediana je uporabna predvsem pri nesimetričnih

porazdelitvah, kot je to tudi v primeru porazdelitve potovalnih časov. Uporabna je tudi v primerih, ko so v določenem vzorcu meritev prisotni osamelci, katerih vpliv želimo zmanjšati. Mediana je uporabna vse dokler osamelci ne predstavljajo več kot 50 % vseh vrednosti.

4.3.5.2 Drseča mediana

Drseča mediana je filter za analizo podatkov s kreiranjem mediane za različne podmnožice podatkov znotraj celotnega niza podatkov. Pri vnaprej znanem številu elementov podmnožice, prvo vrednost drseče mediane izračunamo kot mediano prve podmnožice podatkov. V naslednjem koraku naredimo »premik naprej« in kot novo podmnožico definiramo elemente tako, da izpustimo prvi element iz prejšnje podmnožice in dodamo prvi naslednji element, ki v prejšnji podmnožici ni bil upoštevan. To definira novo podmnožico, katere mediano izračunamo. Ta proces nato ponavljamo za celoten niz podatkov. Vse tako izračunane mediane predstavljajo drsečo mediano. Drseča mediana torej predstavlja niz podatkov, pri katerem vsak od njih predstavlja mediano pripadajoče podmnožice podatkov. Drseča mediana lahko uporablja tudi različne uteži za različne podatke, s čimer poudarimo pomembnost posameznega podatka.

Drsečo mediano pogosto uporabljamo v časovnih vrstah z namenom glajenja kratkoročnih nihanj, pri čemer poudarimo dolgoročneje trende oz. cikle. Drseča mediana v primerjavi z drsečim povprečen predstavlja robustnejšo oceno, saj ni občutljiva na posamezne vrednosti in ostale anomalije.



Slika 4-7: Primerjava drseče mediane in drsečega povprečja
Figure 4-7: Comparison between running median and running average

4.3.5.3 Centil

Centil je točka, ki deli statistično populacijo na enake dele. Po številu delov, na katere delimo po neki vrednosti urejeno populacijo, poznamo različne centile, ki jih označujemo kot centile razreda p , pri čemer velja $0 < p \leq 100$. Centili so tako mejne vrednosti med posameznimi podmnožicami slučajne spremenljivke, kjer obravnavamo po velikosti urejeno populacijo. Kadar populacijo razdelimo na n delov, imamo n podmnožic vrednosti slučajne spremenljivke in $n-1$ vrednosti centilov, ki jih ločijo med seboj. Vsaka vrednost slučajne spremenljivke se nahaja v enem izmed centilov. Običajno navajamo, da se določena vrednost slučajne spremenljivke nahaja v k -tem centilu (v k -ti podmnožici). Kot predhodno omenjeno, predstavlja 50 centil mediano, ki populacijo razdeli na dva enaka dela.

Tako kot mediana imajo različne vrednosti centilov pomembno vlogo v robustni statistiki, saj glede na osamelce predstavljajo odporno statistiko. Centili so uporabni predvsem pri nesimetričnih porazdelitvah, kot je to v primeru porazdelitve potovalnih časov. Uporabni so tudi v primerih, ko so v določenem vzorcu meritev prisotni osamelci, katerih vpliv želimo kar se le da zmanjšati.

4.3.5.4 Drseči centil

Tako kot drseča mediana tudi drseči centil predstavlja filter za analizo podatkov s kreiranjem izbranega centila za različne podmnožice podatkov znotraj celotnega niza podatkov. Pri vnaprej znanem številu elementov podmnožice, prvo vrednost drsečega centila izračunamo kot izbrani centil prve podmnožice podatkov. V naslednjem koraku naredimo »premik naprej« in kot novo podmnožico definiramo elemente tako, da izpustimo prvi element iz prejšnje podmnožice in dodamo prvi naslednji element, ki v prejšnji podmnožici ni bil upoštevan. To definira novo podmnožico, katere izbran centil izračunamo. Ta proces nato ponavljamo za celoten niz podatkov. Črta, ki povezuje vse izračunane centile se imenuje drseči centil.

Drseči centil pogosto uporabljamo v časovnih vrstah z namenom glajenja kratkoročnih nihanj, pri čemer poudarimo dolgoročnejsše trende oz. cikle.

4.3.6 Mere razpršenosti

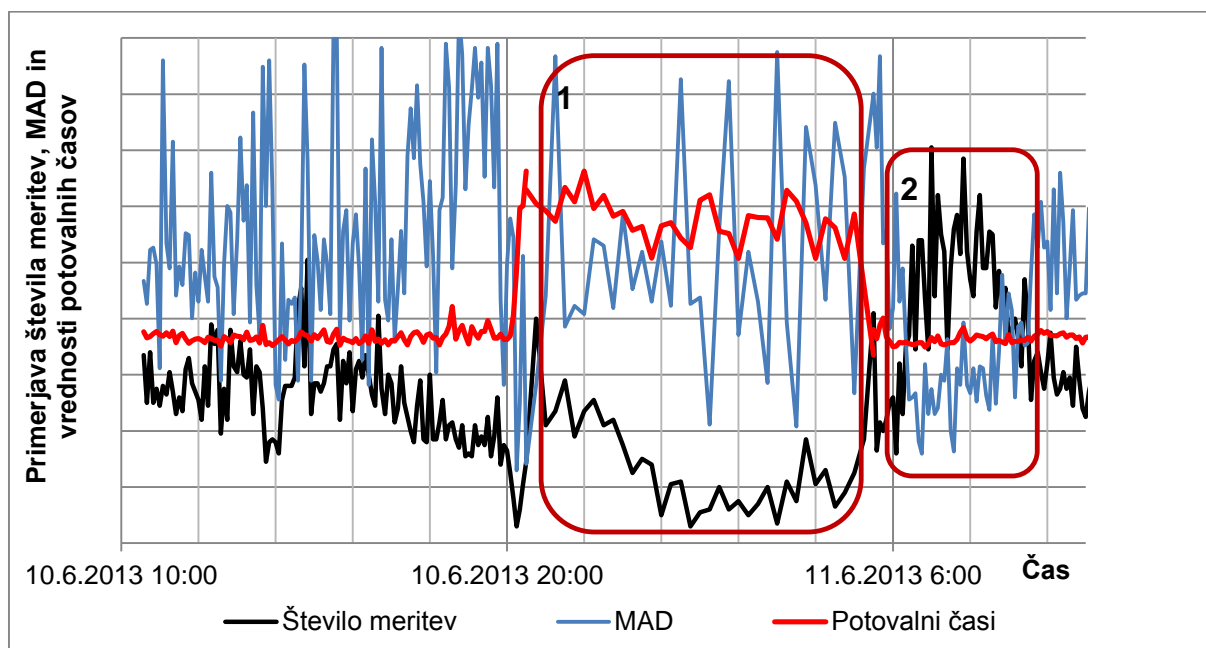
Statistična razpršenost (disperzija ali variacija) v opisni statistiki predstavlja odstopanja elementov v populaciji glede na mero lege. Pod pojmom razpršenost razumemo odstopanje individualnih vrednosti neke populacije okoli mere lege. Velika odstopanja posameznih vrednosti od srednje vrednosti populacije pomenijo veliko razpršenost. Pogosto uporabljena mera razpršenosti je standardna deviacija od povprečja oz. od mediane, ki pa ni robustna statistika. V robustni statistiki uporabni meri razpršenosti sta predvsem interkvartilni razmik (razmik) ter mediana absolutnega odklona (odklon), ki se robustno obnašata na vzorcih z osamelci.

Robustne cenilke imajo ponavadi nekoliko slabšo statistično učinkovitost v primerjavi s konvencionalnimi cenilkami pri porazdelitvah, ki ne vključujejo osamelcev (kot npr. normalna porazdelitev), vendar imajo veliko boljše učinkovitost pri porazdelitvah z repom, za katere nerobustne metode niso primerne.

4.3.6.1 Mediana absolutnega odklona (od mediane) - MAD

Mediana absolutnega odklona od mediane predstavlja mediano absolutnih razlik med izbrano spremenljivko in mediano njene statistične populacije, pomnoženo s faktorjem 1,483. Absolutni odklon mediane, v literaturi poznan tudi kot MAD (ang. median absolute deviation), je robustno merilo razpršenosti podatkov. MAD je veliko bolj odporen na osamelce kot standardni odklon in ostale mere absolutnih deviacij povezanih s srednjo vrednostjo.

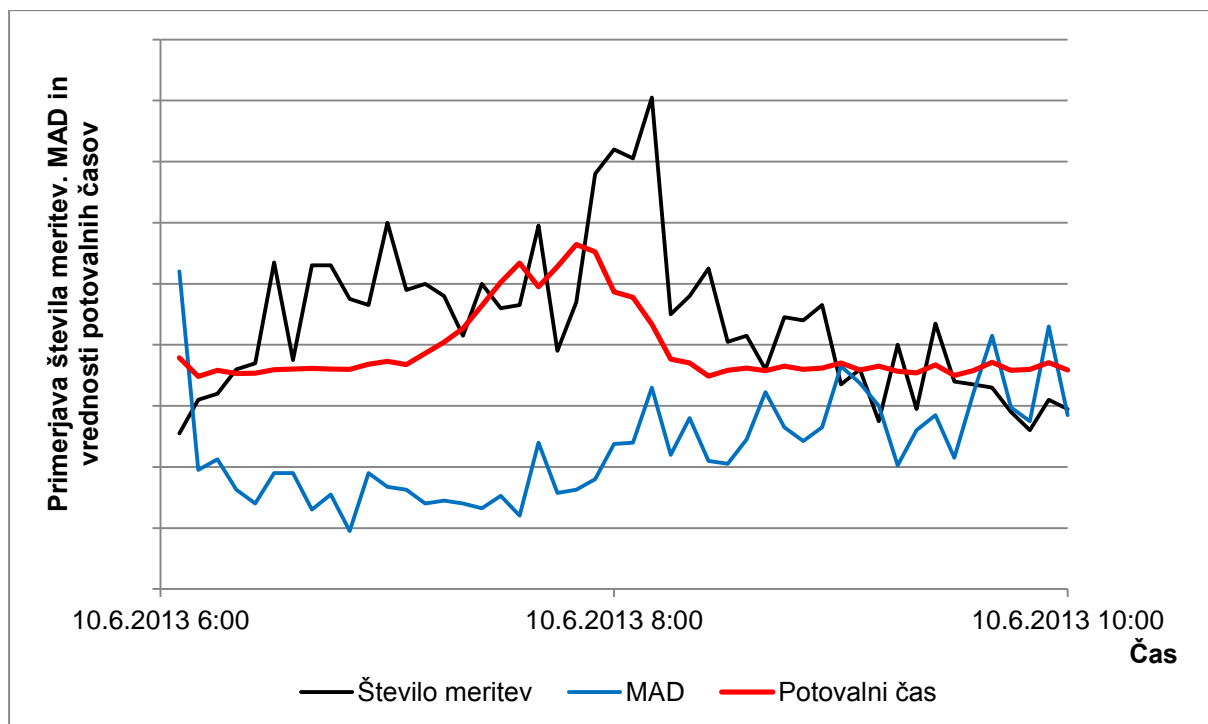
V realnih okoliščinah pa se je pokazalo, da je nihanje MAD zelo odvisno od števila izmerjenih potovalnih časov znotraj vzorca, število izmerjenih potovalnih časov pa je v razmerju s količino prometnega toka. V času nizkih prometnih obremenitev ponoči (Slika 4-8: območje točke 1), dobimo manjši vzorec izmerjenih potovalnih časov, izmerjene vrednosti potovalnih časov pa precej bolj odstopajo od vrednosti mediane. Vzrok za to so razmere prostega prometnega toka, kjer vozila po odseku vozijo brez posebnih interakcij in popolno svobodo manevriranja, kar vodi k veliki razpršenosti potovalnih časov znotraj časovnega intervala, to pa se kaže v večjih vrednostih MAD. Po drugi strani v primeru večjih prometnih obremenitev (Slika 4-8: območje točke 2) vozila potujejo z manjšo možnostjo manevriranja in določenim vplivom med vozili, pri čemer se vrednost MAD zmanjša. Vrednost MAD tako doseže najnižjo vrednost v času jutranje prometne konice, ko poraste delež osebnih vozil, ki po odseku vozijo z zelo primerljivimi potovalnimi časi.



Slika 4-8: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa v primeru preusmeritve na vzporedno cestno omrežje
Figure 4-8: Comparison between number of measurements, median absolute deviation (MAD) and median during re-routing of traffic on a parallel road

V primeru izrednega dogodka na avtocesti, zaradi katerega so se potovalni časi s 13 minut podaljšali na 19 minut, je v času jutranje konice, ko v prometnem toku prevladujejo osebna vozila, mogoče opaziti dokaj konstantno vrednost MAD, kar sovпада s predhodno ugotovitvijo,

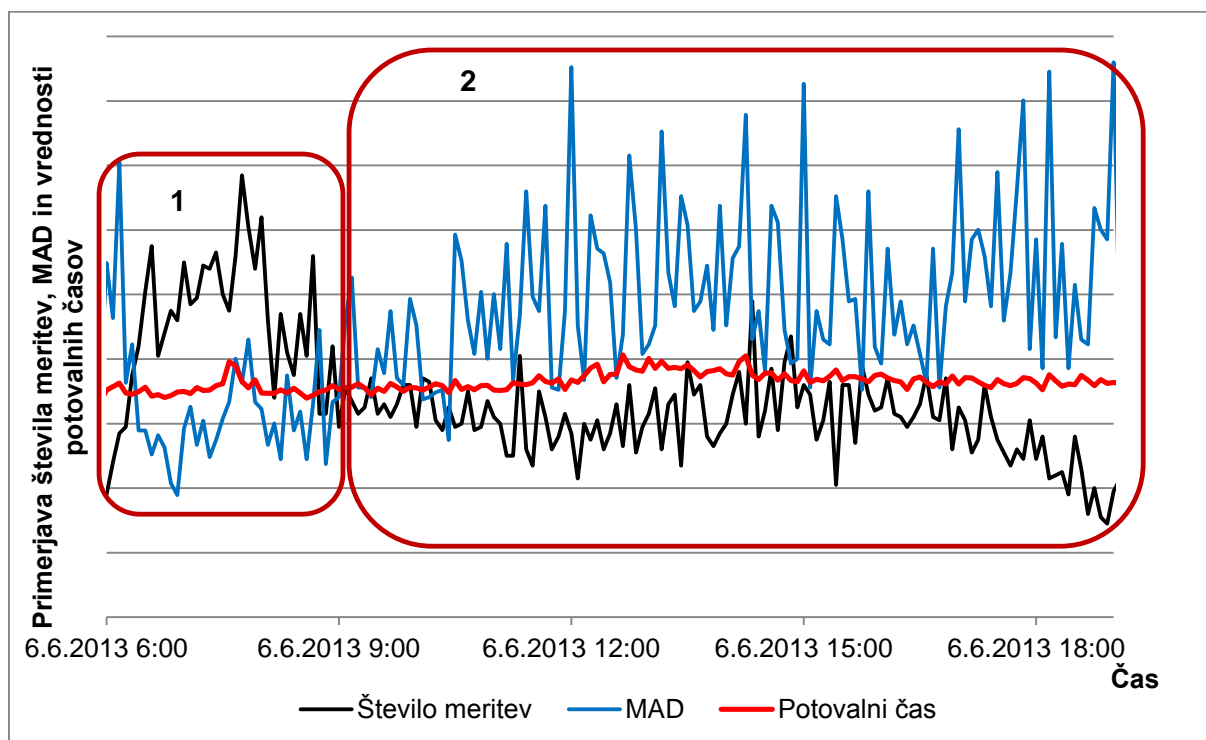
da zaradi vpliva med vozili tudi v primeru zgostitve, potovalni časi za isto kategorijo vozil niso bistveno različni.



Slika 4-9: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa v primeru izrednega dogodka na AC

Figure 4-9: Comparison between number of measurements, median absolute deviation (MAD) and median during incident situation

Očitna razlika v vrednostih MAD je glede na strukturo prometnega toka razvidna iz spodnjega grafa, kjer je prikazano gibanje MAD med dnevom: v jutranji konici (Slika 4-10: območje točke 1), ko je prometni tok sestavljen predvsem iz osebnih vozil je vrednost MAD razmeroma nizka; od 10. ure dalje pa vse do večera, ko se poveča delež tovornih vozil, je opaženo povečanje MAD (Slika 4-10: območje točke 2).



Slika 4-10: Primerjava števila meritev potovalnega časa, MAD in mediane vrednosti potovalnega časa: jutranja konica v primerjavi s preostalim dnevom

Figure 4-10: Comparison between number of measurements, median absolute deviation (MAD) and median: morning peak period Vs rest of the day

Prvotna predpostavka, da se bo v času zastoja oz. drugega izrednega dogodka, ki vodi v zgostitev prometnega toka, MAD zmanjšal, s čimer bi prometni tok lahko opisali kot bolj homogen, se ni uresničila. V realnih okoliščinah je bilo namreč opaženo, da vozila, ki so pred zastojem vozila nad hitrostnimi omejitvami, tako vozila tudi po zapustitvi območja zgostitve, kar se je v primerjavi s počasnejšim tovornim vozilom ponovno pokazalo kot velika vrednost MAD.

Prvotna ideja je bila spremljati spremembo drsečega MAD in ga primerjati z vrednostmi in spremembami drseče mediane. Tako bi v primeru, ko vrednost mediane, na podlagi katere določamo reprezentativno vrednost potovalnega časa, preskoči za manj, kot je sprememba MAD, ta preskok ne šteli kot kritičen, saj bi pomenil, da gre za slučajna nihanja. V kolikor bi vrednost mediane preskočila za več kot je MAD pomnožen z nekim faktorjem, ki bi določil kritičnost preskoka, potem bi to pomenilo, da je prišlo do neke hipne spremembe, katere vzrok je lahko nastanek zastoja. Med raziskavami je bilo ugotovljeno, da so ti preskoki največkrat slučajnega značaja in jih ne gre preprosto enačiti z opisanim razmerjem.

4.4 Izračun potovalnega časa

4.4.1 Izločitev podvojenih vrednosti potovalnega časa

4.4.1.1 Podvajanje meritev iz različnih virov

V splošnem lahko linijsko izmerjene podatke o potovalnih časih med dvema točkama pridobimo iz različnih virov kakor so: reidentifikacija registrskih tablic, reidentifikacija naslovov »bluetooth«, reidentifikacija medijev za elektronsko cestninjenje, reidentifikacija vozil z analizo video slike, določevanje potovalnih časov v zaprtem cestninskem sistemu z uporabo tradicionalnih cestninskih listkov.

Občasno, kot tudi v našem pilotskem primeru, meritve potovalnih časov na istem odseku izvajamo z dvema različnima tehnologijama kot npr. z reidentifikacijo registrskih tablic in naslovov »bluetooth«. Izkaže se, da nekatera vozila zaznamo z obema tehnologijama, kar nam »lažno« poveča velikost vzorca potovalnih časov za nadaljnjo obdelavo.

Meritev se obravnava kot podvojena, v kolikor se začetek in konec dveh potovanj iz dveh različnih sistemov reidentifikacije razlikujeta za manj kot 30 sekund in v kolikor se čas obeh potovanj razlikuje za manj kot 20 sekund.

Preglednica 4-2: Podvajanje meritev iz različnih virov (zaznava istega vozila z dvema različnima tehnologijama)

Table 4-2: Duplication of measurements coming from various technologies

ID	Tip naprave	Začetek	Konec	Potovanje (s)	Povprečna hitrost (km/h)
2017058	Registrska tablica	2:36:32	2:51:26	894	89
606576	Bluetooth	2:36:58	2:51:51	893	89
2017504	Registrska tablica	4:08:09	4:22:43	874	91
606753	Bluetooth	4:08:35	4:23:06	871	91
2018074	Registrska tablica	4:59:34	5:13:52	858	93
606980	Bluetooth	4:59:49	5:13:54	845	94
2018179	Registrska tablica	5:05:23	5:18:39	796	100
607011	Bluetooth	5:05:48	5:19:00	792	100
607285	Bluetooth	5:39:31	5:51:22	711	112
2018980	Registrska tablica	5:39:36	5:51:28	712	112
610097	Bluetooth	7:50:36	8:01:06	630	126
2026398	Registrska tablica	7:50:39	8:01:07	628	126
2026425	Registrska tablica	7:50:04	8:01:40	696	114
610104	Bluetooth	7:50:10	8:01:41	691	115

4.4.1.2 Podvajanje meritev iz istega vira

Nekatere tehnologije, ki temeljijo na zaznavanju in reidentifikaciji mikrovalovnih signalov, zaznajo več naprav v istem vozilu, kot je to v primeru zaznave naslovov »bluetooth«. To lahko pomeni, da avtobus, na katerem ima vseh 50 potnikov vklopljen signal »bluetooth«, povzroči 50 meritev potovalnega časa, ki se le za malenkost razlikujejo med seboj. Do razlik, ki so sicer velikostnega razreda nekaj sekund, pride zato, ker antena »bluetooth« in njen procesor posameznemu signalu pripišeta časovno vrednost v času, ko je le-ta najmočnejši, kar pa niha.

Tako podvojene potovalne čase iz istega vozila moramo izločiti ter za celotno vozilo določiti le en potovalni čas, ki ga v nadaljevanju uporabimo za izračun reprezentativne vrednosti potovalnega časa.

Meritev se šteje kot podvojena, v kolikor se začetek in konec dveh potovanj iz istega sistema reidentifikacije razlikujeta za manj kot 10 sekund in v kolikor se čas obeh potovanj razlikuje za manj kot 20 sekund. To velja le za sisteme reidentifikacije, ki na enem vozilu lahko zaznajo več virov, kot je to v primeru reidentifikacije naslovov »bluetooth«.

Preglednica 4-3: Podvajanje meritev iz istega vira (večkratno zaznavanje istega vozila z isto tehnologijo)

Table 4-3: Duplication of measurements coming from the same technology

ID	Tip naprave	Začetek	Konec	Potovanje (s)	Povprečna hitrost (km/h)
606327	Bluetooth	0:30:32	0:44:22	830	96
606329	Bluetooth	0:30:32	0:44:26	834	95
606756	Bluetooth	4:11:56	4:23:18	682	116
606755	Bluetooth	4:11:56	4:23:18	682	116
606997	Bluetooth	5:05:07	5:16:40	693	115
606998	Bluetooth	5:05:07	5:16:41	694	114
613632	Bluetooth	9:56:37	10:54:47	3490	23
613633	Bluetooth	9:56:37	10:54:50	3493	23
613794	Bluetooth	10:48:04	11:01:35	811	98
613788	Bluetooth	10:48:04	11:01:36	812	98

4.4.2 Izbira časovnega intervala zajema podatkov za pridobitev reprezentativnega vzorca potovalnih časov

Velik pomen v sistemu za določevanje potovalnih časov iz neposrednih linijskih meritev ima izbira časovnega intervala zajema podatkov Δt , ker neposredno določa uspešnost metode. Izbira časovnega intervala zajema podatkov mora zadostiti dvema pogojema: po eni strani mora biti Δt kar se le da kratek, da zagotovimo pogoste posodobitve informacije in s tem natančno sledenje razvoju potovalnega časa z izognitvijo povprečenju in glajenju možnih hitro spreminjajočih se prometnih razmer oziroma prometnih stanj. Po drugi strani pa mora biti Δt dovolj dolg, da zajame reprezentativen vzorec prometnega toka in s tem zadostno količino vozil, s čimer je ocena potovalnega časa statistično zanesljiva.

Največkrat uporabljene vrednosti časovnega intervala zajema podatkov so 1, 3, 5 ali 15 minut. Spodnja meja časovnega intervala zajema podatkov je 1 minuta. Manjša vrednost posodobitve informacije o potovalnem času ni smiselna, saj se prometne razmere ne spreminjajo tako hitro. Spodnja meja zajema je lahko problematična v času izven prometnih konic, saj v nekaterih primerih ne zajame statistično pomembnega števila meritev. Zgornjo mejo časovnega intervala zajema podatkov, da še lahko govorimo o sistemu, ki deluje v trenutnem času, predstavlja vrednost 15 minut.

Za statistično zanesljivo oceno potovalnega časa na opazovanem odseku potrebujemo reprezentativen vzorec potovalnih časov na odseku znotraj časovnega intervala Δt . Občasno se zgodi, predvsem v času nizkih prometnih obremenitev, da za opazovano obdobje ni na voljo

podatkov o potovalnem času oz. je na voljo le majhen vzorec podatkov vozil, ki so prepotovala odsek. V takih primerih se pogosto zgodi, da zaradi strukture prometnega toka sestavljenega iz kombinacije osebnih in tovornih vozil, predvsem ponoči pride do velikega odklona meritev od srednje vrednosti znotraj časovnega intervala zajema, kot posledica zelo različnih izmerjenih potovalnih časov pri majhnem številu vozil. Občasno se zgodi celo, da so na obravnavanem odseku prisotna le tovorna vozila, ki zaradi konfiguracije in višinskega poteka trase na odseku potujejo z bistveno nižjimi hitrostmi kot osebna vozila, kar vodi k nerazumno dolgim potovalnim časom. Brez uporabe primerne metode filtriranja, bi pri obveščanju voznikov s sistemom za nadzor in vodenje prometa, to pomenilo veliko kvantitativno razpršenost vrednosti potovalnega časa, kljub temu, da na odseku prevladujejo razmere prostega prometnega toka.

Do problemov pri pridobitvi reprezentativnega vzorca povprečnih potovalnih časov znotraj časovnega intervala Δt lahko pride v naslednjih primerih:

- v danem časovnem intervalu sistem za merjenje potovalnega časa ni zabeležil nobenega potovalnega časa, kar ima lahko za vzrok obdobje brez prometnega pretoka ali slabo stopnjo prepoznavanja tehnologij kot npr. prepoznavanje registrskih tablic v času sneženja oz. neaktivnost naprav, ki oddajajo signal »bluetooth«. Problem nastane tudi v primerih, ko je zaradi nizke penetracije oprema za linijsko merjenje potovalnih časov sposobna zaznati le majhen delež vozil v prometnem toku.
- majhen vzorec vozil predvsem ponoči, katerih izmerjeni potovalni časi zelo nihajo, kar ima za posledico velika odstopanja od srednje vrednosti. Za določitev reprezentativne vrednosti potovalnega časa je potrebna uporaba metod robustne statistike.
- velik vzorec vozil, katerih izmerjeni potovalni časi zelo nihajo, kar ima za posledico velika odstopanja od srednje vrednosti. Za določitev reprezentativne vrednosti potovalnega časa je potrebna uporaba metod robustne statistike.
- prisotnost osamelcev, katerih izmerjen potovalni čas ni povezan s prometnimi razmerami na odseku kot npr. ustavljanje na počivališču. Ločimo dve vrsti osamelcev: tisti, katerih potovalni čas je znatno daljši zaradi vmesnega prenehanja potovanja (zaustavitev) in tisti, katerih potovalni čas je krajši kot npr. vozniki motorjev, ki prehitvajo kolono stoječih vozil. Za izločitev osamelcev je potrebno uporabiti metode robustne statistike.

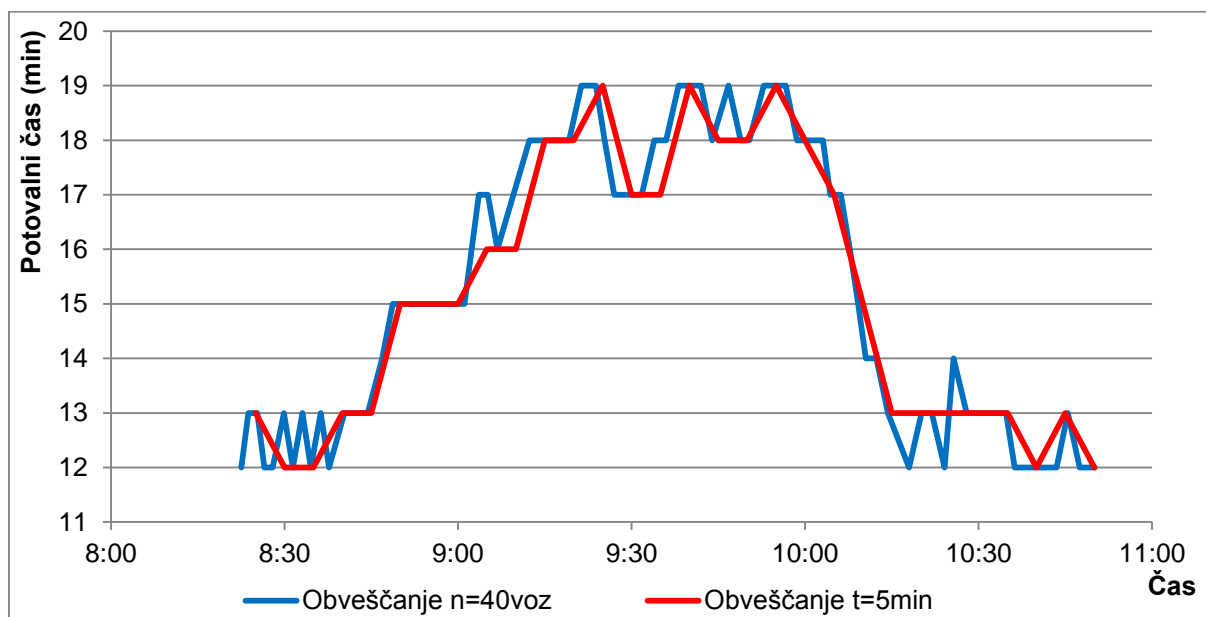
Potovalnih časov, ki predstavljajo osamelce ne smemo upoštevati pri določevanju reprezentativnega potovalnega časa znotraj časovnega intervala Δt . V nekaterih primerih je izredno težko ugotoviti, katera vozila dejansko so osamelci in katera vozila imajo podaljšan potovalni čas zaradi izrednega dogodka, kar je težko ugotoviti predvsem v primerih, ko ni na voljo veliko meritev in vrednosti potovalnega časa potencialnih osamelcev ne segajo izrazito izven območja ostalih meritev. V takih primerih moramo uporabiti metodo izločanja podatkov, ki temelji na robustni statistiki.

4.4.2.1 Izbira časovnega intervala zajema podatkov za pridobitev reprezentativnega vzorca potovalnih časov podnevi

Podnevi je v splošnem zaradi velikega pretoka na voljo sorazmerno velik delež izmerjenih potovalnih časov. Z namenom pogoste posodobitve informacije, natančnega sledenja razvoju potovalnega časa in izognitvi povprečenja ter glajenja možnih hitro spreminjajočih se prometnih razmer/prometnih stanj, mora biti časovni interval kar se le da kratek.

Izbrana dolžina časovnega intervala zajema podatkov v dnevnem času je v sistemu nastavljiv parameter, njegova začetna vrednost pa je $\Delta t = 5$ minut. Dnevni čas delovanja algoritma se v sistemu določi v fazi kalibracije ter je nastavljiv parameter, ki se po potrebi glede na izkušnje na terenu oz. v primeru uporabe na drugi lokaciji, ustrezno prilagodi glede na ugotovljeno obnašanje prometnega toka. Interval posodabljanja informacije o potovalnem času na 5 minut predstavlja kompromisno vrednost za uporabo v vseh prometnih razmerah. V tem primeru je algoritem dovolj natančen, da zajame zadostno število meritev za dosego statistične zanesljivosti, po drugi strani pa je sposoben odreagirati na hitro spreminjajoče se prometne razmere na cesti.

Na analiziranem vzorcu potovalnih časov, ki je zajemal obdobje treh tednov, je bilo ugotovljeno, da 94 % časovnih intervalov zajema podatkov $\Delta t = 5$ minut zagotavlja vzorec vsaj dvajsetih meritev, 99,6 % časovnih intervalov pa zagotavlja vsaj pet meritev.




Slika 4-11: Primerjava obveščanja voznikov s 40. centilom na podlagi $n = 40$ vozil in $t = 5$ minut v primeru zapora voznega pasu v predoru (Trojane) v času dopoldanskih prometnih obremenitev 9. maja 2013 (8:52)

Figure 4-11: Comparison between informing the drivers with 40th percentile based on $n = 40$ vehicles Vs $t = 5$ min in case of a lane closure in tunnel Trojane on May 9, 2013 (8:52)

Če zadnji časovni interval ne zagotavlja nobene meritve potovalnega časa, je to lahko posledica razmer, ko na odseku ni nobenega vozila bodisi zaradi majhnih prometnih obremenitev ali pa

zaradi izrednega dogodka, ki je blokiral pretok na odseku. Medtem, ko v prvem primeru lahko predpostavimo razmere prostega prometnega toka in zato privzeto potovalni čas prostega prometnega toka to je čas, ki ga vozila potrebujejo za prevoz odseka ob upoštevanju omejitev hitrosti, zaokrožen navzgor na naslednjo celo minuto, pa v drugem primeru obdobje brez izvedenih meritev o potovalnem času pomeni močno zgostitev prometnega toka, katere posledica so podaljšani potovalni časi. Zato v obeh primerih, ki jih samo z metodo neposrednega linijskega merjenja potovalnega časa ne moremo razlikovati, vse do prihoda naslednjega reprezentativnega vzorca, voznikom ne moremo posredovati informacije o potovalnem času, zato izračunana vrednost potovalnega časa ostane brez vrednosti.



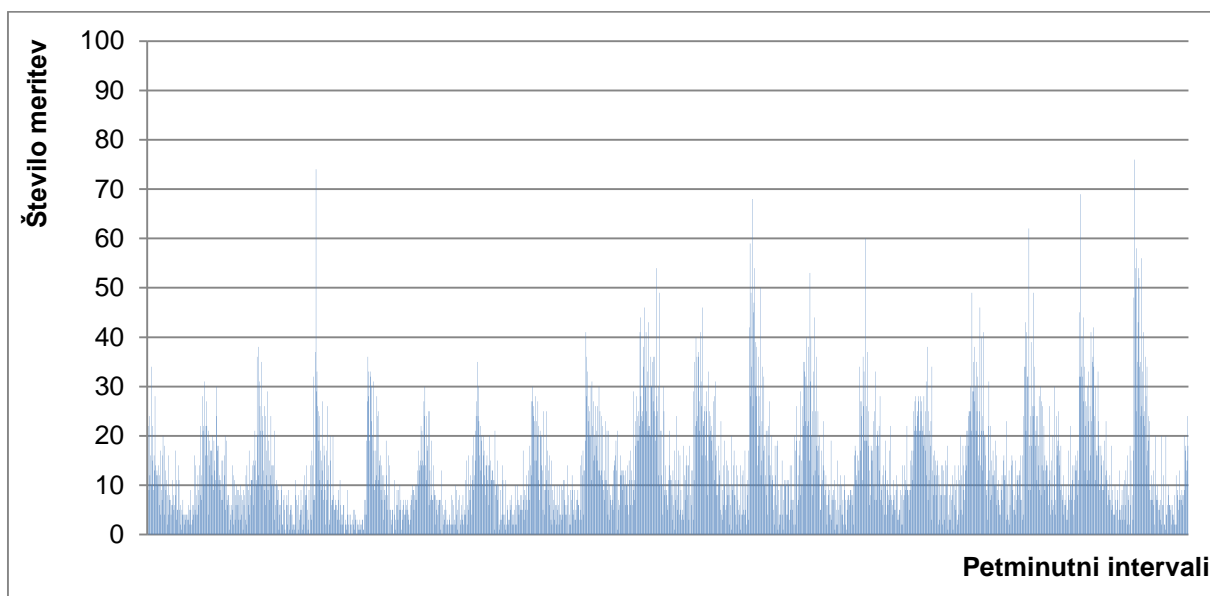
Slika 4-12: Število pridobljenih meritev potovalnega časa znotraj petminutnih intervalov podnevi. Majhno število meritev je posledica zgodnje jutranje ure (5:00 - 5:15) prazničnega dne 2. maja 2013

Figure 4-12: Number of travel times measured in 5 min intervals during the day. Low number of measurements is a consequence of a national holiday on May 2, 2013 (5:00 – 5:15)

4.4.2.2 Izbira časovnega intervala zajema podatkov za pridobitev reprezentativnega vzorca potovalnih časov ponoči


V nočnem času prometni pretoki močno padejo, pomemben delež prometnega toka pa predstavljajo tovorna vozila. Nizki pretoki vodijo k majhnemu številu izmerjenih potovalnih časov. Ker se v času nizkih prometnih pretokov prometne razmere ne spreminjajo zelo hitro, natančno sledenje razvoju potovalnega časa ni tako pomembno kot zagotovitev reprezentativnega vzorca potovalnih časov. Na podlagi analize števila pridobljenih meritev je za vsak odsek potrebno določiti časovni okvir nočnega režima delovanja, ki je v sistemu nastavljiv parameter.

V kolikor bi v nočnem času izračun izvajali z zajemom časovnega intervala $\Delta t = 5$ minut, bi kar v 77 % primerih imeli izmerjen vzorec manj kot 20 vozil. V kolikor časovni interval zajema povečamo na $\Delta t = 15$ minut, imamo v 78 % časovnih intervalov na voljo več kot 20 izmerjenih potovalnih časov, pet meritev potovalnih časov pa je na voljo v 99,8 % časovnih intervalov.



Slika 4-13: Število pridobljenih meritev potovalnega časa znotraj petminutnih intervalov ponoči (20:30 - 5:30) za 19 noči meseca maja 2013

Figure 4-13: Number of travel times measured in 5 min intervals during the 19 nights in May, 2013

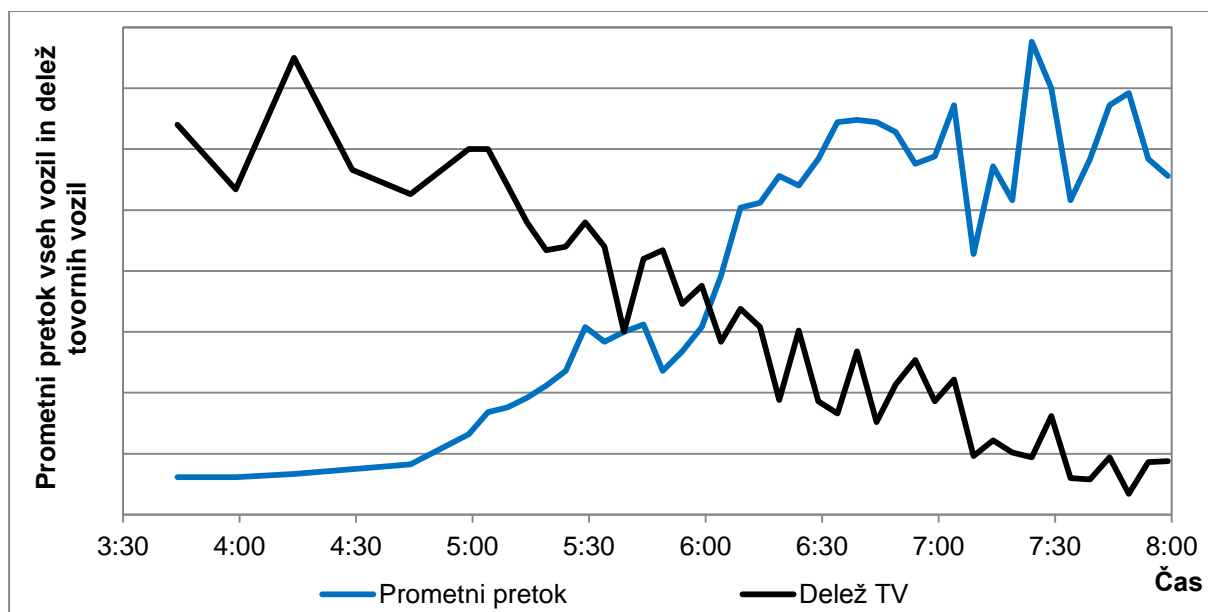


Slika 4-14: Število pridobljenih meritev potovalnega časa znotraj petnajst minutnih intervalov ponoči (20:30 - 5:30) za 19 noči meseca maja 2013

Figure 4-14: Number of travel times measured in 15 min intervals during the 19 nights in May, 2013

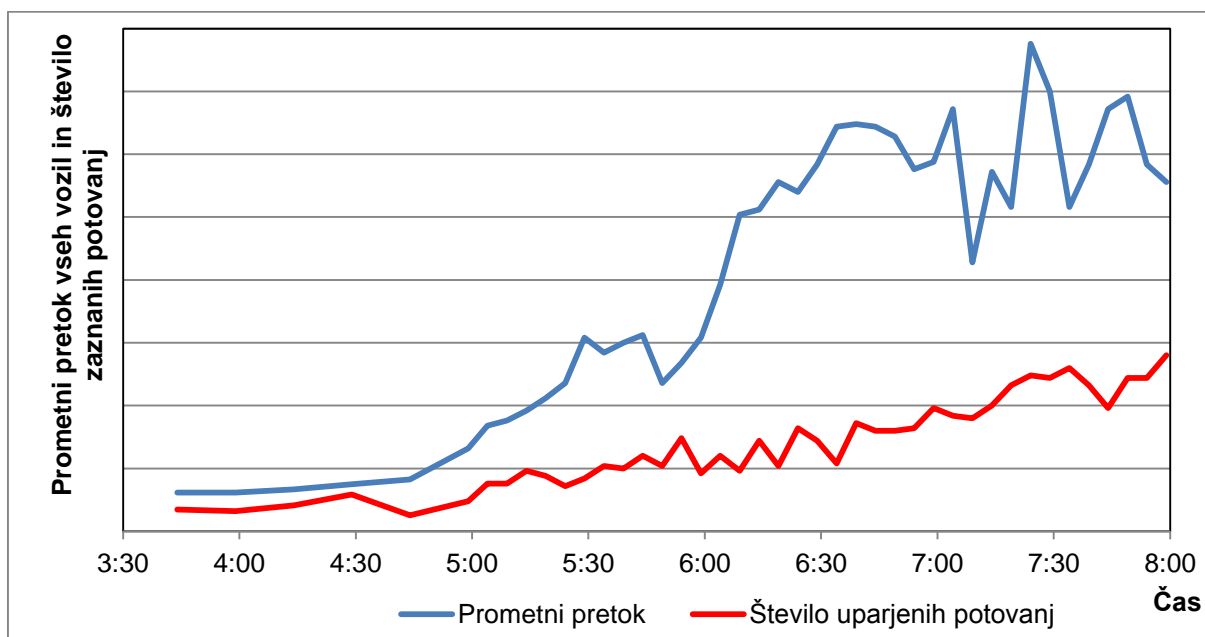
V nočnem času je zato delovanje algoritma nastavljeno na zajem časovnega intervala $\Delta t = 15$ minut (nastavljiv parameter), s čimer poizkušamo pridobiti dovolj meritev za zagotovitev reprezentativnega vzorca potovalnih časov.

V večernem času prehod iz dnevnega režima delovanja v nočni režim ni tako skokovit, saj prometni pretoki proti večeru počasi upadajo. V jutranjem času pa začne prometni tok, predvsem osebni, skokovito naraščati. Posebno pozornost moramo nameniti kalibraciji časovnega okvira delovanja v času, ko delež tovornih vozil v celotnem prometnem toku močno pade, vzorec izmerjenih potovalnih časov zaradi povečanega pretoka osebnih vozil pa se bistveno poveča, kar nam olajša določitev reprezentativnega vzorca potovalnega časa. Tu izvedemo prehod na dnevni režim delovanja. Na obravnavanem odseku med Vranskim in Blagovico je nočni režim delovanja vzpostavljen med 20:30 in 5:30.



Slika 4-15: Nenadno povečanje prometnega pretoka ter padanje deleža tovornih vozil v jutranji konici 6. maja 2013

Figure 4-15: A sudden increase in traffic flow and reduced share of heavy vehicles during the morning peak period on May 6, 2013



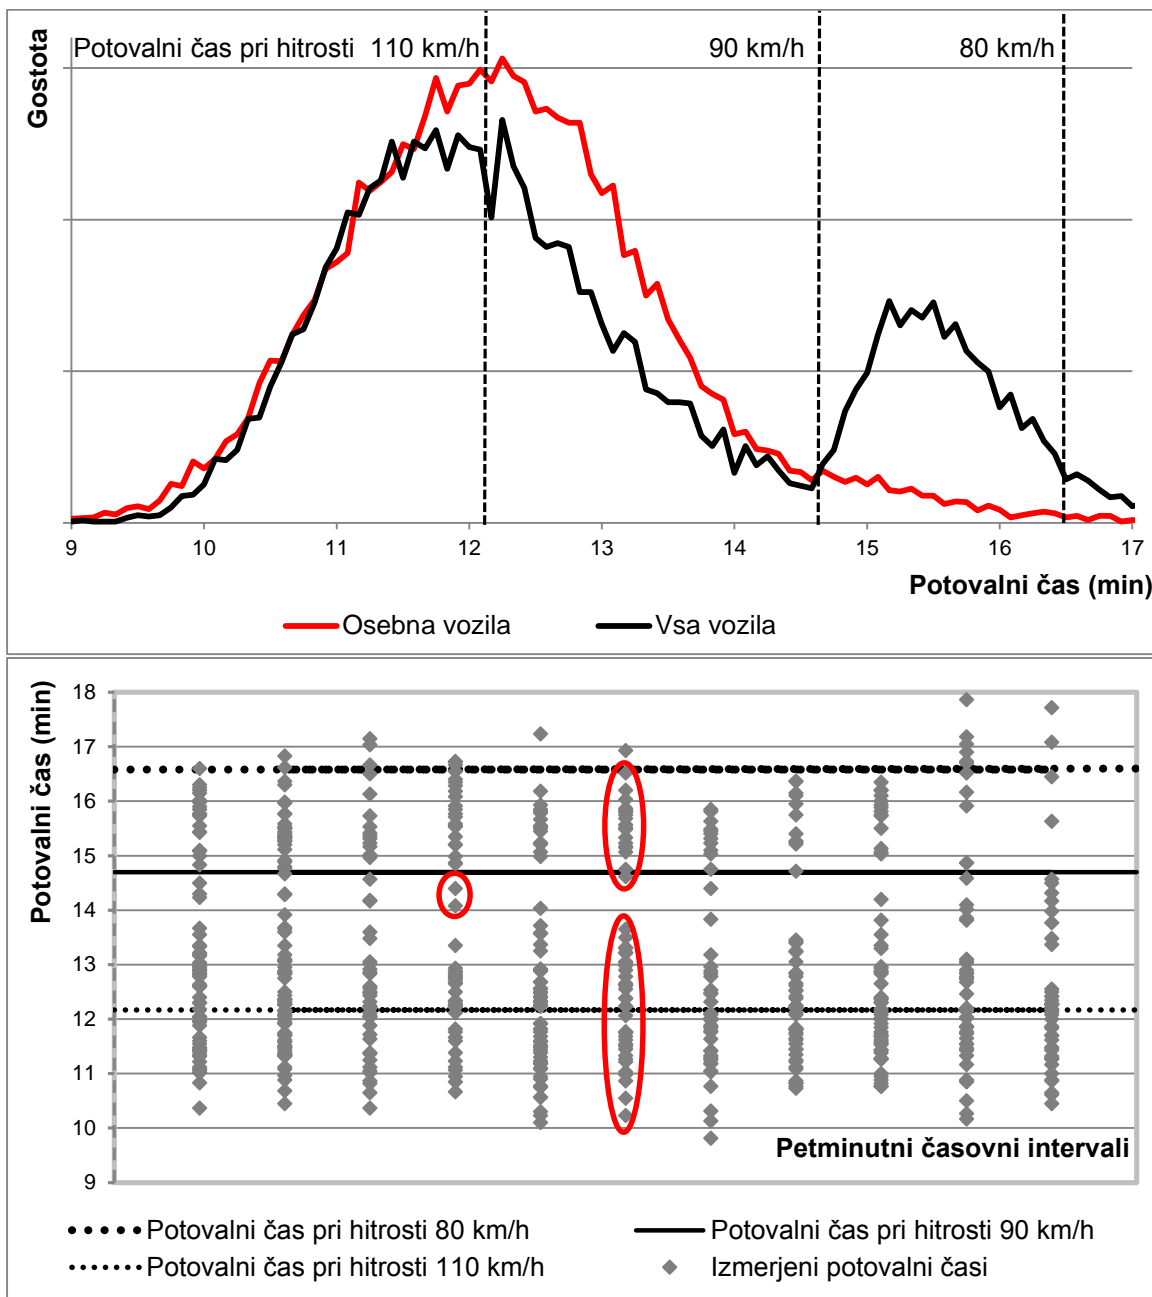
Slika 4-16: Razmerje med prometnim pretokom in številom zaznanih potovanj v času jutranje konice 6. maja 2013 (število zaznanih potovanj ni neposredno primerljivo s prometnim pretokom zaradi treh vmesnih priključkov)

Figure 4-16: Ratio between traffic flow and number of travel times captured during the morning peak period on May 6, 2013 (the number of travel times captured can not be directly compared to traffic flow due to intermediate junctions)

4.4.3 Določevanje potovalnih časov podnevi

Kot omenjeno v uvodnih poglavjih, so se v svetu uveljavile različne metode in tehnologije merjenja potovalnih časov med dvema točkama t.i. neposredno linijsko merjenje. Izbira tehnologije in njena penetracija v veliki meri vplivata na vzorec meritev potovalnih časov, ki ga nadalje obdelujemo. V kolikor se odločimo za reidentifikacijo naprav, ki jih uporablja samo en razred vozil kot npr. ABC elektronske tablice v Sloveniji trenutno uporabljajo le tovorna vozila, dobimo popolnoma drugačen vzorec izmerjenih potovalnih časov, kot če podatke pridobivamo s tehnologijo, ki zajame celoten prometni tok kot npr. reidentifikacija registrskih tablic ali naslovov »bluetooth«.

V času razmer prostega prometnega toka, sta iz zbranih podatkov o potovalnih časih dobro vidni dve večji skupini vozil. Prva so osebna vozila, ki vozijo z naključnimi hitrostmi, razporejenimi okoli povprečne hitrostne omejitve na odseku, v našem primeru 109 km/h, izračunamo ob upoštevanju, da na 70 % trase velja omejitev hitrosti 100 km/h, na 30 % trase pa 130 km/h. Naključno porazdelitev hitrosti osebnih vozil lahko v veliki meri pripišemo individualnemu upoštevanju hitrostne omejitve na obravnavani trasi. Drugo večjo skupino predstavljajo tovorna vozila, katerih hitrosti so porazdeljene med 80 in 90 km/h, kolikor glede na posamezno kategorijo tovornega vozila do 3,5 tone oz. nad 3,5 tone, znaša najvišja dovoljena hitrost. Zaradi razgibanega višinskega poteka trase, tovorna vozila po odseku zaradi fizičnih omejitev težko vozijo hitreje. Vmesne potovalne čase predstavljajo ostale kategorije vozil kot so kombiji in dostavna vozila oz. počasnejša osebna vozila.



Slika 4-17: Gostota porazdelitve potovalnih časov (zgoraj) ter potovalni časi različnih kategorij vozil (spodaj)

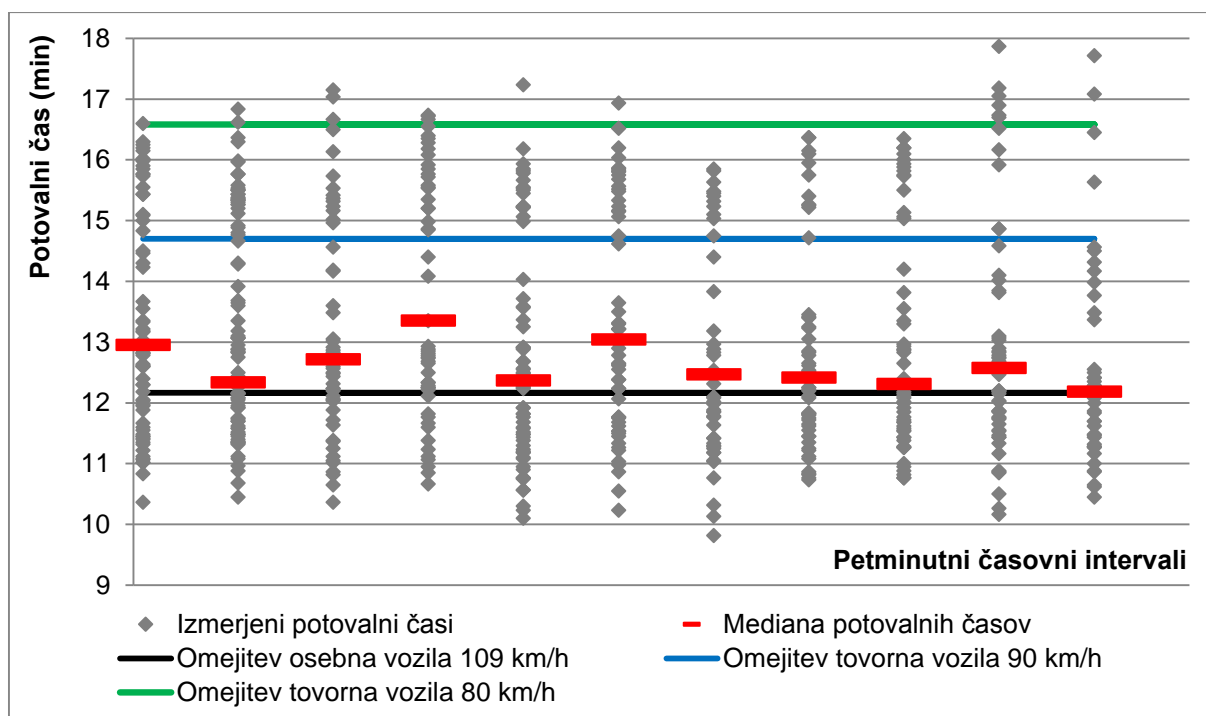
Figure 4-17: Probability density function of travel times (above) and travel times of various vehicle categories (below)

V splošnem bi za izračun reprezentativne vrednosti potovalnega časa na odseku železi pridobiti le meritve potovalnih časov osebnih vozil, saj se le-ta v prostem prometnem toku gibljejo skoraj brez fizičnih omejitev. V nasprotju z osebnimi vozili na težka tovorna vozila vpliva vrsta dejavnikov kot so naklon trase, nižje hitrostne omejitve in fizične omejitve pri vožnji, zaradi česar so izmerjeni potovalni časi tovornih vozil bistveno daljši od tistih, ki jih za prevoz odseka potrebujejo osebna vozila. Ker tovorna vozila za prevoz odseka potrebujejo daljši čas kot

osebna, želimo njihov vpliv pri določitvi reprezentativnega potovalnega časa kar se le da zmanjšati.

Reidentifikacija vozil na kontrolnih točkah nam v trenutnih razmerah omogoča le pridobivanje mešanega vzorca potovalnih časov vseh kategorij vozil, pri čemer razlikovanje med razredi ni možno. To narekuje uporabo primerne metode izločanja podatkov za zagotovitev reprezentativne vrednosti izračunanega potovalnega časa, na podlagi katerega voznike obveščamo o potovalnem času na odseku.

Ob opaženem dejstvu, da je razpršitev potovalnih časov znotraj izbranega časovnega intervala v času prostega prometnega toka velika in da nekatera vozila dosegajo bistveno nižje hitrosti kot druga, očitno povprečna vrednost potovalnih časov ne predstavlja reprezentativne vrednosti razmer na trasi.

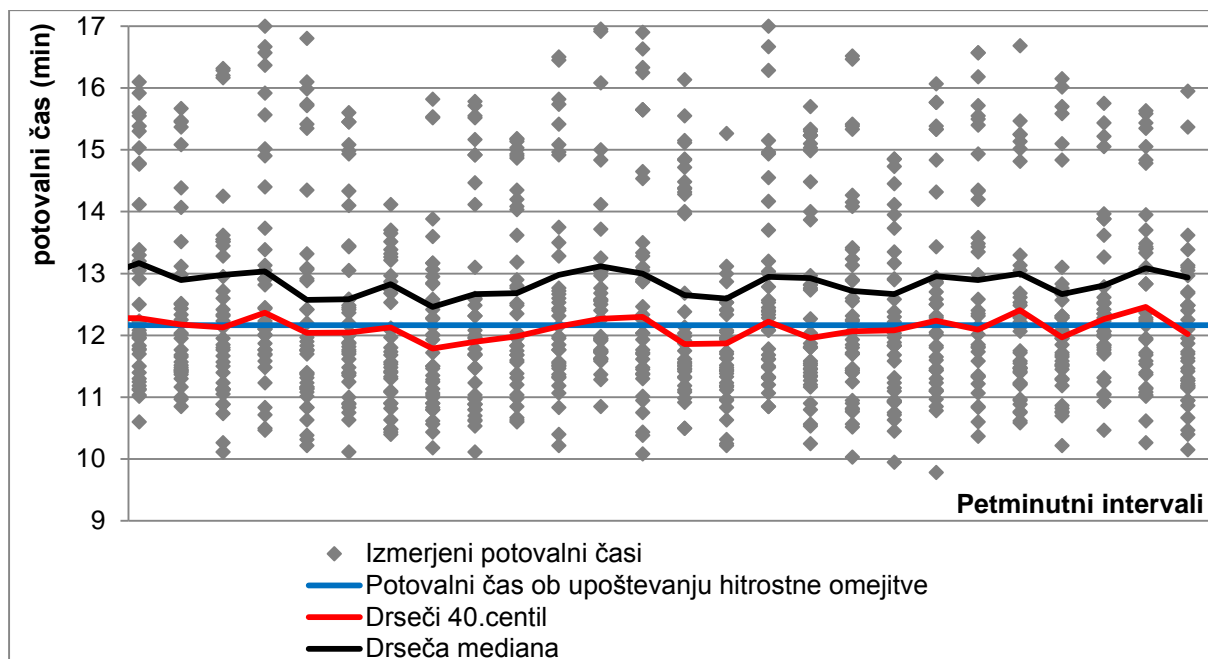


Slika 4-18: Vpliv različnih kategorij vozil na mediano potovalnih časov
Figure 4-18: Influence of various categories of vehicles on the median of travel time

Z uporabo robustne statistike želimo poiskati tisto statistiko, ki v razmerah prostega prometnega toka najbolje karakterizira voznike, ki upoštevajo omejitev hitrosti na obravnavanem odseku. To statistiko nato spremljamo tudi v razmerah izven prostega prometnega toka ob predpostavki, da opisuje voznike, ki sicer vozijo skladno s hitrostnimi omejitvami, na njihov potovalni čas pa so med potovanjem vplivale različne motnje znotraj prometnega toka.


Pri primerjavi z izmerjenimi podatki o potovalnih časih se je kot najbolj uporabna statistika izkazal centil. Analiza podatkov za daljše časovno obdobje je za izbrani odsek pokazala, da voznike, ki v prostem prometnem toku podnevi upoštevajo omejitev hitrosti, najbolje opiše vrednost 40. centila. Vrednost centila, ki ga model upošteva za določitev reprezentativnega

potovalnega časa podnevi, je nastavljen parameter, ki je odvisen od odseka izvajanja meritve in ga moramo za vsak odsek določiti s kalibracijo izkustveno.



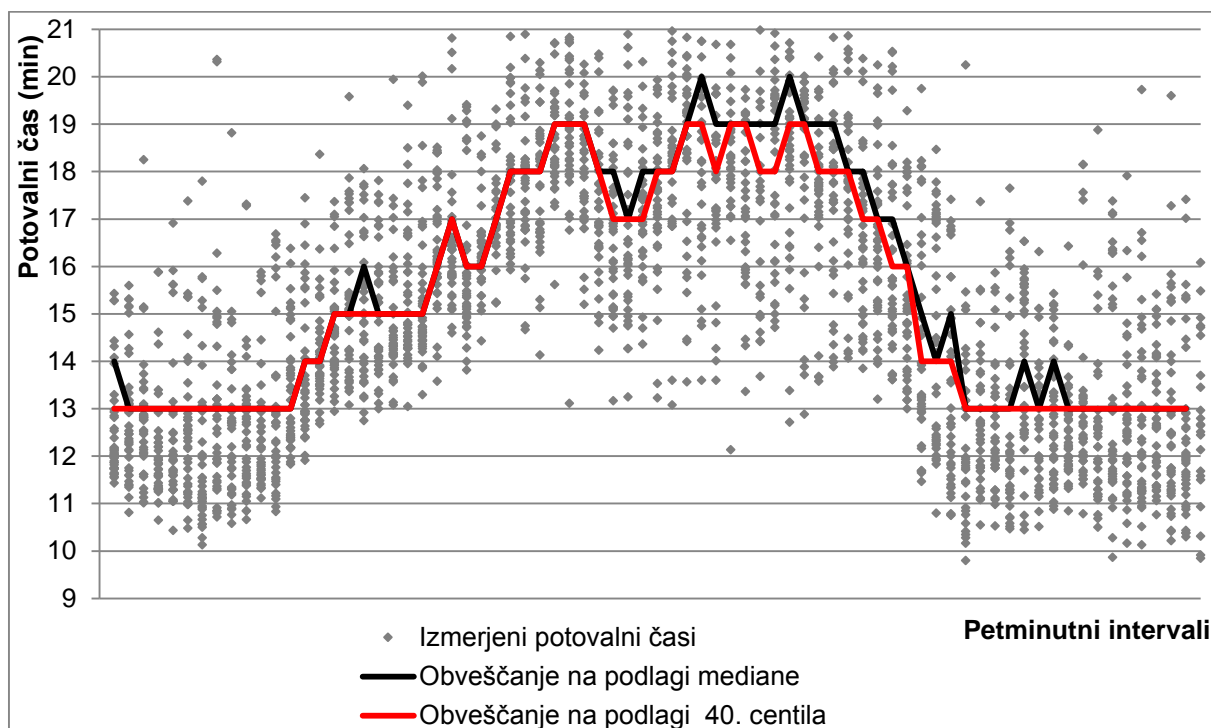
Slika 4-19: 40. centil predstavlja vrednost potovalnega časa za vozila, ki upoštevajo omejitev hitrosti na odseku

Figure 4-19: Percentile rank that best describes personal cars driving by the posted speed limit



Slika 4-20: Primerjava drsečega 40. centila in drseče mediane

Figure 4-20: Comparison between running 40th percentile and running median



Slika 4-21: Primerjava obveščanja voznikov na podlagi drsečega 40. centila in drseče mediane


Figure 4-21: Informing the drivers about travel times based on running 40th percentile Vs running median

4.4.4 Določevanje potovalnih časov ponoči

Prometni tok na podeželskih avtocestah, predvsem tistih, ki so tranzitne narave, ponoči v večini sestavljajo tovorna vozila. Kot že predhodno omenjeno, se način vožnje tovornih vozil bistveno razlikuje od načina vožnje osebnih vozil. To vodi k v bistveno daljšim potovalnim časom tovornih vozil, kljub temu, da ponoči v večini časa prevladujejo razmere prostega prometnega toka.

V primeru velikega deleža tovornih vozil, moramo uporabiti drugo vrednost centila, kot reprezentativne vrednosti vozil, ki vozijo skladno z omejitvami. Določitev centila, ki ga uporabimo za izračun potovalnega časa na posameznem odseku, je odvisna od deleža tovornih vozil na tem odseku v času nočnih ur.

Analiza podatkov za daljše časovno obdobje je za obravnavani odsek pokazala, da bi uporaba 40. centila kot podnevi kljub razmeram prostega prometnega toka, v večini primerov javljala nerazumno podaljšane potovalne čase. Ugotovljeno je bilo, da voznike, ki v prostem prometnem toku ponoči upoštevajo omejitev hitrosti, najbolje opiše vrednost 10. centila. Vrednost centila, ki ga model upošteva za določitev reprezentativnega potovalnega časa ponoči je nastavljen parameter, ki je odvisen od odseka izvajanja meritve in ga moramo za vsak odsek določiti izkustveno.



Slika 4-22: Primerjava obveščanja ponoči na podlagi 40. in 10. centila

Figure 4-22: Informing the drivers about travel times based on 40th percentile Vs 10th percentile

Kljub uporabi robustne statistike se občasno zgodi, da potovalni čas ponoči iz 13 minut naraste na 14 oz. 15 minut. Pri podrobnejši analizi je bilo ugotovljeno, da kljub sorazmerno velikemu vzorcu vozil ponoči (od 9 do 21 vozil) občasno pridobimo potovalne čase le od tovornih vozil, kar pomeni, da tudi uporaba 10. centila ne reši problema. V takih primerih algoritem odreagira s podaljšanim potovalnim časom, kar pa glede na dosedanje izkušnje s terena pomeni podaljšanje za največ 2 minuti.

4.4.5 Opis algoritma za določevanje potovalnih časov iz neposrednih linijskih meritev

4.4.5.1 Izračun in obdelava potovalnega časa posameznega vozila

Na podlagi reidentifikacije določenega vozila na dveh zaporednih merilnih mestih ob pogoju sinhronizacije ure na obeh lokacijah, dobimo izmerjen potovalni čas, ki ga je vozilo potrebovalo za prevoz obravnavanega odseka:

$$tt_{ABi} = t_{Bi} - t_{Ai} \quad i=1, \dots, n \quad (4-3)$$

pri čemer je:

tt_{ABi} = vrednosti potovalnega časa i -tega vozila med točkama A (gortočni rob odseka) in B (doltočni rob odseka),

t_{Ai} = čas i -tega vozila ob prehodu preko točke A (gortočni rob odseka),

t_{Bi} = čas i -tega vozila ob prehodu preko točke B (doltočni rob odseka),

n = število reidentificiranih vozil znotraj časovnega intervala zajema podatkov.

Naslednji korak izloči podvojene vrednosti potovalnega časa:

- Podvajanje meritev iz različnih virov – v primeru uporabe različnih tehnologij za določanje potovalnega časa na odseku. Meritev se šteje kot podvojena, v kolikor se

začetek in konec dveh potovanj iz dveh različnih sistemov reidentifikacije razlikujeta za manj kot 30 sekund in v kolikor se čas obeh potovanj razlikuje za manj kot 20 sekund.

- Podvajanje meritev iz istega vira – v primeru uporabe tehnologij, ki lahko posamezno vozilo zaznajo večkrat kot npr. pri reidentifikaciji naslova »bluetooth«. Meritev se šteje kot podvojena, v kolikor se začetek in konec dveh potovanj iz istega sistema reidentifikacije (velja le za sisteme reidentifikacije, ki na enem vozilu lahko zaznajo več virov kot je to v primeru reidentifikacije naslovov »bluetooth«) razlikujeta za manj kot 10 sekund in v kolikor se čas obeh potovanj razlikuje za manj kot 20 sekund.

4.4.5.2 Izračun reprezentativne vrednosti potovalnega časa za časovno obdobje in odsek izvajanja meritve

Reprezentativno vrednost potovalnega časa za izbrano časovno obdobje izračuna, odsek izvajanja meritve in dnevni oz. nočni režim delovanja izračunamo z eno od naslednjih enačb:

- če je $n \geq 20$

V kolikor je na voljo več kot 20 meritev potovalnega časa, vrednost potovalnega časa izračunamo z uporabo centilne vrednosti za dnevni oz. nočni način delovanja.

$$tt_{AB} = p\text{-ti centil vzorca potovalnih časov } tt_{ABi}, \text{ pridobljenega v zadnjem časovnem intervalu zajema } \Delta t \quad (4-4)$$

- če je $2 < n < 20$

V kolikor je na voljo med 2 in 20 meritev potovalnega časa, vrednost potovalnega časa izračunamo na podlagi predpostavke ob uporabi parametrov logaritemsko normalne porazdelitve (Benjamin and Cornell, 1970).

$$\tilde{m}_{TT} = \frac{m_{TT}^2}{\sqrt{m_{TT}^2 + \sigma_{TT}^2}} \quad (4-5)$$

$$\sigma_{\ln TT}^2 = \ln\left(\frac{\sigma_{TT}^2}{m_{TT}^2} + 1\right) \quad (4-6)$$

$$tt_{AB} = \tilde{m}_{TT} \exp(k_{\alpha} \sigma_{\ln TT}) \quad (4-7)$$

pri čemer je:

tt_{AB} = vrednost potovalnega časa za izbrano časovno obdobje med točkama A (gortočni rob odseka) in B (doltočni rob odseka),

n = število izmerjenih potovalnih časov v izbranem časovnem obdobju,

p = vrednost centila glede na dnevni oz. nočni način delovanja algoritma,

Δt = časovni interval zajema podatkov,

m_{TT} = povprečje vzorca potovalnih časov,

σ_{TT}^2 = varianca vzorca potovalnih časov,
 \tilde{m}_{TT} = mediana vzorca potovalnih časov,
 k_α = inverzna kumulativna funkcija standardizirane normalne porazdelitve,
 α = p -ti centil glede na dnevni oz. nočni način delovanja algoritma.

- če je $n \leq 2$

V kolikor sta v časovnem intervalu zajema podatkov na voljo manj kot 2 meritvi potovalnega časa, algoritem ni sposoben zagotoviti statistično zanesljive ocene zato vrednosti potovalnega časa ne moremo izračunati. Vrednost potovalnega časa v takem primeru ostane enaka kot v prejšnjem časovnem intervalu.

Reprezentativna vrednost potovalnega časa TT_{AB} se izračuna ob predpostavki logaritemsko normalne porazdelitve potovalnih časov:

$$TT_{AB} = e^{[\alpha \cdot \ln(tt_{AB}(t_k)) + (1-\alpha) \cdot \ln(tt_{AB}(t_{k-1}))]} \quad (4-8)$$

$$\alpha = 1 - (1 - \beta)^n \quad (4-9)$$

pri čemer je:

TT_{AB} = reprezentativna vrednost potovalnega časa za izbrano časovno obdobje med točkama A (gortočni rob odseka) in B (doltočni rob odseka),

α = faktor eksponentnega glajenja,

n = število meritev n v časovnem intervalu t_k ,

β = parameter občutljivosti (vrednost med 0,1 in 0,3). Z uporabo vrednosti $\beta = 0.2$ 24 meritev potovalnega časa znotraj časovnega intervala zagotavlja dovolj velik vzorec, da za izračun reprezentativne vrednosti potovalnega časa ne potrebujemo podatkov iz prejšnjega časovnega intervala,

$tt_{AB}(t_k)$ = vrednost potovalnega časa v trenutnem časovnem intervalu,

$tt_{AB}(t_{k-1})$ = vrednost potovalnega časa v predhodnem časovnem intervalu

V zadnjem koraku reprezentativno vrednost potovalnega časa zaokrožimo na zgornjo vrednost cele minute, da voznikom zagotovimo informacijo z minutno natančnostjo.

4.4.6 Kalibracija algoritma

Za pravilno delovanje algoritma za določevanje potovalnih časov iz neposrednih linijskih meritev je potrebna njegova kalibracija, saj določitev parametrov algoritma ni trivialna. Izračun reprezentativne vrednosti potovalnega časa za časovno obdobje izračuna in odsek izvajanja meritve se izvaja na podlagi predhodno kalibriranega algoritma.

Kalibracija algoritma se izvede za vsak posamezen odsek izvajanja meritve v odvisnosti od uporabljene tehnologije zajema podatkov in je v največji meri odvisna od količine in strukture prometnega toka, ki na danem odseku prevladuje. Kalibracija se izvede v času prostega prometnega toka ločeno za dnevni in nočni režim delovanja. Z izbiro trajanja časovnega intervala zajema podatkov za pridobitev reprezentativnega vzorca potovalnih časov podnevi in

ponoči poizkušamo pridobiti kar se le da veliko število meritev za zagotovitev reprezentativnega vzorca potovalnih časov.

Glavna naloga kalibracije algoritma je določiti vrednosti robustnih statistik, ki dobro opišejo prometni tok v dnevnem in nočnem času. Na podlagi izmerjenih potovalnih časov je potrebno določiti centilni vrednosti za dnevni in nočni čas, ki najboljše opišeta vozila, ki vozijo skladno s hitrostnimi omejitvami na danem odseku. To naredimo s primerjavo korenov povprečnih kvadratnih napak (RMSE) za različne vrednosti centilov potovalnega časa, izračunanih glede na vrednost potovalnega časa ob upoštevanju hitrostne omejitve. Centilna vrednost potovalnega časa z najmanjšo napako se v algoritmu uporabi kot reprezentativen centil.

$$RMSE_p = \sqrt{\frac{1}{m} \sum_{i=1}^m (tt_{i,p} - tt_{omejitev})^2} \quad (4-10)$$

pri čemer je:

$RMSE_p$ = koren povprečnega kvadratnega odstopanja od časa pri upoštevanju hitrostne omejitve,

m = število upoštevanih časovnih intervalov,

$tt_{i,p}$ = vrednost potovalnega časa pri uporabljenem p -tem centilu v časovnem intervalu i ,

$tt_{omejitev}$ = vrednost potovalnega časa pri upoštevanju hitrostne omejitve.

Naslednji korak kalibracije algoritma določi dnevni in nočni režim delovanja ter prehode med njima. Natančen čas prehoda je odvisen predvsem od količine prometnega toka in deleža tovornih vozil v prometnem toku.

Ko so določene vrednosti robustnih statistik in čas delovanja posameznega dnevnega oz. nočnega režima, moramo preveriti, kako algoritem deluje v daljšem časovnem obdobju in kako robusten je na prisotnost osamelcev v prometnem toku. Tu po potrebi izvedemo še manjše popravke, kot npr. zaokroževanje vrednosti za potrebe obveščanja voznikov.

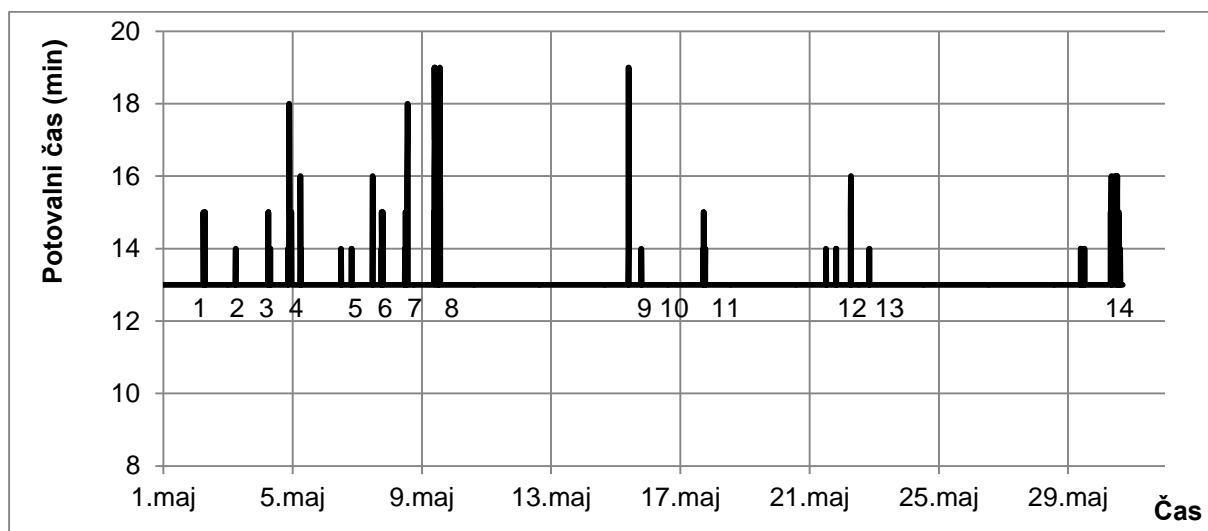
4.5 Preverjanje delovanja algoritma

4.5.1 Preverjanje delovanja algoritma za daljše časovno obdobje

Preverjanje delovanja algoritma je potekala na podatkih, pridobljenih med 1. in 30. majem 2013. V tem času je bilo zaznanih 321.983 potovanj, ki so bila razporejena v 6328 časovnih obdobjih, trajanja 5 minut podnevi (med 5:30 in 20:30) in 15 minut ponoči (med 20:30 in 5:30). V tem obdobju je bilo 176 časovnih intervalov s povečanim potovalnim časom večjim od 13 minut, katerih vzrok so bili različni izredni dogodki na trasi kot npr. dela na cesti, zapore pasov, prometne nesreče oz. slabe vremenske razmere, kar predstavlja 2,8 % skupnega časa. Algoritem je brez pojasnjene vzroka potovalni čas podaljšal v 17 časovnih intervalih, kar je 0,27 % časa. Neprimerno delovanje algoritma je posledica podaljšanih potovalnih časov, za katere nismo uspeli najti vidnega vzroka v prometnem toku. Neprimerno delovanje algoritma ni bilo nikoli večje od 2 minut. V kategorijo »nepojasnen vzrok« spadajo dogodki, ki jih nadzornik prometa

ni zabeležil kot izredni dogodek in lahko predstavljajo različne dogodke: slučajno podaljšane potovalne čase zaradi skupine tovornih vozil, različne motnje v prometnem toku in podobno.

Odstotek pravilno ocenjenih potovalnih časov je tako nad 99.7 %.



Slika 4-23: Nihanje obveščanja o potovalnem času za mesec maj 2013
Figure 4-23: Informing the drivers about travel times in the month of May, 2013

Opis dogodkov v mesecu maju 2013:

1. Nepojasnen vzrok
2. Nepojasnen vzrok
3. Nepojasnen vzrok
4. Močan naliv s točo na odseku med Vranskim in Trojanami
5. Nepojasnen vzrok
6. Izpad napajanja v predoru Trojane, zaprtje predora in nastanek kolone
7. Delo v predoru Jasovnik, zaprt vozni pas, nastanek zastoja pred predorom
8. Zaprt vozni pas v predoru Trojane zaradi pokvarjenega vozila, dela v predoru Jasovnik, zastoj pred predorom v dolžini 2 km
9. Prometna nesreča v predoru Jasovnik, nastanek kolone
10. Močne padavine na odseku med Trojanami in Blagovico
11. Zaprt vozni pas v predoru Jasovnik
12. Nepojasnen vzrok
13. Kratkotrajna zapora predora Trojane zaradi prometne nesreče
14. Zapora prehitevalnega pasu v predoru Ločica
15. Zapora na Vranskem, nastanek zastoja

4.5.2 Preverjanje delovanja algoritma v času izrednih dogodkov


4.5.2.1 Preverjanje delovanja algoritma v času izrednega dogodka na avtocesti

V nadaljevanju je izvedeno ovrednotenje delovanja algoritma za določanje potovalnih časov v primeru izrednega dogodka na avtocesti.

9. maja 2013 je bila v predoru Trojane v smeri Ljubljane dopoldne zaradi okvarjenega vozila na voznem pasu postavljena zapora voznega pasu. Pred poldnevom pa je bila v predoru Jasovnik izvedena delovna zapora voznega pasu, ki je kasneje povzročila 2 km dolg zastoj pred predorom. V nadaljevanju je podrobneje opisan odziv algoritma na razmere na cesti.

Okoli 8:40 je bila v predoru Trojane zaradi okvarjenega vozila postavljena zapora voznega pasu. Redukcija kapacitete ceste iz dveh voznih pasov v enega je pomenila zgostitev prometnega toka in posledično podaljšane potovalne čase, ki so bili prvič vidni v časovnem intervalu med 8:45 in 8:50, to je v časovnem intervalu, ko so prva vozila, na katera je vplivala redukcija kapacitete prispela na dolgotrajno merilno mesto potovalnega časa. Potovalni čas se je iz potovalnega časa v prostem prometnem toku, ki znaša 13 minut, podaljšal na 15 minut. Ob 9:05 je potovalni čas narasel na 16 minut in nato počasi na 19 minut ob 9:40, ko je dosegel največjo vrednost. Z manjšimi nihanji je potovalni čas do 10:00 ostal na vrednosti 18 minut. Po odstranitvi zapore voznega pasu se je prometni tok postopoma do 10:15 normaliziral in ob tem času ponovno opazimo potovalni čas prostega prometnega toka.

Trajanje izrednega dogodka v predoru Trojane je označeno z vodoravno rdečo črto (Slika 4-24). Na grafičnem prikazu lahko poleg gibanja centile, merodajne za določitev reprezentativne vrednosti potovalnega časa, vidimo tudi nihanje najkrajšega izmerjenega potovalnega časa, izmerjenega v posameznih časovnih intervalih. Najkrajši izmerjeni potovalni čas predstavlja vozila, ki vozijo nad hitrostnimi omejitvami, ki veljajo na danem odseku. Na spodnjem grafu je prikazana tudi razlika med 40. centilom in najkrajšim potovalnim časom za posamezni časovni interval zajema podatkov. Ta razlika je bistveno večja v času zgoščenega prometnega toka in podaljšanih potovalnih časov, kar si lahko razlagamo tako, da bolj »agresivni« vozniki, po tem ko zapustijo območje zgostitve, z veliko večjo hitrostjo nadaljujejo svojo pot kot ostala vozila v prometnem toku.




Slika 4-24: Primerjava med reprezentativnim potovalnim časom za obveščanje, minimalnim izmerjenim potovalnim časom ter njuno razliko v času izrednega dogodka

Figure 4-24: Comparison between the representative values of travel time, lowest measured travel times and the difference between both in case of an incident

Ob 11:10 so zaradi vzdrževalnih del v predoru Jasovnik izvedli zaporo voznega pasu. Prvi vpliv zapore je bil opažen ob 11:20, ko je vrednost potovalnega časa narasla s 13 na 14 minut. Z vmesnim skokom na 15 minut je vrednost ostala taka vse do 12:40, ko se je začel potovalni čas bistveno podaljševati. Ob 12:52 je nadzornik prometa v regionalnem nadzornem centru Vransko javil kolono, potovalni časi so se podaljšali na 17 minut. Ob 13:06 je bila kolona pred predorom Jasovnik dolga že 2 km, potovalni čas pa je narasel na 19 minut. Po odstranitvi zapore ob 13:20 so se prometne razmere izboljšale in vrednosti potovalnega časa so hitro padle na vrednost, ki velja v prostem prometnem toku.

Tu je zanimivo preveriti tudi, kolikšno vrednost potovalnega časa smo vozniku posredovali preko grafičnega prikazovalnika spremenljive prometno-informativne signalizacije in kolikšen čas je voznik dejansko potreboval za prevoz odseka. Ker sistem za merjenje potovalnih časov informacijo posreduje z zamudo saj so podatki za posamezno vozilo na voljo šele, ko vozilo prevozi odsek, v času spremembe med prometnimi stanji npr. v času nastanka in razpustitve kolone, ne moremo pričakovati, da bo vozilo za prevoz odseka potrebovalo toliko časa, kolikor smo mu napovedali. To je zelo dobro razvidno tudi iz spodnje slike (Slika 4-25), kjer v času konstantnih prometnih razmer razlika med obveščanim in dejanskim potovalnim časom ni prisotna. Na spodnji sliki (Slika 4-25) so sicer vidna manjša odstopanja, do katerih pride zaradi dejstva, da potovalni čas s katerim obveščamo, zaokrožujemo na celo minuto. Najbolj kritično je območje razpustitve kolone, kjer voznike obveščamo o do 5 minut daljšem potovalnem času,

kot ga voznik potem dejansko potrebuje za prevoz odseka. V kolikor v analizo vzamemo daljše časovno obdobje pa vidimo, da so te napake manjše od minute, kar pomeni, da voznik v splošnem dobi informacijo o potovalnem času z minutno natančnostjo.

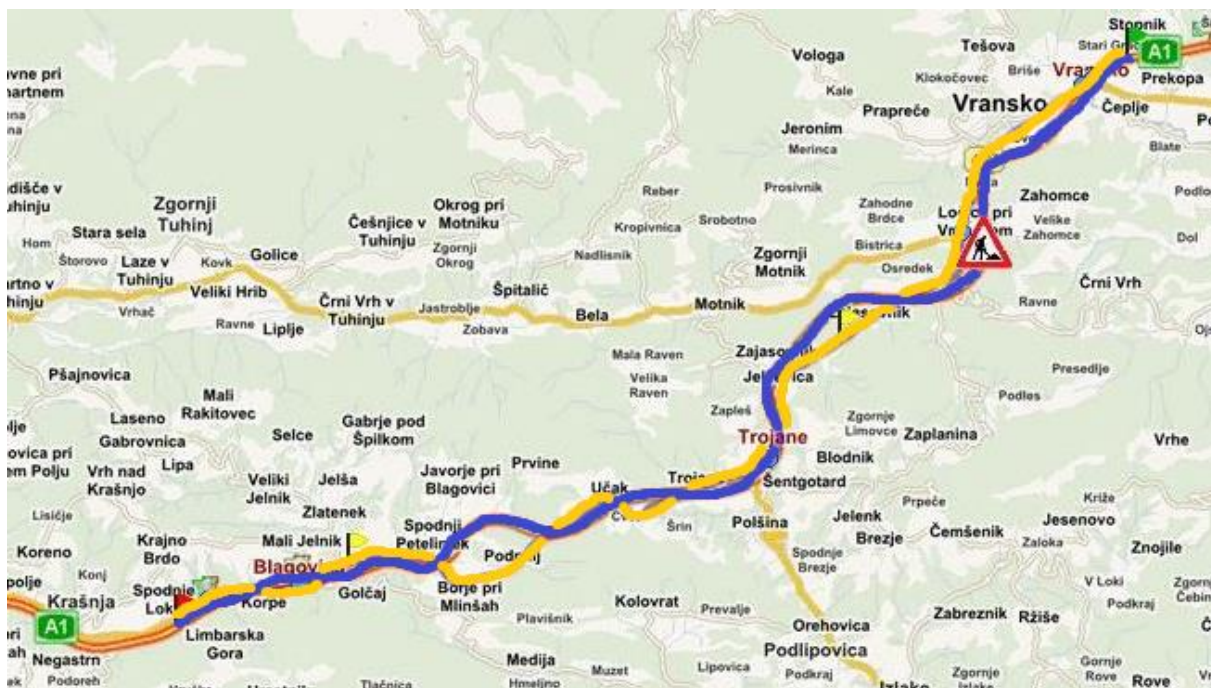


Slika 4-25: Razlika med potovalnimi časi, o katerih smo voznika obvestili in tistimi, ki so jih vozila dejansko potrebovala za prevoz odseka

Figure 4-25: Difference between provided travel time information and experienced travel time

4.5.2.2 Preverjanje delovanja algoritma v času preusmeritve prometa na vzporedno cestno mrežo

V juniju 2013 je na avtocestnem odseku med Vranskim in Blagovico v smeri iz Celja proti Ljubljani potekala rekonstrukcija vozne površine, zaradi česar je bil v nočnem času med 20. in 5. uro zjutraj, med vikendi pa cel dan, promet preusmerjen na vzporedno cestno omrežje. Konfiguracija zapore, locirane med priključkoma Vransko in Blagovica, je omogočila pridobitev meritev o potovalnih časih tudi za vzporedno cestno omrežje, saj je merilna oprema za merjenje potovalnih časov nameščena pred priključkom Vransko in za priključkom Blagovica. Potovalni čas v prostem prometnem toku se je s 13 minut, ki bi jih za prevoz odseka porabilo vozilo po avtocestni trasi, na vzporedni regionalni cesti številka R2-447 podaljšal na 22 minut.



Slika 4-26: Obvozna pot po regionalni cesti (oranžno) in trasa avtoceste (modro)
Figure 4-26: Re-routing during road works via regional road (orange)


Delovanje in parametri algoritma za določevanje potovalnih časov so, kljub obvozni poti, ostali nespremenjeni. S tem smo želeli preveriti odziv in delovanje algoritma v primeru zapore avtocestnega odseka in preusmeritvi prometa na vzporedno cestno omrežje.



Slika 4-27: Primer obveščanja voznikov o potovalnih časih preko grafičnega prikazovalnika spremenljive prometno-informativne signalizacije, nameščenim pred izvozom Vransko v smeri Ljubljane


Figure 4-27: Travel time information provided via Variable Message Sign located in front of Vransko, direction Ljubljana

Zapore avtoceste in preusmeritev na regionalno cesto so se začele s četrtkom, 30. junija 2013, ko je promet po obvozni poti stekel ob 20. uri zvečer. Zapora je trajala do 5. ure zjutraj in nato cel petek do 20. ure zvečer potekala normalno po avtocesti, kar prikazuje Slika 4-28, kjer so v petek med dnevom vidni potovalni časi skladno z omejitvijo, razen dopoldanskega skoka zaradi vzdrževalne zapore (Slika 4-28, točka 1). Od petka zvečer do ponedeljka 3. junija zjutraj, je promet potekal po vzporedni regionalni cesti. Dobro vidne so povečane prometne obremenitve v soboto dopoldan, med 8. in 10. uro, ko so se potovalni časi podaljšali vse do 29 minut (Slika 4-28, točka 2). Potovalni časi se nato gibljejo skladno s prometnimi obremenitvami in naslednji vrh dosežejo v nedeljo okoli 13. ure (Slika 4-28, točka 3). Naslednji ekstrem dosežejo potovalni časi v nedeljo zvečer, ko je opazen povečan prometni tok v smeri Ljubljane (Slika 4-28, točka 4). Potovalni časi so se v ponedeljek ob 5. uri zjutraj, ko se je avtocesta ponovno odprla, spet vrnili na normalne vrednosti.



Slika 4-28: Obveščanje o potovalnih časih med četrtkom 30. maja 2013 in ponedeljkom 3. junija 2013 (1-potovalni časi v času odprte avtoceste, 2-podaljšani potovalni časi ob sobotni jutranji konici, 3-podaljšan potovalni čas v nedeljo opoldne, 4-podaljšan potovalni čas v nedeljo zvečer, 5-zmanjšanje potovalnih časov ob odprtju avtoceste)


Figure 4-28: Travel times during road works and diversion via regional road over the weekend



Slika 4-29: Izmerjeni potovalni časi in obveščanje o potovalnih časih za obdobje od petka 31. maja do ponedeljka 3. junija 2013

Figure 4-29: Measured data and the data provided for travel time dissemination from Friday May 31 until Monday June 3, 2013

V času zapiranja avtocestnega odseka (ob 20. uri zvečer), so nekaj časa po postavitvi zapore izmerjeni potovalni časi še konstantni pri vrednosti 13 minut, saj upoštevajo vozila, ki so bila v času postavitve zapore še na odseku. 20 minut po postavitvi zapore so opaženi prvi podaljšani potovalni časi, ko vozila po obvozni poti dosežejo doltočno merilno mesto.



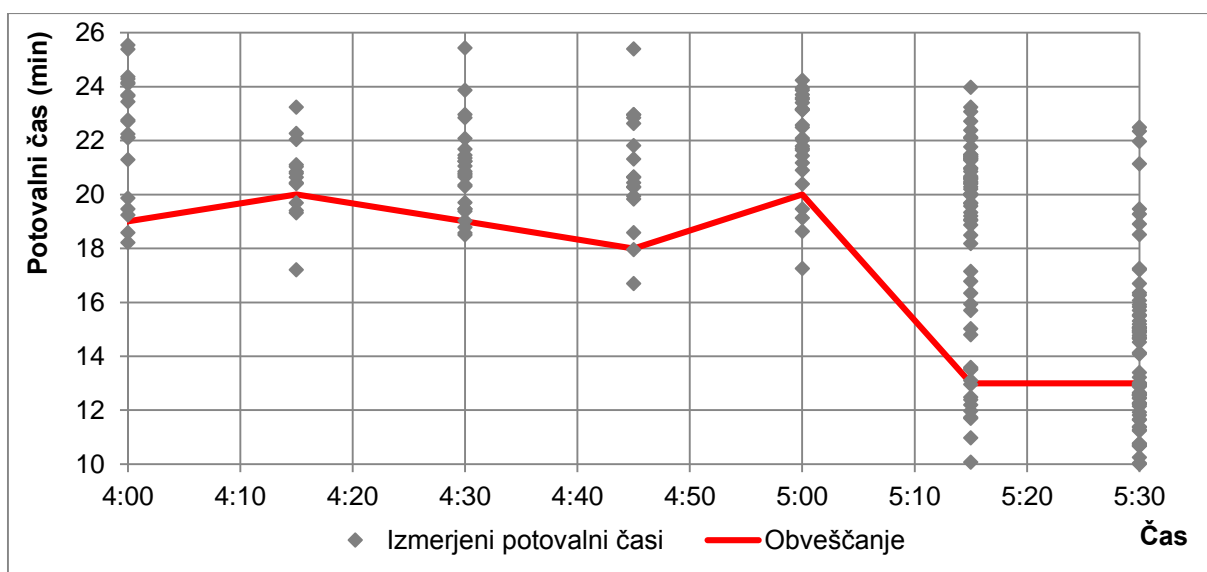
Slika 4-30: Podaljšanje potovalnih časov ob zaprtju avtoceste (20:00) in preusmeritvi na vzporedno regionalno cesto

Figure 4-30: Prolonged travel times after closing the highway (8 pm) and traffic diversion to a regional road




Slika 4-31: Naraščanje potovalnih časov v času aktivacije zapore
Figure 4-31: Increase of travel times during the activation of the road closure

Ob odstranitvi zapore in ponovnem odprtju avtoceste se potovalni čas že v prvem časovnem intervalu vrne na potovalni čas v prostem prometnem toku na avtocesti, vendar na določitev potovalnega časa v prvem intervalu po odstranitvi zapore še vedno delno vplivajo podaljšani časi iz vozil na obvozni poti. Te podaljšane potovalne čase algoritem zaradi uporabe robustne statistike pravilno izloči.



Slika 4-32: Zmanjšanje potovalnih časov ob ponovnem odprtju avtoceste ob 5. uri zjutraj
Figure 4-32: Decrease of travel times after re-opening of the highway at 5 am



Slika 4-33: Primerjava obveščanja in surovih podatkov v noči iz 5. na 6. junij 2013

Figure 4-33: Comparison between measured data and the disseminated travel time data during the night from June 5-6, 2013

4.6 Primerjava z obstoječimi algoritmi za določevanje potovalnega časa

V svetu so se s problemom zasičenosti cestnega omrežja začeli srečevati veliko pred nami. Temu primerno je sledil tudi razvoj sistemov za izračun potovalnih časov ter obveščanje voznikov. Večina algoritmov za izračun potovalnega časa, ki so plod raziskav posameznih podjetij in raziskovalnih ustanov, je na tržišču na voljo v obliki modulov, ki jih avtocestni operaterji lahko vgradijo v svoje sisteme. Podrobnosti delovanja posameznih algoritmov zato velikokrat niso znane, saj jih proizvajalci skrivajo pred konkurenco kot poslovno skrivnost.

4.6.1 Algoritem za določevanje potovalnih časov TransGuide

Eden izmed prosto dostopnih algoritmov je v ZDA široko uporabljen algoritem TransGuide, ki je bil razvit na inštitutu Southwest Research. Algoritem določa potovalne čase na odseku med zaporednimi lokacijami samodejne identifikacije vozil z metodo drsečega povprečja in samodejno izloči vse potovalne čase, ki za več kot prag meritve odstopajo od definirane merodajnega potovalnega časa na izbranem odseku.

Potovalni čas na odseku se računa z metodo drsečih sredin, pri čemer se uporabljata dva parametra: časovni okvir zajema ter prag meritve za izločanje osamelcev. Časovni okvir zajema se uporablja za določitev časovnega okvirja, ki ga upoštevamo pri izračunu potovalnega časa. V primeru časovnega okvira 5 minut, za izračun potovalnega časa upoštevamo le podatke o avtomobilih, ki so v zadnjih 5 minutah prispeli na doltočni odsek. Prag meritve se uporablja za izločitev osamelcev. V primeru, da je prag meritve nastavljen na 20 %, to pomeni, da vsi potovalni časi, ki za več kot 20 % odstopajo od potovalnega časa, določenega v prejšnji časovni iteraciji, ne bodo vključeni v izračun.

Potovalni čas se izračuna po naslednji enačbi:

$$tt_{upoštevan} = \left\{ t_{Bi} - t_{Ai} \mid \begin{array}{l} t_{trenutno} - t_{časovni\ okvir\ zajema} \leq t_{Bi} \leq t_{trenutno} \text{ in} \\ tt_{predhodno}(1 - p_{mejno}) \leq t_{Bi} - t_{Ai} \leq tt_{predhodno}(1 + p_{mejno}) \end{array} \right\} \quad (4-11)$$

$$tt_{ABt} = \frac{\sum_{i=1}^{n_{upoštevanih}} (t_{Bi} - t_{Ai})}{n_{upoštevanih}} \quad (4-12)$$

pri čemer je:

$tt_{upoštevan}$ = vrednosti potovalnega časa, ki jih upoštevamo za nadaljnji izračun,

t_{Ai} = čas i -tega vozila ob prehodu preko točke A (gortočni rob odseka),

t_{Bi} = čas i -tega vozila ob prehodu preko točke B (doltočni rob odseka),

$t_{trenutno}$ = čas, ob katerem izračunavamo potovalni čas,

$tt_{predhodno\ izmerjen}$ = potovalni čas, izmerjen v predhodnem časovnem intervalu,

$t_{časovni\ okvir\ zajema}$ = časovni okvir, za katerega izračunavamo potovalni čas (5 min, 15 min),

p_{mejno} = prag meritve za izločanje osamelcev (začetna vrednost je 0.20 kar pomeni, da vrednosti, ki za več kot 20 % odstopajo od predhodno določenega potovalnega časa ne upoštevamo),

tt_{ABt} = povprečni potovalni čas med točkama A in B v času $t_{trenutno}$,

$n_{upoštevanih}$ = število v izračunu upoštevanih vrednosti potovalnega časa.

4.6.2 Algoritem za določevanje potovalnih časov Dion in Rakha

Dion in Rakha (2006) sta želela zagotoviti, da bi bil algoritem izločanja podatkov uporaben tako v razmerah prostega kot tudi zgoščenega prometnega toka, torej v primeru stabilnih prometnih razmer, kjer nihanje povprečja ni izrazito ter tudi v primeru nestabilnih prometnih razmer, katerih posledica so velika nihanja povprečne vrednosti potovalnega časa. Algoritem zagotavlja uporabnost tudi pri majhnem številu podatkov, pridobljenih iz vira samodejne identifikacije vozil.

Algoritem izločanja podatkov uporablja dinamično spreminjajoče se območje veljavnosti, ki na podlagi števila meritev v danem časovnem intervalu, števila meritev v prejšnjem časovnem intervalu ter na podlagi zaporednih meritev izven območja veljavnosti, določi veljavne potovalne čase. Algoritem vsako vrednost izmerjenega potovalnega časa, ki pade izven območja veljavnosti, zavrže. Območje veljavnosti je definirano z:

- predvidenim potovalnim časom in njegovo razpršenostjo v prihodnjem časovnem intervalu,
- številom zaporednih časovnih intervalov brez izmerjenih potovalnih časov,
- številom zaporednih izmerjenih potovalnih časov izven območja veljavnosti (krajši oz. daljši potovalni časi),
- razpršenostjo potovalnih časov znotraj trenutnega časovnega intervala.

$$tt_{SABk} = \begin{cases} e^{[\alpha \cdot \ln(tt_{ABk-1}) + (1-\alpha) \cdot \ln(tt_{SABk-1})]} & , \text{ če } n_{vk-1} > 0 \\ tt_{SABk-1} & , \text{ če } n_{vk-1} = 0 \end{cases} \quad (4-13)$$

$$\sigma_{sttABk}^2 = \begin{cases} \alpha \cdot \sigma_{ttABk-1}^2 + (1 - \alpha) \cdot \sigma_{sttABk-1}^2 & , \text{če } n_{vk-1} > 1 \\ tt_{sABk-1} & , \text{če } n_{vk-1} = 0 \text{ ali } 1 \end{cases} \quad (4-14)$$

pri čemer je:

tt_{sABk} = predviden glajen povprečni potovalni čas med točkama A in B v trenutnem časovnem intervalu,

σ_{sttABk}^2 = predvidena glajena razpršenost potovalnega časa,

n_{vk-1} = število veljavnih izmerjenih potovalnih časov v predhodnem časovnem intervalu,

tt_{sABk-1} = glajen povprečni potovalni čas v predhodnem časovnem intervalu,

tt_{ABk-1} = reprezentativna vrednost potovalnega časa v predhodnem časovnem intervalu,

α = faktor eksponentnega glajenja (med 0 in 1) glede na število meritev znotraj časovnega intervala.

Predviden povprečni potovalni čas je izračunan na podlagi predpostavke o logaritemsko normalni porazdelitvi potovalnih časov.

Osnovno območje veljavnosti se izračuna na podlagi intervala zaupanja, določenega z izbranim številom standardnih deviacij n_σ nad in pod predvidenim povprečnim potovalnim časom:

$$Stt_{ABk} = \{t_{Bi} - t_{Ai} | t_k - t_{k-1} < t_{Bi} \leq t_k \text{ in } tt_{ABmin k} \leq t_{Bi} - t_{Ai} \leq tt_{ABmax k}\} \quad (4-15)$$

$$tt_{ABmin k} = e^{[\ln(tt_{sABk}) - n_\sigma \cdot (\sigma_{sttABk})]} \quad (4-16)$$

$$tt_{ABmax k} = e^{[\ln(tt_{sABk}) + n_\sigma \cdot (\sigma_{sttABk})]} \quad (4-17)$$

pri čemer je:

$tt_{ABmin k}$ = spodnja meja upoštevanih meritev potovalnega časa,

$tt_{ABmax k}$ = zgornja meja upoštevanih meritev potovalnega časa.

Reprezentativno vrednost potovalnega časa izračunamo po naslednji enačbi:

$$tt_{AB k} = \frac{\sum_{i=1}^{n_{vk}} (t_{Bi} - t_{Ai})}{n_{vk}} \quad (4-18)$$

Za primerjavo delovanja algoritma Dion in Rakha z našim predlaganim algoritmom smo vzeli vrednost parametra $n_\sigma = 2$ ter število zaporednih izmerjenih potovalnih časov izven območja veljavnosti $n_a/n_b = 3$.

4.6.3 Algoritem za določevanje potovalnih časov Ma in Koutsopoulos

Zaradi velikih nihanj v izmerjenih potovalnih časih, ki algoritmu Dion in Rakha zaradi uporabe povprečne vrednosti predstavljajo težave pri izračunu reprezentativne vrednosti potovalnega

časa, sta avtorja Ma in Koutsopoulos (2010) predlagala nadgradnjo algoritma, ki namesto povprečne vrednosti za določitev intervala zaupanja za prihodnji časovni interval uporabi mediano. Mediana se uporabi tudi pri izračunu reprezentativne vrednosti potovalnega časa.

Določitev intervala zaupanja za prihodnji interval se izvede na podlagi razpršenosti, ki za določitev namesto povprečne vrednosti uporabi mediano:

$$\sigma_{ttABk}^2 = \begin{cases} \sum_j (\log(\hat{T}_{AB}(k, j)) - \text{med}(ttlog_{AB}(k)))^2 / (n_k - 1) & , \text{če } n_{vk} > n_{min} \\ \sigma_{ttABk-1}^2 & , \text{drugače} \end{cases} \quad (4-19)$$

$$ttlog_{AB}(k) = [\log(\hat{T}_{AB}(k, 1)), \dots, \log(\hat{T}_{AB}(k, j)), \dots, \log(\hat{T}_{AB}(k, n_k))] \quad (4-20)$$

pri čemer je:

$\hat{T}_{AB}(k, j)$ = meritev potovalnega časa v časovnem intervalu k , ki ni osamelec,

σ_{ttABk}^2 = predvidena razpršenost potovalnega časa.

Osnovno območje veljavnosti izračunamo na podlagi intervala zaupanja, določenega z izbranim številom standardnih deviacij n_σ nad in pod predvidenim povprečnim potovalnim časom:

$$Stt_{ABk} = \{t_{Bi} - t_{Ai} | t_k - t_{k-1} < t_{Bi} \leq t_k \text{ in } tt_{ABmin k} \leq t_{Bi} - t_{Ai} \leq tt_{ABmax k}\} \quad (4-21)$$

$$tt_{ABmin k} = e^{[\ln(tt_{ABk}) - n_\sigma \cdot (\sigma_{ttABk})]} \quad (4-22)$$

$$tt_{ABmax k} = e^{[\ln(tt_{ABk}) + n_\sigma \cdot (\sigma_{ttABk})]} \quad (4-23)$$

pri čemer je:

$tt_{ABmin k}$ = spodnja meja upoštevanih meritev potovalnega časa,

$tt_{ABmax k}$ = zgornja meja upoštevanih meritev potovalnega časa.

Reprezentativno vrednost potovalnega časa izračunamo po naslednji enačbi:

$$tt_{ABk} = \begin{cases} e^{[\text{med}(ttlog_{AB}(k))]} & , \text{če } n_{vk} > n_{min} \\ tt_{ABk-1} & , \text{drugače} \end{cases} \quad (4-24)$$

Za primerjavo delovanja algoritma Ma in Koutsopoulos z našim predlaganim algoritmom smo vzeli vrednost $n_{min} = 6$ ter $n_\sigma = 4$, kot predlagano s strani avtorjev.


4.6.4 Primerjava algoritmov za določevanje potovalnih časov


Za maj in junij 2013 smo vzporedno spremljali delovanje algoritmov za določevanje potovalnih časov: z naše strani razvitega algoritma, ki temelji na uporabi robustnih statističnih metod, v ZDA široko uporabljenega algoritma TransGuide, ki potovalne čase izračuna z določitvijo praga meritve in uporabo običajnih statističnih metod ter dva teoretična algoritma avtorjev Dion in Rakha ter Ma in Koutsopoulos, ki po avtorjevem vedenju nista doživela praktične uporabe.

4.6.4.1 Primerjava delovanja algoritmov v času prostega prometnega toka

V dvomesečnem obdobju primerjave algoritmov smo iz baze podatkov sistema za nadzor in vodenje prometa izluščili 14 različnih izrednih dogodkov kot npr. nesreče, dela na cesti, močan dež ter 13 preusmeritev prometnega toka na vzporedno cestno omrežje zaradi del v predorih. Preusmeritev prometa na vzporedno cesto je bila v desetih primerih ponoči med 20:30 in 5:00 v treh primerih pa čez vikend od petka od 20:30 do ponedeljka do 5:00.

Primerjava uspešnosti določevanja potovalnih časov z različnimi algoritmi v dnevnem času in razmerah prostega prometnega toka pokaže, da so potovalni časi določeni z različnimi algoritmi, v povprečju znotraj nekaj sekund. Vrednosti potovalnega časa se gibljejo okoli vrednosti potovalnega časa ob upoštevanju hitrostne omejitve, ki je za obravnavan odsek 13 minut. Algoritma Dion in Rakha ter TransGuide občasno določata tudi do 30 % podaljšane potovalne čase, kljub temu, da so na odseku prevladovali razmere prostega prometnega toka. Algoritma sta brez razloga podaljšane potovalne čase določevala za časovna obdobja vse tja do ene ure.





Slika 4-34: Primerjava določevanja potovalnih časov z različnimi algoritmi (predlagani, TransGuide, Dion in Rakha, Ma and Koutsopoulos) za obdobje dveh mesecev
 Figure 4-34: Travel time estimation by various algorithms (proposed, TransGuide, Dion and Rakha, Ma and Koutsopoulos) for a period of two months


Preglednica 4-4: Primerjava delovanja algoritmov (* predlagani algoritem je vzet kot referenčen, vendar ne nujno najboljši)

Table 4-4: Comparison of performance of the algorithms (* proposed algorithm is taken as a reference not necessarily meaning it is the best)

	Predlagani	TransGuide	Dion	Ma
Povprečni potovalni čas v času razmer prostega prometnega toka: podnevi	13.03 min	13.06 min	13.26 min	13.10 min
Standardni odklon potovalnega časa: podnevi	0.17 min	0.30 min	0.47 min	0.36 min
Delež časovnih intervalov s podaljšanim potovalnim časom brez razloga: podnevi	2.3 %	4.3 %	24.0 %	8.1 %
Povprečni potovalni čas v času razmer prostega prometnega toka: ponoči	13.02 min	14.22 min	14.32 min	14.35 min
Standardni odklon potovalnega časa: ponoči	0.20 min	1.01 min	0.80 min	1.06 min
Delež časovnih intervalov s podaljšanim potovalnim časom brez razloga: ponoči	1.4 %	70.0 %	85.6 %	73.3 %
Nezmožnost določitve potovalnega časa	0 %	1.75 %	0.008 %	0 %
Primerjava potovalnega časa v času nastanka zastoja (- hitrejši odziv, + počasnejši odziv) *	0 %	-1.0 %	-3.6 %	-1.7 %
Primerjava potovalnega časa v času razpustitve zastoja (- hitrejši odziv, + počasnejši odziv) *	0 %	+8.5 %	+5.5 %	+2.8 %


V nočnem času delovanja algoritma, ko pretežni delež prometnega toka predstavljajo tovorna vozila, algoritmi TransGuide, Dion in Rakha ter Ma in Koutsopoulos niso bili zmožni izločiti podaljšanih potovalnih časov teh tovornih vozil. V času dvomesečne primerjave algoritmov so omenjeni algoritmi vsako noč določevali do 30 % podaljšane potovalne čase, kljub temu da so na odseku prevladovali razmere prostega prometnega toka. Algoritem Dion in Rakha je kar 85 % nočnega časa določeval nepravilno podaljšane potovalne čase, ki so trajali tudi po več kot eno uro.


Naš predlagan algoritem je z upoštevanjem velikega deleža tovornih vozil ves čas pravilno določeval potovalne čase na odseku izvajanja meritve. Kljub temu, da natančnost delovanja algoritma v razmerah prostega prometnega toka ni tako pomembna kot v času zastojev, je vseeno zaželeno, da algoritem dobro deluje tudi v teh razmerah.



Slika 4-35: Robustno delovanje predlaganega algoritma ponoči glede na algoritem Dion in Rakha

Figure 4-35: Robust travel time estimation by proposed algorithm compared to Dion and Rakha algorithm





Slika 4-36: Primerjava delovanja algoritmov za obdobje dveh noči (zgoraj) in podrobneje za eno noč (spodaj). Zaradi boljše predstavitve so potovalni časi zaokroženi na zgornjo minuto. Figure 4-36: Comparing the performance of the algorithms during free flow conditions for a period of two days (above) and during the night (below). Due to easier representation the travel times estimated by the algorithms are rounded to the upper minute.

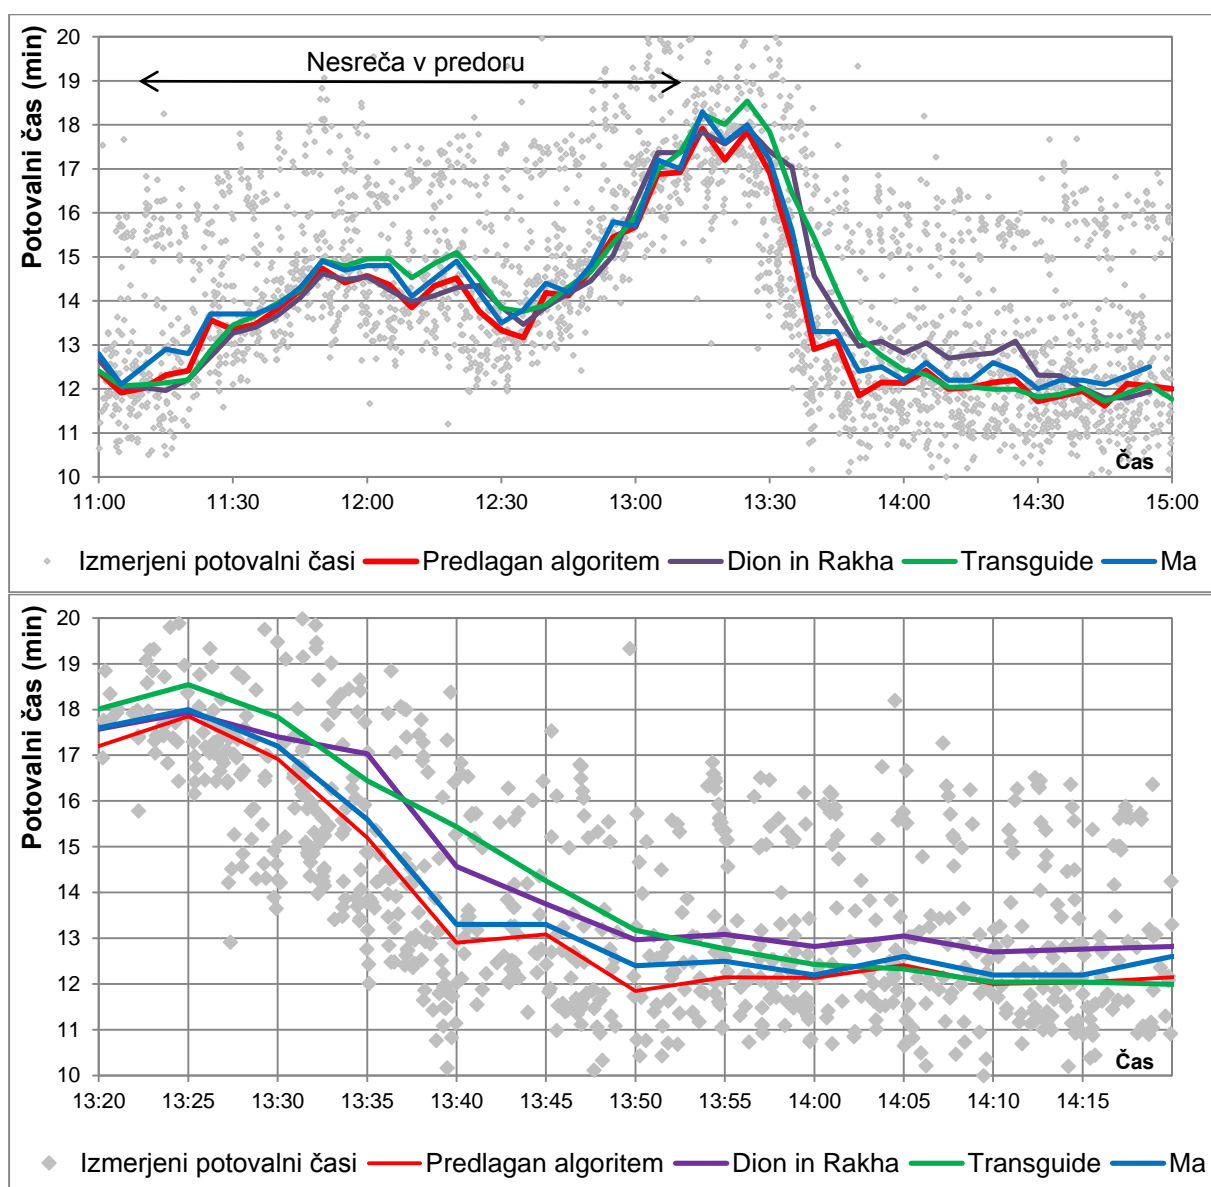
Ob spremljanju algoritma TransGuide v daljšem časovnem obdobju je bilo občasno ugotovljeno tudi, da algoritem od večera proti jutru, ko pretežni del prometnega toka sestavljajo tovorna vozila in je njihova hitrost majhna, počasni območje veljavnosti tako prilagodi počasnim tovornim vozilom, da ob jutranjem prihodu velikega deleža hitrejših osebnih vozil le-te izloči. Tako se je zgodilo, da je algoritem vse do opoldneva izločal vsa osebna vozila in za izračun upošteval le tovorna vozila, kar je vodilo k bistveno podaljšanim potovalnim časom. V takih primerih je z naše strani predlagani algoritem v času jutranje konice pravilno odreagirala in upošteval višje hitrosti/krajše potovalne čase osebnih vozil.

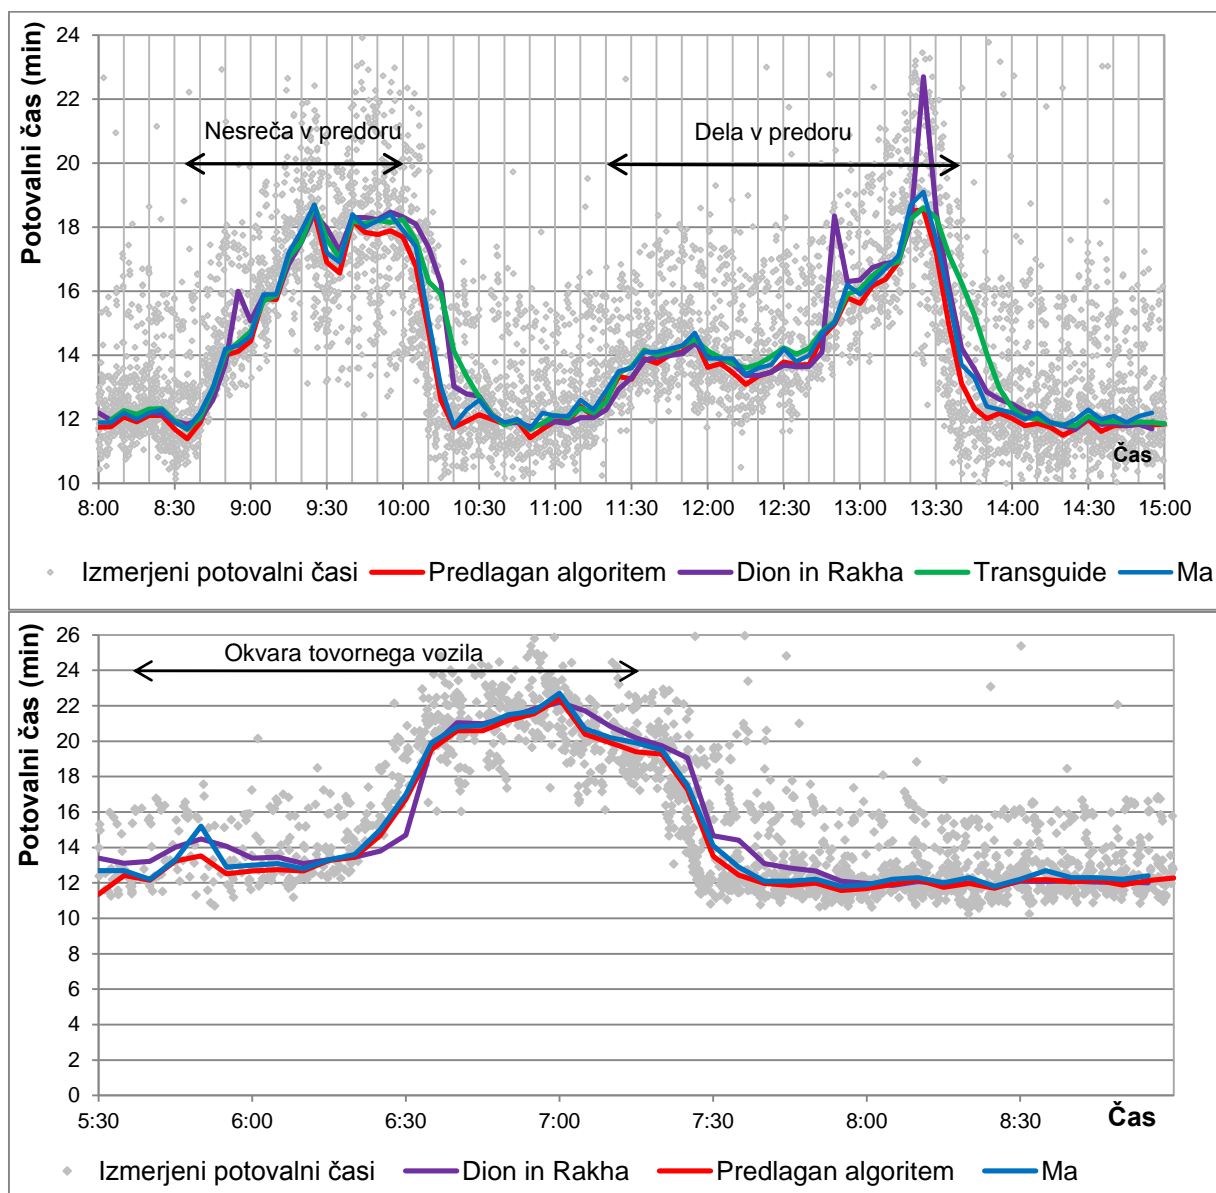
4.6.4.2 Primerjava delovanja algoritmov v času izrednih dogodkov na avtocesti

Med testiranjem smo primerjali tudi odziv algoritmov v primeru izrednih dogodkov na avtocesti. V primeru zapore voznega pasu v predoru zaradi nesreče ob 11:15 (Slika 4-37, prva in druga slika) je odziv vseh algoritmov na podaljšane potovalne čase zaradi nastanka zastoja podoben. Razlika med algoritmi je prisotna v času razpustitve zastoja (Slika 4-37, druga slika) ob 13:25, kjer predlagani algoritem ter algoritem Ma in Koutsopoulos odreagirata precej hitreje. Predlagani algoritem ter algoritem Ma in Koutsopoulos sta že ob 13:40 ocenila razmere normalnega prometnega toka, medtem, ko algoritma Dion in Rakha ter TransGuide sledita deset minut kasneje ob 13:50. Medtem, ko je potovalni čas izračunan s predlaganim algoritmom in posredovan voznikom preko spremenljive prometno-informativne signalizacije že ob 13:35 padel iz 18 na 16 minut, je potovalni čas ocenjen z algoritmom Dion in Rakha še vedno imel vrednost 18 minut. Deset minut kasneje, ob 13:40, je predlagani algoritem voznike že obveščal o potovalnem času 13 minut, medtem ko je algoritem Dion in Rakha voznike obveščal o 15-minutnem potovalnem času, algoritem TransGuide pa celo o 16-minutnem potovalnem času.

Podobno obnašanje algoritmov je bilo opaženo tudi v primeru drugih izrednih dogodkov kot na primer v primeru prometne nesreče in del v predoru v istem dnevu (Slika 4-37, tretja slika). Kot je razvidno iz slike, se je predlagani algoritem po končanju del v predoru precej hitreje odzval. Medtem, ko je predlagani algoritem že ob 13:40 ocenil normalne razmere sta se algoritma Dion in Rakha ter Ma in Koutsopoulos odzvala z deset minutnim zamikom, algoritem TransGuide pa celo s 15-minutnim zamikom. Podoben odziv algoritmov je razviden tudi v primeru zapore pasu zaradi okvare tovornjaka (Slika 4-37, četrta slika).

V vseh obravnavanih primerih se je v času razpustitve zastoja predlagani algoritem odzval precej hitreje, medtem ko algoritem Dion in Rakha občasno ocenjuje precej podaljšane potovalne čase zaradi vključitve tretje zaporedne vrednosti izven območja upoštevanih meritev, ki pa je bila osamelec.





Slika 4-37: Primerjava med algoritmi v primeru prometne nesreče, del v predoru in zapore voznega pasu zaradi okvare vozila

Figure 4-37: Comparison between algorithms in the case of an accident, road works in the tunnel and lane closure due to heavy vehicle breakdown

4.6.4.3 Primerjava delovanja algoritmov v času preusmeritve prometa na vzporedno cestno omrežje

Do nepravilnega delovanja algoritma TransGuide pride tudi v primeru preusmeritve prometnega toka na sekundarno cestno omrežje v času zapor odseka Vransko-Blagovica v mesecu juniju 2013, torej v situaciji, ko po postavitvi zapore potovalni časi vozil zelo hitro narastejo na skoraj dvakratno vrednost potovalnega časa v razmerah prostega prometnega toka iz 13 minut na 22 minut. Ker algoritem TransGuide pri izračunu upošteva le vrednosti potovalnega časa, ki so za do 20 % podaljšane od vrednosti potovalnega časa v prejšnjem časovnem intervalu, ni sposoben slediti veliki spremembi potovalnih časov. Preglednica 4-5

prikazuje situacijo, ko algoritem kar 6 ur ni bil sposoben upoštevati nobene meritve, čeprav jih je bilo veliko. Ker algoritem ni bil sposoben zaznati podaljšanih potovalnih časov, informacija za voznike, čeprav bi jo le-ti v tem času najbolj potrebovali, ni bila na voljo skoraj 7 ur.

Preglednica 4-5: Nepravilno delovanje algoritma TransGuide v primeru preusmeritve na vzporedno cestno omrežje v času postavitve delovne zapore

Table 4-5: Incorrect response of TransGuide algorithm in case of traffic diversion

Obdobje od	Obdobje do	Povprečje	Meritev	Neupoštevanih	Obveščanje
31.5.2013 19:40	19:45:00	12 min	33	3	13 min
31.5.2013 19:45	19:50:00	12 min	18	6	13 min
31.5.2013 19:50	19:55:00	12 min	34	7	13 min
31.5.2013 19:55	20:00:00	12 min	21	4	13 min
31.5.2013 20:00	20:05:00	12 min	19	5	13 min
31.5.2013 20:05	20:10:00	12 min	18	5	13 min
31.5.2013 20:10	20:15:00	13 min	3	2	13 min
31.5.2013 20:15	20:20:00		0	10	
31.5.2013 20:20	20:25:00		0	13	
31.5.2013 20:25	20:30:00		0	29	
31.5.2013 20:30	20:45:00		0	66	
31.5.2013 20:45	21:00:00		0	77	
31.5.2013 21:00	21:15:00		0	84	
31.5.2013 21:15	21:30:00		0	46	
31.5.2013 21:30	21:45:00		0	56	
31.5.2013 21:45	22:00:00		0	64	
31.5.2013 22:00	22:15:00		0	39	
31.5.2013 22:15	22:30:00		0	29	

Algoritem je šele ob 2. uri zjutraj, ko je eno vozilo peljalo precej hitro, uspel zaznati potovalni čas, podaljšan za manj kot 20 % in je tako nastavil novo referenčno vrednost na 16 minut. Ker so v obdobju med 2. in 3. uro zjutraj nato vsa vozila ponovno peljala počasi, je algoritem naslednjo vrednost potovalnega časa izračunal šele ob 3. uri zjutraj.

Preglednica 4-6: Prva sprememba vrednosti potovalnega časa za manj kot 20 % glede na zadnji časovni interval izračuna

Table 4-6: TransGuide algorithm is not able to track sudden changes larger than 20 %

Obdobje od	Obdobje do	Povprečje	Meritev	Neupoštevanih	Obveščanje
1.6.2013 0:45	1:00:00		0	20	
1.6.2013 1:00	1:15:00		0	16	
1.6.2013 1:15	1:30:00		0	20	
1.6.2013 1:30	1:45:00		0	24	
1.6.2013 1:45	2:00:00	16 min	1	18	16 min
1.6.2013 2:00	2:15:00		0	16	
1.6.2013 2:15	2:30:00		0	21	
1.6.2013 2:30	2:45:00		0	22	
1.6.2013 2:45	3:00:00	18 min	1	18	18 min
1.6.2013 3:00	3:15:00	20 min	8	7	20 min
1.6.2013 3:15	3:30:00	23 min	17	7	23 min
1.6.2013 3:30	3:45:00	22 min	17	2	22 min
1.6.2013 3:45	4:00:00	22 min	19	2	22 min
1.6.2013 4:00	4:15:00	22 min	15	3	22 min
1.6.2013 4:15	4:30:00	20 min	8	1	20 min


Do podobne situacije, kot je bilo predhodno opisano, je prišlo tudi v primeru nastanka zastoja, ko se potovalni časi v enem časovnem intervalu izračunavanja podaljšajo za več kot 20 %. Takih sprememb, kot je razvidno v prejšnjem primeru, algoritem TransGuide ni sposoben zaznati in je zato neprimeren za izračunavanje potovalnega časa v primeru sprememb vrednosti potovalnega časa za več kot 20 %, v zaporednih časovnih intervalih.

Kot je razvidno iz spodnje preglednice je naš predlagani algoritem pravilno zaznal podaljšane potovalne čase in voznikom podal ustrezno informacijo.

Preglednica 4-7: Pravilno delovanje predlaganega algoritma v primeru preusmeritve na vzporedno cestno omrežje v času postavitve delovne zapore

Table 4-7: Proper response from proposed algorithm in case of traffic diversion

Obdobje od	Obdobje do	Centil	Meritev	Obveščanje
31.5.2013 19:40	19:45:00	12 min	36	12 min
31.5.2013 19:45	19:50:00	12 min	24	12 min
31.5.2013 19:50	19:55:00	12 min	41	12 min
31.5.2013 19:55	20:00:00	13 min	25	13 min
31.5.2013 20:00	20:05:00	13 min	24	13 min
31.5.2013 20:05	20:10:00	13 min	23	13 min
31.5.2013 20:10	20:15:00	13 min	5	13 min
31.5.2013 20:15	20:20:00	19 min	10	19 min
31.5.2013 20:20	20:25:00	22 min	13	22 min
31.5.2013 20:25	20:30:00	22 min	29	22 min
31.5.2013 20:30	20:45:00	21 min	66	21 min
31.5.2013 20:45	21:00:00	21 min	77	21 min
31.5.2013 21:00	21:15:00	20 min	84	20 min
31.5.2013 21:15	21:30:00	20 min	46	20 min
31.5.2013 21:30	21:45:00	20 min	56	20 min
31.5.2013 21:45	22:00:00	21 min	64	21 min
31.5.2013 22:00	22:15:00	20 min	39	20 min
31.5.2013 22:15	22:30:00	19 min	29	19 min
31.5.2013 22:30	22:45:00	19 min	48	19 min



Slika 4-38: Algoritem TransGuide zaradi nenadne spremembe v potovalnih časih, večje od 20 % glede na predhodni časovni interval, le-te ni bil sposoben zaznati – informacija za voznike zato 7 ur ni bila na voljo

Figure 4-38: Proper response from the proposed algorithm and inability to track sudden changes in travel times by TransGuide algorithm




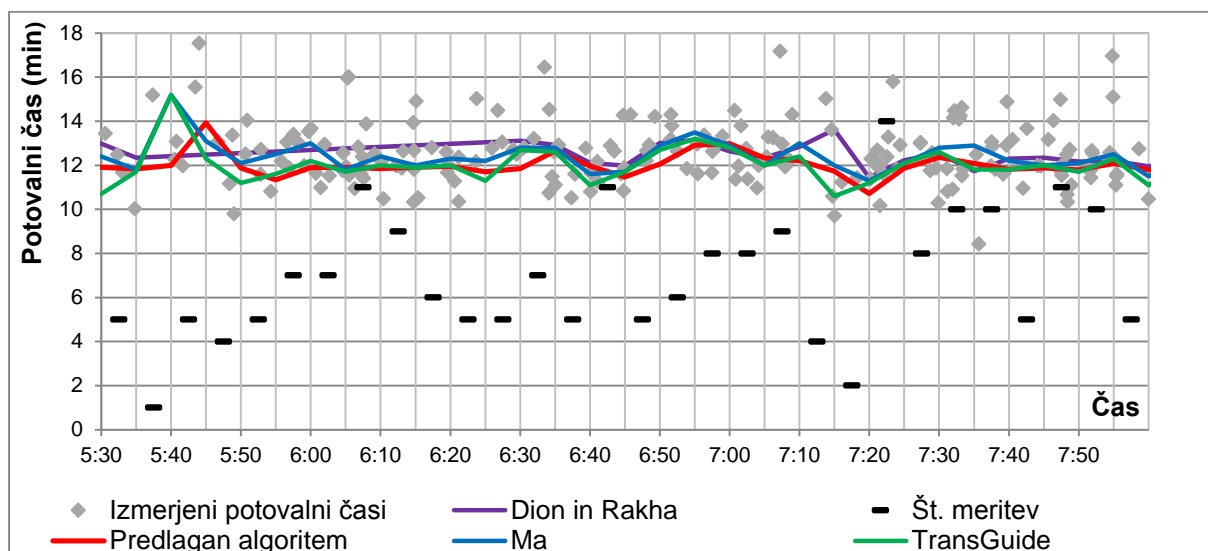
Slika 4-39: Preusmeritev prometa na vzporedno državno cesto

Figure 4-39: Re-routing via regional road

4.6.4.4 Primerjava delovanja algoritmov v primeru majhnih vzorcev izmerjenih potovalnih časov

V času dvomesečne primerjave delovanja algoritmov se je zelo poredko zgodilo, da bi bilo v posameznem časovnem intervalu zajema na voljo manj kot pet meritev potovalnega časa. Slika 4-40 prikazuje teh nekaj primerov. Glavno razliko med ocenjenim potovalnim časom med algoritmi (Slika 4-40, prva slika) lahko pripišemo dejstvu, da predlagani algoritem uporablja nižjo vrednost parametra občutljivosti β , ki v primeru majhnih vzorcev daje prioriteto glajenju. Kot je razvidno (Slika 4-40, druga in tretja slika) prednost glajenja pred hitrim odzivom pomeni manj nihanj. Medtem, ko predlagani algoritem ter algoritma Dion in Rakha ter Ma in Koutsopoulos dobro ocenijo potovalne čase v primeru majhnega vzorca, pa po drugi strani algoritem TransGuide popolnoma odpove. Od 20:15 dalje zaradi velike spremembe večje od 20 % ni bil več sposoben oceniti vrednosti potovalnega časa.






Slika 4-40: Primerjava delovanja algoritmov v primeru majhnega vzorca v času izrednega dogodka (prva slika) ter v času razmer prostega prometa na praznični dan (druga in tretja slika)

Figure 4-40: Comparison of the algorithms in case of low sampling rates during an event (first figure) and during free flow conditions on a national holiday day (second and third figure)

Delovanje predlaganega algoritma smo preverili tudi v primeru zmanjšanja prvotne velikosti vzorca za 90 %, kar pomeni, da je bilo na voljo le 10 % prvotnih meritev. Glede na to, da sistem reidentifikacije registrskih tablic zaradi vmesnih priključkov upari približno 70 % vseh potovanj to pomeni, da je predlagan algoritem sposoben natančno oceniti potovalne čase na odsekih za tehnologije, ki imajo stopnjo penetracije manjšo od 7 %.

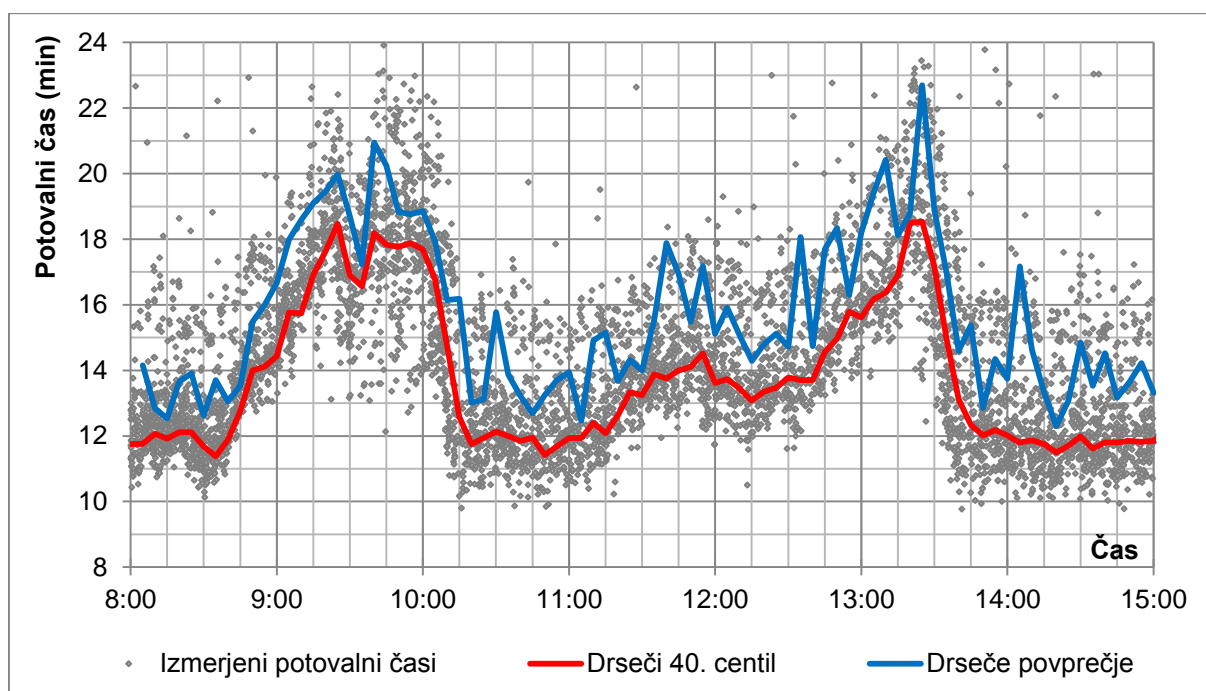


Slika 4-41: Primerjava delovanja algoritmov v primeru zmanjšanja velikosti vzorca za 90 %
Figure 4-41: Comparison of the algorithms in case of a reduction of the sample size for 90 %

4.6.5 Ugotovitve

V splošnem vlada prepričanje, da v času zastojev potovalni časi vseh vozil zaradi homogenizacije prometnega toka postanejo homogeni. Med izvajanjem študije smo ugotovili, da temu ni tako in da kljub razmeram zgoščenega prometnega toka potovalni časi osebnih in tovornih vozil ostanejo razpršeni. Vzrok za to lahko najdemo v dveh razlogih. Prvi je ta, da po zapustitvi območja zastoja osebna vozila hitreje pospešujejo nazaj k razmeram prostega prometnega toka in pripadajoči omejitvi hitrosti, medtem ko tovorna vozila zaradi znanih fizičnih omejitev svojo omejitev hitrosti dosežejo kasneje. Drugi razlog predstavlja dejstvo, da zastoj ponavadi zavzema le krajši del odseka, kjer merimo potovalni čas, zato potovalni časi osebnih in tovornih vozil ostanejo različni kljub delu avtoceste, kjer prevladujejo homogene prometne razmere. V našem primeru je namreč območje meritve dolgo 22 km in težko si predstavljamo, da bi zastoji pogosto zavzemali tako dolgo območje.

Slika 4-42 primerjave med drsečim povprečjem kot nerobustno mero in 40. centilom kot robustno mero kaže, da na centil precej manj vpliva prisotnost osamelcev, kamor spadajo tudi tovorna vozila. Razvidno je tudi, da v primeru uporabe povprečja potovalni časi vodijo tudi k do 30 % daljšim vrednostim kot v primeru uporabe centila.




Slika 4-42: Razpršitev potovalnih časov med zastojem. Uporaba drsečega povprečja namesto drsečega centila vodi k do 30 % podaljšanim potovalnim časom.

Figure 4-42: Dispersion of travel times during congestion. Using running average instead of running percentile results in up to 30 % longer estimated travel times.

Z namenom ovrednotenja razpršenosti potovalnih časov okoli reprezentativne vrednosti potovalnega časa smo primerjali vrednosti mediane absolutnega odklona od mediane (MAD) za razmere prostega prometnega toka in pojava zastoja. Slika 4-43 prikazuje, da potovalni časi osebnih in tovornih vozil ostanejo razpršeni tudi v času zastoja, kar je iz slike razvidno kot

velika vrednost MAD med zastojem. Vrednost MAD je med zastojem enakega velikostnega razreda kot v času razmer prostega prometnega toka. To potrjuje zahtevo, da je za določitev reprezentativne vrednosti potovalnega časa, tako v prostem prometnem toku kot tudi v času zastoja, potrebno razlikovati med osebnimi in tovornimi vozili. To pa za tehnologije, ki zagotavljajo mešan vzorec potovalnih časov tako osebnih kot tovornih vozil najlažje dosežemo z uporabo robustne statistike.



Slika 4-43: Razpršitev izmerjenih potovalnih časov okoli reprezentativne vrednosti potovalnega časa

Figure 4-43: Dispersion of travel times around the representative value of travel time

5 POSREDNA OCENA POTOVALNEGA ČASA IZ TOČKOVNE EKSTRAPOLACIJE HITROSTI

»Izmeri kar lahko, ostalo modeliraj.«


- Francesc Soriguera Martí

V predhodnih poglavjih je opisano, kako s pomočjo neposredno linijsko izmerjenih potovalnih časov na posameznem odseku določimo reprezentativni potovalni čas za obravnavani odsek. Ta izmerjeni potovalni čas na odseku predstavlja natančno informacijo, vendar vsebuje zgodovinsko komponento, ki je posledica tega, da so podatki za posamezno vozilo na voljo šele, ko le-ta prevozi odsek izvajanja meritve. Dostopnost podatkov o neposredno linijsko izmerjenih potovalnih časih je poleg tega na voljo le ob namestitvi ustrezne opreme za reidentifikacijo fizičnih karakteristik vozila, kar predstavlja dodatne stroške.

Poleg neposrednih linijskih meritev potovalnega časa imamo za oceno potovalnih časov na posameznem odseku pogosto na voljo tudi točkovne merilnike parametrov prometnega toka, kjer potovalni čas ocenimo na osnovi točkovnih meritev hitrosti. Prednost meritev, pridobljenih iz točkovnih merilnikov, je možnost določitve trenutnega potovalnega časa z navidezno meritvijo za posamezno vozilo, še preden le-ta konča svoje potovanje.

Posredna ocena potovalnega časa v splošnem temelji na merjenju osnovnih karakteristik prometnega toka na izbranem preseku avtoceste in ekstrapolaciji teh točkovnih meritev z uporabo določenega algoritma na celoten pripadajoči pododsek. Te osnovne karakteristike opišejo vse fizične lastnosti prometnega toka in tako omogočajo izračun količin, ki jih točkovno ne moremo meriti neposredno. Posredna ocena potovalnega časa, pridobljena iz točkovnih meritev hitrosti, tako predstavlja takojšnjo informacijo s sicer manjšo prostorsko natančnostjo.

Dodatna prednost te metode je možnost uporabe obstoječe opreme za točkovno merjenje hitrosti, ki je na nekaterih avtocestnih odsekih že nameščena. V sklopu sistemov za nadzor in vodenje prometa na slovenskih avtocestah se za merjenje karakteristik prometnega toka uporabljajo mikrovalovni detektorji.



Slika 5-1: Točkovno merjenje karakteristik prometnega toka z mikrovalvnim detektorjem
Figure 5-1: Microwave detector measuring traffic flow parameters

V prvi vrsti metoda ocene potovalnega časa z ekstrapolacijo hitrosti temelji na merjenju hitrosti, ki mora biti zato izmerjena kar se le da natančno. Za potrebe sistemov za nadzor in vodenje prometa se uporabljajo prometni podatki, agregirani na minutni ravni. Poleg tega se iz točkovnih merilnikov, znotraj eno-minutnega obdobja, izračunava srednja časovna hitrost, za določevanje potovalnih časov iz točkovnih meritev pa potrebujemo srednjo prostorsko hitrost, saj bi srednja časovna hitrost v splošnem podcenila vrednost potovalnega časa. V nekaterih sistemih prav tako ni mogoče razlikovati med hitrostmi različnih razredov vozil kar dodatno oteži določitev reprezentativne vrednosti hitrosti vozil v prometnem toku.

Za prostorsko ekstrapolacijo točkovnih meritev med detekcijskimi mesti se uporabljajo različne ekstrapolacijske metode kot npr. konstantna, linearna in kvadratna, katerih namen je kar se le da dobro aproksimirati razmere na odseku. Problem vseh znanih metod je neupoštevanje dinamike prometnega toka, kar v primeru pojava zastoja pokaže njihovo nenatančnost. Nenatančnost metode je še toliko večja, v kolikor gostota merilnih mest ni dovolj velika. V literaturi se kot primerna omenja postavitev točkovnih merilnikov v razmiku 500 m (Soriguera in Robusté, 2011-b), tako gosta mreža merilnikov je v realnih okoliščinah dokaj težko izvedljiva razen na nekaterih odsekih mestnih avtocest, kjer je zaradi narave priključkov in velike količine prometnega toka to nujno potrebno.

Potovalni čas za daljšo relacijo/odsek se ponavadi določi s seštevanjem potovalnih časov na posameznih pododsekih, pri čemer je vsak pododsek definiran z merilnim mestom. Potovalni čas za posamezni pododsek je določen na podlagi srednje hitrosti na merilnem mestu za obdobje zadnjih nekaj minut, kar zahteva sprotno posodabljanje.

Potovalni čas za daljšo relacijo, ocenjen kot vsota potovalnih časov na posameznih pododsekih, ni določen na podlagi funkcijske zveze med opravljeno potjo in časom, temveč predstavlja trenutno sliko potovalnih časov na posameznih pododsekih. Ta časovna poravnava se v

literaturi imenuje trenutni potovalni čas (ang. instantaneous travel time) in je najboljša aproksimacija želeni bodoči informaciji o potovalnem času za voznike, ki na odsek šele vstopajo, brez negotovosti pri napovedi bodočih razmer, ki je nevhvaležno opravilo.

5.1 Pregled obstoječe literature in izvedenih raziskav na temo posredne ocene potovalnega časa iz točkovne ekstrapolacije hitrosti

Ekstrapolacija točkovnih meritev hitrosti na celoten pripadajoči odsek predstavlja alternativo neposrednemu merjenju potovalnih časov na odseku avtoceste. Kljub enostavnosti in natančnosti meritev pridobljenih z eno od metod neposrednega merjenja, trenutno stanje že nameščene opreme v sklopu sistemov za nadzor in vodenje prometa vodi k potrebi po sočasni uporabi točkovnih merilnikov pri oceni potovalnih časov. Točkovne meritve namreč s svojo časovno neposrednostjo pomembno pripomorejo k oceni trenutnega potovalnega časa na obravnavanem odseku.


Za oceno potovalnega časa iz točkovnih merilnikov je najbolj uporaben algoritem točkovne hitrosti. Ta metoda temelji na ekstrapolaciji točkovne meritve hitrosti na celoten, merilniku pripadajoč, pododsek. Ob uporabi tega algoritma je upoštevana hipoteza, da so točkovno izmerjene karakteristike prometnega toka reprezentativne za celoten pripadajoč pododsek. Zaradi preprostosti meritve in široke uporabnosti točkovnih merilnikov je ta način v svetu zelo pogosto uporabljen in razširjen pri različnih cestnih upravljavcih.

Glavni izziv oziroma problematika tega načina je zagotoviti natančne točkovne meritve hitrosti ter pravilno ekstrapolacijo teh meritev na celoten pripadajoč odsek. Natančnost meritve hitrosti izvedene z radarsko komponento mikrovalovnega detektorja, vgrajenega na naših avtocestah znaša $\pm 3\%$ za hitrosti večje od 100 km/h oz. ± 3 km/h za hitrosti do 100 km/h. Medtem, ko se na natančnost radarske meritve iz mikrovalovnega detektorja ne da vplivati, pa je točkovna ekstrapolacija izmerjenih hitrosti na pripadajoč pododsek postopek, kjer z izbiro pravilne metode veliko pripomoremo k natančnosti ocene potovalnega časa.

Ponavadi se vsakemu točkovnemu merilniku dodeli pripadajoč avtocestni pododsek, za katerega veljajo točkovno izmerjeni podatki ob predpostavki, da hitrost ostane konstantna na celotni dolžini odseka za celoten časovni interval agregacije meritev. Prvi pogoj je, da iz točkovnih merilnikov zagotovimo srednjo prostorsko hitrost in ne srednjo časovno hitrost, čemur v večini že nameščenih sistemov po svetu ni zadoščeno. Prav tako večina literature oceni potovalne čase iz točkovno ekstrapolirane hitrosti na podlagi srednje časovne hitrosti. Lokalno izmerjena srednja časovna hitrost je namreč vedno večja od srednje prostorske hitrosti, saj je pri točkovni meritvi večje število hitrejših vozil, zato so potovalni časi, ocenjeni z ekstrapolacijo srednje časovne hitrosti, krajši od dejanskih. Razlika med srednjo prostorsko in srednjo časovno hitrostjo je po ugotovitvah Soriguere in Robustéja (2011) v povprečju približno 2%. Zagotovitev srednje prostorske hitrosti namesto srednje časovne hitrosti zahteva »le« spremembo algoritma, ki izračunava prometne karakteristike na lokalnih krmilnih postajah sistema za nadzor in vodenje prometa. Tej zelo pomembni zahtevi je bilo v naši študiji zadoščeno.

Večji problem pri oceni potovalnih časov iz točkovnih merilnikov predstavlja nestabilnost oz. nezveznost prometnega toka v času zgoščenega prometa in nastajanja zastojev, pri katerih lahko

točkovna ekstrapolacija meritev predstavlja kar 30% napako glede na dejanski potovalni čas na tem pododseku, kot sta v svoji študiji ugotovila Rakha in Zhang (2005), četudi so v povprečju prometne razmere na celotnem odseku enake. V primeru t.i. prometnega toka »stop&go« lahko prihaja do velikih napak pri določanju reprezentativne vrednosti hitrosti, saj izmerjena povprečna hitrost predstavlja le tiste situacije, ko se promet dejansko premika (»go«), niso pa zajete situacije, ko vozila mirujejo (»stop«), saj jih je nemogoče izmeriti (Soriguera in Robusté, 2011). Tako je potovalni čas, določen iz točkovne meritve, krepko podcenjen. V takih primerih robnih pogojev tudi ne pridobimo prav veliko, v kolikor namesto srednje točkovne hitrosti uporabimo srednjo prostorsko hitrost. Prav tako do velikih napak prihaja v primeru nastanka zastoja znotraj odseka v kolikor le-ta še ne seže do točkovnega merilnika. V takem primeru so napovedi potovalnega časa napačne, najbolj takrat, ko je večji del odseka pod zastojem, na točkovnem merilniku pa so prometne razmere še normalne (in obratno). V primeru nizke izmerjene vrednosti hitrosti prav tako nimamo informacije o temu, ali je do izrednega dogodka prišlo gortočno ali doltočno od opazovanega merilnika.



Slika 5-2: Prikaz časa preživetega v gibanju in v zastoju (Turner in sodelavci, 1998)

Figure 5-2: Illustration of running time and stopped delay time (Turner et al., 1998)

Kot sta ugotovila Soriguera in Robusté (2011), deluje ocena potovalnega časa iz točkovnih merilnikov dobro v primeru prostega ali zgoščenega prometnega toka na celotnem pododseku, v primeru spremembe karakteristik prometnega toka znotraj pododseka ali v primeru prometnega toka »stop&go«, pa je metoda nenatančna. Velikost napake je odvisna tudi od gostote namestitve točkovnih merilnikov, saj gostejša mreža namestitve točkovnih merilnikov omogoča hitrejšo razpoznavanje sprememb karakteristik prometnega toka saj udarni val hitreje pride do merilnika. Poleg tega v primeru dolgih pododsekov, v kolikor znotraj njih pride do spremembe prometnega stanja, za večjo dolžino napačno predpostavljajo točkovno ekstrapolacijo meritev. Znotraj dolgih pododsekov je tudi večja možnost spremembe prometnega stanja zaradi kakršnega koli vzroka. To govori o jasnem razmerju med gostoto namestitve točkovnih merilnikov in napako pri oceni potovalnega časa.

Več avtorjev (Cortés in sodelavci, 2002; Coifman, 2002a; Treiber and Helbing, 2002; van Lint in van der Zijpp, 2003; Sun in sodelavci, 2008) se je ukvarjalo s problematiko interpoliranja

točkovne meritve hitrosti med zaporednimi lokacijami točkovnih merilnikov. Vsi so predlagali nove metode interpolacije, ki temeljijo na nekonstantnem spreminjanju hitrosti med zaporednimi točkovnimi meritvami, s čimer bi se dalo opisati nekonstantno prostorsko spreminjanje hitrosti. Vsi omenjeni modeli predstavljajo matematični pristop k interpoliranju, pri čemer na različne načine gladijo konstantno interpolacijo med zaporednima merilnikoma v odvisnosti od časa in prostora, vendar noben od njih ne upošteva dinamike prometnega toka (Soriguera in Robusté, 2011). Zato dogodki, ki se zgodijo na območju izven dosega točkovnega merilnika, ostanejo neopaženi.

Coifman (2002a) je predlagal metodo določevanja potovalnih časov iz točkovne ekstrapolacije meritev hitrosti, ki na podlagi ugotovitev teorije prometnega toka določi funkcijsko zvezo med opravljeno potjo in časom. Namesto uporabe povprečne vrednosti hitrosti za nastavljen časovni interval je ocena potovalnega časa znotraj časovnega intervala narejena kot uteženo povprečje posameznih meritev glede na časovni razmik med vozili. Ocena potovalnih časov se je izkazala za zanesljivo, v kolikor so na odseku prevladovale konstantne razmere brez zastojev.

Holt in sodelavci (2003) ugotavljajo, da so metode ekstrapolacije točkovne meritve hitrosti spremenljive v razmerah prostega prometnega toka brez pojavljanja zastojev, medtem ko v času zgoščenega prometnega toka prihaja do razlik med potovalnim časom pridobljenim iz točkovne ekstrapolacije hitrosti in neposredno linijsko izmerjenim potovalnim časom. Ugotavljajo, da točkovno ekstrapolirane hitrosti vodijo k več kot 30 % podcenjenim potovalnim časom, v kolikor prometno povpraševanje preseže 85 % kapacitete avtocestnega pododseka. V kolikor metodo uporabimo na daljšem odseku, se napake v potovalnem času iz posameznih pododsekov seštejejo ali odštejejo.

Sun in sodelavci (2008) so pri analizi ocene potovalnih časov iz točkovne ekstrapolacije hitrosti ugotovili, da dejanski potovalni časi na odseku, izmerjeni s tehnologijo sledenja vozil, močno odstopajo od kvocienta med točkovno izmerjeno hitrostjo ter dolžino odseka. Ugotovitev ni presenetljiva, saj potovalni čas na odseku predstavlja povprečenje prometnih razmer na določenem odseku, medtem ko točkovno izmerjeni podatki predstavljajo povprečenje prometnih razmer v določenem časovnem intervalu samo na eni lokaciji.

Yeon in sodelavci (2008) so za določitev potovalnih časov iz točkovnih merilnikov uporabili časovno diskretne Markove verige, kjer stanje sovpada z informacijo ali na pododseku prevladujejo razmere nasičenega prometnega toka (zastoj) ali ne. Ugotovili so, da potovalne čase s tem modelom lahko pridobimo z 99% natančnostjo glede na neposredno linijsko izmerjen potovalni čas, če je le povpraševanje znotraj časovnih intervalov izračuna dokaj konstantno.

Kwon in sodelavci (2000) so se dotaknili tudi ne tako trivialne napovedi potovalnega časa, pridobljenega s točkovno ekstrapolacijo hitrosti na podlagi linearne regresije, in preteklih podatkov. Ugotovili so, da kljub vloženemu trudu v napoved, dejanski potovalni čas, ki ga voznik potrebuje za prevoz odseka le malokrat sovpada z napovedanim potovalnim časom iz točkovne ekstrapolacije hitrosti. Do podobnih rezultatov so prišli tudi Kothuri in sodelavci. (2007), ki v času izrednega dogodka kot je nesreča ugotavljajo velike razlike med dejanskim potovalnim časom in napovedanim s točkovno ekstrapolacijo hitrosti.


Ban in sodelavci (2010) so med seboj primerjali različne algoritme za določevanje potovalnih časov na podlagi podatkov, pridobljenih iz znančnih detektorjev ter svoje ugotovitve preverili z referenčno tehnologijo reidentifikacije vozil na zaporednih merilnih mestih cestninskega sistema. Ugotovili so, da je razpršenost potovalnih časov pogosto večja v času razmer prostega prometnega toka, da imajo obstoječi algoritmi podobno učinkovitost v razmerah prostega prometnega toka, medtem, ko v času izrednih dogodkov vsi bistveno podcenijo vrednost potovalnega časa ter da je pozicioniranje točkovnih merilnih mest bistvenega pomena za natančnost uporabljene metode.

Avtocestni operaterji po svetu za prostorsko ponazoritev točkovnih meritev uporabljajo različne metode interpolacije hitrosti med zaporednimi merilnimi mesti kot so konstantna, linearna in kvadratna interpolacija, s čimer želijo aproksimirati prometne razmere na odseku. Nobena od teh metod ne upošteva dinamike prometnega toka. Različni avtorji (Kothuri in sodelavci, 2007; Soriguera in Robusté, 2011) v analizi obstoječih metod trdijo, da vse metode interpolacije hitrosti, ki ne upoštevajo dinamike prometa in nastanka zastoja, ne prispevajo k natančnejši oceni potovalnega časa in so zato nenatančne v času nastajanja zastojev. Zaradi pomanjkanja natančnosti se je zato smiselno izogniti prezapletenim interpolacijam in trud vložiti v glajenje detektorskih podatkov, s čimer zmanjšamo nihanja agregiranih podatkov povprečnih hitrosti znotraj krajših časovnih intervalov, pri čemer vseeno ohranimo neposrednost meritev. Omenjene metode interpolacije bi namreč zahtevale precej gosto mrežo merilnih mest, kar pa pogosto ni ekonomsko upravičeno.

5.2 Določitev srednje prostorske hitrosti iz točkovnih merilnikov

5.2.1 Srednja časovna in srednja prostorska hitrost

Hitrost prometnega toka je opredeljena kot razmerje prevožene razdalje in časa. Razvoju hitrosti vsakega posameznega vozila je skoraj nemogoče slediti na celotni poti, zato se povprečna hitrost pogosto določi na podlagi vzorca vozil na preseku ceste za določeno časovno obdobje ali na prostorskem odseku v določenem časovnem trenutku. V kolikor je hitrost izmerjena v časovnem obdobju govorimo o srednji časovni hitrosti, v kolikor pa je izmerjena na odseku ceste, govorimo o srednji prostorski hitrosti (Slika 5-3).



Slika 5-3: Točkovno (levo) in prostorsko (desno) merjenje hitrosti
Figure 5-3: Spot (left) and linear (right) speed measurement

Srednjo časovno hitrost izmerimo na preseku ceste v določenem časovnem intervalu. Točkovni merilniki hitrosti kot npr. induktivne zanke, laserski detektorji oz. radarski detektorji izmerijo hitrost posameznega vozila. Povprečne hitrosti izračunane s to metodo ne opisujejo razvoja hitrosti posameznega vozila na odseku ceste.

$$\bar{v}_t = \frac{1}{n} \sum_{i=1}^n v_i \quad (5-1)$$

pri čemer je:

\bar{v}_t = srednja časovna hitrost,

v_i = hitrost i -tega vozila,

n = število vozil na danem preseku ceste.

Srednjo prostorsko hitrost izmerimo z upoštevanjem celotnega opazovanega odseka. Metoda sledi prostorskemu razvoju hitrosti posameznega vozila na podlagi česar se izračuna njegova povprečna hitrost. Srednja prostorska hitrost je bolj uporabna od srednje časovne hitrosti in jo uporabljamo za prostorsko aproksimacijo točkovne meritve pri ocenjevanju potovalnih časov.

$$\bar{v}_s = \frac{1}{\frac{1}{n} \sum_{i=1}^n \frac{1}{v_i}} \quad (5-2)$$

pri čemer je:

\bar{v}_s = srednja prostorska hitrost,

v_i = hitrost i -tega vozila,

n = število vozil na danem odseku ceste.

Srednja prostorska hitrost, pridobljena iz točkovnega merilnika, kot je razvidno iz zgornje enačbe, predstavlja harmonično sredino hitrosti vozil na preseku izvajanja meritve v časovnem intervalu, medtem ko srednja časovna hitrost predstavlja aritmetično sredino meritev individualnih hitrosti vozila.

Srednja časovna hitrost predstavlja povprečno vrednost točkovno izmerjenih hitrosti vozil na preseku ceste v danem časovnem obdobju, srednja prostorska hitrost pa predstavlja povprečno vrednost izmerjenih hitrosti vseh vozil na določenem odseku v časovnem trenutku. Srednja časovna hitrost predstavlja časovno povprečje, srednja prostorska hitrost pa predstavlja prostorsko povprečje hitrosti. Srednja časovna in srednja prostorska hitrost nista enaki, razen v primeru, ko vsa vozila vozijo z enako hitrostjo. Če si kot točkovni opazovalec predstavljamo zaprt krožni odsek ceste, kjer dve vrsti vozil, polovica je počasnih, polovica pa hitrih, krožita brez vmesnih interakcij, opazimo, da je delež hitrejših vozil večji kot delež počasnih vozil. V kolikor kroženje vozil opazujemo iz tlorisne perspektive vidimo, da je delež hitrih in počasnih vozil razporejen na pol. To je razumljivo, saj hitrejša vozila mimo točkovnega opazovalca

pridejo večkrat. To pomeni, da je srednja točkovna hitrost vedno večja ali enaka od srednje prostorske hitrosti.

Izračun t.i. srednje prostorske hitrosti iz točkovnega merilnika, ki jo izračunamo na majhnem območju dx , ki predstavlja območje detektiranja točkovnega detektorja - v primeru uporabe induktivnih zank je to območje zanke, v primeru uporabe mikrovalovnega detektorja pa območje dosega radarja, v času dolžine T , iz časovno-prostorskega diagrama $t-x$, dejansko nima prostorske ponazoritve, kot je določeno v osnovni definiciji srednje prostorske hitrosti. V osnovni definiciji srednje prostorske hitrosti namreč srednja prostorska hitrost predstavlja prostorsko povprečje hitrosti, ki pa jo je s točkovnim merilnikom nemogoče izmeriti.

V kolikor v sistemu ne beležimo individualnih hitrosti vozil, temveč le izračunavamo (ponavadi) srednjo časovno hitrost, nam koristi zveza med srednjo časovno in srednjo prostorsko hitrostjo, ki jo je definiral Wardrop (1952).

$$\bar{v}_t = \bar{v}_s + \frac{\sigma_s^2}{\bar{v}_s} \quad (5-3)$$

pri čemer je:

σ_s^2 = varianca srednje prostorske hitrosti.

Rakha in Zhang (2005) sta dokazala, da je prvotna zveza za izračun srednje časovne hitrosti iz srednje prostorske hitrosti (Wardrop, 1952) obrnljiva, s čimer je določena zveza med srednjo časovno in srednjo prostorsko hitrostjo ob pogoju, da poznamo varianco srednje časovne hitrosti.


$$\bar{v}_s = \bar{v}_t - \frac{\sigma_t^2}{\bar{v}_t} \quad (5-4)$$

pri čemer je:

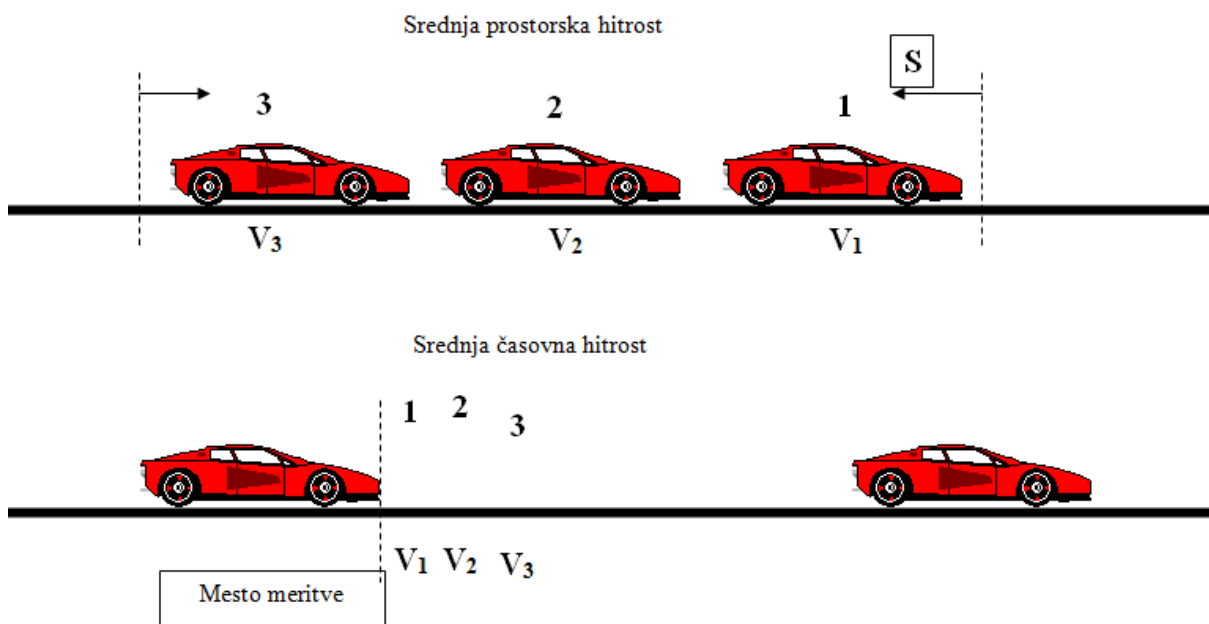
σ_t^2 = varianca srednje časovne hitrosti.

V sistemih za nadzor in vodenje prometa so podatki o hitrostih pogosto na voljo na minutni agregirani ravni. V teh primerih varianca hitrosti ni znana, če jo posebej ne izračunavamo, zato v literaturi najdemo različne predloge linearne odvisnosti med srednjo časovno in srednjo prostorsko hitrostjo, ki so podane v obliki analitičnih enačb. Te enačbe so zasnovane na podlagi dejanskih podatkov, njihova uporaba pa je zato omejena le na specifične odseke.

V prostorsko-časovnem diagramu je trenutna hitrost vozila ($v = \frac{dx}{dt}$) enaka naklonu funkcijske zveze med prevoženo potjo in časom. Povprečna hitrost vozila je enaka naklonu črte, ki povezuje končni točki, kjer vozilo vstopi in izstopi iz opazovanega časovno-prostorskega segmenta na grafu. Vertikalna razdalja med vzporednimi funkcijskimi zvezami predstavlja prostorski razmik med zaporednimi vozili. Podobno, horizontalna razdalja med vzporednimi funkcijskimi zvezami predstavlja časovni razmik med zaporednimi vozili (ang. headway).



Slika 5-4: Časovno-prostorski diagram
Figure 5-4: Time-space diagram



Slika 5-5: Primerjava srednje časovne in srednje prostorske hitrosti (Sever, 2002)
Figure 5-5: Comparison of time-mean speed and space-mean speed (Sever, 2002)

5.2.2 Porazdelitev hitrosti


5.2.2.1 Porazdelitev hitrosti vseh vozil

Točkovni merilniki hitrosti merijo hitrost prevoza preko detekcijskega polja. Vzorec izmerjenih hitrosti, ki je na voljo, zajame celoten delež prometnega toka, torej vse razrede vozil v prometnem toku. S tem dobimo srednjo prostorsko hitrost vseh vozil. Iz znanih razlogov tovorna vozila kljub razmeram prostega prometnega toka vozijo precej počasneje kot osebna.

Če pogledamo gostoto verjetnosti hitrosti vseh vozil na izbranem merilnem mestu pri čemer sta upoštevana tako vozni kot prehitvalni pas, vidimo dva ekstrema, pri čemer prvi pripada tovornim vozilom, drugi pa osebnim (Slika 5-6). Tako porazdelitev imenujemo bimodalna

porazdelitev. Bimodalna porazdelitev je v statistiki verjetnostna porazdelitev, ki ima dve ločeni zgostitvi podatkov. Bimodalna porazdelitev je lahko simetrična ali nesimetrična.

Iz izmerjenih hitrosti vseh vozil je iz bimodalne porazdelitve pogosto nemogoče enolično določiti, ali nizka hitrost pripada počasi vozečemu osebnemu vozilu, ki je zaradi izrednega dogodka zmanjšal hitrost, ali nizka izmerjena hitrost pripada počasi, za njegov razred sicer hitro, vozečemu tovornemu vozilu.



Slika 5-6: Porazdelitev hitrosti vseh vozil na merilnem mestu ter primer hitrosti, za katero ne moremo enolično določiti, kateremu razredu vozil pripada

Figure 5-6: Speed distribution of all vehicles and an example of the speed measurement for which it could not be said to which vehicle's class it belongs

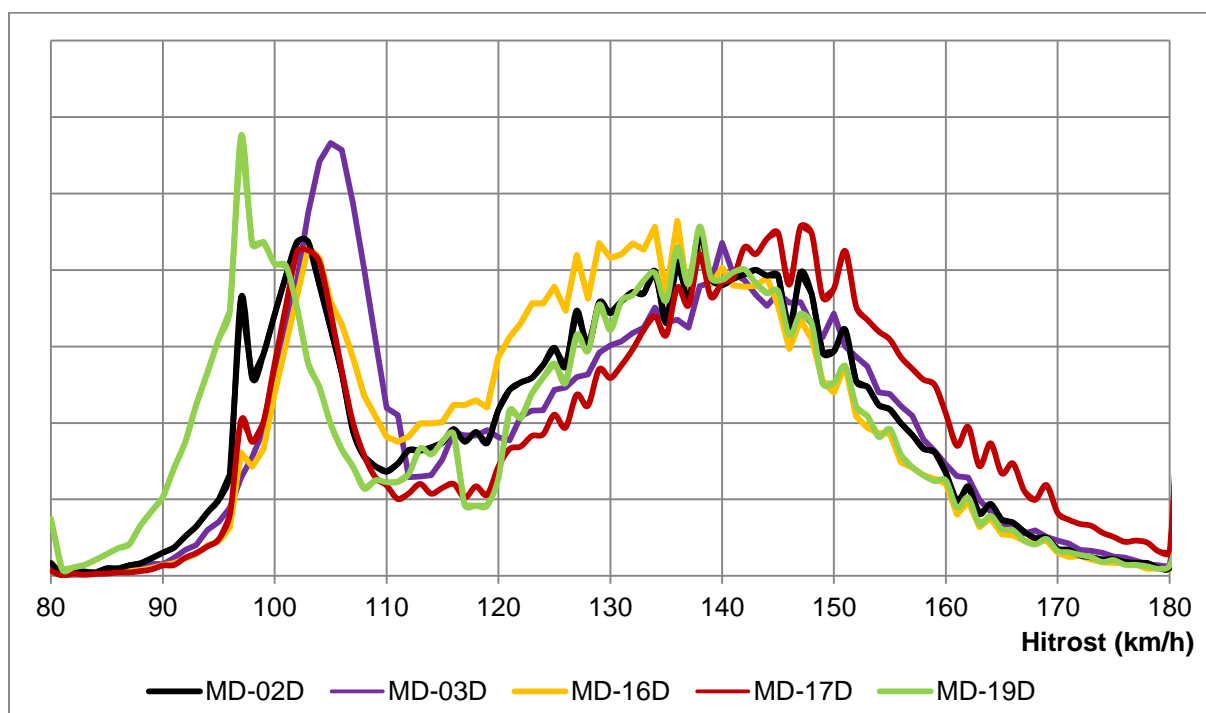
V večini znane literature je privzeta predpostavka o normalni porazdelitvi hitrosti vseh vozil v časovnem obdobju zajema podatkov na merilnem mestu. Nekateri izmed avtorjev (Soriguera in Robusté, 2011), v svojih delih sicer omenjajo druge porazdelitve, vendar jih razlagajo kot kombinacijo različnih faktorjev med drugim tipa voznikov, vrste vozil in namenske uporabnosti posameznega pasu, ki jih zanemarijo in pravijo, da vsak od teh faktorjev sicer vpliva, vendar le kot parameter njemu pripadajoče normalne porazdelitve. Soriguera in Robusté (2011) trdita, da je uporaba normalne porazdelitve smiselna v primeru enega voznega pasu, kjer so prisotna vozila le enega razreda kot npr. osebna vozila oz. tovorna vozila v časovnem intervalu, znotraj katerega so prometne razmere konstantne. To naj bi po besedah avtorjev prišlo v poštev v treh primerih:

- v primeru nizkih gostot lahko na prehitevalnem pasu porazdelitev vzamemo kot normalno, na voznem pasu pa je, zaradi kombiniranega deleža osebnih in tovornih vozil, porazdelitev očitno drugačna od normalne.
- v primeru srednjih gostot lahko na vseh pasovih porazdelitev vzamemo kot normalno, vendar le na pasovih, ne pa na avtocestnem odseku kot celoti, saj ima vsak pas svojo srednjo hitrost.
- v primeru zgoščenega prometa lahko na vsakem posameznem pasu porazdelitev vzamemo kot normalno, prav tako na celotnem avtocestnem odseku.

Tu moramo omeniti tudi, da je porazdelitev hitrosti po pasovih odvisna tudi od lokacije priključnih uvoznih oz. izvoznih ramp, saj na hitrosti na skrajnem desnem pasu vplivajo vozila, ki pospešujejo oz. zavirajo. Na teh pasovih prihaja do velikega odklona od srednje vrednosti

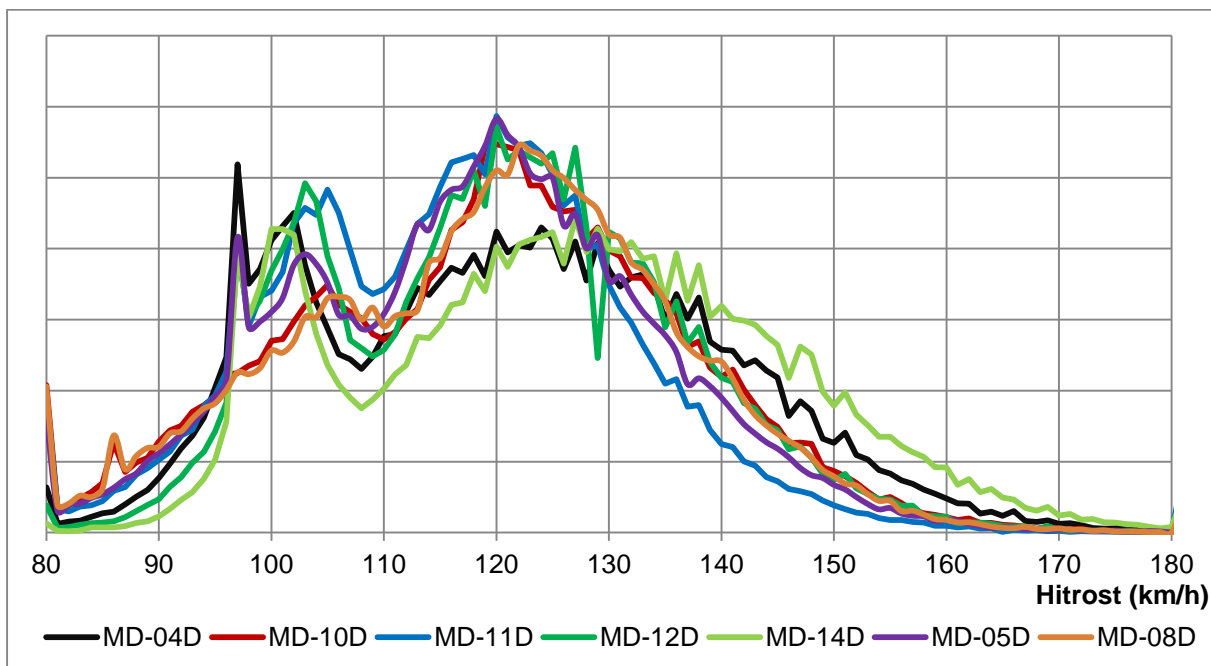
hitrosti, ki je odvisen tako od fizičnih lastnosti vozila kot tudi od tipa voznikov. Pri vseh teh dodatnih pogojih se je smiselno vprašati, kdaj in če sploh, je celoten prometni tok tako homogen, da je uporaba normalne porazdelitve hitrosti vseh vozil upravičena.

Analiza porazdelitve hitrosti vseh vozil po posameznih merilnih mestih na avtocestni trasi med Vranskim in Blagovico je bila narejena na podatkih med 26. junijem in 3. julijem 2013. Zaradi spremenljive omejitve hitrosti, ki velja na odseku, izvajanja meritve, so v nadaljevanju prikazane porazdelitve hitrosti ločeno za lokacije s predpisano omejitvev hitrosti 130 km/h in 100 km/h. Kot je razvidno iz spodnjih slik (Slika 5-7, Slika 5-8), je porazdelitev hitrosti na merilnem mestu, sestavljenem iz več pasov, izrazito bimodalna.



Slika 5-7: Porazdelitve hitrosti vseh vozil na točkovnih merilnih mestih med Vranskim in Blagovico v smeri Ljubljane, kjer je omejitev hitrosti 130 km/h


Figure 5-7: Speed distribution for different locations with speed limit 130 km/h



Slika 5-8: Porazdelitve hitrosti vseh vozil na točkovnih merilnih mestih med Vranskim in Blagovico v smeri Ljubljane, kjer je omejitev hitrosti 100 km/h

Figure 5-8: Speed distribution for different locations with speed limit 100 km/h


Slika 5-9 prikazuje povprečne vrednosti hitrosti vseh vozil na zaporednih merilnih mestih v smeri proti Ljubljani ter primerjavo s predpisano omejitvijo hitrosti na posameznem merilnem mestu. Kot je razvidno iz slike, so povprečne hitrosti na vseh merilnih mestih nad predpisano omejitvijo hitrosti.



Slika 5-9: Povprečne vrednosti hitrosti vseh vozil na zaporednih merilnih mestih v primerjavi z omejitvijo hitrosti za obdobje med 20. in 30. junijem 2013

Figure 5-9: Average speeds on consecutive measurement sites


Razporeditev izmerjenih hitrosti vseh vozil po pasovih prikazuje večje število vozil na voznom pasu v času nizkih prometnih obremenitev, ter povečano število vozil na prehitevalnem času v času jutranje prometne konice. Slika 5-10 prikazuje, da velik delež vozil vozi nad predpisano omejitvijo hitrosti.



Slika 5-10: Izmerjene vrednosti hitrosti vseh vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 03D (omejitev hitrosti 130 km/h) za jutranje obdobje

Figure 5-10: Measured speeds on both lanes for the morning peak period on the driving and overtaking lane of the VMS 03D (speed limit 130 km/h) for the morning period

Porazdelitev hitrosti vseh vozil po pasovih pokaže različna tipa porazdelitve za vozni in prehitevalni pas (Slika 5-11). Medtem, ko je na prehitevalnem pasu zaradi homogene strukture prometnega toka hitrost vseh vozil približno normalno porazdeljena, tega za vozni pas ne moremo trditi. Na voznem pasu poleg osebnih vozil večji delež v porazdelitveni funkciji prispevajo tovorna vozila s podskupinami. Porazdelitev na voznem pasu je bimodalna.



Slika 5-11: Porazdelitev hitrosti vseh vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 03D (omejitev hitrosti 130 km/h)

Figure 5-11: Speed distribution on both lanes by VMS 03D for speed limit 130 km/h

Glede na predhodno opisana dejstva velja ugotovitev, da na podlagi povprečne hitrosti vseh vozil v prometnem toku, ki se porazdeljuje bimodalno, težko enolično interpretiramo razmere na posameznem pododseku. Zaradi različnih parametrov porazdelitev, ki pripadajo posameznim kategorijam vozil, občasno ne moremo oceniti ali je vzrok nizki povprečni hitrosti velik delež tovornih vozil, ki sicer vozijo z njim normalnimi hitrostmi ali počasna vožnja osebnih vozil zaradi izrednega dogodka.









5.2.2.2 Porazdelitev hitrosti po razredih


V prejšnjem poglavju je bilo ugotovljeno, da razmere na posameznem pododseku niso enolično opredeljene s skupno povprečno hitrostjo vseh vozil v prometnem toku. Ker so za določitev reprezentativne vrednosti hitrosti na posameznem pododseku merodajna osebna vozila, moramo iz točkovnih merilnikov parametrov prometnega toka za vsak prevoz preko detekcijskega polja združiti podatke o izmerjeni hitrosti in razredu vozila v kolikor merilna oprema to omogoča, kar nam iz nabora vseh izmerjenih hitrosti omogoča izluščiti hitrosti osebnih vozil.

Na podlagi pridobljenega vzorca hitrosti osebnih vozil lahko bolj zanesljivo določimo razmere na pododseku. Osebna vozila v času razmer prostega prometnega toka, ko ni interakcije med vozili, na pododseku vozijo brez posebnih omejitev, v primeru zgoščenega prometnega toka pa te hitrosti postanejo veliko bolj homogene.

Točkovni merilniki - mikrovalovni detektorji na slovenskih avtocestah, ki so nameščeni v sklopu sistemov za nadzor in vodenje prometa, omogočajo pridobivanje podatkov o hitrosti in razredu posameznega vozila. Radarska komponenta vsakemu vozilu izmeri pripadajočo hitrost, ultrazvočna komponenta pa z oddajanjem kratkih snopov ultrazvoka posname profil vozila. Vsako vozilo, ki prevozi območje detektiranja lahko na podlagi profila vozila glede na nemški standard TLS (Technische Lieferbedingungen für Streckenstationen) klasificiramo v ustrezni razred. Mikrovalovni detektorji omogočajo razpoznavanje 2 oz. 5 razredov vozil, odvisno od modela.


Preglednica 5-1: Klasifikacija vozil po razredih glede na nemški standard TLS
Table 5-1: Vehicles' classification based on german standard TLS

Model detektorja		TT 292	TT 295
Razred		2 razreda	5 razredov
	osebni avtomobil	Osebni avto	Osebni avto
	motorno kolo		
	dostavno vozilo		
	tovorno vozilo	Tovorno vozilo	Lahko tovorno vozilo
	tovorno vozilo s prikolico		Težko tovorno vozilo
	tovorno vozilo s priklopnikom		
	avtobus		Avtobus
	osebno vozilo s prikolico		Osebno vozilo s prikolico



Slika 5-12: Porazdelitev hitrosti za različne kategorije vozil na merilnem mestu SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013

Figure 5-12: Speed distribution for different vehicle classes (speed limit 130 km/h) between July 10 - 12, 2013




Slika 5-13: Porazdelitev hitrosti za osebna in tovorna vozila na merilnem mestu SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013

Figure 5-13: Speed distribution for personal cars and heavy vehicles (speed limit 130 km/h) between July 10 - 12, 2013

Slika 5-13 prikazuje porazdelitev hitrosti osebnih vozil na merilnem mestu, ki se porazdeljujejo približno normalno.

5.2.2.3 Porazdelitev hitrosti osebnih vozil po pasovih

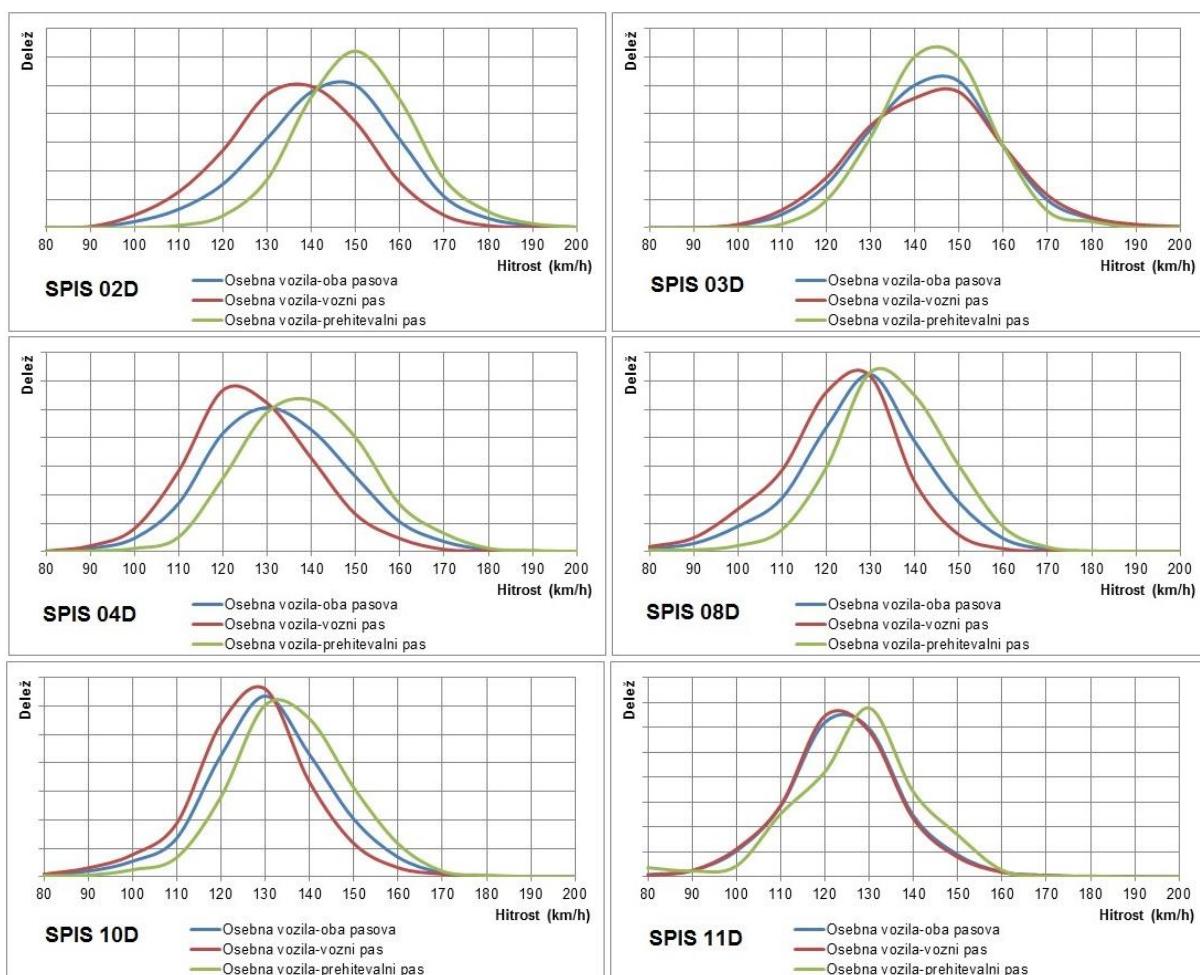
V prejšnjem poglavju smo ugotovili, da se hitrost osebnih vozil porazdeljuje približno normalno.

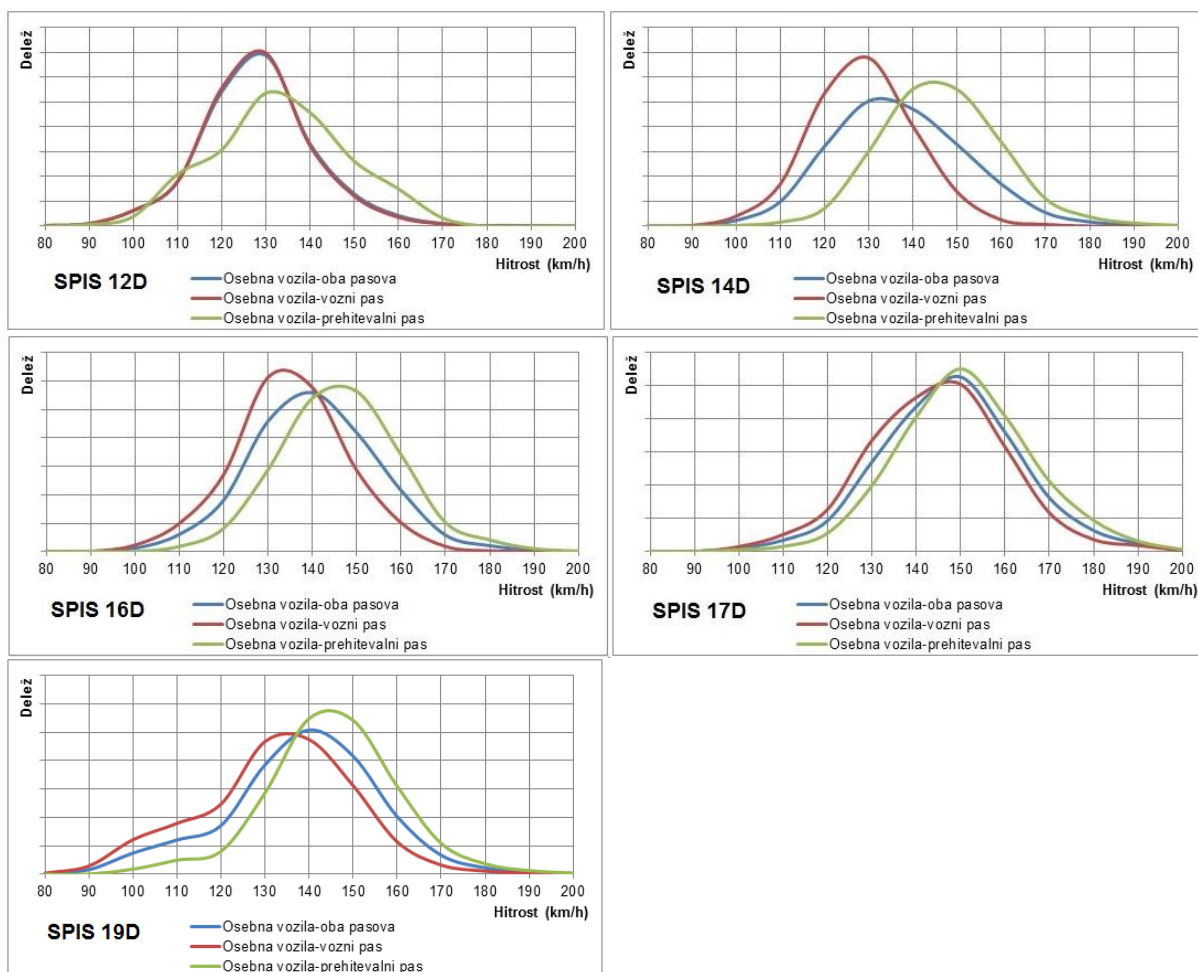


Slika 5-14: Porazdelitev hitrosti osebnih vozil na voznem in prehitevalnem pasu merilnega mesta SPIS 02D, kjer velja omejitev hitrosti 130 km/h, v času med 10. in 12. julijem 2013

Figure 5-14: Personal cars speed distribution for both lanes (speed limit 130 km/h) between July 10 - 12, 2013

V nadaljevanju (Slika 5-15) so prikazane porazdelitve hitrosti osebnih vozil po posameznih pasovih za različna merilna mesta na trasi med Vranskim in Blagovico. Iz porazdelitev hitrosti so dobro razvidne lastnosti prometnega toka na posameznem merilnem mestu. Na primer merilno mesto SPIS 14D, ki je locirano takoj za zadnjim predorom (Podmilj) v smeri proti Ljubljani, na blagem klancu navzdol, pokaže izrazito različno porazdelitev hitrosti na voznem in prehitevalnem pasu. To sovпада z dejansko opaženimi razmerami, ko nekatera osebna vozila takoj po zadnjem predoru na odseku, hitro pospešijo, čeprav na pododseku še vedno velja omejitev hitrosti 100 km/h. Po drugi strani lokaciji merilnih mest pred predoroma Trojane (SPIS 11D) in Podmilj (SPIS 12D) pokažeta veliko bolj homogene razmere na voznem in prehitevalnem pasu, kar je posledica zmanjšanja hitrosti vozil pred vstopom v predor.





Slika 5-15: Porazdelitev hitrosti osebnih vozil na voznem in prehitevalnem pasu posameznih merilnih mest za obdobje med 22. in 23. julijem 2013

Figure 5-15: Personal cars speed distribution for different locations between July 22 - 23, 2013

V nadaljevanju so za izračun srednje prostorske hitrosti uporabljene hitrosti osebnih vozil, saj se le-ta v prostem prometnem toku gibljejo skorajda brez fizičnih omejitev in so zato merodajna za določitev reprezentativne vrednosti hitrosti na pododseku. V nasprotju z osebnimi vozili na težka tovorna vozila vpliva vrsta dejavnikov kot npr. naklon trase, nižje predpisane hitrostne omejitve in fizične omejitve pri vožnji, zaradi česar so izmerjene hitrosti tovornih vozil bistveno nižje, kljub temu, da na odseku prevladujejo razmere prostega prometnega toka.

5.2.3 Časovni interval zajema podatkov za izračun srednje prostorske hitrosti osebnih vozil

Časovni interval zajema hitrosti osebnih vozil ima velik vpliv na natančnost metode. Čim daljši je čas zajema, tem večje število meritev je za določen prometni pretok na voljo in tem večja je natančnost ocene srednje prostorske hitrosti. Po drugi strani mora biti čas zajema kar se da kratek, da ne zgladimo preveč nihanj hitrosti, ki so posledica spremembe prometnega stanja. V realnih okoliščinah moramo poiskati optimalni čas zajema z zadostnim številom meritev in mejo, ki še zagotavlja pravočasno reagiranje.

Časovni interval zajema hitrosti osebnih vozil je v sistemu nastavljen parameter, za njegovo začetno vrednost pa smo izbrali 1 minuto.

5.2.4 Izračun srednje prostorske hitrosti osebnih vozil

Srednja prostorska hitrost se izračuna kot harmonična sredina izmerjenih hitrosti. Srednja prostorska hitrost v primerjavi s srednjo časovno hitrostjo zmanjša vpliv višjih hitrosti ter poveča vpliv nižjih hitrosti. Vrednost srednje prostorske hitrosti osebnih vozil, pridobljeno na merilnem mestu, izračunamo z enačbo:

$$\bar{v}_s = \frac{1}{\frac{1}{n} \sum_{i=1}^n \frac{1}{v_i}} \quad (5-5)$$

V kolikor na posameznem merilnem mestu ne zaznamo nobenega vozila za srednjo prostorsko hitrost privzamemo hitrost prometnega toka po predpisani omejitvi hitrosti na tej lokaciji. V kolikor bi za srednjo prostorsko hitrost vzeli vrednost 0 km/h, bi to pri prostorski ekstrapolaciji hitrosti pomenilo podaljšane potovalne čase na tem pododseku, kar pa v realnih okoliščinah ni res. To sovpada z ugotovitvijo, da v kolikor na merilnem mestu ni nobenega prevoza vozila, povprečna hitrost ni enaka nič, temveč je brez vrednosti.

Merilna oprema na avtocestah se lahko pokvari. Induktivne zanke, nameščene v voziščno konstrukcijo zaradi fizičnih vplivov pogosto ne delujejo dalj časa, tudi nekaj mesecev. Mikrovalovni detektorji, nameščeni v sklopu sistemov za nadzor in vodenje prometa, poleg prometnih podatkov v nadzorni računalnik pošiljajo tudi status delovanja in morebitne okvare. Usposobljena vzdrževalna služba takoj ob ugotovitvi napake pokvarjen mikrovalovni detektor zamenja, zato so ti izpadi kratkotrajne narave. Prav tako izpad v večini primerov pomeni, da eden od dveh merilnikov na merilnem mestu (preseku) ceste ne deluje, kar pomeni da drug merilnik na isti lokaciji kljub temu meri hitrost vozil. Srednja prostorska hitrost se tako izračuna na podlagi le enega, pravilno delujočega, merilnika.

V kolikor sta v izpadu oba merilnika na merilnem mestu, algoritem za to merilno mesto privzame hitrost prometnega toka po predpisani omejitvi hitrosti na tej lokaciji, kar v primeru nastanka izrednega dogodka ni pravilno. Izpad merilne opreme zato predstavlja nepravilnost v delovanju algoritma in ga moramo zato kar se le da hitro odpraviti.

5.2.5 Določitev standardnega odklona harmonične sredine

V literaturi se pri oceni potovalnega časa iz točkovne ekstrapolacije hitrosti pogosto uporabi srednja časovna hitrost, kljub temu, da je za to potrebna srednja prostorska hitrost. Nekatere študije namreč nimajo možnosti dostopa do izmerjenih hitrosti posameznih vozil oz. do standardnega odklona srednje časovne hitrosti, iz katerih bi lahko namesto srednje časovne hitrosti izračunali srednjo prostorsko hitrost. Študije, ki temeljijo na srednji časovni hitrosti, za merjenje razpršenosti okoli povprečne vrednosti (aritmetične sredine) srednje časovne hitrosti temu primerno uporabijo standardni odklon aritmetične sredine.

Pri izračunu statistične razpršenosti okoli srednje prostorske hitrosti, uporaba klasičnih enačb za izračun standardnega odklona aritmetične sredine ne drži. Za izračun razpršenosti okoli harmonične sredine moramo uporabiti standardni odklon harmonične sredine. V statistiki sta za izračun standardnega odklona harmonične sredine največkrat uporabljeni dve metodi: metoda Delta ter metoda Jackknife. Metoda Jackknife temelji na vzorčenju populacije, medtem ko metoda Delta izračuna standardni odklon harmonične sredine na podlagi centralnega limitnega izreka. Zaradi lažje implementacije računskega modela je bila izbrana metoda Delta.

Izračun standardnega odklona harmonične sredine se po metodi Delta izvede na podlagi naslednjih enačb:

$$m = \frac{1}{n} \sum_{i=1}^n \frac{1}{v_i} \quad (5-6)$$

$$H = \frac{1}{m} \quad (5-7)$$

$$s_r^2 = \text{var} \left(\frac{1}{v} \right) \quad (5-8)$$

pri čemer je:

m = aritmetična sredina recipročnih vrednosti,

H = harmonična sredina,

s_r^2 = varianca recipročnih vrednosti hitrosti,

n = število izmerjenih hitrosti,

v_i = posamezna meritev hitrosti.

V kolikor želimo oceniti natančnost pridobljene srednje prostorske hitrosti, lahko to določimo iz standardnega odklona harmonične sredine. Standardni odklon harmonične sredine je povezan z varianco recipročnih vrednosti hitrosti preko naslednje enačbe:


$$\sigma_H = \frac{s_r}{\sqrt{n} \cdot m^2} \quad (5-9)$$

5.3 Izračun reprezentativne vrednosti srednje prostorske hitrosti

5.3.1 Nihanja srednje prostorske hitrosti

Zaradi narave obnašanja prometnega toka je za obveščanje voznikov o potovalnih časih, pridobljenih iz točkovne ekstrapolacije hitrosti, zaželen čim krajši časovni interval zajema podatkov Δt , kar v realnih okoliščinah pogosto pomeni majhno število izmerjenih hitrosti. Te meritve hitrosti imajo ponavadi sorazmerno veliko odstopanje od srednje prostorske hitrosti, kar bi pomenilo, da bi dejanska vrednost potovalnega časa, o kateri obveščamo voznika, zaradi naključne narave obnašanja voznikov, močno nihala. Odstopanje od srednje hitrosti bi se v primeru večjega števila meritev zmanjšalo, bi pa za to potrebovali daljši časovni interval zajema

in posledično kasnejše reagiranje. Nihanja potovalnega časa v zaporednih časovnih intervalih pa posledično zmanjšajo kredibilnost sistema za obveščanje o potovalnih časih.



Slika 5-16: Nihanje srednje prostorske hitrosti v zaporednih časovnih intervalih ob pojavu izrednega dogodka

Figure 5-16: Space-mean speed fluctuations over time in case of an incident

Nihanja srednje prostorske hitrosti v zaporednih časovnih intervalih napeljujejo na idejo o glajenju. Uporaba neprimerne metode glajenja, lahko prinese zamudo pri zaznavanju nenadnih sprememb hitrosti, ki niso posledica hitrostnih nihanj temveč udarnega vala. Teh hitrostnih nihanj v želji po hitri zaznavi začetka ali konca zastoja ne želimo zgladiti.

5.3.2 Glajenje z drsečim povprečjem

Drseče povprečje je filter za analizo podatkov s kreiranjem povprečne vrednosti za različne podmnožice podatkov znotraj celotnega niza podatkov. Drseče povprečje predstavlja niz podatkov, pri katerem vsak od njih predstavlja povprečje pripadajoče podmnožice podatkov.

Drseče povprečje pogosto uporabljamo v časovnih vrstah z namenom glajenja kratkoročnih nihanj, pri čemer poudarimo dolgoročnejshe trende oz. cikle in ga izračunamo z naslednjo enačbo:

$$\bar{v}_{s_drseče_popvprečje} = \frac{\bar{v}_s + \bar{v}_{s-1} + \dots + \bar{v}_{s-(n-1)}}{n} \quad (5-10)$$

pri čemer je:


$\bar{v}_{s_drseče_popvprečje}$ = drseče povprečje srednje prostorske hitrosti,

\bar{v}_s = vrednost srednje prostorske hitrosti v trenutnem časovnem intervalu,

$\bar{v}_{s-(n-1)}$ = vrednost srednje prostorske hitrosti v predhodnih časovnih intervalih,

n = število časovnih intervalov, za katere računamo drseče povprečje (začetna vrednost $n = 5$; 5-minutno glajenje) in ki vsebujejo vsaj eno vozilo.

V kolikor v nekem časovnem intervalu ni vozil, je to časovno obdobje izvzeto iz izračuna. Drseče povprečje izračunamo na podlagi ostalih srednjih prostorskih hitrosti v intervalih, ki vsebujejo vsaj eno vozilo. V primeru zaporednih časovnih obdobj brez izmerjenih hitrosti se namreč zgodi, da glajena vrednost srednje prostorske hitrosti počasi začne padati proti 0, kar dejansko ne odraža razmer na cesti. V kolikor na pododseku ni vozil, srednja prostorska hitrost namreč ni enaka 0 km/h, temveč je brez vrednosti.



Slika 5-17: Glajenje srednje prostorske hitrosti
Figure 5-17: Space-mean speed smoothing

5.3.3 Izračun reprezentativne vrednosti srednje prostorske hitrosti z glajenjem in upoštevanjem nihanj

Soriguera in Robusté (2011, 2013) sta predlagala proces glajenja, ki zgladi nihanja hitrosti, pri čemer ohranja hiter odziv na znatne spremembe hitrosti, ki niso posledica nihanj temveč udarnega vala. Metoda določi, ali je sprememba hitrosti posledica naključnega nihanja zaradi obnašanja voznikov in jo moramo zgladiti, ali pa gre za spremembo prometnega stanja in jo ni smiselno gladiti, s čimer zagotovimo hiter odziv algoritma.

Ali gre v dveh zaporednih časovnih intervalih za majhno spremembo hitrosti ali za veliko nihanje, določimo s preizkusom domneve o razliki med pričakovanima vrednostma srednje prostorske hitrosti v dveh zaporednih časovnih intervalih.

Predpostavimo, da se harmonični hitrosti H_i in H_j porazdeljujeta normalno $N(m_{H_i}, \sigma_{H_i})$ in $N(m_{H_j}, \sigma_{H_j})$ s pričakovanima vrednostima m_{H_i} in m_{H_j} ter standardnima odklonoma σ_{H_i} in σ_{H_j} . Izvedemo preizkus domneve o razliki med vrednostma srednje prostorske hitrosti. Najprej postavimo ničelno ter alternativno domnevo ter izberemo stopnjo tveganja:

H_0 : Vrednosti srednjih prostorskih hitrosti v zaporednih časovnih intervalih sta enaki
 H_1 : Vrednosti srednjih prostorskih hitrosti v zaporednih časovnih intervalih nista enaki
 $\alpha = 0,05$

Tvorimo statistiko T

$$T = \frac{H_i - H_j}{\sqrt{\sigma_{H_i}^2 + \sigma_{H_j}^2}} \quad (5-11)$$

pri čemer je:

H = harmonična sredina,

σ_H = standardni odklon harmonične sredine,

i, j = zaporedni časovni intervali.

Statistika T se porazdeljuje približno po porazdelitvi t z $n_i + n_j - 2$ prostostnimi stopnjami. Kritično območje zavrnitve se nahaja v intervalu $(-\infty, -t_{1-\alpha/2}) \cup (t_{1-\alpha/2}, \infty)$. V kolikor statistika T zavzame vrednost manjšo od $-t_{1-\alpha/2}$ oz. večjo $t_{1-\alpha/2}$ ničelno domnevo zavrnemo in s stopnjo značilnosti α trdimo, da vrednosti srednjih prostorskih hitrosti dveh zaporednih časovnih intervalov nista enaki. Preizkus ničelne in alternativne domneve izvedemo v vsakem zaporednem koraku.

Reprezentativno vrednost srednje prostorske hitrosti tako določimo v odvisnosti od nihanja hitrosti med zaporednimi časovnimi intervali. V kolikor veliki spremembi hitrosti sledi ponovna velika sprememba hitrosti istega predznaka ničelno domnevo zavrnemo v dveh zaporednih časovnih intervalih, reprezentativno vrednost srednje prostorske hitrosti predstavlja kar srednja prostorska hitrost v trenutnem časovnem intervalu (preskok). Dve zaporedni veliki spremembi istega predznaka najverjetneje pomenita, da je sprememba hitrosti posledica spremembe prometnega stanja, zato algoritem ne izvaja glajenja. Algoritem prav tako ne izvede glajenja, v kolikor veliki spremembi hitrosti sledi majhna sprememba istega predznaka.

V kolikor pa nihanje med zaporednimi časovnimi intervali ni veliko in ničelne hipoteze ne moremo zavrniti, reprezentativno vrednost srednje prostorske hitrosti predstavlja glajena vrednost srednjih prostorskih hitrosti, pridobljena z drsečim povprečjem. Majhna nihanja med zaporednimi časovnimi intervali najverjetneje predstavljajo nihanja zaradi obnašanja voznikov in jih zato algoritem gladi. Algoritem tako izvaja glajenje, v kolikor gre za zaporedje majhnih nihanj hitrosti, zaporednih velikih nihanj različnega predznaka ali znatni spremembi hitrosti, ki sledi majhni spremembi. Za določitev ali gre v zadnjem primeru za nihanje ali spremembo prometnega stanja moramo počakati do naslednjega časovnega intervala.


Z glajenjem srednjih prostorskih hitrosti za zaporedne časovne intervale (glajenje) oz. z upoštevanjem dejanske prostorske hitrosti v trenutnem časovnem intervalu (preskok), algoritmu za posredno oceno potovalnih časov iz točkovne ekstrapolacije hitrosti dodamo komponento upoštevanja dinamike prometnega toka. Algoritem določi ali je sprememba hitrosti posledica naključnega nihanja zaradi obnašanja voznikov in jo moramo zgladiti ali gre za spremembo prometnega stanja in jo ne gladimo, s čimer zagotovimo hiter odziv algoritma. Z glajenjem hitrosti v zaporednih časovnih intervalih zmanjšamo naključna nihanja v

izmerjenih hitrostih, ki so posledica individualnega obnašanja voznikov osebnih vozil s čimer povečamo kredibilnost sistema. Z upoštevanjem preskoka zagotovimo hiter odziv algoritma na nenadna večja nihanja hitrosti, ki so najverjetneje posledica izrednega dogodka.

V predlaganem algoritmu je uporabljena metoda drsečega povprečja za zadnjih 5 minut (nastavljiv parameter) oz. od zadnje velike spremembe hitrosti. V samem izračunu je dana prednost glajenju pred hitrim odzivom, kar pomeni, da se algoritem odzove na spremembo po dveh časovnih intervalih, glede na trenutno nastavljen časovni interval zajema 1 minuta, to pomeni z dve minutno zakasnitvijo. Dva časovna intervala sta namreč potrebna, da določimo, ali gre za dve veliki zaporedni nihanji istega predznaka.

Ugotovljeno je bilo, da algoritem v primeru nenadne spremembe srednje prostorske hitrosti hitro reagira na spremembo, saj v tem primeru ne vzame glajene vrednosti temveč dejansko vrednost srednje prostorske hitrosti. V primeru zaporednih majhnih nihanj hitrosti istega predznaka pa odziv algoritma ni tako hiter in sicer najkasneje v petih časovnih intervalih zajema, saj v tem primeru ni izpolnjen pogoj za prenehanje glajenja. V primeru majhnih zaporednih nihanj se algoritem odzove z nekaj minutno zamudo.

Slika 5-18 prikazuje odziv algoritma na nenadno zmanjšanje hitrosti zaradi kratkotrajne zapore predora. Ker je srednja prostorska hitrost v dveh zaporednih časovnih intervalih skokovito padla, je algoritem prenehal z glajenjem in za reprezentativno vrednost hitrosti upošteval trenutno izmerjeno srednjo prostorsko hitrost. V nadaljevanju je nato hitrosti v dveh zaporednih časovnih intervalih skokovito narastla, kar je algoritem ponovno upošteval s preskokom.



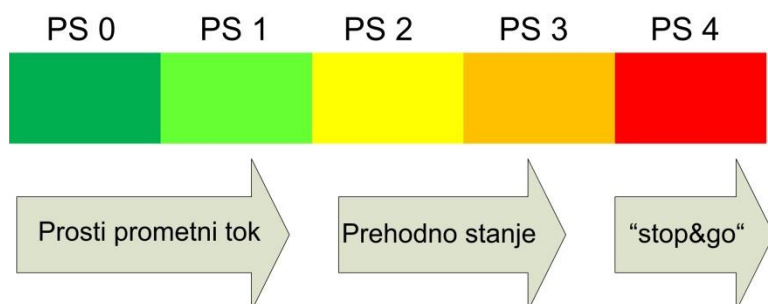
Slika 5-18: Primerjava srednje prostorske, glajene in reprezentativne hitrosti ob pojavu izrednega dogodka (kratkotrajna zapore predora Jasovnik 13. novembra 2013)

Figure 5-18: Comparison between space-mean speed, smoothed speed and representative value of speed for an incident situation (short term tunnel closure on November 13, 2013)

5.3.4 Določitev reprezentativne vrednosti srednje prostorske hitrosti v času nasičenega in zgoščenega prometnega toka

Določitev reprezentativne vrednosti hitrosti v razmerah nasičenega in zgoščenega prometnega toka je pogosto zelo zahtevna naloga, predvsem v razmerah t.i. prometnega toka »stop&go«, ko so točkovni merilniki zmožni zajeti le primere, ko se vozila premikajo, ne pa tudi tistih, ko vozila mirujejo. V takih primerih s točkovno ekstrapolacijo hitrosti dobimo potovalni čas, ki je podcenjen.

Pri določitvi reprezentativne vrednosti hitrosti lahko poleg pogoja glajenja oz. upoštevanja nihanj, upoštevamo tudi dinamiko prometnega toka v obliki stopnje prometnega stanja. Stopnje prometnega stanja (Pirc, 2008) so v tesni povezavi z nivoji uslug, ki predstavljajo kvalitativno merilo, ki opisuje vozne pogoje znotraj prometnega toka v smislu različnih merjenj, kot so hitrost, potovalni čas, svoboda manevriranja, motnje toka in udobnost. Podrobnejši opis določitve stopnje prometnega stanja je opisan v poglavju združevanja točkovnih in linijskih meritev.



Slika 5-19: Povezava med stopnjami prometnega stanja sistema za nadzor in vodenje prometa ter stopnjami pretoka

Figure 5-19: Relationship between traffic state and flow state

Glede na to, da v razmerah nasičenega in zgoščenega prometnega toka pogosto pride do t.i. prometnega toka »stop&go«, kjer točkovni merilniki lahko kar za 100 % precenijo srednjo prostorsko hitrost (vozila se približno pol časa gibljejo, pol časa stojijo), reprezentativno vrednost srednje prostorske hitrosti določimo na podlagi naslednjih enačb:

$$\bar{v}_{s(j,q)} = \begin{cases} \bar{v}_{s(j,q)} & , \text{če } PS = PS 0, PS 1 \text{ ali } PS 2, \\ 0,5 \cdot \bar{v}_{s(j,q)} & , \text{če } PS = PS 3 \text{ ali } PS 4, \end{cases} \quad (5-12)$$

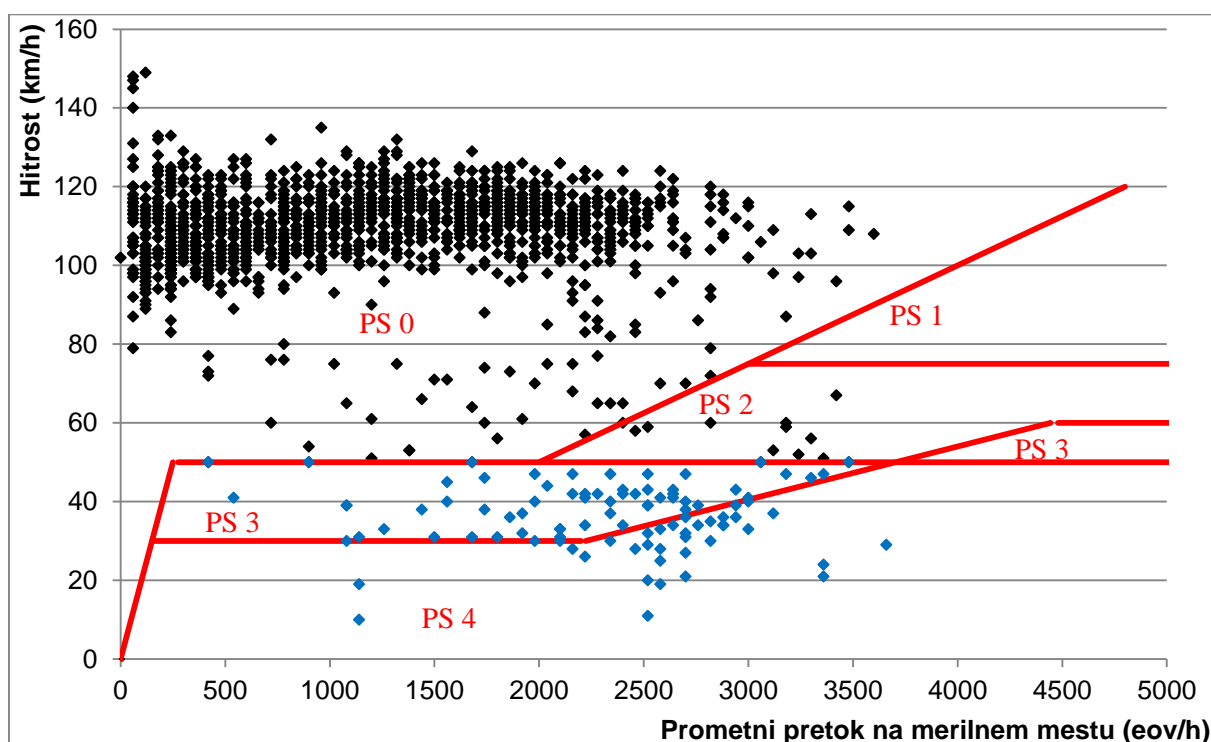
pri čemer je:

$\bar{v}_{s(j,q)}$ = reprezentativna vrednost srednje prostorske hitrosti osebnih vozil na merilnem mestu pododseka j v časovnem intervalu q .

Z uporabo predhodnih enačb zagotovimo, da v primeru razmer prometnega toka »stop&go« ne upoštevamo le tistih primerov, ko se vozila gibljejo, temveč tudi primere, ko vozila mirujejo. Faktor, s katerim množimo (0,5) je samo približek, ki predstavlja redukcijo pri določitvi reprezentativne vrednosti hitrosti na pododseku. Z uporabo te redukcije želimo zagotoviti, da pri določitvi potovalnih časov iz točkovno ekstrapolirane hitrosti ne bi prihajalo do podcenjenih vrednosti potovalnega časa. Vrednost redukcije ima različen vpliv pri različnih dolžinah

pododseka. Medtem, ko je na kratkih pododsekih redukcija smiselna, se je v primeru daljših pododsekov pokazalo, da so zaradi uporabe faktorja potovalni časi v nekaterih primerih tudi precenjeni. Do precenjenih potovalnih časov pride predvsem v primeru daljših pododsekov, kjer vplivi izrednega dogodka niso opazni na celotni dolžini pododseka – v primerih, ko so na delu pododseka prisotne razmere prometnega toka »stop&go«, medtem ko na delu pododseka gortočno ali doltočno lahko še/že prevladujejo normalne razmere. Na daljših pododsekih se tako prevelika izmerjena hitrost (izmerimo le situacije, ko se vozila premikajo) na območju točkovnega merilnika v času t.i. prometnega toka »stop&go« uravnovesi z delom pododseka, kjer so prisotne normalne razmere in zato redukcija hitrosti ni potrebna.

Slika 5-20 prikazuje z modro barvo pare pretok-hitrost, ki predstavljajo razmere nasičenega oz. zgoščenega prometnega toka, ki potencialno lahko vodi k prometnemu toku »stop&go«.



Slika 5-20: Razmere nasičenega (PS 3) oz. zgoščenega prometnega toka (PS 4)
Figure 5-20: Level of service E (PS 3) and F (PS 4)

5.4 Metode za oceno potovalnega časa na pododseku iz točkovnih meritev hitrosti

Glavni problem pri natančni oceni potovalnega časa na pododseku iz ekstrapolacije točkovnih meritev hitrosti (tako potovalni čas po prihodu vozil za kalibracijo modela in naknadne študije, kot tudi trenutni potovalni čas za informiranje voznikov), predstavlja določitev natančne ocene trenutnega potovalnega časa v danem časovnem intervalu, saj je le-ta osnovni gradnik vseh ostalih definicij potovalnega časa. Zato se pri analizah vedno uporablja nivo pododseka, od koder se vrednosti razširijo na celoten odsek.

Kot že omenjeno v predhodnih poglavjih, predstavlja glavno neznanko pri določevanju potovalnega časa z ekstrapolacijo točkovnih meritev hitrosti neznanje o razvoju hitrosti v

prostoru $v(x)$ med zaporednimi točkovnimi merilnimi mesti. To pomeni, da je lahko metoda za oceno potovalnega časa na pododseku iz točkovnih meritev hitrosti skrajno nenatančna v primeru prehoda med prometnimi stanji znotraj pododseka. Velikost teh napak oz. nenatančnost je neposredno povezana z dolžino pododseka in obratno sorazmerna z gostoto namestitve točkovnih merilnikov.

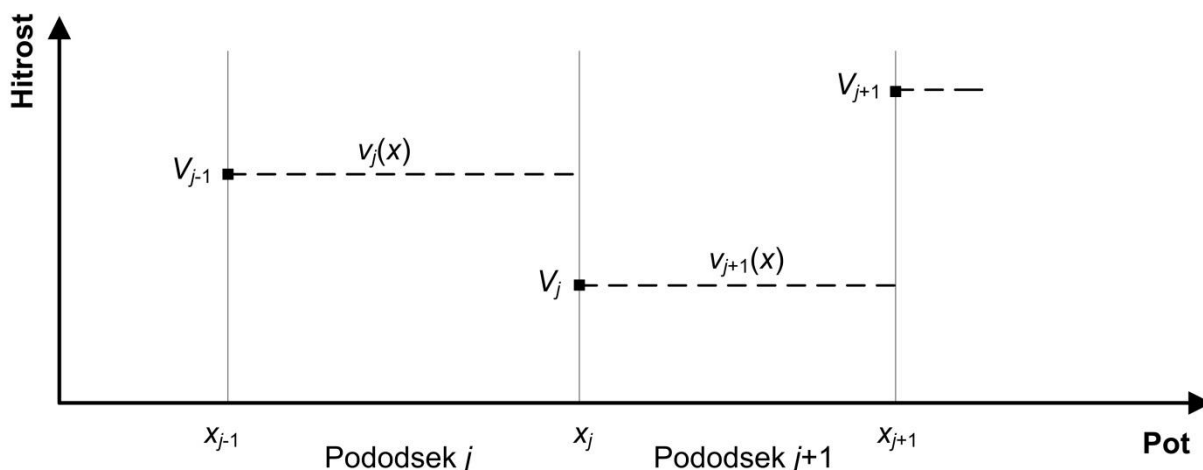
Kako natančna je metoda točkovne ekstrapolacije hitrosti na celoten, merilniku pripadajoč pododsek je odvisno od različnih faktorjev. Eden od teh je lokacija postavitve točkovnega merilnika in uspešnost ter sposobnost te lokacije, da določi reprezentativno vrednost potovalnega časa za celoten pripadajoč pododsek.

V nadaljevanju so prikazane različne metode interpolacije hitrosti med točkovnimi merilniki na avtocestnem odseku (Soriguera in Robusté, 2011).

5.4.1 Metode interpolacije in ekstrapolacije hitrosti iz točkovnih merilnikov

5.4.1.1 Konstantna ekstrapolacija hitrosti iz točkovnih merilnikov

Do najbolj enostavnega pristopa k prostorski posplošitvi hitrosti med zaporednimi točkovnimi merilniki vodi predpostavka konstantne hitrosti. Zaradi enostavnosti je metoda konstantne ekstrapolacije hitrosti iz točkovnih merilnikov v svetu široko uporabljena (van Lint in van der Zijpp, 2003). Obstaja več možnosti, katera meritev hitrosti je upoštevana na celotnem pododseku: celotnemu pododseku j lahko pripišemo hitrost $v_j(x)$, izmerjeno na začetni točki pododseka V_{j-1} , kot prikazuje Slika 5-21. Temu pravimo gortočna konstantna ekstrapolacija iz merilnikov.




Slika 5-21: Gortočna konstantna ekstrapolacija iz točkovnih merilnikov

Figure 5-21: Upstream constant extrapolation from point detectors

V realnih okoliščinah težko najdemo razlago, zakaj bi na celotnem pododseku veljala hitrost, izmerjena na gortočni meji pododseka. Podobno lahko predpostavimo, da na celotnem pododseku velja hitrost izmerjena na doltočni meji pododseka. Konzervativna metoda predlaga, da celotnemu pododseku j pripišemo nižjo od hitrostnih vrednosti, izmerjenih na gortočni in doltočni meji pododseka x_j oz. x_{j-1} , kot je to praksa v prometno-informacijskem sistemu San

Antonia v Texasu. Poleg tega lahko uporabimo tudi optimističen pristop, s čimer celotnemu odseku pripišemo višjo od vrednosti hitrosti, izmerjenih na gortočni oz. doltočni meji pododseka. Po predlogu Cortésa (2002) lahko uporabimo tudi uteženo povprečje hitrosti.

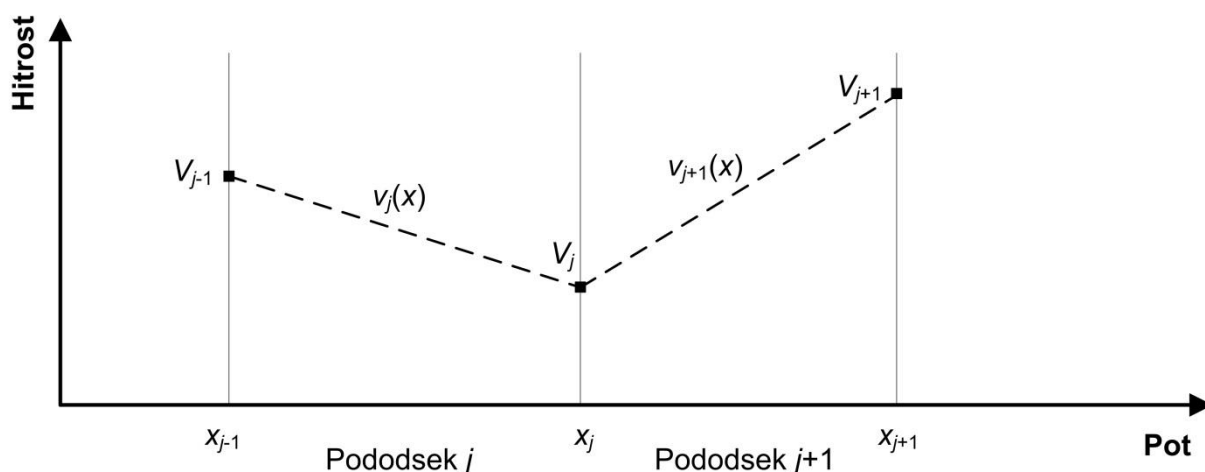


Slika 5-22: Konstantna interpolacija med točkovnimi merilniki z uporabo uteženega povprečja

Figure 5-22: Constant interpolation between point detectors using weighted average

5.4.1.2 Linearna interpolacija hitrosti med točkovnimi merilniki

Konstantna interpolacija med točkovnimi merilniki je v realnih okoliščinah vprašljiva, saj do sprememb hitrosti lahko pride hitro, čeprav je dejansko ta prehod zvezen. Da dobimo zglajen prehod med točkovnimi meritvami hitrosti, lahko uporabimo linearno interpolacijo med točkovnimi merilniki, čeprav tudi ta ne opisuje dejanskega obnašanja voznikov na pododseku, saj se spremembe hitrosti dogajajo na predolgem prostorskem območju.




Slika 5-23: Linearna interpolacija med točkovnimi merilniki

Figure 5-23: Linear interpolation between detectors

5.4.1.3 Odsekoma konstantna ekstrapolacija hitrosti iz točkovnih merilnikov

Manjšo spremembo predpostavke o konstantnem poteku hitrosti med zaporednimi merilnimi mesti predstavlja predpostavka odsekoma konstantne vrednosti hitrosti med točkovnimi merilniki. Edina razlika v primerjavi s prejšnjo metodo je, da v drugem primeru pride do spremembe hitrosti znotraj pododseka in ne na mestu točkovnih merilnikov. S tem se skupna vrednost napake ne zmanjša nujno, razen v primeru, ko so lokacije sprememb hitrosti izbrane glede na dinamiko prometnega toka znotraj pododseka. Odsekoma konstantna ekstrapolacija hitrosti med točkovnimi merilniki se izvede tako, da vsakemu točkovnemu merilniku pripišemo del trase, na katerem velja ekstrapolirana hitrost iz tega merilnika.




Slika 5-24: Odsekoma konstantna ekstrapolacija iz točkovnih merilnikov - algoritem srednje vrednosti

Figure 5-24: Piecewise constant extrapolation from detectors - midpoint algorithm

5.4.1.4 Kvadratna interpolacija hitrosti med točkovnimi merilniki

Sun in sodelavci (2008) v svoji študiji navajajo, da relacijo med voznikovim obnašanjem v času pospeševanja in zaviranja najbolje opišemo z uporabo kvadratne interpolacije. Tako naj bi dosegli spremenljive stopnje pospeškov oz. pojemkov, ki so vidne pri intenzivnejšem zaviranju, ko se vozilo približuje območju nastanka zastoja oz. intenzivnejšem pospeševanju, ko vozilo zapusti območje zastoja in se želi približati hitrosti prostega prometnega toka. Metoda konceptualno izboljšuje predvidevanja linearne interpolacije, predvsem v smislu, da v primeru linearne interpolacije voznikovo obnašanje prekomerno upošteva dolgotrajne razmere, še preden dejansko do njih pride, zaradi česar hitrost nerazumno dolgo narašča/pada. V primeru uporabe kvadratne interpolacije hitrosti so te odzivi intenzivnejši in prostorsko ne tako obsežni. Opozoriti pa moramo, da ostri prehodi hitrosti v realnih okoliščinah ne posnemajo dinamike prometnega toka pri nastanku zastoja, temveč so le posledica uporabe matematične funkcije. Metoda kvadratne interpolacije uporabi podatke iz treh zaporednih točkovnih merilnih mest, kar je pri postavitvah merilnih mest na večji medsebojni razdalji lahko zelo nerealno.



Slika 5-25: Kvadratna interpolacija med točkovnimi merilniki
Figure 5-25: Quadratic interpolation between detectors

5.4.2 Primerjava in uporabnost predstavljenih metod interpolacije in ekstrapolacije hitrosti

Predstavljene metode interpolacije in ekstrapolacije hitrosti med točkovnimi merilniki so bile razvite z namenom rešitve glavnega problema pri oceni potovalnega časa na pododseku iz točkovno izmerjenih hitrosti, ki ga predstavlja pomanjkanje podatkov o prehodu med prometnimi stanji znotraj pododseka. Ko voznik naleti na udarni val, se v kratkem časovnem in prostorskem intervalu prilagodi novim razmeram. Ta prilagoditev je odvisna od fizičnih zmožnosti vozila po pospeševanju in pojemanju, od lastnosti voznika in njegovega obnašanja (agresiven voznik, miren voznik) ter od dojemanja resnosti nastale situacije. Iz tega je razvidno, da sprememba hitrosti in prilagoditev novim razmeram v prometnem toku ne trajata dolgo časa niti se ne zgodita na dolgem prostorskem odseku, kakor pripisuje linearna interpolacija. Nobena od preprostih metod interpolacije oz. ekstrapolacije hitrosti, ki ne upošteva konfiguracije trase ter lastnosti vozila, voznika in prometnega toka zato ne doprinese k izboljšani oceni hitrosti na pododseku.

Kot sta v svoji študiji ugotovila Soriguera in Robusté (2011), nobena od omenjenih metod ne upošteva ključnega dejavnika: mesta spremembe hitrosti znotraj pododseka. Predlagane matematične metode ne upoštevajo dinamike prometnega toka in zato pride do napak, saj spremembo hitrosti locirajo glede na lastnosti matematičnih funkcij in ne glede na dejansko spremembo hitrosti znotraj pododseka. Vse izboljšave v oceni potovalnega časa, pridobljene s podrobnejšo interpolacijo ali ekstrapolacijo, so zanemarljive v primerjavi s koristmi, ki jih prinese natančno lociranje prehoda med hitrostmi znotraj pododseka. Matematične metode se kot najbolj uporabne pokažejo v primeru obnašanja prometa ob koncu zastoja, saj pospeševanje ni sunkovito, tako kot je zaviranje pri nastanku zastoja. V realnih okoliščinah se nenadnim spremembam hitrosti ob srečanju z udarnim valom še najbolj približa metoda odsekoma konstantne ekstrapolacije. Pri tem moramo zagotoviti, da srečanje z udarnim valom na pododseku sovпада s spremembo hitrosti v modelu, kar pa je pri razmiku med točkovnimi merilniki pogosto zelo težka naloga.

Iz zgoraj navedenega sledi, da uporaba še tako kompleksne metode ocene potovalnega časa na podlagi interpolacije oz. ekstrapolacije hitrosti med točkovnimi merilniki, ki ne upošteva

dinamike prometnega toka, ne prispeva bistveno k izboljšanju ocene. Vse metode v času zgoščenega prometnega toka močno podcenijo potovalni čas, medtem ko je njihova uporabnost v primeru delno zgoščenega prometnega toka odvisna od posameznega primera.

5.4.3 Predlagana metoda ekstrapolacije točkovnih meritev hitrosti na pripadajoč pododsek


V predhodnih poglavjih so predstavljene različne metode interpolacije hitrosti med zaporednimi merilnimi mesti na avtocestnem odseku, pri čemer metode ob poznavanju izmerjenih hitrosti na sosednjih merilnih mestih določijo reprezentativno vrednost hitrosti za posamezen pododsek.

Na avtocestnih pododsekih se dinamika prometnega toka spreminja glede na konfiguracijo in geometrijske lastnosti trase ter glede na predpisane hitrostne omejitve, ki na posameznih pododsekih veljajo. Naša želja je bila določiti metodo ekstrapolacije točkovnih meritev hitrosti na pripadajoč pododsek ob upoštevanju lastnosti prometnega toka znotraj obravnavanih pododsekov.

Predlagali smo modificirano metodo odsekoma konstantne ekstrapolacije, kjer glede na konfiguracijo in geometrijske lastnosti trase ter glede na predpisane hitrostne omejitve, vsakemu merilnemu mestu pripišemo pripadajoče vplivno območje. Lokacije sprememb hitrosti in pripadajoča vplivna območja so izbrana glede na lastnosti prometnega toka znotraj pododseka v času razmer prostega prometnega toka.

Metoda je uporabna tudi na odsekih, znotraj katerih pride do spremembe hitrostne omejitve. Tak primer je trasa avtoceste med Vranskim in Blagovico, kjer zaradi geometrije trase, velikega števila predorov in drugih objektov omejitev hitrosti preide iz 130 km/h na 100 km/h na pododseku med dvema zaporednima merilnima mestoma ter kasneje prehod iz 100 km/h nazaj na 130 km/h znotraj doltočno ležečega pododseka.

Metodo modificirane odsekoma konstantne ekstrapolacije hitrosti iz točkovnih merilnikov uporabimo tako, da vsakemu točkovnemu merilniku pripišemo del trase, na katerem velja ekstrapolirana hitrost iz tega merilnika. Spremembe hitrosti znotraj odseka so določene empirično na podlagi konfiguracije in geometrijskih lastnosti trase, predpisanih omejitev hitrosti, ter na podlagi drugih dejavnikov, ki vplivajo na porazdelitev hitrosti na vplivnem območju.




Slika 5-26: Metoda modificirane odsekoma konstantne ekstrapolacije
 Figure 5-26: Modified piecewise constant extrapolation

5.5 Določitev vplivnega območja posameznega merilnega mesta

Vplivno območje posameznega merilnega mesta je odvisno od konfiguracije in geometrijskih lastnosti trase kot npr. geometrija ceste, število pasov, naklon in preglednost, od predpisanih omejitev hitrosti ter od drugih dejavnikov, ki vplivajo na porazdelitev hitrosti na vplivnem območju.

Določitev vplivnega območja posameznega detektorja izvedemo empirično, po predhodni analizi obravnavanega dotičnega odseka. Lokacije so tako določene glede na dejanske razmere na pododseku, kjer so opažene spremembe v hitrostih kot npr. prehod iz odprte trase v predor, redukcija števila pasov, spremembe geometrijskih karakteristik trase oz. postavitve radarja za kaznovanje prehitrih voznikov. Vplivno območje posameznega merilnega mesta določimo tako, da so razmere na pripadajočem vplivnem območju kar se da podobne tistim, ki veljajo na merilnem mestu. Predvsem v primeru večje medsebojne razdalje med merilnimi mesti, je to pogosto zelo težka naloga.



Slika 5-27: Merilnik, merilno mesto in vplivno območje merilnega mesta
 Figure 5-27: Detector, measurement site and detectors influence area

5.6 Ocena potovalnega časa na pododseku iz točkovne ekstrapolacije hitrosti

Po izbiri primerne metode ekstrapolacije točkovnih meritev in določitvi posameznemu merilniku pripadajočega pododseka, lahko za vsak posamezen pododsek ocenimo potovalni čas z naslednjo enačbo:

$$TT_{(j,q)} = \frac{\Delta x_j}{\bar{v}_{s(j,q)}} \quad (5-13)$$

pri čemer je:

$TT_{(j,q)}$ = potovalni čas na pododseku j v časovnem intervalu q ,

Δx_j = dolžina vplivnega območja (pododseka) merilnega mesta j ,

$\bar{v}_{s(j,q)}$ = reprezentativna vrednost srednje prostorske hitrosti osebnih vozil na merilnem mestu pododseka j v časovnem intervalu q .

Pri uporabi algoritma za oceno potovalnega časa iz točkovne ekstrapolacije hitrosti velja predpostavka, da znotraj časovnega intervala in na celotnem pododseku meritve prometni tok ostane konstanten. Za izpolnitev tega pogoja je potrebna dovolj gosta postavitev točkovnih merilnikov, čemur ni nujno vedno zadoščeno ter kratek čas posodabljanja informacije (1 minuta).

V realnih okoliščinah se pogosto dogaja, da je izračunana vrednost srednje prostorske hitrosti višja od vrednosti hitrostne omejitve na tem odseku. Do precejšnjih razlik prihaja predvsem na območju znižane hitrostne omejitve (npr. 100 km/h), ki jo vozniki pogosto ne upoštevajo oz. le malenkost zmanjšajo hitrost. V takem primeru bi na pododseku prišlo do potovalnega časa, ki je krajši od potovalnega časa ob upoštevanju hitrostne omejitve – takrat obravnavanemu pododseku pripišemo vrednost potovalnega časa ob upoštevanju hitrostne omejitve, ki ga izračunamo kot kvocient dolžine pododseka in hitrostne omejitve.

$$TT_{(j,q)} < TT_{(j,q) \text{ omejitve hitrosti}} \rightarrow TT_{(j,q)} = TT_{(j,q) \text{ omejitve hitrosti}} \quad (5-14)$$

pri čemer je:

$TT_{(j,q) \text{ omejitve hitrosti}}$ = potovalni čas na pododseku j ob upoštevanju predpisane hitrostne omejitve za odsek j .

5.7 Ocena trenutnega potovalnega časa na odseku iz točkovne ekstrapolacije hitrosti

Reprezentativno vrednost potovalnega časa iz točkovne ekstrapolacije hitrosti na odseku, sestavljenem iz pododsekov, dobimo tako, da seštejemo trenutne potovalne čase na posameznih pododsekih v časovnem trenutku izračuna.

$$TT_{AB} = \sum_{j=1}^n TT_{(j,q)} \quad (5-15)$$

pri čemer je:

TT_{AB} = reprezentativna vrednost potovalnega časa iz točkovne ekstrapolacije hitrosti na odseku med začetno (A) in končno točko (B) odseka za trenutni časovni interval q .

Ta trenutni povprečni potovalni čas se šteje kot najboljši približek zelenega potovalnega časa ob odhodu vozila za prihodnji časovni interval, v kolikor se želimo izogniti negotovostim napovedi prihodnjega potovalnega časa ob predpostavki, da lastnosti prometnega toka ostanejo enake. Razlike med resničnim in napovedanim potovalnim časom so v veliki meri odvisne od dolžine odseka in časa agregacije, ki določata obzorje napovedi. Z namenom zmanjšanja razlik med trenutnim in napovedanim potovalnim časom ter z namenom izboljšanja napovedi je zaželeno, da je dolžina odseka, za katerega izvajamo obveščanje, kar se da kratka, pri čemer natančno informacijo o potovalnem času dobimo s pogostim osveževanjem/posodabljanjem ter kratkim časovnim obzorjem napovedi.

Prednost meritev, pridobljenih iz točkovnih merilnikov, je torej možnost določitve dejanskega potovalnega časa na osnovi navidezne meritve za posamezno vozilo, še preden le-ta konča svoje potovanje.

5.8 Primerjava potovalnega časa, ocenjenega s točkovno ekstrapolacije hitrosti z neposredno linijsko izmerjenim potovalnim časom

Natančnost ocene potovalnega časa iz točkovne ekstrapolacije hitrosti najlažje preverimo v primerjavi z eno od metod, ki potovalne čase na izbranem odseku neposredno izmeri, bodisi s sledenjem vozila na njegovi poti (Kothuri in sodelavci, 2007), bodisi z reidentifikacijo vozila na dveh zaporednih točkah (Coifman and Cassidy, 2002b; Coifman and Ergueta, 2003; Coifman and Krishnamurthya, 2007). Obe metodi po končanem potovanju vozila zagotavljata referenčno informacijo, ki pove, kako natančno smo ocenili funkcijsko zvezo med opravljeno potjo in časom na podlagi točkovne ekstrapolacije hitrosti. Ker imamo na obravnavanem odseku nameščen tudi sistem za neposredno linijsko merjenje potovalnega časa z reidentifikacijo vozil s sistemom za reidentifikacijo registrskih tablic in sistem za reidentifikacijo naslovov »bluetooth«, smo reprezentativno vrednost potovalnega časa na odseku, pridobljenega s prostorsko ekstrapolacijo hitrosti, primerjali z reprezentativno vrednostjo potovalnega časa po prihodu vozil, pridobljenega z neposredno linijsko meritvijo. Primerjavo smo izvedli na podlagi zgodovinskih podatkov.

V kolikor želimo med seboj primerjati reprezentativno vrednost potovalnega časa na odseku, pridobljeno iz točkovnih merilnikov, ter reprezentativno vrednost potovalnega časa po prihodu vozil na odseku pridobljeno s sistemom neposrednega linijskega merjenja potovalnih časov, moramo najprej izvesti časovno in prostorsko poravnavo obeh meritev.

Prostorska poravnava obeh meritev je dosežena s prekrivanjem območja, ki ga pokriva posamezna od tehnologij. Zaželeno je, da vplivno območje prvega in zadnjega merilnega mesta točkovne ekstrapolacije hitrosti sovпада z začetno in končno točko reidentifikacije vozil za pridobitev neposredne linijske meritve potovalnega časa.

Precej zahtevnejšo nalogo predstavlja časovna poravnava, saj moramo za verodostojno primerjavo obeh meritev upoštevati dejanski časovni interval, ko je navidezno vozilo prevozilo posamezno mesto točkovne ekstrapolacije hitrosti. To izvedemo z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom.

5.8.1 Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom

Proces rekonstrukcije funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom je proces, v katerem iz znanih srednjih prostorskih hitrosti vozil v diskretni prostorsko-časovni ravnini, z rekonstrukcijo gibanja navideznega vozila dobimo povprečni potovalni čas na pododseku oz. odseku. Če je za vsak pododsek na voljo srednja prostorska hitrost kot funkcija prevožene poti x (lega navideznega vozila znotraj pododseka) in če za to funkcijo $v(x)$ predpostavimo konstantno vrednost znotraj časovnega intervala Δt , potem lahko rekonstruiramo funkcijsko zvezo med opravljeno potjo navideznega vozila in njegovim potovalnim časom, ki predstavlja povprečni potovalni čas po prihodu ali ob odhodu vozila za določen pododsek ali odsek. V realnih okoliščinah zaradi točkovnih meritev hitrosti predpostavimo konstantno vrednost hitrosti v odvisnosti od prevožene poti, kar sicer predstavlja posplošitev razmer na pododseku (Ni in Wang, 2008), saj samo z uporabo metode točkovnih meritev natančnejšega spreminjanja hitrosti znotraj odseka ne moremo zaznati.

Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom vozil se uporablja v primeru zgodovinskih analiz ter v fazi kalibracije sistema, kjer med seboj primerjamo neposredno izmerjeni linijski potovalni čas ter potovalni čas, ocenjen s točkovno ekstrapolacijo hitrosti.

V nadaljevanju je prikazan postopek (Soriguera in Robusté, 2011), ki je potreben, da trenutni povprečni potovalni čas, pridobljen iz točkovne ekstrapolacije hitrosti, pretvorimo v povprečni potovalni čas, opisan s funkcijsko zvezo med opravljeno potjo vozil in njihovim potovalnim časom. Ta proces je analogen za povprečne potovalne čase po prihodu vozil pri čemer rekonstruiramo nazaj ali ob odhodu vozil, kjer rekonstruiramo naprej.

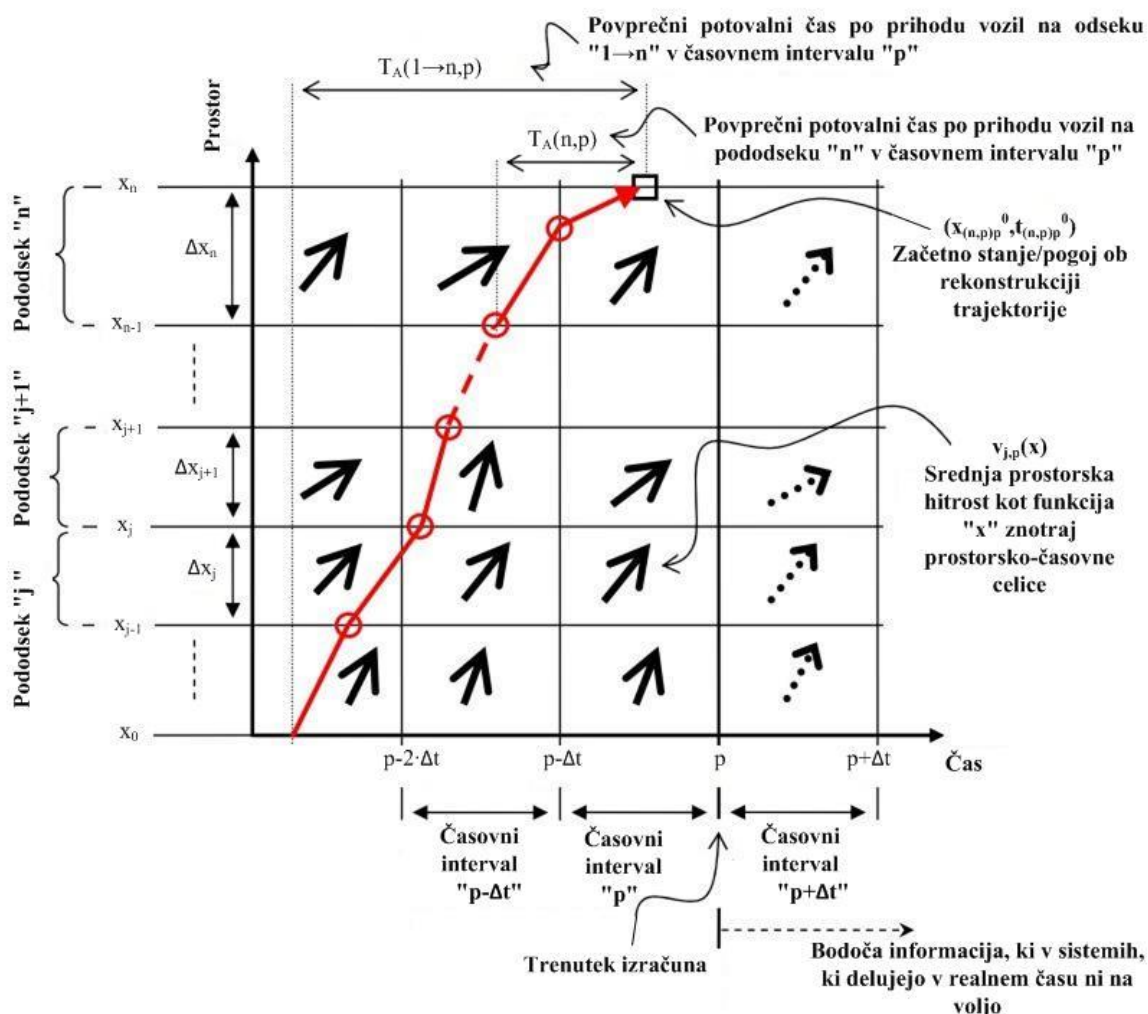
Kot sta opisala van Lint in van der Zijpp (2003), je za rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom (funkcija $x(t)$) znotraj celice hitrostnega polja, potrebno le rešiti naslednjo diferencialno enačbo:

$$\frac{\partial x}{\partial t} = v_{j,q}(x) \quad (5-16)$$

Za osnovo vzemimo $v_{j,q}(x)$, ki ni odvisna od časa znotraj posamezne celice in začetni pogoj $x(t_{j,q}^0) = x_{j,q}^0$, ki pri procesu rekonstrukcije po prihodu vozila predstavlja izhodno točko iz celice. Za rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom na območju celotnega odseka z namenom določitve povprečnega potovalnega časa po prihodu vozila v časovnem intervalu p , moramo ponoviti predhodno opisani postopek iteracije od zadnje celice, dokler ni dosežen začetek odseka. V vsakem koraku posodobimo $v_{j,q}(x)$, ki je funkcija celice in časovnega intervala, ter začetni pogoj. Začetni pogoj pri zaporednih celicah sovpada z izstopno točko funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom iz predhodno izračunane celice, zato je edini začetni pogoj, ki ga je potrebo določiti, le prvi začetni pogoj, ki sovpada s trenutkom izračuna povprečnega potovalnega časa na odseku. Najbolj ustrezno je, da prvi začetni pogoj, kadar izračunavamo povprečni potovalni čas po prihodu vozil na odseku n v časovnem intervalu p , postavimo na sredino časovnega intervala:

$$x\left(p - \frac{\Delta t}{2}\right) = x_n \quad (5-17)$$

Vsi ostali začetni pogoji so, glede na to, da je vsaka celica omejena s prostorsko in časovno mejo, določeni s trenutkom, ko navidezno vozilo prečka mejo pododseka ali glede na lego znotraj pododseka, ko vozilo prevozi časovno mejo.



Slika 5-28: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom (Soriguera in Robusté, 2011)

Figure 5-28: Trajectory reconstruction process (Soriguera and Robusté, 2011)

Medtem, ko v fazi kalibracije sistema in zgodovinskih analiz uporabljamo rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, pa za določevanje potovalnih časov v trenutnem času upoštevamo le trenutne srednje prostorske hitrosti osebnih vozil na posameznem pododseku.

Za izračun povprečnega trenutnega potovalnega časa na odseku j v časovnem intervalu p $T_{T(j,p)}$, ki ga bomo potrebovali v fazi združevanja točkovnih in linijskih meritev, moramo rešiti le zgoraj navedeno diferencialno enačbo brez upoštevanja časovnih meja posamezne celice. Na

vsakem pododseku je začetni pogoj $x(p) = x_j$. Ko je diferencialna enačba rešena in funkcijska zveza med opravljeno potjo vozil in njihovim potovalnim časom $x(t)$ znana, izračunamo povprečni trenutni potovalni čas na odseku n za časovni interval p z:

$$T_T(1 \rightarrow n, p) = \sum_{j=1}^n T_T(j, p) \quad (5-18)$$

5.9 Študija primera

5.9.1 Območje izvajanja meritve

Na avtocestnem odseku A1 med Vranskim in Blagovico so v sklopu sistema za nadzor in vodenje prometa nameščeni mikrovalovni detektorji, ki predstavljajo točkovne merilnike karakteristik prometnega toka kot npr. merjenje hitrosti, štetje in klasifikacija vozil v razrede. V smeri iz Celja proti Ljubljani je na odseku čez Trojane na 13 merilnih mestih nad vsakim voznim pasom nameščenih 26 mikrovalovnih detektorjev. Območje postavitve prvega in zadnjega točkovnega merilnika sovпада s postavitvijo začetne in končne točke neposrednega linijskega merjenja potovalnega časa.

Na odseku med Vranskim in Blagovico je zaradi zahtevnih geometrijskih elementov trase in velikega števila objektov, hitrost na delu trase od SPIS 04D do SPIS 16D omejena na 100 km/h.



Slika 5-29: Točkovna merilna mesta na avtocestnem odseku med Vranskim in Blagovico
Figure 5-29: Point measurements on the highway section between Vranksko and Blagovica

5.9.2 Vplivno območje posameznega merilnega mesta

Vsakemu merilnemu mestu smo glede na konfiguracijo in geometrijske lastnosti trase kot npr. geometrija ceste, število voznih pasov, naklon trase, preglednost in predpisana omejitev hitrosti empirično določili vplivno območje. Vplivno območje smo določili glede na dejanske razmere na pododseku, kjer so bile opažene spremembe v hitrostih kot npr. prehod iz odprte trase v predor, redukcija števila pasov, spremembe geometrijskih karakteristik trase oz. postavitev radarja za kaznovanje prehitrih voznikov.

Preglednica 5-2: Vplivno območje posameznega merilnega mesta

Table 5-2: Detectors influence area

Merilno mesto	Lokacija SPIS [m]	Odsek od [m]	Odsek do [m]	Dolžina [m]	Odsek trase od SPIS [m]		Delež trase [%]
					gortočno	doltočno	
SPIS-02D	0	0	697	697	0	697	3
SPIS-03D	1841	697	2627	1930	1144	786	9
SPIS-04D	3875	2627	4500	1873	1248	625	8
SPIS-05D	5464	4500	6000	1500	964	536	7
SPIS-07D	6637	6000	8100	2100	637	1463	10
SPIS-08D	9405	8100	9650	1550	1305	245	7
SPIS-10D	9915	9650	10637	987	265	722	4
SPIS-11D	10998	10637	12500	1863	361	1502	8
SPIS-12D	14761	12500	15516	3016	2261	755	14
SPIS-14D	16102	15516	17800	2284	586	1698	10
SPIS-16D	17851	17800	19320	1520	51	1469	7
SPIS-17D	20074	19320	21000	1680	754	926	8
SPIS-19D	22063	21000	22063	1063	1063	0	5

Za obdobje od 1. januarja 2013 do 1. julija 2013 smo za vsako merilno mesto izračunali srednjo prostorsko hitrost in ob primerjavi s pripadajočimi predpisanimi hitrostnimi omejitvami ugotovili, da je povprečna hitrost vozil skoraj na vseh lokacijah večja od predpisane hitrostne omejitve. Na podlagi povprečnih hitrosti smo izvedli ekstrapolacijo hitrosti na posameznemu merilnemu mestu pripadajoč pododsek in tako izračunali povprečen potovalni čas na podlagi prostorske ekstrapolacije hitrosti za obdobje pol leta.

Preglednica 5-3: Povprečni potovalni časi na obravnavanem odseku za obdobje pol leta, pridobljeni s točkovno ekstrapolacijo hitrosti


Table 5-3: Average travel time on the section for a period of six month, estimated by the extrapolation of point speed measurements

Merilno mesto	Dolžina pododseka [m]	Delež odseka [%]	Omejitev hitrosti [km/h]	Povprečna polletna hitrost [km/h]	Potovalni čas [s]		Odstopanje od omejitve [%]
					skladno z omejitvijo	povprečje meritev za pol leta	
SPIS-02D	697	3.2	130	134	19.3	18.8	2.8
SPIS-03D	1930	8.7	130	135	53.4	51.5	3.6
SPIS-04D	1873	8.5	100	126	67.4	53.4	20.9
SPIS-05D	1500	6.8	100	122	54.0	44.4	17.7
SPIS-07D	2100	9.5	100	123	75.6	61.6	18.5
SPIS-08D	1550	7.0	100	121	55.8	46.0	17.6
SPIS-10D	987	4.5	100	124	35.5	28.7	19.1
SPIS-11D	1863	8.4	100	119	67.1	56.5	15.8
SPIS-12D	3016	13.7	100	122	108.6	88.7	18.3
SPIS-14D	2284	10.4	100	128	82.2	64.4	21.6
SPIS-16D	1520	6.9	130	130	42.1	42.3	-0.4
SPIS-17D	1680	7.6	130	138	46.5	43.7	6.0
SPIS-19D	1063	4.8	130	130	29.4	29.4	0.0
skupaj	22063				737.0	629.0	14.7

5.9.3 Primerjava potovalnega časa, pridobljenega s točkovno ekstrapolacijo hitrosti, z neposredno linijsko izmerjenim potovalnim časom – rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom

Natančnost potovalnega časa, pridobljenega iz točkovne ekstrapolacije hitrosti, ocenimo s primerjavo s potovalnim časom, pridobljenim z eno od referenčnih tehnologij neposredno linijsko izmerjenega potovalnega časa. V našem primeru je to tehnologija reidentifikacije vozil na podlagi razpoznavanja registrskih tablic. Primerjavo izvedemo z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, kjer med seboj primerjamo neposredno linijsko izmerjen potovalni čas po prihodu vozil z reprezentativnim potovalnim časom, ocenjenim s točkovno ekstrapolacijo hitrosti po prihodu navideznega vozila v posameznem časovnem intervalu. Trenutni povprečni potovalni čas, pridobljen iz točkovne ekstrapolacije hitrosti v posameznem časovnem intervalu, pretvorimo v povprečni potovalni čas po prihodu vozil, opisan s funkcijsko zvezo med opravljeno potjo vozil in njihovim potovalnim časom. Pri tem za celoten časovni interval zajema podatkov predpostavimo konstantno vrednost hitrosti, kar glede na dejanske razmere na odseku predstavlja poenostavitev. Z uporabo metode modificirane odsekoma konstantne ekstrapolacije za celoten merilniku pripadajoči pododsek predpostavimo konstantno vrednost hitrosti v odvisnosti od prevožene poti.

V prvem koraku izvedemo časovno in prostorsko poravnavo obeh meritev. Prostorska poravnava obeh meritev je dosežena s prekrivanjem območja, ki ga pokriva posamezna tehnologija. Vplivno območje prvega in zadnjega merilnega mesta točkovne ekstrapolacije hitrosti sovpadata z začetno in končno točko reidentifikacije vozil za pridobitev neposredne linijske meritve potovalnega časa.



Slika 5-30: Prostorska poravnava obeh meritev na odseku: območje neposredne linijske meritve potovalnega časa (zgoraj) ter območje točkovne ekstrapolacije hitrosti (spodaj)
Figure 5-30: Measured travel time (above) versus estimated travel time (below): area of coverage

Nekoliko zahtevnejša je naloga časovne poravnave obeh meritev, saj moramo za verodostojno primerjavo obeh meritev upoštevati dejanski časovni interval, ko je navidezno vozilo prevozilo posamezno mesto točkovne ekstrapolacije hitrosti. To izvedemo grafično, tako da rekonstruiramo funkcijsko zvezo med opravljeno potjo vozil in njihovim potovalnim časom.

5.9.3.1 Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času razmer prostega prometnega toka

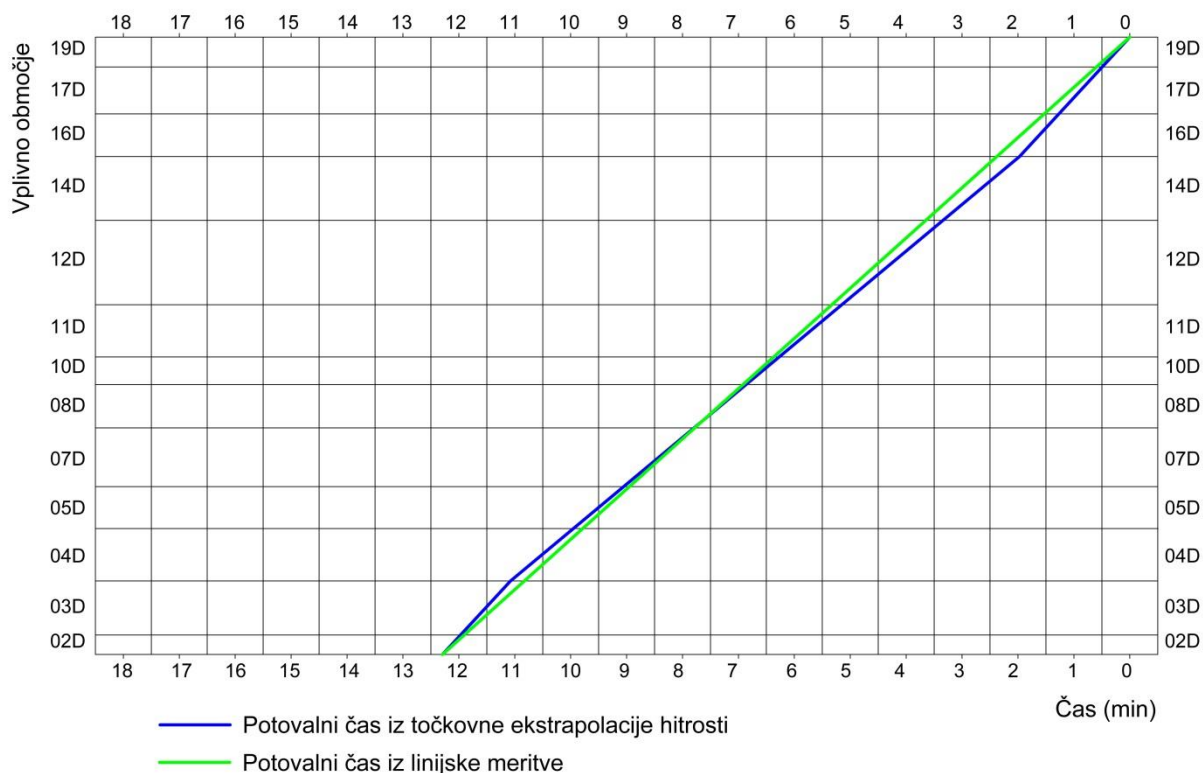
S primerjavo neposredno linijsko izmerjenega potovalnega časa po prihodu vozil s potovalnim časom, ocenjenim s točkovno ekstrapolacijo hitrosti po prihodu navideznega vozila v posameznem časovnem intervalu, preverimo natančnost delovanja algoritma točkovne ekstrapolacije hitrosti.

V prvi fazi izvedemo rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času razmer prostega prometnega toka, kar predstavlja trivialno nalogo, saj v tem primeru primerjamo vrednost neposredno linijsko izmerjenega potovalnega časa ob upoštevanju predpisane hitrostne omejitve ter točkovno ekstrapolirane hitrosti predpisane hitrostne omejitve na posameznem pododseku. Vrednosti potovalnega časa morata biti za razmere prostega prometnega toka enaki.

Podrobna izvedba rekonstrukcije funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom je opisana v nadaljevanju za primer izrednega dogodka. Potovalni čas za razmere prostega prometnega toka znaša 737 sekund tako za neposredno linijsko izmerjen potovalni čas kot tudi za potovalni čas pridobljen s točkovno ekstrapolacijo hitrosti.

Opozoriti moramo, da grafični prikaz potovalnega časa iz neposredne linijske meritve ne prikazuje dejanskega porabljenega potovalnega časa na posameznem pododseku, saj reidentifikacija vozila na začetni in končni točki ne omogoča zaznave evolucije potovalnega časa med točkami izvajanja meritve. Grafični prikaz neposredne linijske meritve samo povezuje začetno in končno točko časovne zaznave vozila na začetni in končni točki.

Lom funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom, pridobljene iz točkovne ekstrapolacije hitrosti, je posledica spremembe predpisane hitrostne omejitve iz 130 km/h na 100 km/h in kasneje spet nazaj na 130 km/h.




Slika 5-31: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času razmer prostega prometnega toka
Figure 5-31: Trajectory reconstruction for free flow traffic

5.9.3.2 Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času izrednega dogodka


V oktobru 2013 so na območju viadukta Petelinjek (pododsek 14D), v smeri Ljubljane potekala vzdrževalna dela voziščne konstrukcije, zaradi česar je bil več dni zaprt vozni pas v dolžini enega kilometra. Merilno mesto SPIS 14D, ki definira pododsek 14D leži dobrih 500 m pred začetkom zapore, medtem, ko merilno mesto SPIS 16D, ki definira pododsek 16D leži 200 m za koncem zapore.

Ukrep del na cesti je od lokacije SPIS 14D zahteval omejitev hitrosti 80 km/h, v času dopoldanske urne konice pa so zaradi zmanjšane kapacitete nastajale zgostitve prometnega toka, katerih posledica so bile zmanjšane hitrosti na lokaciji merilnega mesta SPIS 14D. Na lokaciji SPIS 16D, ki leži takoj po koncu zapore, v času povečane kapacitete, niso bile opažene znatno nižje hitrosti kot v razmerah prostega prometnega toka. Povečana kapaciteta ceste po koncu zapore in konec predpisane hitrostne omejitve 100 km/h sta voznikom osebnih vozil omogočila hitro pospeševanje.



Slika 5-32: Območje postavitve delovne zapore
Figure 5-32: Road works area

Prikaz spreminjanja reprezentativne vrednosti srednje prostorske hitrosti za obdobje trajanja zapore voznega pasu kaže, da kljub predpisani omejitvi hitrosti 80 km/h, večina voznikov le-te ni upoštevala. Do precejšnjega padca hitrosti kot posledica zgoščitve prometnega toka pred začetkom zapore, je prišlo predvsem v času jutranje konice med 6:30 in 7:30. Rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom smo izvedli za dva naključno izbrana časovna trenutka znotraj jutranje konice: 15. oktober ob 6:44 ter 16. oktober ob 7:05. Oba navedena časovna trenutka predstavljata začetno točko rekonstruiranja »za nazaj«, kar sovpada z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom po prihodu.



Slika 5-33: Reprezentativna vrednost srednje prostorske hitrosti na merilnem mestu 14D v času trajanja zapore voznega pasu med 15. in 16. oktobrom 2013
Figure 5-33: Representative value of space-mean speed on the measurement site 14D during road works between October 15-16, 2013

Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za primer izrednega dogodka na avtocesti predstavlja nekoliko zahtevnejšo nalogo. Postopek je


nekoliko bolj zamuden, saj ponavadi zaradi izrednega dogodka hitrost pade na območju bližnjega gortočnega merilnega mesta, zaradi česar navidezno vozilo po obravnavanem odseku »potuje« več časovnih intervalov.

Rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom »za nazaj« začnemo na sredini »trenutnega« časovnega intervala, to je ob času $t = 0$, ki predstavlja izhodno točko iz prostorsko-časovne celice (Slika 5-34). Za osnovo vzamemo reprezentativno vrednost hitrosti na zadnjem obravnavanem pododseku 19D na trasi ob času $t = 0$. Opisani postopek iteracije ponavljamo, dokler ni dosežen začetek odseka. V vsakem koraku posodobimo vrednost hitrosti, ki je funkcija posameznega pododseka in časovnega intervala ter začetni pogoj izstopne točke funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom iz predhodno izračunane celice. Vsi začetni pogoji razen prvega so, glede na to, da je vsaka celica omejena s prostorsko in časovno mejo, določeni s trenutkom, ko navidezno vozilo prečka mejo pododseka ali glede na lego znotraj pododseka, ko vozilo prevozi časovno mejo.

Ker vplivi izrednega dogodka niso segali doltočno od območja zapore, so na zadnjih treh pododsekih 16D, 17D in 19D prevladovale razmere prostega prometnega toka. To je razvidno tudi iz grafičnega prikaza (Slika 5-34), kjer potovalni čas iz točkovne ekstrapolacije hitrostnih meritev sovпада s potovalnim časom ob upoštevanju hitrostne omejitve.

Na območju pododseka 14D, ki ga definirajo točkovno ekstrapolirane hitrosti iz merilnega mesta 14D, so zabeležene bistveno nižje vrednosti reprezentativne srednje prostorske hitrosti za obravnavane časovne intervale 15. oktobra med 28 km/h in 44 km/h ter 16. oktobra med 23 km/h in 46 km/h. Temu primerno funkcijska zveza med opravljeno potjo vozil in njihovim potovalnim časom navideznega vozila poteka precej bolj horizontalno, kar ima za posledico, da navidezno vozilo po pododseku 14D potuje kar 5 časovnih intervalov. Tu se zato začetni pogoji ne posodablajo, ko navidezno vozilo prečka mejo pododseka temveč glede na lego znotraj pododseka, ko vozilo prevozi časovno mejo.

Na merilnih mestih gortočno od predhodno obravnavanega pododseka 14D ni bilo opaženih motenj v prometnem toku, srednja prostorska hitrost je bila enaka tisti skladno z omejitvijo hitrosti, zato rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom do začetka odseka na merilnem mestu 02D poteka trivialno: začetni pogoji vstopa v celico so posodobljeni s trenutkom, ko navidezno vozilo prečka mejo pododseka ali glede na lego znotraj pododseka, ko vozilo prevozi časovno mejo.



Slika 5-34: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času zgoščenega prometnega toka zaradi delovne zapore dne 15. oktobra 2013 ob 6:44

Figure 5-34: Trajectory reconstruction for dense traffic due to road works on October 15, 2013 at 6:44


Iz rekonstruirane funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom vozil za 15. oktober pridemo do naslednjih rezultatov:

Preglednica 5-4: Razlike med potovalnimi časi pridobljenimi z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za 15. oktober 2013
 Table 5-4: Differences between travel times obtained by trajectory reconstruction for October 15, 2013

	Potovalni čas [s]	Zamuda [s]	Zamuda [%]	Obveščanje voznikov [min]	Zamuda [min]	Zamuda [%]
Omejitev hitrosti	737			13		
Ekstrapolacija hitrosti	925	188	26	16	3	23
Linijska meritev	894	157	21	15	2	15

	Potovalni čas [s]	Razlika [s]	Razlika [%]	Obveščanje voznikov [s]	Razlika [min]	Razlika [%]
Ekstrapolacija hitrosti	925	31	3,4	16	1	6,5
Linijska meritev	894			15		

Do nekoliko drugačnih rezultatov pridemo z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za jutranjo konico 16. oktobra. Če je v prejšnjem primeru točkovna ekstrapolacija hitrosti vodila k nekoliko daljšim potovalnim časom glede na neposredno linijsko izmerjenemu, je v tem primeru ravno nasprotno – potovalni čas ocenjen s točkovno ekstrapolacijo hitrosti, je krajši od tistega določenega z neposredno linijsko meritvijo:



Slika 5-35: Rekonstrukcija funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom v času zgoščenega prometnega toka zaradi delovne zapore dne 16. oktober 2013 ob 7:05

Figure 5-35: Trajectory reconstruction for dense traffic due to road works on October 16, 2013 at 7:05

Preglednica 5-5: Razlike med potovalnimi časi pridobljenimi z rekonstrukcijo funkcijske zveze med opravljeno potjo vozil in njihovim potovalnim časom za 16. oktober 2013

Table 5-5: Differences between travel times obtained by trajectory reconstruction for 16th October 2013

	Potovalni čas [s]	Zamuda [s]	Zamuda [%]	Obveščanje voznikov [min]	Zamuda [min]	Zamuda [%]
Omejitev hitrosti	737			13		
Ekstrapolacija hitrosti	904	167	23	16	3	23
Linijska meritev	967	230	31	17	4	31


	Potovalni čas [s]	Razlika [s]	Razlika [%]	Obveščanje voznikov [s]	Razlika [min]	Razlika [%]
Ekstrapolacija hitrosti	904	63	6,7	16	1	6
Linijska meritev	967			17		

5.9.4 Ocena trenutnega potovalnega časa na odseku iz točkovne ekstrapolacije hitrosti

Trenutni potovalni čas na odseku določimo kot vsoto trenutnih potovalnih časov ocenjenih z ekstrapolacijo točkovne hitrosti na posameznem pododseku. Ta potovalni čas ni vezan na funkcijsko zvezo med opravljeno potjo določenega vozila in njegovim potovalnim časom, saj predstavlja sliko trenutnih razmer na posameznih pododsekih.

Ta časovna poravnava predstavlja najboljši približek pravega potovalnega časa ob odhodu vozila za prihodnji časovni interval, v kolikor se želimo izogniti negotovostim napovedi prihodnjega potovalnega časa, ob predpostavki, da bodo lastnosti prometnega toka ostale enake. Razlika med resničnim in napovedanim potovalnim časom je nato v veliki meri odvisna od dolžine odseka in časa agregacije, ki določata časovni interval napovedi.

V nadaljevanju je prikazan primer izrednega dogodka z dne 13. novembra 2013, ko je bil zaradi izrednega dogodka krajši čas zaprt predor Jasovnik v smeri proti Celju (Slika 5-36). Predor so zaprli ob 13:56 in dve minuti zatem je udarni val prišel do merilnega mesta 07D, ležečega 650 m gortočno od začetka predora, ki je zaznal padec srednje prostorske hitrosti vozil iz 102 km/h na 29 km/h. Zaradi padca hitrosti je prišlo do skokovito podaljšanih potovalnih časov, določenih s točkovno ekstrapolacijo hitrosti. Iz spodnje slike je razvidno, da je potovalni čas iz neposredne linijske meritve reagiral na podaljšane potovalne čase šele ob 14:10, ko so prva vozila prispela na doltočno merilno mesto, ki predstavlja konec odseka neposredne linijske meritve, kar je 12 minut kasneje kot odziv potovalnega časa iz točkovne ekstrapolacije hitrosti.



Slika 5-36: Primerjava potovalnega časa določenega iz neposredne linijske meritve in točkovne ekstrapolacije hitrosti v času izrednega dogodka

Figure 5-36: Comparison between measured and estimated travel times in case of an incident

Razlika med hitrostjo odziva neposredne linijske meritve in točkovne ekstrapolacije hitrosti je v veliki meri odvisna od lokacije izrednega dogodka na odseku izvajanja meritve. V kolikor do izrednega dogodka pride na začetku odseka, je ta razlika bistveno večja, kot če se izredni dogodek zgodi na koncu odseka. Informacija o potovalnem času iz neposredne linijske meritve je namreč na voljo šele, ko vozilo prevozi celotni odsek.




Slika 5-37: Lokacija izrednega dogodka pred predorom Jasovnik

Figure 5-37: Location of the incident in front of the tunnel Jasovnik

Zanimivo je preveriti tudi primerjavo med trenutnim potovalnim časom iz točkovne ekstrapolacije hitrosti in potovalnim časom ob odhodu vozila iz neposredne linijske meritve (Slika 5-38). Potovalni čas po prihodu vozil iz neposredne linijske meritve je prikazan le za primerjavo. Namen neposredne ocene trenutnega potovalnega časa iz točkovne ekstrapolacije hitrosti je čim boljši približek potovalnemu času ob odhodu vozila iz neposredne linijske meritve, ki v trenutnem času ni na voljo, saj predstavlja bodočo informacijo. Potovalni čas ob odhodu vozila iz neposredne linijske meritve je na voljo le v primeru zgodovinskih analiz. Iz spodnje slike (Slika 5-38) je dobro vidna zakasnitev potovalnega časa po prihodu vozila iz neposredne linijske meritve v času nastajanja zastoja ter korist pri upoštevanju potovalnega časa iz točkovne ekstrapolacije hitrosti. Potovalni čas iz točkovne ekstrapolacije hitrosti je namreč podaljšane potovalne čase javil takoj, ko je udarni val prišel na merilno mesto. Poleg tega pa je dobro vidna tudi slabost ocene potovalnega časa iz točkovne ekstrapolacije hitrosti – slaba

natančnost pri prostorski posplošitvi točkovnih razmer. Ker je merilnemu mestu 07D pripisan pododsek dolžine 2100 m, dejanski vpliv kolone pred predorom pa je zajemal le 650 m kar predstavlja 30 % celotnega pododseka, je temu primerno ekstrapolirana hitrost na celoten pododsek vodila k precej podaljšanim potovalnim časom za celoten odsek, čeprav so na 70 % odseka prevladovala razmere prostega prometnega toka. Do takšnih napak pogosto pride v primeru relativno nizke gostote merilnih mest na pododseku, kakor na primeru testnega odseka med Vranskim in Blagovico.



Slika 5-38: Primerjava med potovalnim časom ob odhodu vozila iz neposredne linijske meritve, trenutnim potovalnim časom iz točkovne ekstrapolacije hitrosti in potovalnim časom ob prihodu vozila iz neposredne linijske meritve

Figure 5-38: Comparison between departure based, instantaneous and arrival based travel times

Zaradi precej nenatančnega merjenja hitrosti točkovnih merilnikov v času prometnega toka »stop&go« pri čemer točkovni merilnik izmeri le tiste trenutke, ko se vozila premikajo, ne pa tudi trenutkov, ko mirujejo, Soriguera in Robusté (2011) v svojem delu navajata precej podcenjene potovalne čase iz točkovne ekstrapolacije hitrosti v času nastanka izrednega dogodka. V naši študiji je bilo ugotovljeno, da neposredna ocena potovalnega časa, pridobljena iz točkovne ekstrapolacije hitrosti, lahko tudi preceni vrednost potovalnega časa na pododseku. Kot predhodno omenjeno je to v veliki meri odvisno od lokacije izrednega dogodka oz. nastanka zastoja znotraj pododseka glede na lego točkovnega merilnika ter od dolžine posameznemu merilniku pripadajočega pododseka.

Zgoraj navedene ugotovitve nakazujejo, da je iz točkovne ekstrapolacije hitrosti v nekaterih primerih zelo težko natančno oceniti vrednost potovalnega časa na posameznih pododsekih predvsem v primeru redke gostote namestitve točkovnih merilnikov ter v primerih, ko do izrednega dogodka pride na večji oddaljenosti od lokacije točkovnega merilnika. Tako se lahko

zgori, da v primeru lokacije izrednega dogodka le nekaj metrov gortočno od lokacije merilnega mesta, algoritem zelo pozno zazna podaljšane potovalne čase iz točkovne ekstrapolacije hitrosti, saj mora udarni val (motnja) prispeti do naslednjega gortočnega merilnega mesta.

6 DOLOČITEV TRENUTNEGA POTOVALNEGA ČASA Z ZDRUŽEVANJEM POTOVALNIH ČASOV PRIDOBLENIH IZ NEPOSREDNIH LINIJSKIH MERITEV IN TOČKOVNE EKSTRAPOLCIJE HITROSTI

»Proces združevanja podatkov je v svojem smislu varljivo preprost, implementacija pa silno zapletena.«

- Ameriško ministrstvo za obrambo

6.1 Uvod

Vse večje potrebe prebivalstva po mobilnosti zahtevajo pametno upravljanje prometnega toka za zagotovitev optimalnega pretoka. Avtocestni operaterji v večini razvitejših držav so v preteklem desetletju znatna sredstva namenili razvoju in namestitvi sistemov za nadzor in vodenje prometa (SNVP), s katerimi brez fizičnih posegov v razširitev voziščne konstrukcije dosežemo povečan pretok prometnega toka. Uvedbi tehnologij za merjenje osnovnih karakteristik prometnega toka kot npr. pretok in hitrost, zaradi skokovitega razvoja tehnologij v zadnjih letih sledijo namestitve sistemov, ki omogočajo neposredno merjenje potovalnega časa s sledenjem vozil. Tako so dolgoletne težnje prometnih inženirjev o ekonomični rešitvi spremljanja posameznega vozila na njegovi poti oz. med dvema točkama, postale resničnost. Vse več avtocestnih odsekov pokritih s sistemi za nadzor in vodenje prometa ter grafičnimi prikazovalniki spremenljive prometno-informativne signalizacije (SPIS), omogoča preprosto in zanesljivo posredovanje informacij voznikom.

Obstoječa oprema za točkovno merjenje osnovnih karakteristik prometnega toka v obliki točkovnih merilnikov ter oprema za neposredno linijsko merjenje potovalnih časov, vsaka s svojimi prednostmi in slabostmi, predstavljata primeren okvir za združevanje podatkov. Točkovno izmerjena srednja prostorska hitrost predstavlja informacijo v trenutnem času, katere slabost je neznana prostorska razporeditev, po drugi strani pa neposredno linijsko izmerjen potovalni čas predstavlja natančno meritev, ki pa je časovno nekoliko zakasnela. Namen združevanja podatkov je združiti pozitivne lastnosti posamezne od meritev v rezultat z višjo zanesljivostjo.

Nadzorni centri sistemov za nadzor in vodenje prometa se že vrsto let srečujejo s problemom podvajanja prometnih informacij iz različnih virov, ki dejansko predstavljajo isto informacijo. Dodajanje nove merilne opreme in pridobivanje novih meritev bi nadzornikom prometa predstavljalo le dodatno breme, ki bi še bolj upočasnilo njihov odziv v kritičnih situacijah. Optimalno rešitev v takih primerih predstavljajo metode združevanja podatkov, ki informacije iz različnih virov združijo v razumljivejšo reprezentativnejšo vrednost, na podlagi katere nadzornik prometa lažje sprejme ukrepe vodenja prometa. Združevanje podatkov iz različnih virov in tehnologij tako prinaša vrsto kvalitativnih prednosti, pri čemer pa tudi kvantitativno omeji število informacij za nadaljnjo obdelavo. Zaradi vseh teh razlogov predstavlja sistem združevanja podatkov, ne le za združevanje podatkov za oceno potovalnih časov, nujen korak pri optimizaciji nadzornih centrov za vodenje prometa.




Slika 6-1: Nadzorni center sistema za nadzor in vodenje prometa v Ljubljani
Figure 6-1: Traffic management and control center in Ljubljana

Razlog za združevanje podatkov iz različnih virov je zagotoviti rezultat, ki je učinkovitejši, zanesljivejši in natančnejši od osnovnih podatkov, ki jih združujemo. Pri združevanju vsak od virov lahko doprinese svoje ugodne lastnosti ter tako omogoča pridobitev rezultata, do katerega pri uporabi posameznega vira morda ne bi bilo možno priti. Združitev podatkov iz različnih virov lahko zato vodi k izboljšani operativni učinkovitosti sistema, razširjeni prostorski in časovni pokritosti meritve, povečani zanesljivosti in nedvoumnosti informacije ter izboljššanemu zaznavanju izrednih dogodkov.

6.2 Problem časovne zakasnitve

Problem časovne zakasnitve, na katerega naletimo ob uporabi metod neposrednih linijskih meritev, lahko povežemo z razliko v potovalnem času ob odhodu vozil, na podlagi katerih smo ta potovalni čas ocenili in vozil, ki informacijo o tem potovalnem času prejmejo. Gledano na trenutni čas t je čas odhoda vozil, na podlagi katerih smo ocenili reprezentativno vrednost potovalnega časa $t - \Delta$, čas odhoda vozil, ki informacijo o tem potovalnem času prejmejo pa je t . Razlika Δ med $t - \Delta$ in t se imenuje časovna zakasnitev informacije o potovalnem času, posledica te časovne zakasnitve pa je v primeru spreminjajočih se prometnih razmer lahko napaka v oceni potovalnega časa, zaradi različnega časa odhoda vozil (Slika 6-2).



Slika 6-2: Napaka v oceni potovalnega časa ob uporabi neposredne linijske meritve - problem časovne zakasnitve

Figure 6-2: Error in travel time estimation while using measured travel times - time-lag problem

Ko voznik dobi informacijo o potovalnem času v trenutku t , bi rad bil informiran o predvidenem potovalnem času, ki ga bo potreboval za prevoz odseka ceste. To predstavlja prihodnji potovalni čas ob odhodu vozila za časovni interval (t_i, t_{i+1}) , na katerega vplivajo številni dejavniki in ga je ob spremenljivih prometnih razmerah težko predvideti. Kar je v sistemu za merjenje potovalnih časov na voljo, je izmerjen potovalni čas po prihodu vozila za predhodni časovni interval (t_{i-1}, t_i) , ki ga pridobimo iz neposrednih linijskih meritev (s sistemom za reidentifikacijo registrskih tablic oz. reidentifikacijo naslovov »bluetooth«) ter dejanski potovalni čas, ki ga dobimo s točkovno ekstrapolacijo meritev hitrosti za interval (t_{i-1}, t_i) . Problem kratkoročne napovedi torej predstavlja iz izmerjenega potovalnega časa po prihodu vozila in ocenjenega trenutnega potovalnega časa, določiti pričakovani potovalni čas ob odhodu vozila za naslednji časovni interval. Glede na to, da potovalni čas po prihodu vozila predstavlja zakasnelo informacijo, se lahko zgodi, da groba ocena iz trenutnega potovalnega časa, pridobljenega s točkovno ekstrapolacijo hitrosti predstavlja natančnejšo napoved potovalnega časa ob odhodu vozila. Trenutni potovalni čas namreč nima zakasnitve, do katere pride pri potovalnem času po prihodu vozil, pri katerem moramo počakati, da vozilo konča svoje potovanje.

6.3 Pregled obstoječe literature in izvedenih raziskav

Dostopnost tehnologij ter povečan interes predvsem avtocestnih operaterjev sta v zadnjih letih vodila k namestitvi različnih sistemov za neposredno merjenje in posredno oceno potovalnega časa na avtocestnih odsekih. Temu primerno je bila razvita vrsta različnih metodologij in algoritmov za izračun potovalnega časa bodisi le iz enega vira podatkov, bodisi kot sinteza podatkov pridobljenih iz različnih tehnologij. Vsak vir podatkov ima svojo lastno napako, ki pri kombinaciji različnih virov podatkov lahko vodi k dodatni napaki ocene. To vodi do uporabe tehnik za združevanje podatkov o potovalnih časih, pridobljenih iz različnih virov.

Namen združevanja podatkov je premostiti na eni strani prostorsko nenatančnost potovalnega časa pridobljenega iz točkovne ekstrapolacije hitrosti, na drugi strani pa časovno zakasnelost neposredno izmerjenega potovalnega časa na odseku. Z združevanjem podatkov želimo doseči kratkoročno napoved trenda razvoja potovalnega časa, kot podlago za informacijo vozniku, ki šele vstopa na odsek izvajanja meritve.

Interes raziskovalcev za pridobivanje podatkov o potovalnem času s pomočjo združevanja je postal izrazit na koncu devetdesetih let prejšnjega stoletja. V literaturi najdemo različne modele uporabljene za združevanje podatkov, ki jih konceptualno lahko delimo na naslednje sklope (van Hinsbergen in sodelavci, 2007; Fei in sodelavci, 2011):

- Parametrični modeli:
 - Linearna regresija,
 - Avtoregresija (ARIMA),
 - Vektorska regresija,
 - Kalmanov filter.
- Neparometrični modeli:
 - Nevronske mreže,
 - Bayesov model,
 - Dempster-Shaferjeva teorija,
 - Mehka logika,
 - Metoda k najbližjih sosedov.
- Hibridni modeli.

6.3.1 Parametrični modeli

Parametrični modeli predstavljajo funkcije, pri katerih parametre pridobimo iz podatkov, struktura funkcije pa je prednastavljena. Sama struktura odraža karakteristike prometnega toka, s čimer je omogočeno modeliranje različnih tudi neznanih izrednih dogodkov. Parametrični modeli v primerjavi z neparometričnimi za svoj izračun potrebujejo manjše število podatkov, zaradi česar so za izvedbo izračuna ponavadi preprostejši.

Različne izvedene študije obravnavajo parametrične modele združevanja podatkov za določitev potovalnih časov iz različnih virov. Choi in Chung (2002) sta združila podatke o potovalnih časih iz induktivnih zank in vzorčnih vozil opremljenih z GPS tehnologijo z določevanjem uteži posamezni meritvi ter uporabo metod Fuzzy regresije in Bayesove teorije. Ugotovila sta, da so združeni podatki bolj zanesljivi kot če bi za določitev potovalnega časa vzeli aritmetično sredino meritev.

Chu in sodelavci (2005) so razvili metodo za določevanje potovalnega časa na avtocesti na podlagi prilagojenega Kalmanovega filtra. Števnih podatki o pretoku in gostoti so pridobljeni iz enojnih induktivnih zanknih detektorjev, ki nimajo zmožnosti merjenja hitrosti. Z uporabo prilagojenega Kalmanovega filtra so podatke iz enojnih induktivnih zank združili s podatki pridobljenimi s sledenjem sicer majhnega števila vzorčnih vozil. Kljub temu, da je bil Kalmanov filter uporabljen že v mnogo prometnih študijah kot npr. za dinamično določevanje gostote prometnega toka (Gazis in sodelavci, 1971; Szeto in sodelavci, 1972), za napoved prometnega pretoka in potovalnega časa (Okutani in sodelavci, 1984; Gazis in sodelavci, 2003; Chen in sodelavci, 2001), te študije niso obravnavale problema, kako opisati matriko

kovariance za napako modela (dejanski šum) in napako merilnika (šum pri opazovanju), čeprav sta to ključni vprašanji pri uporabi Kalmanovega filtra (Chu in sodelavci, 2005). Prilagojen Kalmanov filter ima v tem primeru funkcijo dinamičnega določevanja šuma podatkov z uporabo podatkov v trenutnem času. Prednost metode je zmožnost računanja z nepravilnimi detektorskimi podatki in napakami, ki so posledica modela. Chu in sodelavci (2005) so v študiji upoštevali napako na strani modela in tudi na strani podatkov pridobljenih iz detektorja. Model je bil evalviran v času ponavljajočih se izrednih dogodkov (zastojev) na odseku avtoceste in tudi na primeru naključnih izrednih dogodkov in je v primerjavi z določevanjem potovalnega časa samo na podlagi sledenja vzorčnih vozil oz. na podlagi prostorske ekstrapolacije točkovnih podatkov iz dvojnih induktivnih zank, pokazal boljšo natančnost napovedi potovalnega časa in robustnost metode. Algoritem na podlagi prilagojenega Kalmanovega filtra se je izkazal za izredno uporabnega, pri deležu vzorčnih vozil do 20 %. Večji delež vzorčnih vozil ne zagotavlja bistveno izboljšanih rezultatov.

Hage in sodelavci (2012) so za združevanje podatkov iz točkovnih merilnikov in vzorčnih vozil uporabili razširjen Kalmanov filter in zagotovili uporabnost metodologije v trenutnem času ob majhnem vzorcu vzorčnih vozil 1 % na mestni cestni mreži.

6.3.2 Neparometrični modeli

Neparometrične modele moramo uporabiti takrat, ko nimamo informacije za opredelitev analitičnega parametričnega modela. Pri neparometričnih modelih število in narava parametrov nista določena vnaprej temveč tako strukturo kot tudi parametre modela določimo glede na tip podatkov. Zatorej je za izračun potrebnih več podatkov kot pri parametričnih modelih. Prednost teh modelov je zmožnost modeliranja kompliciranih dinamičnih in nelinearnih procesov.

Neparometrični modeli so bili v preteklosti pogosto uporabljeni za združevanje podatkov iz različnih virov. Ivan (1997) je razvil fuzijski model za združevanje potovalnega časa iz vzorčnih vozil in točkovnih detektorjev na podlagi nevronske mreže z namenom določitve izrednih dogodkov na glavnih arterijah.

Palacharla in Nelson (1999) sta študirala uporabnost mehke logike za oceno potovalnih časov, pri čemer sta primerjala uporabnost različnih hibridnih sistemov (mehka logika na podlagi nevronske mreže v primerjavi z ekspertnimi sistemi). Ugotovila sta, da je hibridni sistem z nevronskimi mrežami bolj natančen in povečuje natančnost rezultatov, pridobljenih s klasičnimi metodami ocene potovalnega časa. Podobno metodologijo so leta 2006 testirali naši sosedje v Avstriji na oddelku za promet, inovacije in tehnologijo (Quendler in sodelavci, 2006). Namen je bil pridobitev zanesljivih potovalnih časov in določitev nastanka zastoja na cestni mreži z uporabo različnih vrst senzorjev kot npr. sledenje taksijem, induktivne zanke in laserski detektorji. Pri določevanju stopnje prometnega stanja je bila napaka zmanjšana za 50 % z uporabo metodologije znane pod imenom ANFIS (Adaptable Neural Fuzzy Inference System). Kasneje je Sazi-Murat (2006) uporabil metodologijo ANFIS za določitev zamud v semaforiziranih križiščih, s čimer je predvsem v zasičenih prometnih stanjih dosegel boljše rezultate kot Highway Capacity Manual (2010).

Klein in sodelavci (2002) so predlagali fuzijski model za pomoč pri upravljanju sistemov za nadzor in vodenje prometa na osnovi Dempster-Shaferjeve teorije. Dempster-Shaferjeva

omogoča združevanje podatkov iz različnih virov ter določa stopnjo verjetnosti z upoštevanjem vseh dostopnih dejstev.

Xie in sodelavci (2004) so primerjali večnivojsko nevronske mreže in večstopenjski regresijski model, pri katerem je podatek iz točkovnega detektorja za določevanje potovalnih časov sestavljen iz časa gibanja in zamud, linijske meritve potovalnega časa pa so uporabljene le v primeru, da je na voljo vzorec vsaj 10 vozil v danem časovnem intervalu. Boljše rezultate je prikazal večstopenjski regresijski model.

Francoz El Faouzi (2005) je uporabil Dempster-Shaferjevo teorijo. Na testnem sistemu blizu Toulousea sta bili uporabljeni dve vrsti podatkov in sicer induktivne zanke in sledenje registrskim tablicam, pri čemer so bili opaženi izboljšani rezultati v primerjavi z uporabo klasične Bayesove teorije. Izsledke omenjene raziskave so uporabili francoski avtocestni operaterji za oceno in napoved potovalnih časov na njihovem avtocestnem omrežju (Ferré, 2005; Vuadelle, 2006). Sistem ima visoko stopnjo zanesljivosti z zelo majhno napako v razmerah prostega prometnega toka in napako približno 15 % v času nastanka zastoja oz. zgoščenih prometnih razmer. Sistem prikazuje relacijske podatke za različna obdobja med letom: v času dopustov prikazuje potovalni čas za daljše relacije, medtem, ko v času izven sezonskih konic prikazuje informacije za vsakodnevne voznike, ki se vozijo na delovno mesto ali popoldanske aktivnosti.

Bajwa in sodelavci (2005) so uporabili neparametrično metodo prepoznavanja vzorcev, pri čemer so trenutne prometne razmere primerjali z bazo zgodovinskih podatkov in s tem iskali ponavljajoče se vzorce. Učinkovitost metode je zmanjšana v primeru neponavljajočih se izrednih dogodkov.

Na Nizozemskem so van Lint in sodelavci (2005) uporabili nevronske mreže za napoved potovalnih časov z nepopolnimi podatki in kljub pomanjkljivosti v osnovnih podatkih dosegli zanesljive rezultate. Metoda fuzije podatkov po Bayesu temelji na Bayesovem izreku klasične verjetnostne teorije in pripada razredu algoritmov, ki uporabljajo a priori (predhodno) znanje o opazovani spremenljivki z namenom sklepanja odločitve o identiteti analiziranih objektov. Bayesova metoda predstavlja model za izračun a posteriori (naknadne) verjetnosti glede na dane okoliščine. Van Hinsbergen in van Lint (2008) sta predlagala Bayesov model za kratkoročno napoved potovalnega časa z namenom izboljšanja napovedi za aplikacije, ki delujejo v trenutnem času (sistemi obveščanja). Metoda oceni zmožnost natančne ocene modela na podlagi vhodnih podatkov in podatkov, na podlagi katerih je bil model kalibriran. Njuna kritika do tedaj izvedenih modelov napovedi potovalnega časa z združevanjem podatkov je, da le-ti uporabljajo napako modela v predhodnih časovnih intervalih, kar za sisteme, ki delujejo v trenutnem času ni mogoče. Rezultati študije so obetajoči, nadaljnje raziskave pa so potrebne na temo zagotovitve robustnejšega delovanja metode v primeru, da so bili vsi podatki pri kalibraciji odstopajoči. Predlagana rešitev naj bi bilo večje število in raznolikost vhodnih podatkov, ki se jih združuje.

Azijski raziskovalci iz Kitajske in Singapurja so se ukvarjali z napovedjo prometnega toka z uporabo Bayesove teorije na osnovi nevronske mreže. Rezultati študije Weizhong in sodelavcev (2006) prikazujejo do 85% izboljšanje natančnosti v primerjavi s preprostimi nevronske mreže. Korejca Park in Lee (2004) sta na območju mestnih cestnih mrež združevala podatke

iz induktivnih zank in tistih, pridobljenih s sledenjem avtomobilov z ločeno uporabo nevronskih mrež in Bayesove teorije. V obeh primerih so rezultati obetajoči.

Lee (2009) je razvil model napovedi potovalnega časa na avtocestah z uporabo nevronskih mrež in metode grozda. Vhodne podatke predstavljajo različni podatki s terena (potovalni časi pridobljeni s sledenjem vozil, izmerjene hitrosti iz točkovnih merilnikov, baza podatkov o nesrečah), pri čemer se z uporabo metode grozda vhodne podatke razvrsti v skupine. Napoved potovalnega časa je na voljo po vnosu trenutnih prometnih razmer v nevronske mreže.

Korejca Lim in Lee (2010) sta predlagala algoritem za združevanje potovalnega časa, ocenjenega iz točkovno ekstrapolirane hitrosti in potovalnega časa iz neposredne linijske meritve na podlagi modela k najbližjih sosedov. Algoritem za napoved potovalnega časa se je na podlagi rezultatov izkazal kot obetaven.

Fei in sodelavci (2011) so za kratkoročno napoved potovalnega časa na avtocestnem odseku uporabili dinamični linearni model na osnovi Bayesove teorije. Predlagani model oceni potovalni čas na podlagi mediane zgodovinskih potovalnih časov ter napake modela. Pri tem je mediana uporabljena za ponazoritev prvotnega vzorca potovalnega časa, nihanja pa opišejo spremembe v povpraševanju in kapaciteti. Bayesova teorija predstavlja proces učenja, ki v zaporednih korakih preveri a priori znanje o potovalnem času na podlagi nove informacije. Rezultat napovedi predstavlja a posteriori porazdelitev potovalnega časa, s katero lahko ocenimo srednjo vrednost potovalnega časa in interval zaupanja. Rezultati s terena kažejo na uspešno delovanje modela tako v času ponavljajočih kot tudi naključnih izrednih dogodkov.

Khan (2012) je za združevanje podatkov in kratkoročno napoved potovalnih časov iz točkovnih merilnikov in mobilne tehnologije za sledenje vozil uporabil Bayesovo teorijo. Avtor zatrjuje, da so podatki o potovalnih časih, sami po sebi zastareli, v kolikor jih ne uporabimo kot vhodni podatek v modelu za napoved potovalnega časa.

6.3.3 Hibridni modeli

Hibridni modeli predstavljajo kombinacijo različnih metod. V literaturi najdemo različne predloge hibridnih modelov za združevanje podatkov o potovalnih časih iz različnih virov.

Rouphil in sodelavci (1993) ter Berka in sodelavci (1995) so za določevanje potovalnega časa na odseku združili podatke regresijske analize in Bayesove teorije, pri čemer je bila regresijska analiza uporabljena za izračun potovalnega časa iz točkovnih detektorjev, Bayesova teorija pa za fuzijo podatkov, pridobljenih s sledenjem vozil in točkovnih detektorjev, tako za trenutne kot tudi za zgodovinske podatke. Uporabljen je bil podoben model kot pri virtualni metodi vzorčenja, kjer se za fuzijo linijskih in točkovnih podatkov uporablja metoda uteženih povprečij, ki uporablja varianco posameznega sistema linijskih oz. točkovnih detektorjev. Varianca pri temu predstavlja statistično razpršenost določene spremenljivke, v tem primeru potovalnega časa.

Yeon-Sik in Choi (1999) sta za fuzijo podatkov iz znančnih detektorjev in signala GPS vzorčnih vozil uporabila model linearne regresije in stopnjo verjetnosti na podlagi Bayesove teorije.

Soriguera in Robusté (2011) sta predlagala dvostopenjski model fuzije podatkov, pri čemer v prvi fazi združi dve vrsti podatkov iz točkovnih merilnikov, v drugi fazi pa podatkom iz prve faze doda še linijsko izmerjene podatke o potovalnem času. Testiranje na podeželski avtocesti v predmestju Barcelone kaže na uspešnost metode z uporabo Bayesove teorije.

Anusha in sodelavci (2012) so predlagali hibridni pristop k oceni potovalnega časa na cestni arteriji za precej kaotične prometne razmere v indijskih mestih. Podatki iz induktivnih zank so združeni s podatki vzorčnih vozil, pridobljeni s sledenjem signala GPS z uporabo t.i. hibridne metode združevanja podatkov HCM. Metoda je v primerjavi z osnovno metodo HCM in metodo Kalmanovega filtra prikazala dobre rezultate.

6.3.4 Ugotovitve na podlagi literature

»Če eden zmaga, morajo vsi drugi zgubiti. Je to splah zabavno?«

- Marlo Morgan

Večina do sedaj izvedenih študij na temo združevanja podatkov iz različnih virov z namenom ocene potovalnega časa rezultate združevanja primerja z osnovnim virom informacij, ki jih združuje. Predhodno predstavljeni modeli združevanja podatkov izboljšajo natančnost osnovnega vira informacij, primerjava med njimi pa pogosto ni možna, saj veliko študij rezultate poda le v kvalitativni obliki. V kolikor pa so rezultati podani v kvantitativni obliki, se njihov prikaz med študijami razlikuje in zato njihova primerjava ni možna. Prav tako testiranje različnih metod poteka v različnih pogojih odvijanja prometnega toka, kar oteži primerjavo med njimi.

Kanadska študija avtorjev Bachmann in sodelavci (2013) predstavlja eno izmed redkih primerjav med različnimi metodami združevanja podatkov: v svoji študiji so primerjali sedem različnih metod z vidika zmožnosti združevanja podatkov iz sistema reidentifikacije naslovov »bluetooth« in podatkov iz dvojnih induktivnih zank za določitev ocene hitrosti na avtocesti. Med seboj so primerjali linearno regresijo, kombinacijo Bar-Shalom/Campo, Kalmanov filter, SCAAT Kalmanov filter, urejeno uteženo povprečje (OWA), Fuzzy integrale in umetne nevronske mreže. Praktična primerjava metod kaže, da metode združevanja podatkov naredijo napako, ki je načeloma manjša od napake najboljše osnovne cenilke osnovnega podatka. Ugotovitve nadalje kažejo, da se vse metode obnašajo podobno in da nobena od metod ne prekaša ostalih v vseh opazovanih primerih. Kot najboljši sta se izkazali metoda linearne regresije in Kalmanov filter. To predstavlja pomembno ugotovitev, saj so nekatere izmed metod tako teoretično kot računsko precej kompleksne in je zato njihova implementacija vprašljiva, glede na to da ne zagotavljajo nobene bistvene prednosti.

Do podobnih ugotovitev v svoji študiji, ki je sicer bolj osredotočena na kratkoročno napoved, prihajajo tudi van Hinsbergen in sodelavci (2007) in Keever in sodelavci (2003). Iz pregleda obstoječih metod ugotavljajo, da nobena od metod ne izstopa, kot najboljše z vidika natančne napovedi in računske enostavnosti pa se pokažejo metoda linearne regresije in nevronske mreže.

Do sedaj izvedene študije podatke združene iz neposredne linijske meritve ter iz posredne točkovno ocene primerjajo z izmerjenim potovalnim časom po prihodu vozila za predhodni časovni interval. Namen naše študije je podatka iz neposredne linijske meritve ter iz posredne točkovne ocene združiti na tak način, da se združen potovalni čas kar se le da dobro približa potovalnemu času ob odhodu vozila, ki za voznika pravkar odpravljajočega se na pot predstavlja merodajno informacijo.

Obstoječe študije kot merilo uspešnosti izvedene združitve podatkov iz neposredne meritve in posredne ocene večinoma uporabijo le koren povprečne kvadratne napake glede na osnovni vir informacije, ne ozirajoč se na primerjavo korelacije kot številske mere linearne povezanosti dveh spremenljivk, ki predstavlja globalni parameter.

Namen našega algoritma je zagotoviti združevanje podatkov iz neposredne linijske meritve in točkovne ocene za potrebe obveščanja voznikov. To od algoritma zahteva zmožnost po enostavnem sprotnem učenju o novih izrednih dogodkih po prednastavljeni strukturi modela, s čimer se uspešnost metode postopoma izboljšuje z učenjem.

Prav tako nobena od obstoječih študij v obzir ne vzame kvalitativnih meril odvijanja prometnega toka v smislu različnih merjenj kot so hitrost, gostota in pretok prometnega toka, ki definirajo nivoje uslug.

Kljub velikemu številu izvedenih študij na temo združevanja podatkov, univerzalna metoda združevanja podatkov, ki bi zares dobro delovala v vseh primerih še vedno ni na voljo.

6.4 Splošno o združevanju podatkov iz različnih virov

6.4.1 Definicije in pomen združevanja podatkov

Združevanje podatkov je inteligenen proces, ki se izvaja z namenom obogatitve informacije glede na osnovni vir podatkov (Ng, 2003). Osnovni način združevanja podatkov iz različnih senzorjev je podoben načinu, kako ljudje in živali uporabljamo kombinacijo različnih čutil, izkušenj in sposobnosti, da izboljšamo našo možnost preživetja (Mitchell, 2007). Združevanje podatkov iz različnih virov je proces, sestavljen iz kombinirane uporabe različnih multidisciplinarnih metod, podobnih miselnim procesom človeka, katerega namen je priti do zaključka na podlagi resničnih vidikov, ki omogočajo sprejetje odločitve (Soriguera, 2007). Z vidika natančnosti ocene, kombinirana uporaba podatkov iz različnih virov in njihovo združevanje omogočata doseganje rezultatov, ki so potencialno bolj natančni, kot če bi jih pridobili iz enega samega vira. Pri združevanju podatkov iz različnih virov je zelo pomembno primerno oceniti pričakovano napako vsake posamezne spremenljivke, ki jo združujemo.

Medtem ko obstaja več definicij združevanja podatkov, pa obstaja soglasje, kaj združevanje podatkov iz več virov pomeni. Mitchell (2007) pravi, da združevanje podatkov iz različnih virov predstavlja »teorije, metode in orodja, ki se uporabljajo za združevanje podatkov v skupen reprezentativen format, pri čemer združevanje podatkov izvajamo z namenom doseganja izboljšane kvalitete podatkov, kot bi jo dosegli, če bi bili osnovni viri podatkov uporabljeni posamično.«

6.4.2 Namen združevanja podatkov

V obstoječi literaturi na temo združevanja različnih vrst podatkov (Ng , 2003; Mitchell, 2007; Bachmann in sodelavci, 2012) najdemo številne razloge, ki govorijo v prid združevanju podatkov iz različnih virov:

- Zagotovitev zanesljivosti, robustnosti in redundance
Sistem, ki je odvisen od informacije iz enega samega merilnika, ni robusten, saj v primeru izpada oz. nedelovanja edinega merilnika izpade celoten sistem. Po drugi strani sistem, ki združuje podatke iz večih merilnikov zagotavlja zanesljivejše delovanje, saj različni merilniki zagotavljajo redundantno delovanje.
- Natančnost in zanesljivost delovanja
Kombinacija podatkov iz različnih vrst merilnikov zagotavlja natančnejšo informacijo. Kombinacija zaporednih podatkov iz istega merilnika zmanjša občutljivost sistema na šum in kratkotrajne izpade ter nepravilnosti. Kombinacija različnih neodvisnih merilnikov zagotavlja ne le večjo natančnost, temveč tudi varnost delovanja in izločanje nezanesljivih podatkov.
- Popolnost, dopolnilnost in pokritje vseh informacij
Več virov podatkov zagotavlja razširjeno pokritost posameznega dogodka, predvsem z vidika zagotovitve časovne in prostorske pokritosti. Včasih je informacija iz različnih senzorjev dopolnilna, kar zagotavlja informacijo o dogodkih, ki jih s posameznim merilnikom ni mogoče zaznati.
- Stroškovna učinkovitost
Izdelava merilnika, ki bi bil sposoben različnih funkcionalnosti, je pogosto dražja kot integracija preprostejših in cenejših merilnikov s specifičnimi lastnostmi.
- Zagotovitev reprezentativne informacije
Čas, potreben za sprejetje odločitve, narašča s povečanjem števila informacij, ki so na voljo. Združevanje podatkov iz različnih virov zagotavlja enostavnejšo pridobitev reprezentativne informacije, na podlagi katere je možna hitra interpretacija in sprejem pravilne odločitve.
- Pravočasnost
Hitrost obdelave podatka na posameznem merilniku in možnost paralelnega procesiranja pri združitvi podatkov iz več virov omogoča hitrejšo pridobitev rezultata. Prav tako kombinacija podatkov iz večih merilnikov omogoča hitrejšo zaznavo izrednega dogodka, kakor v primeru kombinacije točkovne ocene in neposredne linijske meritve potovalnega časa.


Vse zgoraj našteje prednosti veljajo ob predpostavki, da popoln vir informacije ne obstaja. To drži, saj ima vsak merilnik določeno stopnjo napake, omejeno območje zaznave in pod določenimi vplivi nepravilno delovanje.

6.4.3 Konfiguracija merilnikov pri združevanju podatkov

Razporeditev merilnikov pomembno vpliva na izbiro kombinacije in način združevanja podatkov. Glede na podatke iz merilnikov, ki opazujejo isti objekt ali dogodek ločimo naslednje konfiguracije merilnikov (Ng, 2003; Mitchell, 2007; Bachmann in sodelavci, 2012):

- Dopolnjujoča konfiguracija merilnikov


Konfiguracija merilnikov je dopolnjujoča, v kolikor povezani merilniki zagotavljajo popolnejši in dopolnjujoč pregled nad stanjem, ki ga opazujejo. Tak primer predstavljajo točkovni merilniki parametrov prometnega toka, kjer vsak merilnik pokriva del avtocestnega odseka (Slika 6-3). Taka konfiguracija je dopolnilna, saj vsak od točkovnih merilnikov zagotavlja enako vrsto podatka (hitrost, pretok, gostota...), vendar za različno stacionažo na avtocesti.



Slika 6-3: Dopolnjujoča konfiguracija merilnikov
Figure 6-3: Complementary detector configuration

- Konkurenčna konfiguracija merilnikov

Konfiguracija merilnikov je konkurenčna, v kolikor vsak od merilnikov zagotavlja meritev iste lastnosti. Glede na to, da zagotavljajo informacijo o istem izmerjenem podatku, merilniki med seboj »tekmujejo«, katero od meritev bo sistem upošteval v primeru odstopanj med meritvami. Konkurenčni merilniki so lahko enakega tipa ali pa uporabljajo različne metode za merjenje istega pojava. Namen konkurenčne konfiguracije merilnikov je zmanjšati napake pri merjenju in s tem povečati zanesljivost sistema. Primer konkurenčne konfiguracije merilnikov predstavljata sistem za reidentifikacijo registrskih tablic ter sistem za reidentifikacijo naslovov »bluetooth«, ki na istem odseku za ista vozila merita potovalne čase (Slika 6-4).




Slika 6-4: Konkurenčna konfiguracija merilnikov
Figure 6-4: Competitive detector configuration

- Zadružna konfiguracija merilnikov

Zadružna (kooperativna) konfiguracija merilnikov uporablja informacijo iz dveh ali več neodvisnih merilnikov, ki je iz enega samega merilnika ne bi bilo mogoče dobiti. Tak primer predstavljajo točkovni merilniki hitrosti na odseku, iz katerih določimo

povprečno hitrost na odseku. Ti merilniki zagotavljajo informacijo o hitrosti na različnih merilnih mestih in tudi razvoj hitrosti ter njeno povprečje na odseku. Iz enega samega senzorja povprečne hitrosti na odseku ne bi mogli izmeriti (Slika 6-5).




Slika 6-5: Zadružna konfiguracija merilnikov
Figure 6-5: Cooperative detector configuration

6.4.4 Arhitektura združevanja podatkov

Arhitektura združevanja podatkov določa lege vozlišč, kjer se izvaja procesiranje podatkov ter njihov odnos do posameznih merilnikov. V obstoječi literaturi najdemo različne načine arhitektur združevanja podatkov, ki se razlikujejo glede na razporeditev vozlišč za združevanje podatkov (Ng, 2003; Mitchell, 2007):

- Centralizirana arhitektura združevanja podatkov


V centralizirani arhitekturi združevanja podatkov se enota združevanja nahaja v osrednjem procesorju, ki zbira podatke od različnih merilnikov (Slika 6-6). Procesiranje in združevanje podatkov ter sprejemanje vseh ostalih odločitev izvedemo v tem osrednjem vozlišču, ki posreduje in razdeli naloge pripadajočim merilnikom.



Slika 6-6: Centralizirana arhitektura združevanja podatkov
Figure 6-6: Centralized fusion architecture

- Decentralizirana arhitektura združevanja podatkov

Decentralizirana arhitektura združevanja podatkov je sestavljena iz mreže vozlišč, v kateri ima vsako vozlišče svoj procesor (Slika 6-7). Združevanje podatkov izvedemo v posameznih vozliščih na podlagi lokalne informacije in informacije iz sosednjih vozlišč. V tem primeru nimamo osrednjega komunikacijskega in združevalnega vozlišča posamezno. Vozlišča nimajo informacije o globalni arhitekturi mreže, katere del so.

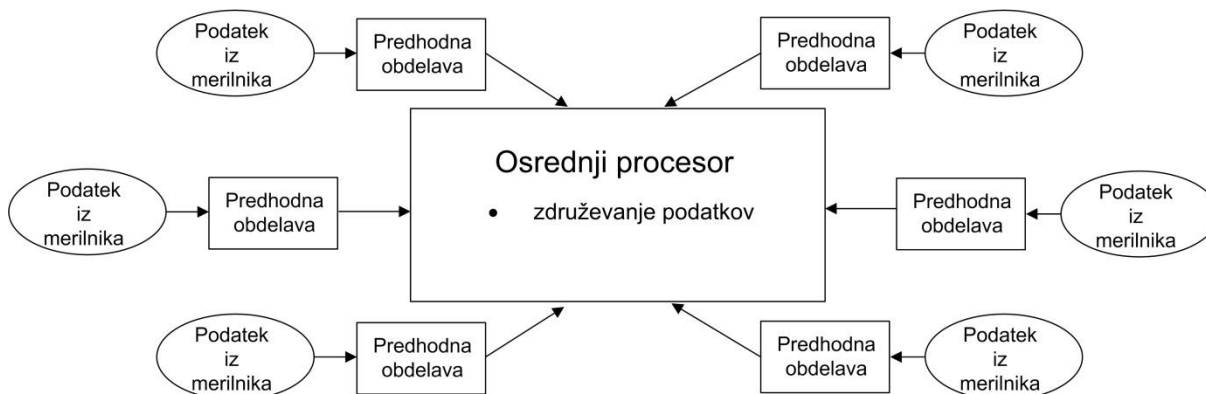


Slika 6-7: Decentralizirana arhitektura združevanja podatkov

Figure 6-7: Decentralized fusion architecture

- Porazdeljena arhitektura združevanja podatkov

Porazdeljene arhitekture združevanja podatkov predstavljajo razširitev centralizirane arhitekture, pri čemer so podatki iz vsakega posameznega merilnika predhodno obdelani, preden so poslani v osrednje vozlišče (Slika 6-8). V osrednjem vozlišču se nato izvede združevanje podatkov z ostalimi podatki.



Slika 6-8: Porazdeljena arhitektura združevanja podatkov

Figure 6-8: Distributed fusion architecture


- Hierarhična in hibridna arhitektura združevanja podatkov

Hierarhična in hibridna arhitektura predstavljata kombinacijo predhodnih treh arhitektur združevanja podatkov.

6.4.5 Glavne prednosti in pomanjkljivosti metod za združevanje podatkov

Pred odločitvijo o uporabi metod za združevanje podatkov moramo poznati prednosti in pomanjkljivosti, ki nam jih združevanje prinese. Nahin in Pokoski (1980) v svoji študiji ugotavljata:

- kombinacija virov podatkov z nizko stopnjo verodostojnosti (majhna verjetnost točne meritve iz posameznega merilnika $P_N < 0,5$) ne prispeva k večji zanesljivosti. Osnovna zahteva za doseglo natančnejših podatkov z združevanjem je torej minimalna natančnost posameznega vira.
- kombinacija virov podatkov z visoko natančnostjo ($P_N > 0,95$), ne pripomore k bistvenemu izboljšanju natančnosti. Če so merilniki že v osnovi zelo natančni, ni potrebe po združevanju podatkov.
- povečanje števila merilnikov poveča natančnost rezultata, pridobljenega z združevanjem do določenega števila merilnikov. Kljub temu pa skupne koristi padajo s povečanjem števila merilnikov nad določeno mejo ($N=10$).
- povečanje učinkovitosti z združevanjem podatkov iz različnih merilnikov poveča učinkovitost v primerjavi z le enim merilnikom za 15-25 %, odvisno od načina združevanja. Največja učinkovitost glede na osnovni merilnik je dosežena, v kolikor je natančnost zaznave osnovnega merilnika v območju med 0.6 in 0.75 (Slika 6-9).



Slika 6-9: Predvidene koristi združevanja podatkov glede na število in natančnost merilnikov (Nahin in Pokoski, 1980)

Figure 6-9: Expected benefits of data fusion in relation to the number and accuracy of detectors (Nahin and Pokoski, 1980)

Glavne slabosti združevanja podatkov so naslednje:

- potreba po minimalnem številu in minimalni kvaliteti verodostojnih merilnikov,
- potreba po predhodnem poznavanju kvalitete podatkov iz vsakega posameznega merilnika, s čimer lahko bistveno izboljšamo kvaliteto rezultatov,
- popoln združevalni operator ne obstaja, vsak ima svoje prednosti in slabosti,

- splošno pomanjkanje podatkov za učenje algoritmov,
- dinamičen proces, pri katerem je težko evalvirati rezultate, saj se uspešnost metode postopoma izboljšuje z učenjem.

6.5 Regresijska analiza

Regresijska analiza kot veja statistike vključuje številne metode za modeliranje odnosa med odvisno spremenljivko in eno ali več neodvisnimi spremenljivkami. Z uporabo regresijske analize ugotovimo kako se spreminja vrednost odvisne spremenljivke v primeru, ko se ena od spremenljivk spreminja, ostale neodvisne spremenljivke pa ostanejo nespremenjene. Cilj modeliranja je določitev regresijske funkcije na podlagi katere iz neodvisnih spremenljivk določimo odvisno spremenljivko. Pri regresijski analizi ocenjujemo tudi spremembe odvisne spremenljivke okoli regresijske funkcije, ki jih imenujemo porazdelitev verjetnosti.

V uporabi so različne metode regresijske analize, ki jih v grobem lahko delimo na parametrične in neparametrične. Pri parametričnih metodah je regresijska funkcija določena iz končnega števila neznanih parametrov, ki jih določimo iz podatkov, med najbolj znane parametrične metode pa spada linearna regresija. Pri neparametričnih metodah regresije je lahko regresijska funkcija definirana kot niz funkcij, ki lahko definirajo neskončno-dimenzionalni prostor.

6.5.1 Linearna regresija več spremenljivk

Linearna regresija več spremenljivk oz. multipla linearna regresija predstavlja modeliranje odvisnosti med dvema ali več spremenljivkami X_j , $j=1, \dots, k$ in slučajno spremenljivko Y , z uporabo linearne enačbe, ki se najbolj prilega opazovanim podatkom. Linearni regresijski model predpostavlja, da je povezava med odvisno spremenljivko in neodvisnimi spremenljivkami linearna. Ta povezava se modelira preko naključne spremenljivke ε , ki dodaja šum v linearno zvezo med odvisno in neodvisnimi spremenljivkami. Linearni model zapišemo z enačbo:

$$Y = \hat{Y} + \varepsilon = b_0 + b_1X_1 + b_2X_2 + \dots + b_kX_k + \varepsilon \quad (6-1)$$

pri čemer so:

b_0, b_1, \dots, b_k = regresijski koeficienti,

ε = odstopanje od modela (porazdeljen normalno s pričakovano vrednostjo 0 in standardno deviacijo σ) v literaturi pogosto imenovan tudi kot šum, rezidual itd.

Vzorec je običajno podan z vrednostmi neodvisnih spremenljivk X_{ij} ter ustreznimi vrednostmi odvisnih spremenljivk Y_i . Za posamezni element vzorca X_{ij} , Y_i velja regresijska enačba:

$$Y_i = b_0 + b_1X_{i1} + b_2X_{i2} + \dots + b_kX_{ik} + \varepsilon_i = b_0 + \sum_{j=1}^k b_jX_{ij} + \varepsilon_i \quad (6-2)$$

za $i = 1, \dots, n$; $j = 1, \dots, k$ in $n \geq k$

Odstopanje od modela predstavlja razliko med dejansko vrednostjo odvisne spremenljivke Y_i in vrednostjo odvisne spremenljivke \hat{Y}_i , ocenjene z modelom regresije:

$$\varepsilon_i = Y_i - \hat{Y}_i \quad (6-3)$$

V kolikor imamo k neodvisnih spremenljivk in za odvisno spremenljivko n vzorčnih podatkov dobimo matriko:

$$\begin{bmatrix} X_{11} & X_{12} & \dots & X_{1k} & Y_1 \\ X_{21} & X_{22} & \dots & X_{2k} & Y_2 \\ \vdots & \vdots & & \vdots & \vdots \\ X_{n1} & X_{n2} & \dots & X_{nk} & Y_n \end{bmatrix} \quad (6-4)$$

za katero lahko s pomočjo zgornjega modela zapišemo enačbe:

$$\begin{aligned} Y_1 &= b_0 + b_1 X_{11} + b_2 X_{12} + \dots + b_k X_{1k} + \varepsilon_1 \\ Y_2 &= b_0 + b_1 X_{21} + b_2 X_{22} + \dots + b_k X_{2k} + \varepsilon_2 \\ &\quad \vdots \\ Y_n &= b_0 + b_1 X_{n1} + b_2 X_{n2} + \dots + b_k X_{nk} + \varepsilon_n \end{aligned} \quad (6-5)$$

Napake $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ medsebojno niso povezane, zato je njihova kovarianca enaka 0.

Ta funkcija določa hiperravnino v $k+1$ razsežnem prostoru. Koeficienti b_0, b_1, \dots, b_k so regresijski koeficienti, za katere določimo ocene iz podatkov vzorca tako, da so odstopanja dejanskih vrednosti Y_i od modela čim manjša. Za ocene $\hat{b}_0, \hat{b}_1, \dots, \hat{b}_k$ parametrov b_0, b_1, \dots, b_k obstaja veliko število metod, ki se razlikujejo po računski zahtevnosti algoritmov, obstoju rešitve, robustnosti itd. Najpogosteje uporabljena metoda za ocenjevanje parametrov je metoda najmanjših kvadratov, ki je preprosta in računsko enostavna, poleg tega pa je vgrajena tudi v večini programov s statističnimi orodji kot npr. Mathematica ter Oracle za poizvedbe nad bazami podatkov. Metoda minimizira vsoto kvadratov ostankov ε , kar pomeni, da moramo poiskati minimum funkcije:

$$\begin{aligned} F(b_0, \dots, b_k) &= \sum_{i=1}^n \varepsilon_i^2 \\ &= \sum_{i=1}^n \left(Y_i - b_0 - \sum_{j=1}^k b_j X_{ij} \right)^2 \\ &= \sum_{i=1}^n (Y_i - b_0 - b_1 X_{i1} - \dots - b_k X_{ik})^2 \end{aligned} \quad (6-6)$$

Ocene $\hat{b}_0, \hat{b}_1, \dots, \hat{b}_k$ določimo tako, da poiščemo ekstrem funkcije. Minimum te funkcije poiščemo tako, da jo odvajamo po b_0, b_1, \dots, b_k ter postavimo pogoj, da so vsi te odvodi enaki 0.

$$\begin{aligned}
 \frac{\partial F}{\partial b_0} &= (-2) \sum_{i=1}^n [Y_i - (\hat{b}_0 + \hat{b}_1 X_{i1} + \dots + \hat{b}_k X_{ik})] = 0 \\
 \frac{\partial F}{\partial b_1} &= (-2) x_{i1} \sum_{i=1}^n [Y_i - (\hat{b}_0 + \hat{b}_1 X_{i1} + \dots + \hat{b}_k X_{ik})] = 0 \\
 &\vdots \\
 \frac{\partial F}{\partial b_k} &= (-2) x_{ik} \sum_{i=1}^n [Y_i - (\hat{b}_0 + \hat{b}_1 X_{i1} + \dots + \hat{b}_k X_{ik})] = 0
 \end{aligned} \tag{6-7}$$

Po preureditvi zgornjih enačb dobimo sistem $k+1$ linearnih enačb za oceno $k+1$ neznanih ocen parametrov $\hat{b}_0, \hat{b}_1, \dots, \hat{b}_k$.

$$\begin{aligned}
 \hat{b}_0 n + \hat{b}_1 \sum_{i=1}^n X_{i1} + \hat{b}_2 \sum_{i=1}^n X_{i2} + \dots + \hat{b}_k \sum_{i=1}^n X_{ik} &= \sum_{i=1}^n Y_i \\
 \hat{b}_0 \sum_{i=1}^n X_{i1} + \hat{b}_1 \sum_{i=1}^n X_{i1}^2 + \hat{b}_2 \sum_{i=1}^n X_{i2} X_{i1} + \dots + \hat{b}_k \sum_{i=1}^n X_{ik} X_{i1} &= \sum_{i=1}^n Y_i X_{i1} \\
 \vdots &\vdots \\
 \hat{b}_0 \sum_{i=1}^n X_{ik} + \hat{b}_1 \sum_{i=1}^n X_{i1} X_{ik} + \hat{b}_2 \sum_{i=1}^n X_{i2} X_{ik} + \dots + \hat{b}_k \sum_{i=1}^n X_{ik}^2 &= \sum_{i=1}^n Y_i X_{ik}
 \end{aligned} \tag{6-8}$$

Ta sistem enačb lahko zapišemo tudi v matrični obliki:

$$\begin{bmatrix} n & \sum X_{i1} & \dots & \sum X_{ik} \\ \sum X_{i1} & \sum X_{i1}^2 & \dots & \sum X_{ik} X_{i1} \\ \vdots & \vdots & \ddots & \vdots \\ \sum X_{ik} & \sum X_{i1} X_{ik} & \dots & \sum X_{ik}^2 \end{bmatrix} \cdot \begin{bmatrix} \hat{b}_0 \\ \hat{b}_1 \\ \vdots \\ \hat{b}_k \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum Y_i X_{i1} \\ \vdots \\ \sum Y_i X_{ik} \end{bmatrix} \tag{6-9}$$

S tem dobimo sistem $k+1$ linearnih enačb s $k+1$ neznankami.

6.5.2 Preverjanje uspešnosti izvedene linearne regresije

Ko je regresijski model oz. funkcija določena, moramo preveriti, kako se model prilega dejanskim podatkom in ugotoviti, kakšne so statistične značilnosti ocenjenih parametrov. S tem preverimo uspešnost izvedene regresije. Ena izmed metod testiranja prileganja modela dejanskim podatkom je določitev determinacijskega koeficienta, ki meri moč povezave med odvisno in neodvisnimi spremenljivkami na podlagi vzorca odstopanj od modela. Preizkušanje

domnev izvedemo s testom F za prileganje regresijske funkcije, ter s testi T za prileganje posameznih koeficientov.

6.5.2.1 Določitev determinacijskega koeficienta – delež pojasnjene variance

Kolikšen delež variance odvisne spremenljivke Y je pojasnjen z linearnim modelom nam pove determinacijski koeficient R^2 . Determinacijski koeficient definiramo kot kvocient pojasnjene in celotne variance, pri čemer je skupna varianca Y vsota pojasnjene variance spremenljivke $\hat{Y} = b_0 + b_1X_1 + \dots + b_kX_k$ in nepojasnjene variance spremenljivke ε .

$$R^2 = \frac{\sigma_{\hat{Y}}^2}{\sigma_Y^2} \quad (6-10)$$

pri čemer je:

R^2 = determinacijski koeficient,

$\sigma_{\hat{Y}}^2$ = pojasnjena varianca spremenljivke \hat{Y} ,

σ_Y^2 = celotna varianca.

Determinacijski koeficient zavzema vrednosti med 0 in 1. Čim večja je vrednost determinacijskega koeficienta, večji delež variabilnosti odvisne spremenljivke Y je opisan z linearnim modelom spremenljivk. Vrednost determinacijskega koeficienta tako odraža delež šuma v podatkih, majhna vrednost determinacijskega koeficienta pa lahko pomeni, da v regresijskem modelu niso zajete spremenljivke (faktorji), ki na obnašanje regresijskega modela pomembno vplivajo.

Ker bi se v primeru dodajanja novih neodvisnih spremenljivk v splošnem delež pojasnjene variance povečeval, moramo v izračunu uporabiti popravljen vrednost determinacijskega koeficienta glede na število spremenljivk v modelu. Razlaga popravljenega koeficienta determinacije je enaka kot pri osnovnem determinacijskem koeficientu, le da je ta popravljen glede na število dodatnih spremenljivk v modelu:

$$R^2_{\text{popravljen}} = 1 - (1 - R^2) \frac{n - 1}{n - k - 1} \quad (6-11)$$

pri čemer je:

$R^2_{\text{popravljen}}$ = popravljen determinacijski koeficient,

R^2 = determinacijski koeficient,

n = velikost vzorca,

k = število ocenjenih parametrov.

6.5.2.2 Ocena standardne napake regresijskega modela

Standardna napaka regresijskega modela meri razpršenost točk okoli regresijske premice. Standardno napako izračunamo po naslednji enačbi:

$$\sigma_{\varepsilon} = \sqrt{\frac{\sum \varepsilon_i^2}{n - k - 1}} \quad (6-12)$$

pri čemer je:

σ_{ε} = standardna napaka regresijskega modela,

ε_i = naključni vplivi (odstopanje od modela),

n = velikost vzorca,

k = število ocenjenih parametrov.

6.5.2.3 Preizkušanje domneve o linearni neodvisnosti spremenljivk

Nazadnje preizkusimo še domnevo o linearni neodvisnosti spremenljivk X_i in Y , s katero preverimo ali so spremenljivke X_i in Y statistično značilno linearno odvisne oz. ali X_i statistično značilno vplivajo na Y . Ničelna hipoteza v tem primeru pravi, da linearni model ni ustrezen oz. da X_i ne vplivajo linearno na Y .

Preizkušanje domnev izvedemo s testom F . Pri tem testiramo model kot celoto, in v kolikor je po rezultatu testa F za model kot celoto statistično značilno ustrezen, v nadaljevanju uporabimo teste T za ugotavljanje značilnosti vplivov posameznih neodvisnih spremenljivk X_i , kjer za vsako neodvisno spremenljivko izvedemo po en test T .

Pri testu F najprej postavimo ničelno in alternativno hipotezo:

$H_0: b_0 = b_1 = b_2 = \dots = b_k = 0$

H_1 : najmanj eden izmed parametrov ni enak 0

Iz podatkov vzorca izračunamo testno statistiko F :

$$F = \frac{\text{pojasnjena odstopanja}}{\text{nepojasnjena odstopanja}} = \frac{\text{odstopanja med razredi}}{\text{odstopanja znotraj razredov}} \quad (6-13)$$

Pojasnjena odstopanja oz. odstopanja med razredi izračunamo:

$$MSA = \frac{\sum_{i=1}^{n_i} n_i (\bar{Y}_i - \bar{Y})^2}{K - 1} \quad (6-14)$$

pri čemer je:

\bar{Y}_i = srednja vrednost i -tega razreda,
 \bar{Y} = srednja vrednost vseh podatkov,
 n_i = število podatkov i -tega razreda,
 K = število razredov.

Nepojasnjena odstopanja oz. odstopanja znotraj razredov izračunamo:

$$MSE = \frac{\sum_{ij}(Y_{ij} - \bar{Y}_i)^2}{N - K} \quad (6-15)$$

pri čemer je:

Y_{ij} = j -to opazovanje i -tega razreda,
 N = število vseh podatkov,
 K = število razredov.

Statistiko F lahko izračunamo tudi s pomočjo determinacijskega koeficienta po naslednji enačbi:

$$F = \frac{MSA}{MSE} = \frac{N - K - 1}{K} \cdot \frac{R^2}{1 - R^2} \quad (6-16)$$

Vrednost statistike F v primeru izračuna z enim od statističnih programov razberemo iz preglednice ANOVA.

Ničelno hipotezo zavrnilo, v kolikor pri danem tveganju α velja $F > F_{\alpha; k; n-k-1}$, kjer je F_{α} kritična vrednost statistike F . V kolikor ničelno hipotezo zavrnilo, trdimo, da so parametri b_i statistično značilno različni od 0 in zato vplivajo na vrednost odvisne spremenljivke Y .

Značilnost vplivov posameznih neodvisnih spremenljivk preverimo z uporabo testa T . Tudi tu najprej postavimo ničelno in alternativno hipotezo:

$H_0: b_i = 0$

$H_1: b_i \neq 0$

Ničelna hipoteza tukaj pravi, da vključitev izraza $b_i X_i$ v regresijsko enačbo dodatno ne pojasni variabilnosti med podatki.

Vrednost statistike t z $n - k - 1$ prostostnimi stopnjami izračunamo po enačbi:

$$t = \frac{(\hat{b}_i - b_i)}{\sigma_{\varepsilon} \sqrt{|c_{ii}|}} = \frac{(\hat{b}_i - b_i)}{\sigma_{\varepsilon} \sqrt{\frac{n|c_{ii}|}{n - k - 1}}} \quad (6-17)$$

pri čemer je:

\hat{b}_i = ocena i -tega regresijskega koeficienta,

b_i = i -ti regresijski koeficient,
 σ_ε = standardna napaka regresijskega modela,
 c_{ii} = element v i -ti vrstici in i -tem stolpcu inverzne matrike $(\mathbf{X}^T\mathbf{X})^{-1}$,
 n = velikost vzorca,
 k = število ocenjenih parametrov.

Vrednost statistike t v primeru izračuna z enim od statističnih programov razberemo iz tabele ANOVA.

Ničelno hipotezo zavrnemo, v kolikor je $|t| > t_{\alpha;n-k-1}$. V kolikor ničelno hipotezo zavrnemo, trdimo, da je parameter b_i statistično značilno različen od 0, kar pomeni, da sta spremenljivki X_i in Y statistično značilno linearno povezani.

6.5.3 Interpolacija in ekstrapolacija

Uporabljen model regresije napove obnašanje modela in vrednosti odvisne spremenljivke Y na podlagi izmerjenih in zato znanih vrednosti spremenljivk X . V realnih okoliščinah se pogosto zgodi, da nas zanimajo vrednosti znotraj intervala znanih vrednosti neodvisne spremenljivke in tudi zunaj tega intervala.

Napoved modela znotraj intervala vrednosti neodvisne spremenljivke X imenujemo interpolacija, napoved modela izven intervala vrednosti neodvisne spremenljivke X pa ekstrapolacija. Uporabnost ekstrapolacije je v veliki meri odvisna od predpostavk regresijskega modela. Posebno pozornost moramo posvetiti uporabi modela pri večji oddaljenosti od intervala merjenih neodvisnih spremenljivk X .

Interpolacija in ekstrapolacija sta primerni pri aplikacijah, ki delujejo v trenutnem času, učenje algoritma pa je bilo izvedeno na testnih podatkih. V takih primerih s testnimi podatki ne uspemo zajeti vseh situacij, do katerih v realnih razmerah lahko pride. To pomeni, da moramo pogosto vrednosti interpolirati med znanimi vrednostmi neodvisne spremenljivke, v primeru izrednih dogodkov, ki jih v fazi učenja algoritma nismo zajeli pa občasno tudi do situacij, kjer moramo vrednosti napovedati izven intervala znanih vrednosti neodvisne spremenljivke, torej z ekstrapolacijo. V primerih ekstrapolacije moramo biti še posebej previdni, saj nam algoritem lahko vrne napačne rezultate.

6.6 Učenje algoritma

»Učenje opredeljujemo kot napredek dejavnosti po izkušnji.«

- Anton Trstenjak

Za zagotovitev optimalnega delovanja algoritma za združevanje podatkov iz ocenjene točkovne in neposredne linijske meritve je potrebno učenje algoritma. Učenje algoritma je predpogoj vsakega inteligentnega sistema. Naloga učenja algoritma je iz množice vzorcev z znanimi vrednostmi neodvisnih spremenljivk X_i in odvisne spremenljivke Y_i izračunati zvezno funkcijo, ki jo lahko uporabimo za določanje vrednosti regresijske spremenljivke novih primerov. Osnovna naloga algoritma je ugotoviti pomembnost neodvisnih spremenljivk za podan učni

primer. V fazi učenja algoritem pridobiva znanje na podlagi izkušenj pri čemer išče pravila v učnih podatkih, kar kasneje zagotavlja njegov optimalen odziv tudi v primerih, ki niso sodelovali pri učenju. Naučen algoritem poskuša razlagati podatke in se zato lahko uporabi za odločanje pri opazovanju modeliranega procesa v bodočnosti.

V primeru uporabe linearne regresije več spremenljivk na učni množici izračunamo linearni model, ki ga nato uporabimo za napovedovanje na podlagi vhodnih parametrov. Funkcija, ki jo dobimo pri učenju, je linearna kombinacija vseh atributov ali pa le podmnožice atributov.

6.6.1 Modeliranje prometnega toka s prometno simulacijo

Pri spremljanju obnašanja prometnega toka se ponavadi poslužujemo dveh pristopov. Prvi, najpogosteje uporabljen pristop za razpoznavanje karakteristik prometnega toka je njegovo merjenje. V realnih okoliščinah je to vse prej kot lahka naloga: obstajajo omejitve pri merilnih karakteristikah prometnega toka, nekaterih morda najbolj pomembnih karakteristik prometnega toka se ne da neposredno izmeriti, izvedene meritve včasih niso reprezentativne za celoten prometni tok, prostorska pokritost odseka je omejena, v času merjenja ne zajamemo vseh izrednih situacij, ki vplivajo na prometni tok itd. Drugi alternativni pristop je modeliranje: ob znanih lastnostih voznikov, ob znanih karakteristikah avtocestnega odseka in ob znani prometni obremenitvi napovemo obnašanje prometnega toka in s tem določimo karakteristike prometnega toka. Vendar tudi ta pristop ne predstavlja enostavne rešitve, saj je predhodno navedene lastnosti in karakteristike pogosto težko enolično ovrednotiti in opisati.

V zadnjem času je z razvojem računalnikov in računalniških programov prometno modeliranje postalo zelo popularno. Prometna simulacija je eno od orodij za optimizacijo projektnih rešitev in ureditev prometa brez nepotrebnih posegov v prometni režim. Uporaba simulacijskih orodij odpira možnosti preverjanja in vrednotenja različnih načinov vodenja prometa v računalniškem okolju brez posegov v prostor. Zmožnost hitrega procesiranja obsežne množice podatkov ter izboljšane vizualne možnosti prikaza (tudi 3D) omogočajo prikaz rezultatov kot npr. zamud, povprečne hitrosti, pretoki, potovalni časi itd. skoraj v trenutnem času. Kljub vsemu vloženemu trudu računalniških strokovnjakov in prometnih planerjev pa osnovne neznanke in problemi ostajajo, premostiti se jih da le s kalibracijo na posamezen konkreten primer, kar pa razblini sanje o široki uporabnosti modela za napoved obnašanja prometnega toka v času izrednih dogodkov, ki niso bili upoštevani v fazi kalibracije.

Prometne simulacije so v času učenja algoritma uporabljene kot pomoč pri generiranju obsežnega števila različnih izrednih situacij, do katerih v realnem svetu ne pride prav pogosto oz. bi morali na njihov pojav čakati dolgo časa. Na obravnavani trasi do različnih izrednih dogodkov sicer prihaja, niso pa prav pestri v raznolikosti in se večinoma ne dogajajo v času velikih prometnih obremenitev (npr. zapore in dela se izvajajo v času izven konice).

6.6.1.1 Mikroskopsko modeliranje

Za potrebe učenja algoritma in pripravo različnih scenarijev je bil uporabljen na števne podatke kalibriran makroskopski model obstoječega stanja, analize pa so se izvajale na ustrezno kalibriranem in validiranem mikroskopskem modelu. V fazi kalibracije modela, določimo vrednosti parametrov modela, pri čemer mora biti le-ta skladen z izmerjenimi vrednostmi na

terenu. Le ustrezno kalibriran model namreč lahko uporabimo za napovedovanje prometnih razmer in potovalnih časov pod drugačnimi robnimi pogoji. Z mikrosimulacijskim orodjem lahko simuliramo realne prometne situacije, različne prometne pretoke, različne kapacitete, potek avtoceste ter različne parametre, kot so tip vozil in voznikov, porazdelitev hitrosti, hitrostne omejitve itd. Mikroskopske simulacije nam omogočajo tudi, da so najugodnejše poti vozil določene ne le glede na prostorske spremenljivke kot so hitrost in kapaciteta posameznih odsekov, temveč tudi po modelu sledenja vozil, ki upošteva pospeške, pojemke, prepletanja, agresivne voznike, lastnosti vozila itd., pri čemer je obnašanje posameznega vozila odvisno tudi od položaja in hitrosti drugih vozil.

6.6.1.2 Simulirani scenariji

Z uporabo mikrosimulacijskega orodja smo simulirali večje število izrednih dogodkov kot npr. prometna nesreča, ki vodi v zaporo prehitevalnega pasu, zapora voznega pasu zaradi pokvarjenega tovornega vozila, kratkotrajna zapora predora itd. na različnih lokacijah vzdolž trase med Vranskim in Blagovico. Pri temu smo upoštevali zahtevo, da za pravilno učenje algoritma potrebujemo prisotnost izrednih dogodkov na vseh, točkovnim merilnikom pripadajočih pododsekih, saj je le tako zadoščeno pogoju spreminjanja neodvisne spremenljivke in posledično vrednosti regresijskega koeficienta, ki mora biti različen od nič. Pri lokaciji izrednega dogodka je pomembno ne le, kje na trasi se zgodi kar vpliva na to, kako hitro bo to vplivalo na neposredno izmerjen potovalni čas, temveč tudi na kolikšni razdalji gortočno in doltočno od merilnika se zgodi, kar ima vpliv na to, kako hitro bo padla hitrost na točkovnem merilniku in kako hitro bo točkovna ekstrapolacija zaznala naraščanje potovalnih časov.

Preglednica 6-1: Primer scenarijev za simulacije

Table 6-1: Traffic simulation scenarios

Stacionaža (m)	Odsek BCP	BCP (m)	Lokacija	Med SPISoma	Pas	Izredni dogodek in trajanje
500	0042	7700	Izvozna rampa Vransko	02D - 03D	VP	Nesreča vozni pas - 30 min
2400	0043	1700	Nadvoz iz regionalne ceste Vransko	03D - 04D	VP	Nesreča vozni pas - 30 min
4400	0043	3700	Začetek predora Ločica	04D - 05D	VP	Nesreča vozni pas - 30 min
4800	0043	4100	Predor Ločica	04D - 05D	VP	Nesreča vozni pas - 30 min
6200	0043	5500	Viadukt Ločica nad regionalno cesto	05D - 07D	VP	Nesreča vozni pas - 30 min
7300	0043	6600	Začetek predora Jasovnik	07D - 08D	VP	Nesreča vozni pas - 30 min
7900	0043	7200	V predoru Jasovnik	07D - 08D	VP	Nesreča vozni pas - 30 min
8400	0043	7700	V predoru Jasovnik	07D - 08D	VP	Nesreča vozni pas - 30 min
9000	0043	8300	Konec predora Jasovnik	07D - 08D	VP	Nesreča vozni pas - 30 min
9600	0043	8900	Pri podvozu	08D - 10D	VP	Nesreča vozni pas - 30 min


Stac (m)	Odsek	BCP (m)	Lokacija	Pas	Oznaka	Datum scenarija	Pretok (voz/h)	Izredni dogodek in trajanje
500	0042	7700	Izvozna rampa Vransko	VP	d1_50	1.6.2014	1000	Nesreča vozni pas - 30 min
					d1_75	2.6.2014	1500	Nesreča vozni pas - 30 min
					d1_100	3.6.2014	2000	Nesreča vozni pas - 30 min
					d1_140	3.6.14 10h		Nesreča vozni pas - 30 min
2400	0043	1700	Nadvoz iz regionalne ceste	VP	d2_50	4.6.2014	1000	Nesreča vozni pas - 30 min
					d2_75	5.6.2014	1500	Nesreča vozni pas - 30 min
					d2_100	6.6.2014	2000	Nesreča vozni pas - 30 min
					d2_140	6.6.14 10h		Nesreča vozni pas - 30 min

Prometne simulacije smo izvedli za različne vrednosti pretoka in sicer za:

- jutranjo konico s pretokom 2000 voz/h in deležem tovornih vozil 15 %,
- za povprečen pretok med dnevom 1000 voz/h in deležem tovornih vozil 25 % ter
- za popoldansko konico s pretokom 1500 voz/h in deležem tovornih vozil 20 %.

Iz prometnih simulacij smo dobili podatke o simuliranih potovalnih časih posameznih vozil med začetno in končno točko odseka izvajanja neposredne linijske meritve. Iz posameznih virtualnih točkovnih merilnikov na trasi pa smo dobili podatke o srednji prostorski hitrosti osebnih vozil, za določitev stopnje prometnega stanja na posameznem merilnem mestu pa še podatke o srednji prostorski hitrosti, pretoku ter gostoti vseh vozil.

Podrobnejša predstavitev simuliranih scenarijev, ki služijo le kot sredstvo za učenje algoritma, je izven okvira študije in zato ni podrobneje predstavljena.



Slika 6-10: Izsek iz simulacije
Figure 6-10: Simulation scenario

Podatke, pridobljene s simulacijo, smo obdelali skladno z algoritmi, predstavljenimi v poglavju »Izračun potovalnega časa iz neposrednih linijskih meritev« ter v poglavju »Posredna ocena potovalnega časa iz točkovne ekstrapolacije hitrosti«. Tako smo dobili reprezentativne vrednosti potovalnega časa iz neposredne linijske meritve ter reprezentativne vrednosti potovalnega časa iz točkovne ekstrapolacije hitrosti.

6.6.2 Ocenjevanje uspešnosti učenja

Linearna regresija več spremenljivk se na različnih področjih pogosto uporablja za oceno odvisne spremenljivke na podlagi neodvisnih spremenljivk. Kako uspešen je njen prenos v prometno inženirstvo, natančneje v algoritem za določitev trenutnega potovalnega časa z združevanjem potovalnih časov pridobljenih iz neposredne linijske meritve in točkovne ekstrapolacije hitrosti ugotovimo z eno od mer uspešnosti učenja algoritmov. Mere za ocenjevanje učenja so samo v pomoč, saj resnično vrednost algoritma ocenjujemo z njegovo uporabnostjo in natančnostjo v dejanski uporabi.

V realnih okoliščinah nas zanima predvsem, kako natančne bodo napovedane vrednosti odvisne spremenljivke, ki jih določi algoritem ter kako dobro se algoritem odziva na spremembe v potovalnih časih. Natančnost napovedi ponavadi preverjamo tako, da algoritem naučimo na podlagi učne množice podatkov, potem pa ga preverimo na podlagi testne množice. S takšnim postopkom se izognemo problemu, da se naučeni algoritem preveč prilega testnim primerom, kar bi vodilo k napačni napovedi v novih primerih. Iz tega sledi zahteva, da je učna množica reprezentativna podmnožica danega problema oz. da vsebuje kar se le da pestro paleto možnih dogodkov. V našem konkretnem primeru to zahteva, da so v fazi učenja algoritma zaznane motnje v prometnem toku in potovalnem času v različnih primerih na celotni trasi avtocestnega odseka oz. na vseh točkovnih merilnih mestih. V nasprotnem primeru namreč algoritem lahko točkovnemu merilniku, kjer ni bilo zaznanih nihanj, priredi vrednost regresijskega koeficienta nič.

Obstoječe študije kot merilo uspešnosti izvedene združitve podatkov iz neposredne meritve in posredne ocene po večini uporabijo le koren povprečne kvadratne napake glede na osnovni vir informacije. V naši študiji smo kot merilo za primerjavo dodali še korelacijski faktor kot merilo linearne povezanosti med napovedanim trenutnim, linijsko in točkovno določenim potovalnim časom ter potovalnim časom ob odhodu.

6.6.2.1 Koren povprečne kvadratne napake

V literaturi najdemo različne mere za analizo uspešnosti združevanja podatkov. Za zaznavanje velikih odstopanj od modela, se pravi v primerih, ko so nezaželena predvsem velika odstopanja od modela, se največkrat uporablja koren povprečne kvadratne napake. Koren povprečne kvadratne napake je definiran kot koren povprečnega kvadrata razlike med napovedanim trenutnim potovalnim časom in dejanskim potovalnim časom ob odhodu vozila (RMSE – root mean squared error):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n [TT_{napovedan} - TT_{dejanski}]^2} \quad (6-18)$$

pri čemer je:

$TT_{napovedan}$ = napovedan trenutni potovalni čas,

$TT_{dejanski}$ = dejanski potovalni čas ob odhodu vozila,

n = število izvedenih meritev potovalnega časa.

Koren povprečne kvadratne napake je v tej študiji uporabljen kot merilo odstopanja napovedanega trenutnega potovalnega časa od dejanskega potovalnega časa ob odhodu vozila.

Večina študij primerja rezultate pridobljene z združevanjem točkovne in linijske meritve z eno od linijskih meritev potovalnega časa ob prihodu vozila. Naša študija rezultate primerja s potovalnim časom ob odhodu vozila, ki predstavlja za voznika, ki vstopa na odsek izvajanja meritve merodajno informacijo.

6.6.2.2 Korelacijski koeficient

Korelacijski koeficient, imenovan tudi Pearsonov koeficient korelacije, je najpogosteje uporabljena mera linearne povezanosti dveh številskih spremenljivk. Koeficient lahko zavzame vrednosti med -1 in 1 . Izračunamo ga s kovarianco $C_{TT_{napovedan}TT_{dejanski}}$ in standardnimi odkloni obeh spremenljivk po naslednji enačbi:

$$\rho_{TT_{napovedan}TT_{dejanski}} = \frac{C_{TT_{napovedan}TT_{dejanski}}}{\sigma_{TT_{napovedan}} \cdot \sigma_{TT_{dejanski}}} \quad (6-19)$$

kjer je kovarianca mera linearne povezanosti med spremenljivkama in jo izračunamo po spodnji formuli:

$$C_{TT_{napovedan}TT_{dejanski}} = \frac{1}{N} \sum_{i=1}^N (TT_{napovedan,i} - \mu_{TT_{napovedan}}) \cdot (TT_{dejanski,i} - \mu_{TT_{dejanski}}) \quad (6-20)$$

pri čemer je

N = velikost vzorca,

$TT_{napovedan,i}$ in $TT_{dejanski,i}$ = vrednost i -te spremenljivke potovalnega časa,

$\mu_{TT_{napovedan}}$ in $\mu_{TT_{dejanski}}$ = aritmetična sredina posamezne spremenljivke potovalnega časa.

Pearsonov koeficient korelacije nam odgovori na vprašanje ali linearna povezanost med spremenljivkama sploh obstaja in če obstaja kako močna je linearna povezanost med spremenljivkama.

Kadar preverjamo obstoj linearne povezanosti, se moramo zavedati, da je povezanost lahko pozitivna ali negativna. Pozitivna povezanost obstaja takrat, kadar so vrednosti prve in druge spremenljivke visoke oz. nizke, tedaj je koeficient pozitiven. Negativna povezanost obstaja takrat, kadar so vrednosti prve spremenljivke visoke in vrednosti druge spremenljivke nizke oz. obratno, tedaj je koeficient negativen. Kadar ne gre niti za pozitivno niti za negativno povezanost med spremenljivkama rečemo, da spremenljivki med seboj nista linearno povezani. Tedaj je koeficient blizu 0.

6.7 Združevanje podatkov iz točkovnih in linijskih meritev za oceno trenutnega potovalnega časa

»Inteligenca nastane iz interakcije velikega števila preprostih procesnih enot.«

- David Rumelhart in John McClelland

V predhodnih poglavjih smo govorili, kako iz neposredno izmerjenih potovalnih časov in iz točkovnih meritev hitrosti dobiti reprezentativno vrednost potovalnega časa za posamezen pododsek oz. odsek. Ugotovljeno je bilo, da neposredno izmerjeni potovalni časi predstavljajo natančno meritev z dobro prostorsko pokritostjo, vsebujejo pa precejšnja odstopanja od srednje vrednosti ter določeno časovno zakasnitev glede na dejanski potovalni čas, ki ga bo porabil voznik, ki na odsek šele vstopa. V kolikor uporabimo tehnologijo z nizko stopnjo penetracije, se pojavi tudi problem v primeru, da izmerimo le majhen del prometnega toka, kar ne da nujno reprezentativnih rezultatov. Po drugi strani točkovni merilniki posredujejo podatke o celotnem prometnem toku, ki potuje po obravnavanem odseku avtoceste in omogočajo možnost določitve resničnega potovalnega časa z virtualno meritvijo za posamezno vozilo, še preden le-ta konča svoje potovanje. Vendar so te meritve lahko nenatančne, vprašljiva pa je tudi njihova prostorska ponazoritev v primeru velike razdalje med točkovnimi merilniki, saj hitrost izmerijo le na preseku avtoceste in ne na celotnem pododseku. Tako na eni strani neposredno izmerjen potovalni čas predstavlja natančno informacijo s časovno zakasnitvijo, na drugi strani pa posredna ocena iz točkovnih meritev hitrosti predstavlja takojšnjo informacijo, toda z manjšo prostorsko natančnostjo.

Na podlagi vseh zgoraj opisanih dejstev in očitne dopolnilnosti obeh meritev se ponudi ideja o združitvi točkovnih in linijskih meritev ter premostitev napak, ki jih povzroči posamezna od metod za zagotovitev natančne ocene potovalnega časa za voznika, ki pravkar vstopa na odsek izvajanja meritve.

V primerih, ko imamo na voljo različne tehnologije za pridobivanje prometnih podatkov, nehomogene podatke z izmerjenimi različnimi spremenljivkami, različne algoritme z različnimi natančnostmi, različno prostorsko vplivno območje posameznega merilnika podatkov in različne časovne okvirje, imamo ugodne pogoje za vzpostavitev sistema združevanja podatkov. Vse predhodno opisano vodi k ideji o dopolnilnosti obeh meritev in implementaciji metodologije ter algoritma za združevanje podatkov, z namenom združitve ugodnih lastnosti posamezne meritve v kombinacijo z večjo natančnostjo. Namen združevanja podatkov je kratkoročna napoved potovalnega časa iz trenutno dostopnih najnovejših točkovnih podatkov in iz izmerjenih preteklih linijskih podatkov.


Ob ideji združevanja podatkov iz različnih virov se nam postavijo tudi številna vprašanja. Kako natančno vsak posamezen sistem določi potovalni čas glede na drugega? Ali nam bo združevanje podatkov iz dveh virov prineslo opazne koristi in bo poplačalo trud vložen v implementacijo algoritma? Ali je izbrana metoda združevanja podatkov dovolj uspešna? Ali je algoritem združevanja podatkov dovolj robusten za vgradnjo v resnične okoliščine?

Odgovore na vsa zgornja vprašanja bo dala študija posameznih značilnosti primerov.

6.7.1 Prostorska in časovna poravnava


Pri združevanju podatkov o potovalnem času, pridobljenem iz neposredne linijske meritve in točkovne ekstrapolacije hitrosti združujemo podatke iz virov z različno prostorsko pokritostjo in različnim intervalom posodabljanja informacije, zaradi česar je potrebna tako prostorska kot tudi časovna poravnava obeh podatkov.

V našem primeru odsek neposredne linijske meritve pokriva prostorski odsek med lokacijama SPIS 02D in SPIS 19D na odseku med Vranskim in Blagovico v smeri Ljubljane, na katerem je več točkovnih merilnih mest, tako da odseka linijske meritve in pododseki, katerim so pripisani točkovni podatki, ravno sovpadajo. To pomeni, da več pododsekov, katerim podatke pripisujejo točkovni merilniki ravno sestavlja celoten odsek, pokrit z neposredno linijsko izmerjenim potovalnim časom. S tem je zagotovljena prostorska poravnava obeh meritev.



Slika 6-11: Prostorska poravnava neposredne linijske meritve (zgoraj) in posredne ocene z ekstrapolacijo (spodaj) med Vranskim in Blagovico

Figure 6-11: Spatial alignment of measured travel time (above) and travel time estimated from point speed measurements (below)



Slika 6-12: Prostorska poravnava linijske in točkovnih meritev
Figure 6-12: Spatial alignment of section and point measurements

Poleg prostorske poravnave moramo izvesti tudi časovno poravnavo obeh meritev. Pri linijsko izmerjenih potovalnih časih je potreben daljši čas zajema podatkov, s čimer pridobimo statistično zanesljiv in reprezentativen vzorec. Poleg tega mora biti posodabljanje podatkov iz točkovnih merilnikov primerno kratko, da zaznamo nihanja v prometnem toku. Časovna poravnava se izvede na podlagi najkrajšega časovnega intervala posodabljanja, v našem primeru torej točkovne meritve, pri čemer podatek linijske meritve ostane konstanten, do naslednje posodobitve. Linijska meritev tako ostane konstantna med večkratnimi

posodobitvami točkovne meritve, kot je razvidno iz spodnje preglednice. V spodnji preglednici je prikazan primer, kjer Δt predstavlja časovni interval posodabljanja točkovne meritve, ΔT pa časovni interval posodabljanja linijske meritve, ki sta povezana z $\Delta T = 5\Delta t$ (osveževanje podatkov iz točkovnih meritev $\Delta t = 1$ min ter osveževanje podatkov in neposredne linijske meritve $\Delta T = 5$ min).

Preglednica 6-2: Prostorska in časovna poravnava podatkov
 Table 6-2: Data for the spatial and temporal alignment

		Ocena potovalnega časa					Prostorsko in časovno poravnani podatki	
		Prostor						
		točkovna	Pododsek i	Pododsek $i+1$...	Pododsek $i+n$		
Čas	ΔT	linijska	odsek (i,j)					
		Δt	točkovna	$TT_{i(t)}$	$TT_{i+1(t)}$...	$TT_{i+n(t)}$	$TT_{i(t)} + TT_{i+1(t)} + \dots + TT_{i+n(t)}$
			linijska	$tt_{AB(T)}$				
		Δt	točkovna	$TT_{i(t+1)}$	$TT_{i+1(t+1)}$...	$TT_{i+n(t+1)}$	$TT_{i(t+1)} + TT_{i+1(t+1)} + \dots + TT_{i+n(t+1)}$
			linijska	$tt_{AB(T)}$				
		Δt	točkovna	$TT_{i(t+2)}$	$TT_{i+1(t+2)}$...	$TT_{i+n(t+2)}$	$TT_{i(t+2)} + TT_{i+1(t+2)} + \dots + TT_{i+n(t+2)}$
			linijska	$tt_{AB(T)}$				
		Δt	točkovna	$TT_{i(t+3)}$	$TT_{i+1(t+3)}$...	$TT_{i+n(t+3)}$	$TT_{i(t+3)} + TT_{i+1(t+3)} + \dots + TT_{i+n(t+3)}$
			linijska	$tt_{AB(T)}$				
		Δt	točkovna	$TT_{i(t+4)}$	$TT_{i+1(t+4)}$...	$TT_{i+n(t+4)}$	$TT_{i(t+4)} + TT_{i+1(t+4)} + \dots + TT_{i+n(t+4)}$
			linijska	$tt_{AB(T)}$				
		Δt	točkovna	$TT_{i(t+5)}$	$TT_{i+1(t+5)}$...	$TT_{i+n(t+5)}$	$TT_{i(t+5)} + TT_{i+1(t+5)} + \dots + TT_{i+n(t+5)}$
			linijska	$tt_{AB(T+1)}$				

pri čemer je:

TT = potovalni čas ocenjen na podlagi točkovne ekstrapolacije hitrosti,

tt = potovalni čas iz neposredne linijske meritve.

6.7.2 Vhodni podatki algoritma za združevanje

Algoritem za določitev trenutnega potovalnega časa na podlagi potovalnega časa pridobljenega iz točkovne ekstrapolacije hitrosti in iz neposredne linijske meritve podatke pridobiva iz točkovnih merilnikov parametrov prometnega toka ter iz neposredne linijske meritve.

6.7.2.1 Ocena trenutnega potovalnega časa iz točkovne ekstrapolacije hitrosti

Iz točkovnih merilnikov določimo na podlagi hitrosti osebnih vozil ob upoštevanju nihanj in uporabi glajenja reprezentativno vrednost srednje prostorske hitrosti, iz katere z modificirano metodo odsekoma konstantne ekstrapolacije ocenimo vrednost potovalnega časa na posameznemu merilniku pripadajočemu pododseku. Iz vseh posameznih pododsekov, ki skupaj tvorijo celoten odsek, dobimo trenutne potovalne čase na pododsekih, pridobljene s točkovno ekstrapolacijo hitrosti. Seštevek vseh trenutnih potovalnih časov na posameznih pododsekih nam da trenutni potovalni čas na odseku. Podrobnejši opis ocene trenutnega potovalnega časa je podan v poglavju »Posredna ocena potovalnega časa iz točkovne ekstrapolacije hitrosti«.

6.7.2.2 Določitev stopnje prometnega stanja iz točkovnih merilnikov

Točkovni merilniki nam poleg srednje prostorske hitrosti posredujejo tudi podatke o prometnem pretoku ter povprečni hitrosti vseh vozil, na podlagi česar lahko izračunamo gostoto prometnega toka na merilnem mestu. Iz podatkov o povprečni hitrosti in gostoti prometnega toka določimo stopnjo prometnega stanja. Prometna stanja (Pirc, 2008) so v tesni povezavi z nivoji uslug, ki predstavljajo kvalitativno merilo, ki opisuje vozne pogoje znotraj prometnega toka v smislu različnih merjenj, kot so hitrost, potovalni čas, svoboda manevriranja, motnje toka in udobnost.

Definiranih je pet prometnih stanj od stabilnega do zgoščenega, pri čemer stabilno prometno stanje (PS 0) predstavlja najboljše vozne pogoje, zgoščeno prometno stanje (PS 4) pa najslabše vozne pogoje:

- Stabilno prometno stanje (PS 0): Prosti prometni tok z velikimi hitrostmi, majhno gostoto prometa in popolno svobodo manevriranja. Vozniki lahko ohranjajo želeno hitrost z malo ali pa nič zamudami, zmanjšanje hitrosti je zanemarljivo.



- Pogojno stabilno prometno stanje (PS 1): Pogojno stabilen prometni tok, pri čemer sta tako hitrost kot možnost manevriranja omejena s povečanim številom vozil.



- Nestabilno prometno stanje (PS 2): Stanje v prometnem toku se približuje nestabilnemu toku z bistveno omejenimi hitrostmi in majhno možnostjo manevriranja.



- Nasičeno prometno stanje (PS 3): Stanje v prometnem toku je nestabilno zaradi vožnje v koloni, dosežena je velika gostota prometa, pretok vozil pa je enak prepustnosti. Maksimalni pretok pri nivoju PS 3 je enak kapaciteti.



- Zgoščeno prometno stanje (PS 4): Zgoščeno prometno stanje predstavlja t.i. »stop&go« prometni tok, kjer v skrajnih primerih lahko tako hitrost kot tudi pretok dosežeta vrednost nič.




Za določitev stopnje prometnega stanja na posameznem pododseku ceste uporabimo podatke iz točkovnih merilnikov sistema za nadzor in vodenje prometa. Prometni model kot modul sistema za nadzor in vodenje prometa na podlagi vhodnih prometnih parametrov izmerjenih na terenu, glede na razmere v prometnem toku, izračunava prometna stanja. Prometna stanja se na merilnem mestu določajo z izmerjenimi in preračunanimi prometnimi podatki za posamezen pododsek.

Prometni model sistema za nadzor in vodenje prometa na podlagi dejanskih razmer v prometnem toku (hitrost, pretok, gostota) izračuna pripadajoče prometno stanje, na podlagi katerega se izvajajo ukrepi vodenja prometa. Prometna stanja se izračunavajo v merilnem časovnem intervalu t , ki je nastavljen parameter (trenutna vrednost $t = 1$ min). V cikličnem intervalu 1 minute se preverja skupna hitrost vseh vozil v prometnem toku in gostota prometnega toka na merilnem mestu, na podlagi česar se določa stopnja prometnega stanja za posamezno merilno mesto glede na trenutne razmere v prometnem toku. Meje med prometnimi stanji (PS0-PS4) so določene na podlagi mejnih vrednosti hitrosti, pretoka in gostote v tesni povezavi z nivoji uslug, ki jih definira Highway Capacity Manual (2010).

Preglednica 6-3: Določitev stopnje prometnega stanja
 Table 6-3: Level of service estimation

Stopnja hitrosti	Hitrost (km/h)	Stopnja gostote	Gostota (voz/km)	G0	G1	G2	G3
------------------	----------------	-----------------	------------------	----	----	----	----

V0	0 - 30		G0	0 – 5		V0	PS0	PS4	PS4	PS4
V1	31 - 50		G1	6 – 40		V1	PS0	PS3	PS3	PS4
V2	51-60		G2	41 - 74		V2	PS0	PS0	PS2	PS3
V3	61-74		G3	75 in več		V3	PS0	PS0	PS2	PS2
V4	75 in več					V4	PS0	PS0	PS1	PS2



Slika 6-13: Grafični prikaz določitve stopnje prometnega stanja
 Figure 6-13: Level of service estimation

Potovalni čas je odvisen od hitrosti, le-ta pa od pretoka in gostote. Stopnja prometnega stanja nam v fazi učenja algoritma služi kot dopolnilna informacija o prometnih razmerah.

6.7.2.3 Določitev potovalnega časa po prihodu vozil iz neposredne linijske meritve

Iz vzorca neposredno izmerjenih potovalnih časov na odseku med dvema točkama (ki ravno sovpadata z začetno in končno točko odseka potovalnih časov iz točkovno ekstrapoliranih hitrosti) z uporabo metod robustne statistike za izločitev vpliva osamelcev, določimo reprezentativno vrednost potovalnega časa po prihodu vozil na odseku. Podrobnejši opis določitve potovalnega časa po prihodu vozil je podan v poglavju »Izračun potovalnega časa iz neposrednih linijskih meritev«.

Preglednica 6-4: Primer vhodnih podatkov v algoritmu
 Table 6-4: An example of algorithm input data

Čas	tt (min)	TT (min)	Pododsek 1		Pododsek j		Pododsek n	
			TT_1 (s)	PS_1	TT_j (s)	PS_j	TT_n (s)	PS_n
6:50	15.6	15.9	53	PS 0	47	PS 1	61	PS 0
6:51	15.6	15.9	53	PS 0	47	PS 1	61	PS 0
6:52	15.6	15.9	53	PS 0	47	PS 1	61	PS 0
6:53	15.6	16.7	53	PS 0	61	PS 3	61	PS 0
6:54	15.6	17.4	53	PS 0	72	PS 4	61	PS 0
6:55	16.2	17.9	53	PS 0	83	PS 4	61	PS 0
6:56	16.2	18.6	53	PS 0	90	PS 4	61	PS 0
6:57	16.2	19.5	53	PS 0	98	PS 4	61	PS 0
6:58	16.2	19.8	53	PS 0	112	PS 4	61	PS 0

pri čemer je:

tt = potovalni čas na odseku iz neposredne linijske meritve,

TT = potovalni čas na odseku ocenjen na podlagi točkovne ekstrapolacije hitrosti,

TT_i = potovalni čas na pododseku i ocenjen na podlagi točkovne ekstrapolacije hitrosti,

PS_i = stopnja prometnega stanja na pododseku i .

Kot izhodni podatek je določen potovalni čas ob odhodu vozila.

6.7.3 Metodologija združevanja podatkov

Algoritem za združevanje podatkov združi ocenjene potovalne čase pridobljene s točkovno ekstrapolacijo hitrosti iz posameznega pododseka (TT_i), informacijo o prometnem stanju znotraj posameznega pododseka (PS_i) ter neposredno linijsko izmerjen potovalni čas (tt). Časovno poravnavo izvedemo na podlagi najkrajšega časovnega intervala posodabljanja točkovne meritve, pri čemer podatek linijske meritve do naslednje posodobitve ostane konstanten. Izhodni podatek algoritma predstavlja trenutni potovalni čas ob odhodu, to je potovalni čas, ki bi ga voznik, ki ravno vstopa na odsek izvajanja meritve potreboval za prevoz obravnavanega odseka.

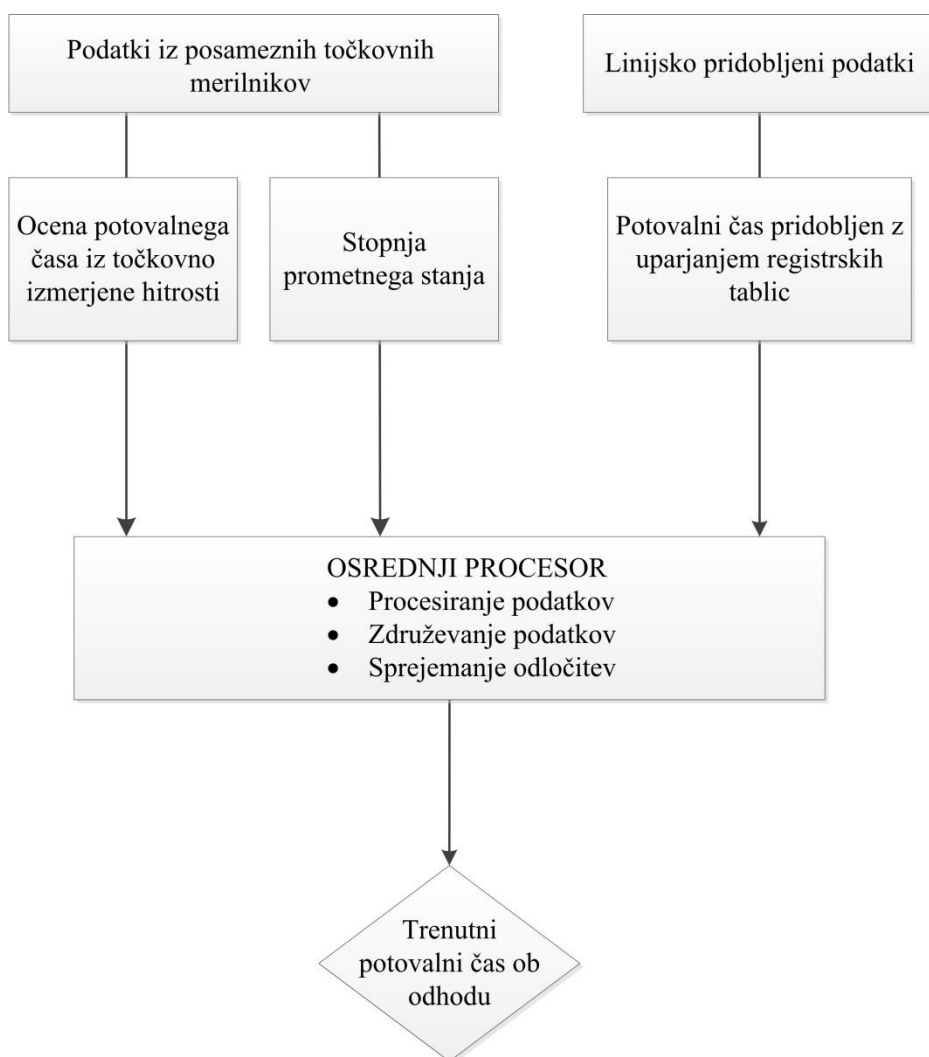
Preglednica 6-5: Vhodni podatki za algoritem združevanja potovalnih časov iz točkovnih (rumeno) in linijskih (oranžno) meritev ter primer podaljšanih potovalnih časov na sedmem pododseku (rdeče). Vsi potovalni časi so v sekundah, PS predstavlja informacijo o prometnem stanju.

Table 6-5: Input data for travel time data fusion algorithm combining travel time estimates based on speed extrapolation (yellow) and direct measurements (orange) and an example of prolonged travel times on 7.th subsection (red). All times are in seconds, PS is information about the level of service.

Pododsek	1		2		6		7		8		9		12		13		Linijski	TT ob
Čas	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	odhodu
3.12.2013 5:30	19	0	53	0	56	0	36	0	67	0	109	0	47	0	32	0	796	1003
3.12.2013 5:31	19	0	53	0	56	0	36	0	67	0	109	0	47	0	31	0	796	1003
3.12.2013 5:32	19	0	53	0	56	0	36	0	67	0	109	0	47	0	32	0	796	1003
3.12.2013 5:33	19	0	53	0	56	0	41	1	67	0	109	0	47	0	32	0	796	1003
3.12.2013 5:34	19	0	53	0	56	0	54	2	67	0	109	0	47	0	33	0	796	1003
3.12.2013 5:35	19	0	53	0	56	0	76	2	67	0	109	0	47	0	32	0	807	1235
3.12.2013 5:36	19	0	53	0	56	0	117	3	67	0	109	0	47	0	33	0	807	1235
3.12.2013 5:37	19	0	53	0	56	0	162	3	67	0	109	0	47	0	33	0	807	1235
3.12.2013 5:38	19	0	53	0	56	0	160	4	67	0	109	0	47	0	33	0	807	1235
3.12.2013 5:39	19	0	53	0	56	0	163	4	67	0	109	0	47	0	32	0	807	1235
3.12.2013 5:40	20	0	53	0	56	0	169	4	67	0	109	0	47	0	33	0	881	1236
3.12.2013 5:41	20	0	54	0	56	0	205	4	67	0	109	0	47	0	32	0	881	1236
3.12.2013 5:42	20	0	54	0	56	0	220	4	67	0	109	0	47	0	33	0	881	1236
3.12.2013 5:43	20	0	53	0	56	0	246	4	67	0	109	0	47	0	33	0	881	1236
3.12.2013 5:44	20	0	53	0	56	0	259	4	67	0	109	0	47	0	33	0	881	1236

Preglednica 6-5 prikazuje, da imamo za vsak interval zajema točkovnih meritev (v našem primeru 1 minuta) ter za vsak pododsek, ki je definiran z merilnim mestom, na voljo podatek o potovalnem času na tem odseku (*TT* označeno rumeno) ter podatek o stopnji prometnega stanja (*PS* označeno s sivo). Zaradi daljšega časovnega intervala združevanja podatkov iz linijske meritve, v našem primeru trajanja 5 minut, se podatek o linijskem potovalnem času (oranžno) posodablja na daljši časovni interval. Rezultat združevanja podatkov je trenutni potovalni čas ob odhodu (zeleno).

Slika 6-14 prikazuje shemo delovanja algoritma za združevanje podatkov. Uporabljena je bila centralizirana arhitektura združevanja podatkov, kar pomeni, da se enota združevanja nahaja v osrednjem procesorju, ki zbira podatke od različnih vrst in tipov merilnikov. Procesiranje in združevanje podatkov ter sprejemanje vseh ostalih odločitev izvedemo v tem osrednjem vozlišču.



Slika 6-14: Algoritem za združevanje podatkov
Figure 6-14: Data fusion algorithm

Med snovanjem algoritma smo izvedli učenje na podlagi različnih arhitektur. V prvem primeru (Preglednica 6-6, prva preglednica) smo uporabili le seštevek točkovnih meritev (TT) ter neposredno linijsko meritev (tt). V drugem primeru (Preglednica 6-6, druga preglednica) smo neposredno linijsko meritev (tt) združili s podatki o potovalnih časih na posameznih pododsekih (TT_i). Tretji primer (Preglednica 6-6, tretja preglednica) združi neposredno linijsko meritev (tt), seštevek točkovnih meritev (TT) ter informacijo o stopnji prometnega stanja na posameznem pododseku (PS_i). V četrtem, najbolj kompleksnem primeru, smo združili podatke o potovalnih časih (TT_i) in prometnih stanjih (PS_i) posameznih pododsekov ter neposredno linijsko meritev (tt) (Preglednica 6-6, četrta preglednica).

Preglednica 6-6: Različni vhodni podatki za učenje algoritma

Table 6-6: Different input data for algorithm learning

Ura	Točkovno	Linijsko	Ob odhodu
3.12.2013 5:30	740	745	729
3.12.2013 5:31	741	745	729
3.12.2013 5:32	743	745	729
3.12.2013 5:33	742	745	729
3.12.2013 5:34	742	745	729
3.12.2013 5:35	742	745	794
3.12.2013 5:36	740	745	794

Ura	TT	TT	TT	TT	TT	TT	TT	TT	TT	TT	TT	TT	TT	TT	Linijsko	Ob odhodu
3.12.2013 5:30	19	53	67	54	76	56	36	67	109	82	43	47	31	745	729	
3.12.2013 5:31	19	53	67	54	76	56	36	67	109	82	43	47	32	745	729	
3.12.2013 5:32	19	55	67	54	76	56	36	67	109	82	44	48	32	745	729	
3.12.2013 5:33	19	54	67	54	76	56	36	67	109	82	43	48	32	745	729	
3.12.2013 5:34	19	53	67	54	76	56	36	67	109	82	43	47	32	745	729	
3.12.2013 5:35	19	54	67	54	76	56	36	67	109	82	43	47	32	745	794	
3.12.2013 5:36	19	53	67	54	76	56	36	67	109	82	43	47	31	745	794	

Ura	PS	PS	PS	PS	PS	PS	PS	PS	PS	PS	PS	PS	PS	PS	Točkovno	Linijsko	Ob odhodu
3.12.2013 5:30	0	0	0	0	0	0	0	0	0	0	0	0	0	0	740	745	729
3.12.2013 5:31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	741	745	729
3.12.2013 5:32	0	0	0	0	0	0	0	0	0	0	0	0	0	0	743	745	729
3.12.2013 5:33	0	0	0	0	0	0	0	0	0	0	0	0	0	0	742	745	729
3.12.2013 5:34	0	0	0	0	0	0	0	0	0	0	0	0	0	0	742	745	729
3.12.2013 5:35	0	0	0	0	0	0	0	0	0	0	0	0	0	0	742	745	794
3.12.2013 5:36	0	0	0	0	0	0	0	0	0	0	0	0	0	0	740	745	794

Ura	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	TT	PS	Linijsko	Ob odhodu
3.12.2013 5:30	19	0	53	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	47	0	31	0	745	729
3.12.2013 5:31	19	0	53	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	47	0	32	0	745	729
3.12.2013 5:32	19	0	55	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	44	0	48	0	32	0	745	729
3.12.2013 5:33	19	0	54	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	48	0	32	0	745	729
3.12.2013 5:34	19	0	53	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	47	0	32	0	745	729
3.12.2013 5:35	19	0	54	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	47	0	32	0	745	794
3.12.2013 5:36	19	0	53	0	67	0	54	0	76	0	56	0	36	0	67	0	109	0	82	0	43	0	47	0	31	0	745	794

Obstoječe študije o združevanju podatkov za določevanje potovalnih časov so uporabile le podatke o potovalnih časih na posameznih pododsekih združene z neposredno linijsko izmerjenim potovalnim časom. Naš predlagani algoritem uporabi poleg potovalnih časov na posameznih pododsekih in neposredne linijske meritve tudi informacijo o stopnji prometnega stanja, ki kvalitativno opisuje vozne pogoje znotraj prometnega toka (Preglednica 6-6: Različni vhodni podatki za učenje algoritma, četrta preglednica).

6.8 Študija primerov

»Vrhovni sodnik vsake fizikalne teorije je eksperiment.«

- Lev Davidovič Landau in Juriš Rumer

Preverjanje algoritma za združevanje podatkov je potekalo med 1. decembrom 2013 in 1. novembrom 2014. Kljub sorazmerno dolgemu obdobju opazovanja je število izrednih dogodkov, ki so imeli za posledico opaznejše motnje prometnega toka, sorazmerno majhno. V tem času se je zgodilo šest izrednih dogodkov, ki so v nadaljevanju analizirani. Dodatni trije izredni dogodki so imeli za posledico preusmeritev prometa na vzporedno regionalno cesto. Ker algoritem točkovne ekstrapolacije hitrosti v primeru preusmeritve prometa z avtoceste ne izmeri nobenih vrednosti, algoritem v tem primeru kot merodajno vrednost vzame vrednost neposredno linijsko izmerjenega potovalnega časa. Te primeri v analizi niso upoštevani, saj so trivialni in so detajlneje obdelani v poglavju »Izračun potovalnega časa iz neposrednih linijskih meritev«.

Obstoječe študije so kot merilo uspešnosti združitve podatkov iz neposredne meritve in posredne ocene uporabile le koren povprečne kvadratne napake glede na osnovni vir informacije. V naši študiji smo kot merilo za primerjavo dodali še korelacijski faktor kot merilo linearne povezanosti s potovalnim časom ob odhodu. Koren povprečne kvadratne napake ter korelacijski faktor sta uporabljena kot merilo ujemanja napovedanega trenutnega potovalnega časa od dejanskega potovalnega časa ob odhodu vozila.

Večina študij primerja rezultate pridobljene z združevanjem točkovne in linijske meritve, z eno od linijskih meritev potovalnega časa ob prihodu vozila. Naša študija primerja rezultate s potovalnim časom ob odhodu vozila, ki za voznika, vstopajočega na odsek izvajanja meritve predstavlja merodajno informacijo.

Uspešnost delovanja algoritma smo preverili za različne arhitekture združevanja podatkov:

- naš predlagan algoritem $tt + TT_i + PS_i$ združi podatke o potovalnih časih (TT_i) in prometnih stanjih (PS_i) posameznih pododsekov ter neposredno linijsko meritev (tt);
- algoritem $tt + TT_i$ združi neposredno linijsko meritev (tt) s podatki o potovalnih časih na posameznih pododsekih (TT_i) – taka arhitektura združevanja podatkov je bila že večkrat obdelana v literaturi;
- algoritem $tt + PS_i$ združi neposredno linijsko meritev (tt), seštevek točkovnih meritev (TT) ter informacijo o stopnji prometnega stanja na posameznem pododseku (PS_i) – modifikacija našega predlaganega algoritma;
- algoritem $tt + TT$ združi neposredno linijsko meritev (tt) ter seštevek potovalnih časov točkovnih meritev iz posameznih pododsekov (TT) – arhitektura združevanja podatkov je bila že obdelana v literaturi.

6.8.1 Preverjanje uspešnosti izvedene linearne regresije

6.8.1.1 Določitev determinacijskega koeficienta

Determinacijski koeficient R^2 nam pove, kolikšen delež variance odvisne spremenljivke Y je pojasnjen z neodvisnimi spremenljivkami X_i . Determinacijski koeficient lahko zavzame vrednosti med 0 in 1, pri čemer večja kot je vrednost determinacijskega koeficienta, večji delež variabilnosti odvisne spremenljivke Y je opisan z neodvisnimi spremenljivkami X_i . Primerjava determinacijskega koeficienta za linearno regresijo z upoštevanjem stopnje prometnega stanja in brez upoštevanja stopnje prometnega stanja pokaže, da je večji delež variabilnosti odvisne spremenljivke Y opisan z neodvisnimi spremenljivkami X_i , v kolikor upoštevamo tudi informacijo o stopnji prometnega stanja.

Preglednica 6-7: Determinacijski koeficient

Table 6-7: Determination coefficient

Linearna regresija	R	$R_{popravljen}$
Z upoštevanjem prometnega stanja (PS)	0.852	0.851
Brez upoštevanja prometnega stanja (PS)	0.809	0.809


6.8.1.2 Ocena standardne napake regresijskega modela

Standardna napaka regresijskega modela meri razpršenost točk okoli regresijske premice. Primerjava standardne napake regresijskega modela za linearno regresijo z upoštevanjem stopnje prometnega stanja in brez upoštevanja stopnje prometnega stanja pokaže, da je standardna napaka regresijskega modela manjša, če upoštevamo tudi informacijo o stopnji prometnega stanja.

Preglednica 6-8: Standardna napaka regresijskega modela
Table 6-8: Standard deviation of the regression model

Linearna regresija	σ_{ε}
Z upoštevanjem prometnega stanja (<i>PS</i>)	82.6
Brez upoštevanja prometnega stanja (<i>PS</i>)	93.7

Grafikon standardiziranih vrednosti rezidualov nam pokaže uspešnost izvedene linearne regresije. Razpršenost večine vrednosti okoli regresijske premice se nahaja znotraj polovice standardne deviacije.



Slika 6-15: Standardizirane vrednosti rezidualov

Figure 6-15: Standardized residuals

6.8.1.3 Preizkušanje domneve o linearni neodvisnosti spremenljivk

Nazadnje preizkusimo še domnevo o linearni neodvisnosti spremenljivk X_i in Y , s katero preverimo ali so spremenljivke X_i in Y statistično značilno linearno odvisne oz. ali X_i statistično značilno vplivajo na Y v linearnem modelu.

Pri testu F najprej postavimo ničelno in alternativno hipotezo:

$$H_0: b_0 = b_1 = b_2 = \dots = b_k = 0$$

H_1 : najmanj eden izmed parametrov ni enak 0

Tveganje $\alpha = 5\%$

Vrednost statistike F razberemo iz preglednice ANOVA, pridobljene s programom Mathematica, s čimer ugotovimo ali linearni model statistično značilno pojasnjuje opazovanja.

Preglednica 6-9: Preglednica ANOVA

Table 6-9: ANOVA table

ANOVA - preizkus domneve o linearnem modelu

vir	SS	nps	MS	F	p-value
lin.reg.	4.05684×10^8	27	1.50253×10^7	2201.25	$2.5231956645 \times 10^{-4247}$
odstop.	7.04628×10^7	10323	6825.81		
skupaj	4.76146×10^8	10350			

Rezultat je statistika F s prostostnimi stopnjami (27, 10323). S tveganjem manjšim od 5 % lahko trdimo, da linearni model s 27 parametri pojasnjuje variabilnost med podatki.

Značilnost vplivov posameznih neodvisnih spremenljivk preverimo z uporabo testa T . Tudi tu najprej postavimo ničelne in alternativno hipotezo:

$$H_0: b_i = 0$$

$$H_1: b_i \neq 0$$

Tveganje $\alpha = 5\%$

Ničelna hipoteza tukaj pravi, da vključitev izraza $b_i X_i$ v regresijsko enačbo dodatno ne pojasni variabilnosti med podatki. Preglednica 6-10 kaže, da lahko v vseh primerih, kjer nastopa spremenljivka prometno stanje (PS) ničelno hipotezo zavrnilo in s tveganjem α trdimo, da je parameter b_i statistično značilno različen od 0, kar pomeni, da stopnja prometnega stanja statistično značilno pojasni variabilnost med podatki. Manjša kot je vrednost P , manjše je tveganje, da zavrnilo ničelno hipotezo in večji je vpliv posameznega parametra b_i . Posamezne spremenljivke pomembno pojasnjujejo variabilnost med podatki, razen v nekaterih primerih in sicer spremenljivka TT-potovalni čas na pododsekih 8 in 13, kar pa lahko pripišemo slučajnemu razporejanju izrednih dogodkov obravnavanih testnih scenarijev.

Preglednica 6-10: Določitev vrednosti P

Table 6-10: P-value determination

Pododsek	Spremenljivka	P-vrednost
1	TT	0.021663
	PS	$3.77567 \cdot 10^{-8}$
2	TT	0.0240362
	PS	$4.56001 \cdot 10^{-22}$
3	TT	$2.88381 \cdot 10^{-14}$
	PS	$2.6684 \cdot 10^{-20}$
4	TT	$8.60684 \cdot 10^{-6}$
	PS	$2.15583 \cdot 10^{-22}$
5	TT	0.0000259462
	PS	$1.9457 \cdot 10^{-60}$
6	TT	0.0472315
	PS	$1.13343 \cdot 10^{-6}$
7	TT	$3.48019 \cdot 10^{-12}$
	PS	$6.52311 \cdot 10^{-6}$
8	TT	0.431882
	PS	$1.0483 \cdot 10^{-95}$
9	TT	0.0000101407
	PS	$9.58747 \cdot 10^{-7}$
10	TT	0.000785819
	PS	$2.82181 \cdot 10^{-22}$
11	TT	0.000053645
	PS	0.000672733
12	TT	0.0513988
	PS	$2.30463 \cdot 10^{-11}$
13	TT	0.398209
	PS	0.0610254


6.8.2 Okvara tovornega vozila v predoru Trojane

3. decembra 2013 je ob 6:14 prišlo do okvare tovornega vozila na voznem pasu predora Trojane. Do dogodka je prišlo v času jutranje konice, kar je za posledico imelo nastanek zastoja in podaljšane potovalne čase.



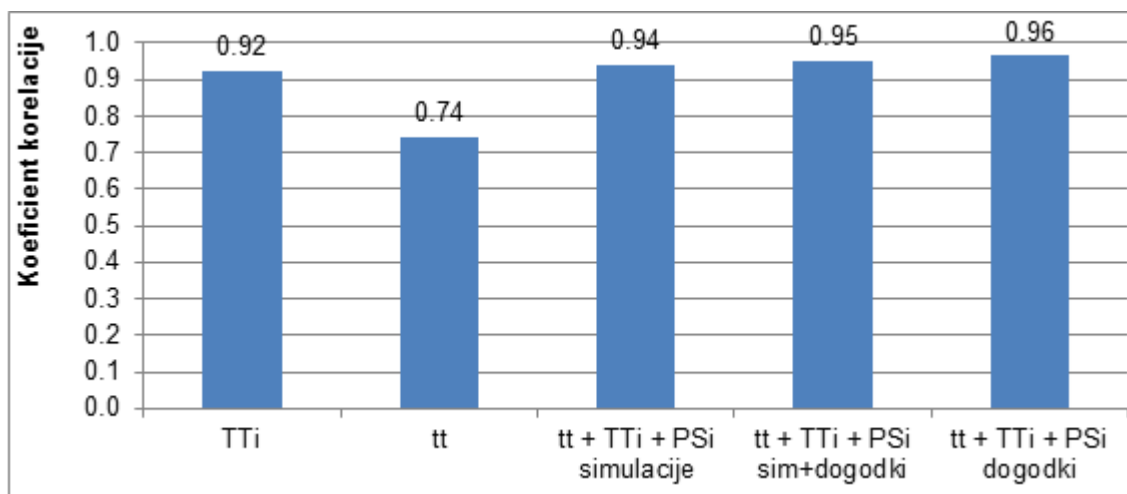
Slika 6-16: Nastanek zastoja pred predorom zaradi okvare tovornega vozila v predoru Trojane
 Figure 6-16: Congestion in front of the tunnel due to heavy vehicle breakdown in tunnel Trojane

Primerjava koeficienta korelacije za različne algoritme združevanja podatkov kaže (Slika 6-17) na močno pozitivno povezanost med potovalnimi časi, določenimi z različnimi algoritmi glede na potovalni čas ob odhodu. Z vidika koeficienta korelacije se kot najboljši izkaže predlagani algoritem z vrednostjo koeficienta korelacije 0.94. Koeficient korelacije med neposredno linijsko določenimi potovalnim časom in potovalnim časom ob odhodu ima skladno s predvidevanji najnižjo vrednost (0.74) kar je posledica časovne zakasnitve, saj moramo pri neposredno linijsko določenemu potovalnemu času počakati, da vozila končajo svoje potovanje, preden je informacija o potovalnem času na voljo.




Slika 6-17: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov
Figure 6-17: Comparing coefficient of correlation for different data fusion architectures

V kolikor učenje algoritma izvedemo samo na podatkih iz simulacije (Slika 6-18), dobimo slabši koeficient korelacije (0.94), kot če učenje izvedemo na učni množici, ki poleg podatkov iz simulacij upošteva tudi podatke o resničnih dogodkih (0.95). V začetni fazi delovanja algoritma za učenje uporabimo podatke iz simulacij, v kasnejših fazah delovanja algoritma pa le-ta deluje samo na podlagi učne množice dejanskih izrednih dogodkov. V izogib prevelikemu sovpadanju učne in validacijske množice so v nadaljevanju za učenje uporabljeni samo podatki iz prometnih simulacij.



Slika 6-18: Primerjava koeficienta korelacije za različne učne množice
Figure 6-18: Comparing coefficient of correlation for different learning sets

Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-19) pokaže, da združevanje podatkov iz različnih virov doprinese k natančnejši oceni potovalnega časa glede na potovalni čas pridobljen iz neposrednih linijskih meritev. Z uporabo združevanja podatkov po predlaganem algoritmu dosežemo 47% zmanjšanje napake pri določevanju potovalnega časa v primerjavi s potovalnim časom, določenem na podlagi neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom napako v primerjavi z obstoječimi algoritmi, ki ne upoštevajo informacije o stopnji prometnega stanja, zmanjšamo za 6 %.

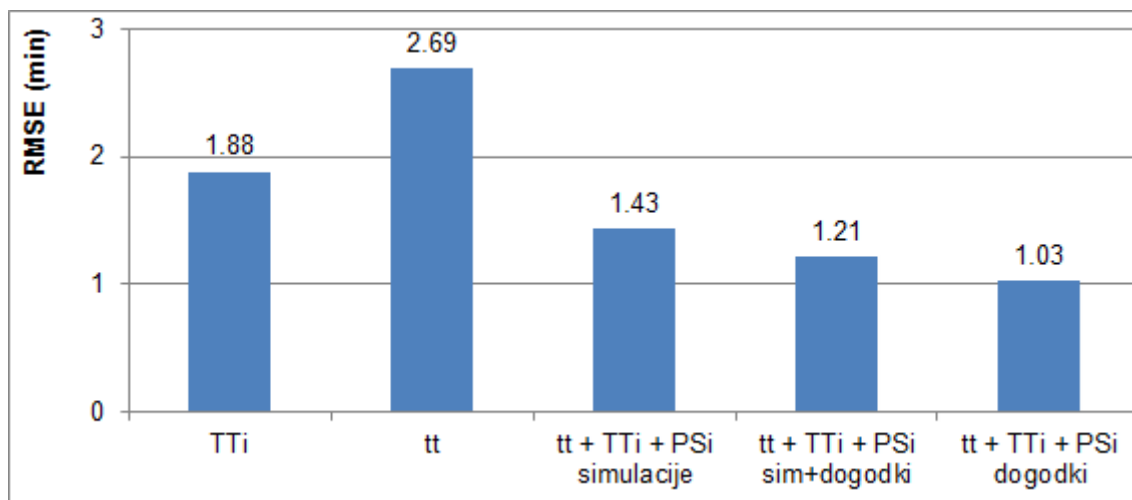


Slika 6-19: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-19: Comparing RMSE for different data fusion architectures


Primerjava korena povprečne kvadratne napake za različne učne množice, v primeru da učenje izvedemo na učni množici, ki poleg podatkov iz simulacij upošteva tudi podatke o resničnih dogodkih prinese 15% zmanjšanje napake v primerjavi z učenjem samo na podlagi simulacij

(Slika 6-20). To pomeni, da se je algoritem sposoben sproti učiti na podlagi zgodovinskih podatkov, kar bo v bodoče še bistveno izboljšalo njegovo delovanje.



Slika 6-20: Primerjava korena povprečne kvadratne napake (RMSE) za različne učne množice
Figure 6-20: Comparing RMSE for different learning sets


Primerjava koeficienta korelacije in povprečne kvadratne napake ne da popolnega odgovora glede primerjave posameznih algoritmov. Za primerjavo med algoritmi je pomembno tudi obnašanje posameznega algoritma in njegov odziv na podaljšane (ob začetku zastoja) in skrajšane (ob koncu zastoja) potovalne čase. Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu (Slika 6-21) pokaže problem časovne zakasnitve, t.j. čakanja da vozilo konča svoje potovanje, preden je informacija o potovalnem času na voljo. Ta zakasnitev je v splošnem enaka času, ki ga v danih razmerah za prevoz odseka potrebujejo vozila v opazovanem časovnem intervalu.



Slika 6-21: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu ter dobro viden vpliv časovne zakasnitve neposredno linijsko določenega potovalnega časa

Figure 6-21: Comparing measured travel time with departure based travel time with evident time-lag of the measured travel time

V kolikor na sliki prikažemo še potovalne čase določene s predlaganim algoritmom, ki za določitev reprezentativne vrednosti potovalnega časa poleg neposredne linijske meritve upošteva še točkovno določene parametre (točkovno ekstrapolirano hitrost in stopnjo prometnega stanja), opazimo precej boljše prileganje potovalnemu času ob odhodu (Slika 6-22). Kot je razvidno iz spodnje slike, so vozila, ki so na odsek vstopila ob 6:20, za prevoz odseka potrebovala nekoliko manj kot 21 minut. Algoritem, ki bi voznike obveščal le na podlagi neposredno linijsko izmerjenih potovalnih časov bi tako podaljšane potovalne čase zaznal šele ob 6:40, kar je 20 minut kasneje. Predlagan algoritem je podaljšane potovalne čase zaznal samo tri minute kasneje, torej ob 6:23. Nekaj minutna zakasnitev je posledica prihoda udarnega vala do prvega točkovnega merilnika hitrosti. Iz tega je razvidno, da gostejša razporeditev točkovnih merilnikov hitreje zazna nihanja v hitrosti in posledično hitrejšo reagiranje predlaganega algoritma na podaljšane potovalne čase. Poleg hitrejšega reagiranja obstaja še ena prednost gostejše namestitve merilnikov in sicer natančnejša prostorska ekstrapolacija točkovno izmerjene meritve na merilniku pripadajočem pododseku.



Slika 6-22: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov
Figure 6-22: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources


6.8.3 Prometna nesreča v predoru Trojane

27. maja 2014 je ob 13:09 prišlo do prometne nesreče na voznem pasu v predoru Trojane, zaradi česar je bil dalj časa zaprt vozni pas. Od 13:11 do 13:16 ter od 13:21 do 13:28 je bil predor zaprt za promet. Ostanke prometne nesreče so bili odstranjeni ob 14:23.




Slika 6-23: Prometna nesreča v predoru Trojane
Figure 6-23: Accident in tunnel Trojane

Primerjava koeficienta korelacije (Slika 6-24) za različne algoritme združevanja podatkov kaže na boljšo korelacijo v primeru uporabe arhitekture, ki poleg točkovnih in linijskih podatkov uporabi tudi informacijo o stopnji prometnega stanja (PS).



Slika 6-24: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov
Figure 6-24: Comparing coefficient of correlation for different data fusion architectures


Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-25) pokaže, da z uporabo združevanja podatkov po predlaganem algoritmu dosežemo 44% zmanjšanje napake pri določevanju potovalnega časa v primerjavi s potovalnim časom določenem na podlagi neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom napako v primerjavi z obstoječim algoritmom zmanjšamo za 9 %.



Slika 6-25: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-25: Comparing RMSE for different data fusion architectures


Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu (Slika 6-26) ponovno pokaže problem časovne zakasnitve, t.j. čakanja da vozilo konča svoje potovanje preden je informacija o potovalnem času na voljo.



Slika 6-26: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu

Figure 6-26: Comparing measured travel time with departure based travel time

V nadaljevanju je prikazana prednost uporabe predlaganega algoritma za združevanje podatkov glede na uporabo neposrednih linijskih oz. točkovnih meritev (Slika 6-27).



Slika 6-27: Zmanjšan vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov

Figure 6-27: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources


6.8.4 Dela na cesti na viaduktu Petelinjek

6. junija 2014 so čez dan na odseku med Trojanami in Blagovico na viaduktu Petelinjek potekala dela na prehitevalnem pasu.



Slika 6-28: Dela na prehitevalnem pasu
Figure 6-28: Road works on left lane


Primerjava koeficienta korelacije za različne algoritme združevanja podatkov (Slika 6-29) kaže na boljšo korelacijo v primeru uporabe arhitekture, ki poleg točkovnih in linijskih podatkov uporabi tudi informacijo o stopnji prometnega stanja.



Slika 6-29: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov
Figure 6-29: Comparing coefficient of correlation for different data fusion architectures

Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-30) pokaže, da z uporabo združevanja podatkov s predlaganim algoritmom dosežemo 27% zmanjšanje napake pri določevanju potovalnega časa v primerjavi s potovalnim časom določenim na podlagi


neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom napako v primerjavi z obstoječim algoritmom zmanjšamo za 5 %.



Slika 6-30: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-30: Comparing RMSE for different data fusion architectures

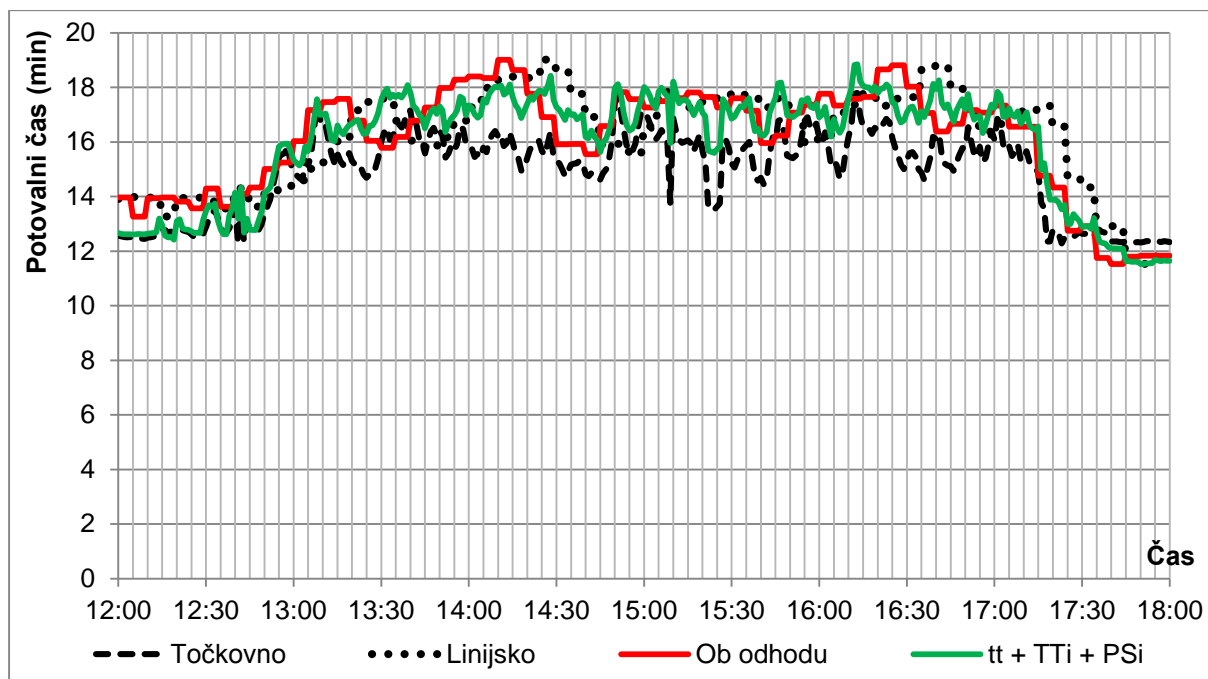
Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu (Slika 6-31) ponovno pokaže problem časovne zakasnitve, t.j. čakanja, da vozilo konča svoje potovanje preden je informacija o potovalnem času na voljo.



Slika 6-31: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu

Figure 6-31: Comparing measured travel time with departure based travel time

V nadaljevanju (Slika 6-32) je prikazana prednost uporabe predlaganega algoritma za združevanje podatkov v primerjavi z neposrednimi linijskimi oz. točkovnimi meritvami.



Slika 6-32: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov

Figure 6-32: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources

6.8.5 Zapora prehitevalnega pasu v predorih Trojane in Podmilj


19. julija 2014 so na odseku med Trojanami in Blagovico v predorih Trojane in Podmilj potekala dela. V času jutranje konice so zaradi zapore voznega pasu nastajali zastoji.



Slika 6-33: Dela na voznem pasu
Figure 6-33: Road works on right lane

Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-34) pokaže, da z

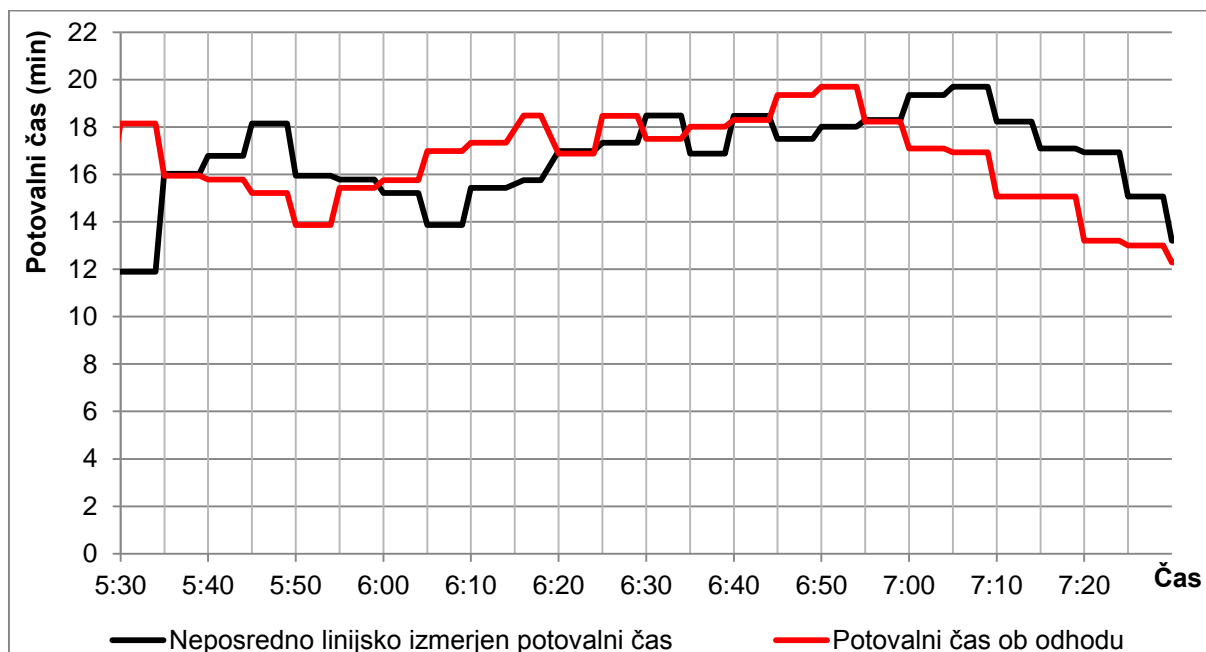
uporabo združevanja podatkov po predlaganem algoritmu dosežemo 46% zmanjšanje napake pri določevanju potovalnega časa v primerjavi s potovalnim časom določenim na podlagi neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom naredimo v primerjavi z obstoječim algoritmom 3% napako.



Slika 6-34: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-34: Comparing RMSE for different data fusion architectures

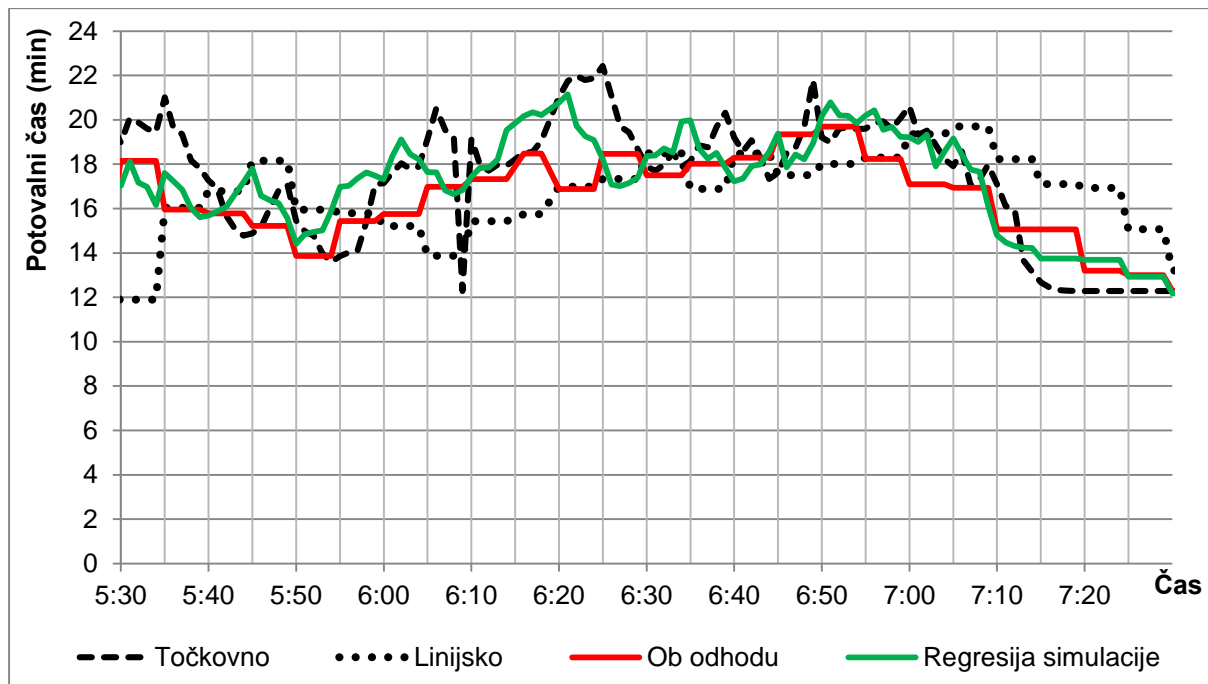
Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu pokaže problem časovne zakasnitve, t.j. čakanja da vozilo konča svoje potovanje, preden je informacija o potovalnem času na voljo.



Slika 6-35: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu

Figure 6-35: Comparing measured travel time with departure based travel time

V nadaljevanju (Slika 6-36) je prikazana prednost uporabe predlaganega algoritma za združevanje podatkov v primerjavi z neposrednimi linijskimi oz. točkovnimi meritvami.



Slika 6-36: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov

Figure 6-36: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources

6.8.6 Prometna nesreča v predoru Trojane

17. avgusta 2014 je ob 15:31 v predoru Trojane prišlo do prometne nesreče. Predor je bil zaprt od 15:51 do 15:53. Posledice prometne nesreče so odstranili ob 17:08.




Slika 6-37: Prometna nesreča v predoru Trojane

Figure 6-37: Accident in Trojane tunnel

Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-38) pokaže, da z uporabo združevanja podatkov s predlaganim algoritmom dosežemo 63% zmanjšanje napake


pri določevanju potovalnega časa v primerjavi s potovalnim časom določenem na podlagi neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom napako v primerjavi z obstoječim algoritmom zmanjšamo za 17 %.



Slika 6-38: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-38: Comparing RMSE for different data fusion architectures


Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu (Slika 6-39) ponovno pokaže problem časovne zakasnitve, t.j. čakanja da vozilo konča svoje potovanje preden je informacija o potovalnem času na voljo.



Slika 6-39: Primerjava neposredno linijsko določenega potovalnega časa s potovalnim časom ob odhodu

Figure 6-39: Comparing measured travel time with departure based travel time

V nadaljevanju (Slika 6-40) je prikazana prednost uporabe predlaganega algoritma za združevanje podatkov v primerjavi z neposrednimi linijskimi oz. točkovnimi meritvami.




Slika 6-40: Zmanjšani vpliv časovne zakasnitve ob uporabi predlaganega algoritma za določevanje potovalnega časa z združevanjem podatkov iz različnih virov

Figure 6-40: Reduced time-lag when using proposed algorithm for travel time estimation by fusing different data sources

6.8.7 Delovanje algoritma v razmerah prostega prometnega toka

Kljub temu, da natančnost delovanja algoritma v razmerah prostega prometnega toka ni tako pomembna kot v času zastojev in različnih izrednih dogodkov, je zaželeno, da algoritem dobro deluje tudi v teh razmerah.

Preverba delovanja predlaganega algoritma združevanja podatkov v času razmer prostega prometnega toka (Slika 6-41) kaže na njegovo pravilno delovanje. Združitev linijske in točkovne meritve v času razmer prostega prometnega toka vodi k potovalnim časom skladno z omejitvijo hitrosti.




Slika 6-41: Delovanje predlaganega algoritma v času razmer prostega prometnega toka
 Figure 6-41: Performance of the proposed algorithm during free-flow conditions

6.8.8 Ugotovitve na podlagi analize različnih izrednih dogodkov


Primerjava različnih algoritmov, ki delujejo na podlagi različnih arhitektur združevanja podatkov kaže na smiselnost vključitve informacije o stopnji prometnega stanja pri združevanju podatkov.

Primerjava koeficienta korelacije za različne algoritme združevanja podatkov kaže na boljšo korelacijo v primeru uporabe arhitekture, ki poleg točkovnih in linijskih podatkov uporabi tudi informacijo o stopnji prometnega stanja (Slika 6-42).



Slika 6-42: Primerjava koeficienta korelacije za različne arhitekture združevanja podatkov
 Figure 6-42: Comparing coefficient of correlation for different data fusion architectures


Primerjava korena povprečne kvadratne napake med določitvijo potovalnega časa z različnimi algoritmi združevanja podatkov ter potovalnim časom ob odhodu (Slika 6-43) pokaže, da z uporabo združevanja podatkov po predlaganem algoritmu dosežemo 43% zmanjšanje napake pri določevanju potovalnega časa v primerjavi s potovalnim časom določenem na podlagi neposrednih linijskih meritev. Z uporabo informacije o stopnji prometnega stanja s predlaganim algoritmom napako v primerjavi z obstoječim algoritmom zmanjšamo za 9 %.



Slika 6-43: Primerjava korena povprečne kvadratne napake (RMSE) za različne arhitekture združevanja podatkov

Figure 6-43: Comparing RMSE for different data fusion architectures


V kolikor učenje algoritma izvedemo samo na podatkih iz simulacije (Slika 6-44) dobimo slabši koeficient korelacije (0.79) kot če učenje izvedemo na učni množici, ki poleg podatkov iz simulacij upošteva tudi podatke o resničnih dogodkih (0.83). V izogib prevelikemu prileganju naučenega algoritma testnim primerom oz. sovpadanju učne in validacijske množice, smo za primerjavo med različnimi algoritmi (arhitekturami) izvedli učenje le na podlagi podatkov iz prometnih simulacij.



Slika 6-44: Primerjava koeficienta korelacije za različne učne množice

Figure 6-44: Comparing coefficient of correlation for different learning sets

Primerjava korena povprečne kvadratne napake za različne učne množice (Slika 6-45), v primeru ko učenje izvedemo na učni množici, ki upošteva samo podatke o resničnih dogodkih prinese 8% zmanjšanje napake v primerjavi z učenjem samo na podlagi simulacij. To pomeni, da se je algoritem sposoben sproti učiti na podlagi zgodovinskih podatkov, kar bo v bodoče še bistveno izboljšalo njegovo delovanje.



Slika 6-45: Primerjava korena povprečne kvadratne napake (RMSE) za različne učne množice
Figure 6-45: Comparing RMSE for different learning sets

6.8.9 Delovanje algoritma v primeru izpada enega od virov podatkov

V primeru izpada enega od virov podatkov algoritem privzame vrednosti drugega točkovnega oz. linijskega vira podatkov. V tem obdobju se združevanje podatkov ne izvaja. Napaka ocene vrednosti potovalnega časa v tem obdobju je enaka napaki osnovnega vira točkovnih oz. linijskih podatkov.

7 ZAKLJUČKI

»Človek mora iskati, kar je in ne kar misli, da mora biti.«

- Albert Einstein

Izvedene študije na temo združevanja podatkov privzamejo kot vhodni podatek potovalne čase iz neposredne linijske in posredne točkovne meritve, ne da bi se ukvarjale z njihovo natančnostjo in načinom, kako so bili pridobljeni. Med študijem obstoječe literature je bilo ugotovljeno, da obstoječe metode nepravilno opišejo karakteristike prometnega toka zaradi neupoštevanja velikega deleža težkih tovornih vozil, kar pomembno vpliva na določitev reprezentativne vrednosti potovalnega časa. Precejšnji del te študije smo posvetili razvoju oz. izboljšavi obstoječih metod neposrednega linijskega merjenja potovalnega časa in posredne ocene iz točkovne ekstrapolacije hitrosti, preden smo podatka združili. Tako smo dosegli robustnejše delovanje algoritma.

7.1 Neposredno merjenje potovalnega časa

»Narava je je zadovoljna s preprostostjo in ne hlini odvečnih vzrokov.«

- Isaac Newton

Prvi del študije je bil posvečen izdelavi algoritma za določevanje potovalnih časov, pridobljenih z neposrednimi linijskimi meritvami, ki je kljub prisotnosti osamelcev v potovalnem času, sposoben dobro oceniti reprezentativno vrednost potovalnega časa na izbranem odseku. Večina že izvedenih študij temelji na uporabi klasičnih statističnih metod, ki z uporabo različnih metod najprej odstranijo podatke, ki za več kot prag meritve odstopajo od srednje vrednosti, nato pa z uporabo povprečne vrednosti izračunajo reprezentativno vrednost potovalnega časa. Ob opaženem dejstvu, da je razpršitev potovalnih časov znotraj izbranega časovnega intervala v času prostega prometnega toka velika in da nekatera vozila dosegajo bistveno nižje hitrosti kot druga, očitno, da povprečna vrednost potovalnih časov ne predstavlja reprezentativne vrednosti razmer na trasi. Nekatero študije sicer uporabijo tudi mediano, ki je glede zaznavanja in odpornosti na osamelce bistveno bolj robustna mera kot povprečje, vendar v primeru velikega deleža tovornega prometa ne predstavlja primerne, vrednosti. Vodilo pri izdelavi algoritma za določitev reprezentativne vrednosti neposredno izmerjenega potovalnega časa je bila zato zahteva po uporabi primerne statistične metode, ki bi bila glede na sicer neznan delež tovornih vozil, sposobna dobro oceniti vrednost potovalnega časa za osebna vozila.

Za izračun reprezentativne vrednosti potovalnega časa na odseku želimo pridobiti le meritve potovalnih časov osebnih vozil, saj se le-ta v prostem prometnem toku gibljejo skoraj da brez fizičnih omejitev. V nasprotju z osebnimi vozili, vpliva na težka tovorna vozila vrsta dejavnikov in sicer naklon trase, nižje hitrostne omejitve ter fizične omejitve pri vožnji, zaradi česar so izmerjeni potovalni časi tovornih vozil bistveno daljši od tistih, ki jih za prevoz odseka potrebujejo osebna vozila. Ker tovorna vozila za prevoz odseka potrebujejo daljši čas kot osebna, želimo njihov vpliv pri določitvi reprezentativnega potovalnega časa kar se le da zmanjšati.

Da je kljub splošnemu prepričanju razlikovanje med osebnimi in tovornimi vozili potrebno tako v času razmer prostega kot tudi zgoščenega prometnega toka, smo ugotovili ob analizi potovalnih časov v času zastoja. S študijo smo ugotovili, da kljub razmeram zgoščenega prometnega toka potovalni časi osebnih in tovornih vozil ostanejo razpršeni. Vzrok za to je dejstvo, da po zapustitvi območja zastoja osebna vozila hitreje pospešujejo nazaj k razmeram prostega prometnega toka in pripadajoči omejitvi hitrosti, medtem ko tovorna vozila zaradi znanih fizičnih omejitev svojo omejitev hitrosti dosežejo kasneje. Drug razlog predstavlja dejstvo, da zastoj ponavadi zavzema le kratek del odseka kjer merimo potovalni čas, zato potovalni časi osebnih in tovornih vozil ostanejo različni kljub delu avtoceste kjer prevladujejo homogene prometne razmere.

Z uporabo robustnih metod smo poiskali statistiko, ki v razmerah prostega prometnega toka najbolje karakterizira voznike, ki upoštevajo hitrostno omejitev na obravnavanem odseku. To statistiko nato spremljamo tudi v razmerah izven prostega prometnega toka ob predpostavki, da opisuje voznike, ki sicer vozijo skladno z omejitvami hitrosti, na njihov potovalni čas pa so med potovanjem vplivale različne motnje znotraj prometnega toka. Kot najbolj uporabna robustna statistika se je izkazal centil. Algoritem na podlagi izmerjenih potovalni časov na odseku z uporabo primerne vrednosti centila za posamezen čas dneva izračuna reprezentativno vrednost potovalnega časa, s katero voznike obveščamo o potovalnem času na odseku. Vrednosti centila, časovni okvir delovanja ter dnevni oz. nočni režim, določimo v fazi prilagoditve algoritma na izbranem avtocestnem odseku.

Neposredno izmerjeni potovalni časi na odseku med dvema kontrolnima točkama predstavljajo dobro informacijo, pridobljeno s sledenjem posameznih vozil, ki pa vsebuje časovno zakasnitev v primerjavi z dejanskim potovalnim časom za voznika, ki na odsek šele vstopa. Metoda je torej prostorsko natančna, saj v obzir vzame vse dejavnike, ki vplivajo na vozilo med njegovim potovanjem, vendar vsebuje napako, ki je posledica časovne zakasnitve, kar je problematično predvsem v času nastajanja zastojev.

Preverjanje delovanja algoritma je potekalo v različnih pogojih odvijanja prometnega toka: od prostega prometnega toka podnevi in ponoči, v času izrednih dogodkov na avtocestni trasi ter tudi v času preusmeritve prometnega toka na sekundarno cestno omrežje. Algoritem se je izkazal za zelo učinkovitega tako za tehnologije z visoko (reidentifikacija registrskih tablic) kot tudi nizko (reidentifikacija naslovov »bluetooth«) stopnjo penetracije. Natančnost predlaganega algoritma je bila uspešna tudi za tehnologije z nizko stopnjo penetracije manjše od 7 %. Delovanje predlaganega algoritma smo primerjali s tremi različnimi algoritmi: z v ZDA široko razširjenim algoritmom TransGuide ter z dvema teoretičnima algoritmoma razvitima s strani Dion in Rakha ter Ma in Koutsopoulos. Primerjava je pokazala, da uporaba robustne statistike prinese boljše rezultate kot uporaba klasičnih statističnih metod. V času prostega prometnega toka podnevi so potovalni časi določeni z vsemi algoritmi v povprečju znotraj nekaj sekund, medtem ko se v nočnih urah izkaže naš predlagani algoritem, ki je edini zmožen upoštevati velik delež tovornih vozil. V času nastanka zastojev algoritmi delujejo podobno, v času razpustitve zastoja pa je opazen hitrejši odziv našega algoritma. Algoritem Dion in Rakha narobe določi reprezentativno vrednost potovalnega časa v primeru vključitve tretje vrednosti izven območja veljavnosti, ki je osamelec. Algoritem TransGuide, v nasprotju z našim, ni sposoben zaznati nenadno podaljšanih (ali skrajšanih) potovalnih časov, do česar pogosto prihaja. Ugotovljeno je bilo, da je algoritem TransGuide neprimeren za izračunavanje

potovalnega časa v primeru sprememb vrednosti potovalnega časa za več kot 20 % v zaporednih časovnih intervalih. V realnih okoliščinah je bilo zaradi nenadnega podaljšanja potovalnega časa kot posledica preusmeritve na vzporedno cestno omrežje opaženo, da algoritem TransGuide kar 7 ur voznikom ni bil sposoben podati informacije, medtem, ko je naš algoritem pravilno sledil evoluciji potovalnega časa. Primerjava z algoritmi, ki uporabljajo klasične statistične metode, je tako pokazala, da uporaba robustne statistike bistveno pripomore k natančnemu sledenju evolucije potovalnega časa.

Tu se postavi tudi splošno vprašanje, vezano na večino že delujočih algoritmov, ki za izračun upoštevajo vrednosti potovalnega časa v predhodnem časovnem intervalu: zakaj moramo v izračunu trenutnega potovalnega časa sploh upoštevati predhodno časovno obdobje, če pa imamo na voljo dovolj velik vzorec izmerjenih potovalnih časov? Potovalni čas namreč v nasprotju s prometnim pretokom, v primeru izrednih dogodkov ne sledi nujno nekim logičnim trendom, kar vodi k ideji, da ga moramo v danem časovnem intervalu obravnavati takega kot je. To pomeni, da moramo v primeru, ko želimo vozniku podati kar se le da zanesljivo in aktualno informacijo, upoštevati le spremembo potovalnega časa v zadnjem časovnem intervalu ne glede na vrednost potovalnega časa v predhodnem časovnem intervalu. Ta lastnost aktualnosti oz. neodvisnosti vrednosti potovalnega časa od prejšnjega časovnega intervala ima tudi svojo slabo lastnost - potovalnega časa se ne da napovedati za razmere nenadnih sprememb v prometnem toku. Informacija o spremembi vrednosti potovalnega časa je tako na voljo šele, ko do nje dejansko pride in postane pretekla informacija.

Podajanje informacij z visoko natančnostjo je v prometnem inženirstvu nemogoče predvsem zaradi narave prometnega toka, kjer občasno zaradi različnih vzrokov lahko pride do netipičnega obnašanja ali neponovljivih izrednih dogodkov kot npr. zastoj ali nesreča. Neponavljajoči izredni dogodki so tisti dogodki, ki niso pričakovani in jih lahko upoštevamo šele, ko so se zgodili in njihove posledice postanejo dejanska informacija. Glede na to, da je napovedovanje včasih nevhvaležno opravilo, pa lahko vozniku v danih razmerah povemo vsaj, kolikšen bi bil njegov potovalni čas v trenutnih razmerah, kar sovпада z zadnjo meritvijo potovalnega časa. In to je vsekakor boljša informacija kot nezanesljiva napoved.

Nadaljnje delo je potekalo predvsem v smeri aktualizacije informacije o potovalnem času, ki smo jo dosegli z združitvijo podatkov iz točkovno izmerjenih hitrosti na vmesnih lokacijah med kontrolnima točkama neposredno izmerjenih potovalnih časov.

7.2 Posredna ocena potovalnega časa

»Vsi modeli so napačni, a nekateri so uporabni.«

- George E. P. Box

Obstoječi točkovni merilniki na avtocestah zagotavljajo meritve različnih parametrov prometnega toka. Kompleksni merilniki prometnega toka omogočajo klasifikacijo vozil v različne razrede, kar pomeni, da so za določeno merilno mesto na voljo izmerjene hitrosti vozil po posameznih razredih. Za določitev potovalnega časa na avtocesti je merodajna hitrost osebnih vozil, saj osebna vozila na odseku vozijo brez fizičnih omejitev. Na slovenskih avtocestah imamo na odsekih, pokritih s sistemi za nadzor in vodenje prometa nameščene mikrovalovne detektorje, ki vse to omogočajo. Majhna sprememba algoritma izračunavanja

poleg srednje časovne hitrosti omogoča tudi izračun srednje prostorske hitrosti ob pogoju, da beležimo in hranimo izmerjeno hitrost vsakega posameznega vozila. In ravno izračun srednje prostorske hitrosti ter klasifikacija vozil na razrede predstavljata bistveno razliko v vhodnih podatkih, danost, ki marsikateri obstoječi študiji točkovne ekstrapolacije hitrosti za določitev potovalnega časa ni bila dana. Medtem, ko v literaturi večina študij temelji na srednji časovni hitrosti celotnega prometnega toka, je bila v našem algoritmu upoštevana srednja prostorska hitrost za osebna vozila, ki precej bolje karakterizira dejanske razmere na odseku. Uporaba harmonične sredine (srednja prostorska hitrost) namesto aritmetične sredine (srednja časovna hitrost) pomeni tudi nekoliko drugačno formulacijo algoritma - namesto standardnega odklona aritmetične sredine moramo za določitev meja upoštevanega območja namreč uporabiti standardni odklon harmonične sredine.

Dobro določena vrednost srednje prostorske hitrosti predstavlja vhodni podatek za določitev reprezentativne hitrosti za posamezno merilno mesto. Pri uporabi algoritma za oceno potovalnega časa iz točkovne ekstrapolacije hitrosti je uporabljena predpostavka, da znotraj časovnega intervala in na celotnem pododseku meritve prometni tok ostane konstanten. Za izpolnitev tega pogoja je potrebna dovolj gosta postavitev točkovnih merilnikov ter kratek čas posodabljanja informacije. Za zagotovitev robustnosti in hitrega odziva je bil uporabljen poseben algoritem, ki zgladi naključna nihanja hitrosti, a zagotavlja odziv na skokovite spremembe hitrosti, ki so posledica udarnega vala. Algoritem določi, ali je sprememba hitrosti posledica naključnega nihanja zaradi obnašanja voznikov in jo moramo zgladiti, ali gre za spremembo prometnega stanja in jo ne smemo gladiti, s čimer zagotovimo hiter odziv algoritma. Ali gre v dveh zaporednih časovnih intervalih za majhno spremembo hitrosti ali za veliko nihanje določimo s preizkusom domneve o razliki med pričakovanima vrednostma srednje prostorske hitrosti v dveh zaporednih časovnih intervalih. Z glajenjem srednjih prostorskih hitrosti za zaporedne časovne intervale (glajenje) oz. z upoštevanjem dejanske prostorske hitrosti v trenutnem časovnem intervalu (preskok), algoritmu za posredno oceno potovalnih časov iz točkovne ekstrapolacije hitrosti dodamo komponento upoštevanja dinamike prometnega toka. Z glajenjem hitrosti v zaporednih časovnih intervalih zmanjšamo naključna nihanja v izmerjenih hitrostih, ki so posledica individualnega obnašanja voznikov osebnih vozil s čimer povečamo kredibilnost sistema. Z upoštevanjem preskoka zagotovimo hipen odziv algoritma na nenadna večja nihanja hitrosti, ki so najverjetneje posledica izrednega dogodka.

Pri določitvi reprezentativne vrednosti hitrosti lahko poleg pogoja glajenja oz. upoštevanja nihanj, upoštevamo tudi dinamiko prometnega toka v obliki stopnje prometnega stanja, ki je v tesni povezavi z nivojem usluge. Določitev reprezentativne vrednosti hitrosti v razmerah nasičenega in zgoščenega prometnega toka je pogosto zelo zahtevna naloga, predvsem v razmerah prometnega toka »stop&go«, ko so točkovni merilniki zmožni zajeti le situacije, ko se vozila premikajo, ne pa tudi tistih, ko vozila mirujejo. V takih primerih s točkovno ekstrapolacijo hitrosti dobimo potovalni čas, ki je podcenjen. Z uporabo redukcije hitrosti v primeru razmer prometnega toka »stop&go« ne upoštevamo samo tistih situacij, ko se vozila gibljejo, temveč tudi situacije, ko vozila mirujejo.

Tako določeno reprezentativno hitrost moramo v nadaljevanju ekstrapolirati na posameznim merilnikom pripadajoče pododseke. Želeli smo se izogniti zapletenim matematičnim metodam ekstrapolacije, predstavljenim v literaturi, katerih prostorska ponazoritev je vprašljiva in bolj sledi teoretičnim matematičnim funkcijam kot dejanskemu obnašanju prometnega toka.

Predlagali smo modificirano metodo odsekoma konstantne ekstrapolacije, kjer glede na karakteristike obnašanja prometnega toka na trasi vsakemu merilniku pripišemo pododsek, na katerem velja reprezentativna hitrost s tega merilnika.

Rekonstrukcija funkcijske zveze med opravljeno potjo vozila in njegovim potovalnim časom in primerjava potovalnega časa, pridobljenega iz točkovne ekstrapolacije hitrosti, s potovalnim časom, pridobljenim z referenčno tehnologijo neposredno linijsko izmerjenega potovalnega časa, pokaže, da je mogoče potovalni čas na odseku z metodo točkovne ekstrapolacije hitrosti določiti dokaj natančno. Pri tem se moramo zavedati tudi, da z metodo rekonstrukcije funkcijske zveze med opravljeno potjo vozila in njegovim potovalnim časom pri primerjavi obeh potovalnih časov primerjamo različne časovne intervale zajema: medtem, ko je podatek točkovne ekstrapolacije hitrosti posodobljen vsako minuto, po drugi strani podatek o neposredno linijsko izmerjenem potovalnem času posodabljam vsakih 5 minut.

Prednost meritev, pridobljenih iz točkovnih merilnikov, je možnost določitve trenutnega potovalnega časa na osnovi virtualne meritve za posamezno vozilo, še preden le-ta konča svoje potovanje. Ta meritev predstavlja takojšnjo informacijo, s sicer manjšo prostorsko natančnostjo glede na neposredno linijsko izmerjen potovalni čas. Dejanska prednost potovalnega časa, določenega iz točkovne ekstrapolacije hitrosti je takojšnji odziv na izredni dogodek, kar kljub slabši prostorski natančnosti lahko izkoristimo za zaznavanje motenj v prometnem toku, še preden to zaznajo neposredne linijske meritve. Točkovna ekstrapolacija hitrosti sicer že sama po sebi vsebuje napako, ki je posledica predpostavke o konstantni hitrosti na celotnem pododseku. Pri natančnosti algoritma točkovne ekstrapolacije hitrosti igra veliko vlogo tudi lokacija postavitve točkovnega merilnika in dolžina območja pripadajoče meritve. Na območju testiranja algoritma je bilo merilniku pripadajoče območje povprečno dolžine 1697 m (najdaljše 3016 m ter najkrajše 697 m). Dolžine, ki so precej nad optimalnimi (v literaturi so navedena primerna vplivna območja dolžine 500 m), lahko ustvarijo precej velike napake.

V primeru redke mreže točkovnih merilnih mest in ob pomanjkanju natančnosti algoritma točkovne ekstrapolacije hitrosti v času zgoščenih prometnih razmer se za oceno potovalnega časa na pododseku lahko uporabi tudi algoritem ravnovesja kumulativnega štetja vozil na pododseku, ki določa potovalne čase na podlagi števnih podatkov iz merilnikov prometa ob predpostavki enačbe ohranjanja vozil na odseku. Ugotovljeno je bilo, čeprav to v literaturi nikjer ni nedvoumno navedeno, da so za uporabo te metode potrebni precej veliki prometni pretoki, ki na podeželski avtocesti med Celjem in Ljubljano žal niso doseženi. Metodo, ki smo ji posvetili kar nekaj časa, bomo tako v prihodnosti dokončno razvili in preverili na eni izmed mestnih avtocest obročja okoli Ljubljane.

7.3 Združevanje podatkov

»Če izločimo zavest, potem se odločanje spremeni v matematično napovedljivo dejavnost, slonečo na informaciji, ki je bila predhodno na voljo.«

- Mortimer Taube

Namen združevanja podatkov iz različnih virov je zagotoviti rezultat, ki je učinkovitejši, zanesljivejši in natančnejši od osnovnih podatkov, ki jih združujemo. Pri združevanju vsak od virov ponavadi doprinese svoje pozitivne lastnosti ter tako omogoča pridobitev rezultata, do katerega pri uporabi posameznega vira morda ne bi bilo možno priti. Združitev podatkov iz različnih virov vodi do kvalitativnih in kvantitativnih koristi, izboljšane operativne učinkovitosti sistema, razširjene prostorske in časovne pokritosti meritve, povečane zanesljivosti in nedvoumnosti informacije ter izboljšane zaznave izrednih dogodkov.

V primeru različnih tehnologij za pridobivanje prometnih podatkov, nehomogenih podatkov z izmerjenimi različnimi spremenljivkami, različnih algoritmov z različnimi natančnostmi, različnega prostorskega vplivnega območja posameznega merilnika in različnih časovnih okvirov, predstavlja sistem združevanja podatkov rešitev za združitev pozitivnih lastnosti posamezne od meritev v rezultat z večjo natančnostjo. V našem primeru gre za združevanje posredne ocene potovalnega časa iz točkovne ekstrapolacije hitrosti, ki predstavlja takojšnjo informacijo z manjšo prostorsko natančnostjo, z neposredno linijsko izmerjenim potovalnim časom, ki predstavlja natančno informacijo s časovno zakasnitvijo. Namen združevanja podatkov je premostiti prostorsko nenatančnost potovalnega časa pridobljenega iz točkovne ekstrapolacije hitrosti in časovno zakasnelost neposredno izmerjenega potovalnega časa na odseku. Z združevanjem podatkov želimo doseči kratkoročno napoved trenda razvoja potovalnega časa, kot podlago za informacijo vzniku, ki šele vstopa na odsek izvajanja meritve. Izziv problematike kratkoročne napovedi torej predstavlja iz izmerjenega potovalnega časa po prihodu vozila in ocenjenega dejanskega potovalnega časa, določiti pričakovan potovalni čas ob odhodu vozila za naslednji časovni interval.

Metodo združevanja smo izbrali na podlagi namena združevanja podatkov, konfiguracije merilnikov ter predvidenih lastnosti vhodnih podatkov. Določili smo arhitekturo združevanja podatkov in se odločili za regresijsko analizo, katere lastnost je robustno obnašanje. Z naše strani predlagana metoda združevanja podatkov temelji na multipli linearni regresiji, ki se je glede na ugotovitve različnih avtorjev (Bachmann in sodelavci, 2013; van Hinsbergen in sodelavci, 2007; Keever in sodelavci, 2003) z vidika računske zahtevnosti ter natančnih rezultatov izkazala kot najbolj optimalna. To predstavlja pomembno ugotovitev, saj so nekatere izmed drugih metod teoretično in računsko precej kompleksne in je zato njihova implementacija vprašljiva, glede na to, da ne zagotavljajo nobene bistvene dodane vrednosti.

Namen našega algoritma je zagotoviti združevanje podatkov iz neposredne linijske meritve in točkovne ocene za potrebe obveščanja voznikov. To od algoritma zahteva zmožnost sprotnega učenja o novih izrednih dogodkih po prednastavljeni strukturi modela, s čimer se uspešnost metode postopoma izboljšuje z učenjem. Ker nobena od obstoječih študij ne vzame v obzir kvalitativnih meril odvijanja prometnega toka v smislu različnih merjenj, kot so hitrost, gostota in pretok prometnega toka, smo metodo združevanja podatkov nadgradili z dodatnimi vhodnimi podatki in sicer informacijo o stopnji prometnega stanja, ki kvalitativno opiše razmere v

prometnem toku na podlagi osnovnih karakteristik prometnega toka (hitrost in gostota). Posebna lastnost našega modela je, da tako neposredno linijsko izmerjen potovalni čas kot tudi posredno ocenjen potovalni čas določi na podlagi meritev osebnih vozil, pri združevanju obeh virov pa si pomaga s stopnjo prometnega stanja, kar doprinese vpliv celotnega prometnega toka. Reprezentativno vrednost potovalnega časa tako določimo le na vzorcu osebnih vozil, ki so za nas merodajna, medtem, ko nam stopnja prometnega stanja pomaga pri odločitvi, kako hitro reagirati na spremenjene prometne razmere.

Zelo pomembno fazo delovanja algoritma predstavlja njegovo učenje, s katerim smo želeli doseči njegovo optimalno delovanje v vseh pogojih. Učenje algoritma je predpogoj vsakega inteligentnega sistema. Za učenje algoritmov so bili uporabljeni podatki, pridobljeni s prometnimi simulacijami, ki so omogočale pripravo različnih scenarijev, do katerih v resničnem svetu ne pride pogosto. Pomemben faktor za odločitev izvajanja učenja s prometnimi simulacijami je bila možnost simuliranja izrednih dogodkov na celotnem modelu pripadajočem območju.

Večina do sedaj izvedenih študij za oceno potovalnih časov rezultate, pridobljene z združevanjem točkovne ocene in linijske meritve, primerja z eno od neposrednih linijskih meritev potovalnega časa po prihodu vozila, ki pa ni merodajen. Potovalni čas po prihodu vozila predstavlja informacijo o vozilih, ki so svoje potovanje že končala in zato vsebuje zgodovinsko komponento, ki ni primerna za obveščane voznikov, ki na obravnavan odsek ceste šele vstopajo. Naša študija zato rezultate primerja s potovalnim časom ob odhodu vozila, saj le-ta predstavlja merodajno informacijo za voznika, ki vstopa na odsek izvajanja meritve. Potovalni čas ob odhodu vozila v trenutnem času ni znan, ga pa brez težav pridobimo iz zgodovinskih podatkov, saj potovalni čas ob odhodu dejansko predstavlja potovalni čas po prihodu s časovno razliko med meritvama, ki je enaka potovalnemu času.

V sklopu združevanja podatkov iz točkovnih in linijskih meritev smo preverili in primerjali uspešnost združevanja podatkov z uporabo različnih algoritmov združevanja podatkov:

- naš algoritem $tt + TT_i + PS_i$, ki združi podatke o potovalnih časih TT_i in prometnih stanjih PS_i posameznih pododsekov ter neposredno linijsko meritev tt ;
- obstoječi algoritem $tt + TT_i$, ki združi neposredno linijsko meritev tt s podatki o potovalnih časih na posameznih pododsekih TT_i ;
- modifikacijo našega algoritma $tt + PS_i$, ki združi neposredno linijsko meritev tt , seštevek potovalnih časov točkovnih meritev iz posameznih pododsekov TT ter informacijo o stopnji prometnega stanja na posameznem pododseku PS_i ;
- obstoječi algoritem $tt + TT$, ki združi neposredno linijsko meritev tt ter seštevek potovalnih časov točkovnih meritev iz posameznih pododsekov TT .

Naš algoritem je na podlagi opazovanj izkazal boljšo sposobnost napovedi potovalnega časa glede na osnovni vir informacij, ki jih združujemo v povprečju za 43 %, ter tudi glede na obstoječe algoritme, ki upoštevajo le neposredno linijsko meritev in potovalne čase na posameznih pododsekih v povprečju za 9 %. Vse primerjane arhitekture združevanja podatkov v vseh primerih izboljšajo natančnost osnovnega vira informacij, ki jih združujejo. Uspešnost algoritma, ki v nobenem primeru ni slabša od osnovne informacije nakazuje, da je algoritem zrel za implementacijo v realne okoliščine.

Naša želja je bila zasnovati algoritem, ki bi na podlagi podatkov s terena kar se le da dobro določil potovalni čas ob odhodu vozila. Uporaba informacije o stopnji prometnega stanja poleg točkovno ekstrapolirane hitrosti in neposredne linijske meritve se je izkazala kot zelo uporabna. Ugotovljeno je bilo, da algoritem združevanja podatkov bolje deluje, če ima na voljo večje število surovih podatkov in sicer v primeru z dodajanjem informacije o stopnji prometnega stanja, s čimer se lažje nauči kompleksnih povezav med posameznimi spremenljivkami. Glede na to, da je informacija o stopnji prometnega stanja na obstoječem omrežju slovenskih avtocest že na voljo v sklopu sistemov za nadzor in vodenje prometa, bo njena vključitev bistveno pripomogla k natančnosti določitve trenutnega potovalnega časa.

Spremljanje delovanja algoritma skozi daljše časovno obdobje ter pridobitev podatkov za sprotno učenje algoritma na podlagi dejanskih izrednih dogodkov na trasi izvajanja meritev bo omogočalo še boljši odziv algoritma na različne izredne dogodke. Primerjava korena povprečne kvadratne napake za različne učne množice, v primeru ko učenje izvedemo na učni množici, ki poleg podatkov iz simulacij upošteva tudi podatke o resničnih dogodkih, prinese 15 % zmanjšanje napake. To pomeni, da se je algoritem sposoben sproti učiti na podlagi zgodovinskih podatkov, kar bo v bodoče še izboljšalo njegovo delovanje.

Dejstvo, da so tehnologije za zbiranje podatkov že na voljo ter na slovenskem avtocestnem omrežju že vgrajene, nakazuje, da je algoritem za združevanje podatkov zrel za zagon v resničnih okoliščinah.

8 POVZETEK

Cilj doktorske disertacije je bil razviti algoritem za sprotno določevanje potovalnih časov, ki bi bil sposoben vozniku nuditi kar se da dobro informacijo o potovalnem času na avtocestnem odseku. Prvi cilj disertacije je bil razviti algoritem za določevanje potovalnega časa iz neposredne linijske meritve ter algoritma, ki na podlagi točkovnih meritev hitrosti in njihove ekstrapolacije v prostor določa potovalne čase na pododsekih. Drugi cilj disertacije pa je bil razviti algoritem za določevanje potovalnih časov, ki združuje ugodne lastnosti neposredno izmerjenega potovalnega časa in potovalnega časa, ocenjenega iz točkovnih meritev hitrosti. Prednost neposredno izmerjenega potovalnega časa je njegova prostorska natančnost, medtem ko ugodno lastnost posredne ocene iz točkovne meritve hitrosti predstavlja časovna neposrednost.

Namen doktorske disertacije je bil razvoj algoritma za določitev reprezentativne vrednosti potovalnega časa, ki deluje v realnem času. Podatek o potovalnem času služi kot vhodni podatek sistemu za obveščanje uporabnikov o potovalnih časih na avtocestnem odseku.

Osnovna hipoteza je bila, da je s pomočjo združevanja točkovnih in neposrednih linijskih meritev možno pridobiti natančnejšo in zanesljivejšo oceno vrednosti potovalnega časa na odseku, kot iz posamezne meritve (bodisi linijske, bodisi točkovne). Metodologija je premostila nekatere omejitve določevanja potovalnega časa iz enega samega vira podatkov ki so posledica omejenega prostorskega pokrivanja točkovnih detektorjev ter zamude pri obveščanju vsled neposrednih linijskih merenj.

Za voznike, cestne operaterje in prometne inženirje podatek o potovalnem času predstavlja najbolj uporabno informacijo pri načrtovanju potovanja, na podlagi katere lahko vozniki optimizirajo in prilagodijo svoje potovanje. Informacija o potovalnem času pa je pomembna tudi za upravljavce avtocestnega omrežja, ker predstavlja kvantitativno vrednost za oceno uspešnosti odvijanja prometnega toka na prometnem omrežju, je kazalec uspešnosti prometnih strategij, uporabljamo pa jo lahko tudi kot zanesljiv kazalec nastanka zastojev.

V splošnem obstajata dve možnosti ocene potovalnega časa na odseku: prva možnost je neposredno merjenje, druga možnost pa posredna ocena. Neposredno meritev predstavlja merjenje časovnega intervala, ki ga izbrano vozilo potrebuje za prevoz med dvema točkama. Najpreprostejša metoda za merjenje potovalnih časov na določenem odseku avtoceste je identifikacija vozila na začetni in končni točki in meritev časa, ki ga je vozilo potrebovalo za prevoz omenjenega odseka. V pridobljenem vzorcu predstavljajo problem osamelci. To so potovalni časi, katerih skrajšana oz. podaljšana vrednost nima vzroka v prometnih razmerah, temveč je posledica individualnega obnašanja posameznega vozila kot npr. motor, ki prehiteva kolono oz. vozilo, ki se je med potovanjem ustavilo za počitek. Odvisno od uporabljene tehnologije meritev lahko dobimo vzorec, ki zajema le posamezno kategorijo vozil kot npr. branje ABC tablic, ki jih pri nas uporabljajo le tovorna vozila ali pa vzorec, ki zajema celotno strukturo prometnega toka kot npr. reidentifikacija registrskih tablic in naslovov »bluetooth«. V obeh primerih moramo uporabiti primerno metodo izločanja za zagotovitev reprezentativne vrednosti izračunanega potovalnega časa, na podlagi katerega se voznike obvešča o potovalnem času na odseku.

V splošnem želimo za izračun reprezentativne vrednosti potovalnega časa na odseku pridobiti samo meritve potovalnih časov osebnih vozil, ki se v prostem prometnem toku gibljejo skoraj da brez fizičnih omejitev. V nasprotju z osebnimi vozili, na težka tovorna vozila vpliva vrsta dejavnikov in sicer naklon trase, nižje hitrostne omejitve ter fizične omejitve pri vožnji, zaradi česar so izmerjeni potovalni časi tovornih vozil bistveno daljši od tistih, ki jih za prevoz odseka potrebujejo osebna vozila. Da je kljub splošnemu prepričanju razlikovanje med osebnimi in tovornimi vozili potrebno tako v času razmer prostega kot tudi zgoščenega prometnega toka, smo ugotovili ob analizi potovalnih časov v času zastoja. Ugotovljeno je bilo, da kljub razmeram zgoščenega prometnega toka potovalni časi osebnih in tovornih vozil ostanejo razpršeni. Vzrok za to je, da po zapustitvi območja zastoja osebna vozila hitreje pospešujejo k razmeram prostega prometnega toka in pripadajoči omejitvi hitrosti, medtem ko tovorna vozila zaradi znanih fizičnih omejitev svojo omejitev hitrosti dosežejo kasneje. Drug razlog predstavlja dejstvo, da zastoj ponavadi zavzema le krajši del odseka kjer merimo potovalni čas, zato potovalni časi osebnih in tovornih vozil ostanejo različni kljub delu avtoceste, kjer prevladujejo homogene prometne razmere.

Ob opaženem dejstvu, da je razpršitev potovalnih časov znotraj izbranega časovnega intervala v času prostega prometnega toka velika in da nekatera vozila dosegajo bistveno nižje hitrosti kot druga, je očitno, da povprečna vrednost potovalnih časov ne predstavlja reprezentativne vrednosti razmer na trasi. Z uporabo robustne statistike smo poiskali tisto cenilko, ki v razmerah prostega prometnega toka najbolje karakterizira voznike, ki upoštevajo omejitve hitrosti na obravnavanem odseku. To cenilko nato spremljamo tudi v razmerah izven prostega prometnega toka ob predpostavki, da opisuje voznike, ki sicer vozijo skladno s hitrostnimi omejitvami, na njihov potovalni čas pa so med potovanjem vplivale različne motnje znotraj prometnega toka. Kot najbolj uporabna cenilka se je pokazal centil.

Drugo možnost ocene potovalnega časa na odseku predstavlja posredna ocena potovalnega časa iz izmerjenih parametrov prometnega toka (hitrost in pretok), pridobljenih iz točkovnih merilnikov in njihovi ekstrapolaciji na pripadajoč odsek izvajanja meritve. Prednost meritev, pridobljenih iz točkovnih merilnikov, je možnost določitve resničnega potovalnega časa na osnovi virtualne meritve za posamezno vozilo, še preden le-ta konča svoje potovanje. Vhodni podatek za določitev reprezentativne vrednosti potovalnega časa predstavlja natančno določena vrednost srednje prostorske (ne časovne) hitrosti. Pri uporabi algoritma za oceno potovalnega časa iz točkovne ekstrapolacije hitrosti velja predpostavka, da znotraj časovnega intervala in na celotnem pododseku meritve prometni tok ostane konstanten. Za izpolnitev tega pogoja je potrebna dovolj gosta postavitev točkovnih merilnikov ter kratek čas posodabljanja informacije. Za zagotovitev robustnosti in hitrega odziva smo razvili poseben algoritem, ki zgladi naključna nihanja hitrosti, pri čemer zagotavlja odziv na skokovite spremembe hitrosti, ki so posledica udarnega vala. Algoritem določi, ali je sprememba hitrosti posledica naključnega nihanja zaradi obnašanja voznikov in jo moramo zgladiti, ali gre za spremembo prometnega stanja in jo ne smemo gladiti, s čimer zagotovimo hipen odziv algoritma. Z glajenjem srednjih prostorskih hitrosti za zaporedne časovne intervale (glajenje) oz. z upoštevanjem dejanske prostorske hitrosti v trenutnem časovnem intervalu (preskok), algoritmu za posredno oceno potovalnih časov iz točkovne ekstrapolacije hitrosti dodamo komponento upoštevanja dinamike prometnega toka, ki v večini obstoječih študij ni bila upoštevana. Z glajenjem hitrosti v zaporednih časovnih intervalih zmanjšamo naključna nihanja hitrosti, ki so posledica individualnega obnašanja voznikov osebnih vozil, s čimer povečamo kredibilnost sistema. Z

upoštevanjem preskoka zagotovimo hiter odziv algoritma na nenadna nihanja hitrosti, ki so najverjetneje posledica izrednega dogodka.

Tako določeno reprezentativno hitrost smo v nadaljevanju ekstrapolirali na posameznim merilnikom pripadajoče pododseke in tako dobili potovalni čas potreben za prevoz posameznega pododseka. Želeli smo se izogniti zapletenim matematičnim metodam ekstrapolacije, katerih prostorska ponazoritev je vprašljiva in bolj sledi teoretičnim matematičnim funkcijam kot dejanskemu obnašanju prometnega toka. Predlagali smo modificirano metodo odsekoma konstantne ekstrapolacije, kjer glede na karakteristike obnašanja prometnega toka na trasi vsakemu merilniku pripišemo pododsek, na katerem velja reprezentativna hitrost s tega merilnika. Seštevek potovalnih časov na posameznih pododsekih posreduje informacijo o potovalnem času na odseku.

Pri neposrednem merjenju, kot tudi pri posredni oceni, se pojavijo težave v samem postopku pridobivanja informacije o potovalnem času. Neposredno izmerjeni potovalni čas je meritev izvedena na podlagi funkcijske zveze med opravljeno potjo vozila in njegovim potovalnim časom v prostoru in času, pri čemer je za izvedbo meritve potrebno, da vozilo dokonča svoje potovanje. Po drugi strani je posredna ocena ponavadi pridobljena na podlagi točkovne meritve, ki jo nato ekstrapoliramo v prostor in zato ne predstavlja potovanja dejanskega vozila. Neposredno izmerjeni potovalni čas predstavlja natančno informacijo s časovno zakasnitvijo, medtem ko posredna ocena iz točkovnih meritev hitrosti predstavlja takojšnjo informacijo z manjšo prostorsko natančnostjo. Nastala situacija, ko imamo na voljo različne tehnologije za pridobivanje prometnih podatkov, različne algoritme z različnimi natančnostmi, različno prostorsko vplivno območje posameznega merilnika podatkov in različne časovne okvire, predstavlja ugodno okolje za vzpostavitev sistema združevanja podatkov. Vse predhodno opisano nas je napeljalo k ideji o dopolnilnosti neposredne linijske meritve in točkovne ocene ter implementaciji metodologije in algoritma za združevanje podatkov, ki združuje lastnosti posamezne meritve v kombinacijo z večjo natančnostjo.

Metodo združevanja smo izbrali na podlagi namena združevanja podatkov, konfiguracije merilnikov ter predvidenega obnašanja vhodnih podatkov. Določili smo arhitekturo združevanja podatkov in se odločili za metodo, katere značilnost je robustno obnašanje. Z naše strani predlagana metoda združevanja podatkov temelji na linearni regresiji, ki se je glede na predhodne ugotovitve različnih avtorjev z vidika računske zahtevnosti ter natančnih rezultatov izkazala kot najbolj optimalna. To predstavlja pomembno ugotovitev, saj so nekatere druge metode tako teoretično kot računsko precej kompleksne in je zato njihova implementacija vprašljiva, glede na to da ne zagotavljajo bistvene dodane vrednosti. Ker nobena od obstoječih študij ne vzame v obzir kvalitativnih meril odvijanja prometnega toka v smislu različnih merenj, kot so hitrost, gostota in pretok prometnega toka, predstavlja bistven izvorni prispevek disertacije nadgradnja metode združevanja podatkov z dodatnimi vhodnimi podatki in sicer informacijo o stopnji prometnega stanja, ki kvalitativno opiše razmere v prometnem toku na podlagi osnovnih karakteristik prometnega toka kot sta hitrost in gostota. Model določi tako neposredno linijsko izmerjen potovalni čas kot tudi potovalni čas in posredne ocene na podlagi osebnih vozil, pri združevanju obeh virov pa si pomaga s stopnjo prometnega stanja, kar doprinese vpliv celotnega prometnega toka. Reprezentativno vrednost potovalnega časa tako določimo le na vzorcu osebnih vozil, ki so za nas merodajna, medtem, ko nam stopnja prometnega stanja pomaga pri odločitvi, kako hitro reagirati na spremenjene prometne razmere.

Glavni namen algoritma je zagotoviti vhodno informacijo sistemu za obveščanje uporabnikov o potovalnih časih. Sistem vozniku posreduje informacijo, koliko časa bo predvidoma potreboval za prevoz odseka na katerega vstopa. Sistem podajanja informacije o potovalnih časih mora tako vozniku zagotoviti prihodnost informacije.

Pri vsaki študiji je zaželeno teoretične ugotovitve preveriti s podatki s terena. V ta namen smo teoretična dognanja preizkusili s pilotskim sistemom za določevanje potovalnih časov nameščenim na odseku med Vranskim in Blagovico, kjer smo z različnimi tehnologijami (reidentifikacija registrskih tablic, reidentifikacija naslovov »bluetooth« ter merjenje karakteristik prometnega toka z mikrovalovnimi detektorji) preverili delovanje algoritma.

9 SUMMARY

Despite the fact that travel time is one of the fundamental characteristics of traffic flow, direct measuring of travel times have been very rare on larger samples of traffic flow until recent times. Travel time is a key input to today's modern Traffic Management and Control Systems as it is the best indicator of the level of service in a road stretch, and it is completely understandable to all users. Travel time is the worthiest information from the user's point of view as it allows him to decide in advance when is the best time to start a trip and the best routing option. Travel time is also useful to the road operators as it is a basic input to assess the operational management of a highway and is a good indicator of the level of service and effectiveness of traffic systems.

Travel time can be obtained by direct measurement or indirect estimation. The direct measurement of travel time is based on measuring the time interval that a particular vehicle takes to travel between two points. There are two main techniques to directly measure travel time: reidentifying the vehicle at two consecutive control points or following the vehicle along its trajectory. In the reidentification-based techniques, the vehicle is identified at the entrance and at the exit of the highway stretch, and the precise passing time of the vehicle is recorded. By pairing both records, the travel time is directly obtained. Direct measuring techniques may be misleading in the case of existence of outlier travel time observations, observations that are numerically distant from the rest of the data. The outliers in travel time measurements are vehicles, whose shortened or extended travel times are not related to traffic conditions, but are the result of an individual behavior of each vehicle. The presence of outliers in the measurements of travel time has a significant impact on determination of the representative value of travel time. These outliers have to be detected and eliminated. Various automated vehicle identification technologies provide various travel time measurement samples: some of them are able to identify only personal cars (e.g. tolling tags), while others provide mixed samples of all vehicle classes (e.g. license plate matching). As the adequate information on travel times should concern the personal cars, the influence of heavy vehicles should be eliminated from the samples, which is not feasible with the use of existing travel time estimation algorithms. By using robust statistics, reliable results are obtained even in case of large deviations of individual values (outliers) from the model.

The objective of the travel time information system is to provide accurate travel time information for the driver of a personal car, whose travel speed is considered as safe and comfortable under the existing traffic conditions by the average driving behavior. Heavy vehicle speeds are, as opposed to personal cars, affected by a range of factors (physical characteristics of the vehicle, lower posted speed limits, the influence of the gradient of the road) which make their measured travel times significantly longer than those of the personal cars. Due to their lower speeds, which would bias the travel time estimations, heavy vehicles should not be considered when determining the representative value of travel time on the highway and shall therefore be treated as outliers. In the course of the research it was observed, that during congestion travel times of different vehicle categories (personal cars and heavy vehicles) are not equal. It seems that speeds are almost equal upstream of the congestion, but on the other hand downstream of the congestion personal cars are accelerating faster back to normal speeds, while heavy vehicles are slow in reaching their normal speeds. It was also noted that downstream of the congestion personal cars are again driving at much higher speeds than

the heavy vehicles, both due to higher speed limit and due to physical capabilities. Since travel time estimation systems are usually covering longer distances (on our test site 22 km), where congestion typically takes only a portion of the section, the difference between various vehicle categories travel times' remains visible also during congestion episodes. Therefore, there is a need to distinguish between personal cars and heavy vehicles travel times both during normal traffic conditions and during congestion (when travel time information is most needed) in order to get a representative value of travel time, which should concern only personal cars.

Considering the fact, that the variation in travel time in sampling time interval is high and that there are some vehicles capable of achieving significantly lower travel times for the same time interval and itinerary than others, it is more than obvious that the average value of travel time is not a representative indicator of the situation on the highway. The new approach proposed in this thesis for estimating the travel time on highways by using the robust statistics, determines the appropriate estimator that best describes the drivers of personal cars driving by the prescribed speed limit. The percentile has proved to be the most suitable robust statistics and its appropriate value is determined in the calibration phase of the algorithm during free-flow conditions. The idea is then to follow the determined percentile rank also during congestion episodes under the assumption that it best describes the behavior of personal cars that are driven by speed restrictions but have encountered a variety of disturbances during their journey.

The alternative to estimate travel times on the highway section is the indirect travel time estimation based on measured traffic flow characteristics (speed and flow) obtained from spot measurements and the extrapolation of these measurements to the belonging subsection. The advantage of spot speed measurements is the possibility to obtain a true travel time by using virtual measurements of a vehicle before it eventually finishes the journey. When applying this algorithm it is assumed that the point measurements reflect the homogenous traffic conditions within a time interval and on the whole part of the section covered by the spot measurements. In order to fulfill this, a sufficiently dense layout of detection sites and a short update frequency are necessary. To ensure the robustness and a quick response a special algorithm has been developed that is able to smooth random speed fluctuations while providing a quick response to abrupt changes in traffic flow. The decision whether the speed variation between two successive time intervals is a small change or a large fluctuation is done with a statistical hypothesis test about the difference between the expected values of the space mean speeds. If the speeds are statistically different, the smoothing process is suspended and the representative value of travel time is the one measured in the last time interval. The method is able to determine whether a speed variation represents a random fluctuation due to individual driver's behavior and should therefore be smoothed or is a consequence of a change in traffic conditions as a result of a shock wave and should therefore be kept as it is in order to provide prompt response of the algorithm. Another measure that is taken into account is the traffic state determination which is, in analogy with the level of service, providing the information about the ratio between speed and density. Based on the corresponding traffic state, the representative value of speed for further extrapolation is obtained by taking into account the issue with detectors measuring only the "go" part of the stop&go traffic.

Once the representative value of speed is determined, the travel times are obtained by applying the extrapolation method. A new extrapolation method has been proposed observing the fact that complex mathematical extrapolations not taking into account traffic dynamics do not provide much of an added value. A modified piecewise constant extrapolation method was

introduced that is extrapolating the speed based on the knowledge of road characteristics. The travel time on the section is then obtained by summing up the travel time values from each individual subsection.

In both, the direct measurement and the indirect estimation of highway travel times, difficulties arise. Directly measured travel times provide the information based on reidentifying vehicles at two consecutive points, so the vehicle has to finish the trip before the travel time is available. On the other hand the indirect estimation does not respond to a vehicle's path and as the point speed measurements could be achieved anytime so is the instantaneous value of travel time. This means that on one hand we have a directly measured travel time which represents accurate information with a delay equal to the duration of the trip and on the other hand the indirect estimation that represents immediate information with less spatial accuracy. The situation with multiple travel time estimation algorithms and various temporal implications represents an ideal environment for combining multiple data into a one more robust, accurate and representative information.

The algorithm for combining directly measured and indirectly estimated travel times was chosen based on the purpose of the data fusion, sensor configuration and predicted input data behavior. The data architecture was defined taking into account the desired robust behavior of the algorithm. The proposed data fusion algorithm is based on the multiple linear regression, that turns out to be the optimal solution in terms of the complexity and computational effort needed. This turns out to be an important fact since some of the methods are very complex both in theoretical formulations and computational requirements but do not provide any significant added value. As none of the existing studies take into account the qualitative measurements of traffic flow, the proposed algorithm was upgraded with additional input data (level of service). The method estimates the representative value of travel time based only on the input data from personal cars while also taking into account level of service as a good indicator of the traffic conditions on the highway.

By combining both data sources, a short-term travel time prediction is achieved, as the input for the travel time information system. The main purpose of the algorithm is to provide the value of travel time as an input to a travel time information system. As the system should provide the driver with a departure based travel time information, some sort of forecast must be made. Since many factors are influencing the behavior of the traffic flow this can be a challenging task.

In each study, it is desirable to support the theoretical findings with the data from the field. The algorithm was put into practice through a pilot travel time estimation system implemented on the A1 highway between Vransko and Blagovica being one of the busiest highway sections in the Republic of Slovenia (EU), as a part of the V. Pan-European corridor stretching from Barcelona (Spain) to Kiev (Ukraine). On the 22 km long highway stretch, the traffic is managed by an Advanced Traffic Management System (ATMS) consisting of 24 variable message signs, 50 microwave detectors, 32 video detection cameras, 35 pan-tilt-zoom video surveillance cameras, 5 road weather stations, a license plate matching system and a Bluetooth signature reidentification system. The system provides an ideal platform for experimentation, allowing for transparent and replicable testing of scientific theories, computational tools and new technologies. The test site with its challenging route and installed surveillance equipment

provides large amount of data for both free flow conditions and different incident situations resulting in congestion episodes (accidents, severe weather situations, road closures, traffic diversions etc.). The database of the events is constantly growing and all the improvements can be tested in the real-time environment.

VIRI

Abdulhai B., Tabib, S.M. 2003. Spatio-temporal inductance-pattern recognition for vehicle reidentification. *Transportation research part C* 11, 3-4: 223-239.

Anusha, S.P., Anand, R.A., Vanajakshi, L. 2012. Data fusion based hybrid approach for the estimation of urban arterial travel time. *Journal of applied mathematics*, 12, article ID 587913, 17 str.

Bachmann, C., Abdulhai, B., Roorda, M.J., Moshiri, B. 2012. Multi-sensor data integration and fusion in traffic operations and management. *Transportation research Record, Journal of the Transportation Research Board* 2308: 27-36.

Bachmann, C., Roorda, M.J., Abdulhai, B., Moshiri, B. 2013. Fusing a Bluetooth traffic monitoring system with loop detector data for improved freeway traffic speed estimation. *Journal of Intelligent Transportation Systems* 17, 2: 152-164.

Bajwa, S.I, Chung, E., Kuwahara, M. 2005. Performance evaluation of an adaptive travel time prediction model. In *Proceedings of the 8th International IEEE Conference on Intelligent Transportation Systems*, Vienna, Austria, 13–16 September, 2005: str. 1000-1005. <http://eprints.qut.edu.au/37430/1/01520187.pdf>. (Pridobljeno 14.2.2014).

Ban, X.J., Li, Y.W., Skabardonis, A., Margulici, J.D. 2010. Performance evaluation of travel-time estimation methods for real time traffic applications. *Journal of intelligent transportation systems* 14, 2: 54-67.

Bar-Gera, H. 2007. Evaluation of a cellular phone-based system for measurements of traffic speeds and travel times: A case study from Israel. *Transportation Research Part C* 15, 6: 380-391.

Barceló, J., Montero, L., Marqués, L. 2010. Travel time forecasting and dynamic OD estimation in freeways based on Bluetooth traffic monitoring. *Proceedings of the 89th Annual meeting of the transportation research board*. Washington D.C. <http://trb.metapress.com/content/17x1v88n6p8363p1/>. (Pridobljeno 27.11.2012).

Batista, M. 2007. Stacionarni prometni tok: zapiski s predavanj. Fakulteta za pomorstvo in promet. Portorož.

Benjamin, C.A., Cornell, J.R. 1970. *Probability, statistics and decision for civil engineers*. McGraw-Hill: 640 str.

Berechman, J. 2003. Transportation-economic aspects of Roman highway development: the case of Via Appia. *Transportation research part A* 37, 5: 453-478.

Berka, S., Tarko, A., Roushil, N.M., Sisiopiku, V.P., Lee, D. H. 1995. Data Fusion Algorithm for ADVANCE Release 1.5. *ADVANCE Working Paper Series* 37.

Berta, T., Török, A. 2010. Travel time reduction due to infrastructure development in Hungary, *Promet – Traffic & Transportation*, 22, 1: 23-27.

Bertini, L.R., Lasky, M., Monsere, M.C. 2005. Validating predicted rural corridor travel times from an automated license plate recognition system: Oregon's frontier project. 2005 IEEE Intelligent Transportation Systems Conference (ITSC), Dunaj, Avstrija: 706-711.

Bloch, I. 1996. Information combination operators for data fusion: comparative review with classification. *IEEE transactions on systems, Man and cybernetics - part A* 26, 1: 52-67.

Blue, V., List, G., Embrechts, M. 1994. Neural net freeway travel time estimation. *Proceedings of intelligent engineering systems through artificial neural networks* 4: 11135-11140.

Cambridge Systematics, Inc. 2012. Travel time data collection - White paper. Florida department of transportation, District IV: 52 str.

Chandola, V., Banerjee, A., Kumar, V. 2009. Anomaly detection: A survey. *ACM computing surveys* 41, 15, 15:1-15:58.

Chen, M., Chien, S.I.J. 2001. Dynamic freeway travel time prediction using probe vehicle data: link-based Vs path-based. 80th Annual meeting preprint, Transportation research board, Washington D.C., ZDA: 14 str.

Chrobok, R., Kaumann O., Wahle J., Schreckenberg, M. 2004. Different methods of traffic forecast based on real data. *European journal of operational research* 155: 558-568.

Choi, K., Chung, Y. 2002. A data fusion algorithm for estimating link travel time. *Intelligent Transportation Systems* 7: 235-260.

Chu, L., Oh, J.S., Recker, W. 2005. Adaptive Kalman filter based freeway travel time estimation. Berkley, University of California, Californian center for innovative transportation: 21 str.

Clark, S.D., Dougherty M.S., Kirby, H.R. 1993. The use of neural network and time series models for short term forecasting: A comparative study. *Proceedings of PTRC*. Manchester UK: 12 str.

Coifman B. 2002a. Estimating travel times and vehicle trajectories on freeways using dual loop detectors. *Transportation research part A* 36, 4: 351-364.

Coifman B., Cassidy M. 2002b. Vehicle reidentification and travel time measurement on congested freeways. *Transportation research part A* 36, 10: 899-917.

Coifman B., Ergueta E. 2003. Improved vehicle reidentification and travel time measurement on congested freeways. *ASCE journal of transportation engineering* 129, 5: 475-483.

Coifman B., Krishnamurthya, S. 2007. Vehicle reidentification and travel time measurement across freeway junctions using the existing detector infrastructure. *Transportation research part C* 15, 3: 135-153.

Cortés, C.E., Lavanya, R., Oh, J., Jayakrishnan, R. 2002. General-purpose methodology for estimating link travel time with multiple-point detection of traffic. *Transportation research record: Journal of transportation research board* 1802: 181-189.

Daganzo, C.F. 1995. Requiem for second-order fluid approximations of traffic flow. *Transportation research part B* 29, 4: 277-286.

Daganzo, C.F. 1995. *Fundamentals of transportation and traffic operations*. Pergamon. Elsevier science ltd.: 339 str.

Daganzo, C.F. 1983. Derivation of delays based on input-output analysis. *Transportation research part A* 17, 5: 341-342.

Daszykowski, M., Kaczmarek, K., Yander Heyden, Y., Walczak, B. 2006. Robust statistics in data analysis-A review basic concepts. *Chemometrics and Intelligent Laboratory Systems*, Volume 85: 203-219.

Dion, F., Rakha, H. 2006. Estimating dynamic roadway travel times using automatic vehicle identification data for low sampling rates. *Transportation Research Part B: Methodological* 40, 9: 745-766.

Direkcija Republike Slovenije za Ceste (DRSC), Republika Slovenija, Ministrstvo za infrastrukturo in prostor. 2012. Prometne obremenitve. http://www.dc.gov.si/si/delovna_podrocja/promet/. (Pridobljeno 28.6.2013).

Edie, L.C., Foote, R.S. 1960. Effect of shock waves on tunnel traffic flow. *Highway Research Board Proceedings* 39: 492-505.

Edie, L.C., Foote, R.S. 1961. Experiments on single-lane flow in tunnels. In R. Herman (Ed.), *Theory of Traffic Flow*. Elsevier, Amsterdam: 175-192.

El Faouzi, N.E., Simon, C. 2005. Bayesian and evidential approaches for traffic data fusion: Methodological issues and case study. Washington D.C, ZDA *Proceedings of the 85th transportation research board annual meeting*: 18 str. http://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=3&ved=0CDUQFjAC&url=http%3A%2F%2Fibrarian.net%2Fnavon%2Fpaper%2FBayesian_and_Evidential_Approaches_for_Traffic_Data.pdf%3Fpaperid%3D13119419&ei=0oUBVdbpJsTnyQPfsoGQDg&usg=AFQjCNHrF-xVj-CfsmSgnsyACoSaibf8iA&sig2=lokRiu84biUnkxXXnDhWJQ&bvm=bv.87920726,d.bGQ&cad=rja. (Pridobljeno 22.8.2013).

El Faouzi, N.-E., Billot, R., Bouzedba, S. 2010. Motorway travel time prediction based on toll data and weather effect integration. *IET Intelligent Transport Systems* 2010, 4, 4: 338-345.

Esteban, J., Starr, A., Willets, R, Hannah, P., Cross, P.B. 2004. A review of data fusion models and architectures: towards engineering guidelines. *Journal of Neural Computing and Applications* 14, 4: 273-281.

Fei, X., Lu, C.C., Liu, K. 2011. A Bayesian dynamic linear model approach for real-time short-term freeway travel time prediction. *Transportation Research Part C* 19: 1306-1318.

Ferré, J. 2005. Quality control and fusion of road and weather data at SAPN (online). http://www.centrico.de/documents/briefing%20notes/20_Data_quality_control.pdf (Pridobljeno 31.2.2013).

Field, M.S. 2010. Application of robust statistical methods to background tracer data characterized by outliers and left-censored data. *Water research* 45: 3107-3118.

Fosgerau, M., Fukuda, D. 2012. Valuing travel time variability: Characteristics of the travel time distribution on an urban road. *Transportation Research Part C* 24, 2012: 83-101.

Friederich, M., Jehlicka, P., Schlaich, J. 2008. Automatic number plate recognition for the observance of travel behavior. 8.th international conference on survey methods in transport: Harmonisation and data comparability, May 2008, Annecy, Francija: 17 str. http://www.isv.uni-stuttgart.de/vuv/publication/downloads/200805_Fr_PJ_JS-ANPR.pdf. (Pridobljeno 11.4.2013).

Gazis, D.C., Potts, R.B. 1965. The oversaturated intersection. *Proceedings of the Second International Symposium on the Theory of Traffic Flow*, OECD, Paris: 221-237.

Gazis, D.C., Knapp, C.H. 1971. On-line estimation of traffic densities from time-series of flow and speed data. *Transport Science* 5, 3: 283-301.

Gazis, D.C., Liu C. 2003. Kalman filtering estimation of traffic counts for two network links in tandem. *Transportation research part B* 37, 8: 737-745.

Grüber, B., Röhr, T. 2007. Reisezeitmessungen setzen sich durh. *Strassenverkehrstechnik* 5: 264-267.

Hage, R.M, Betaille, D., Peyret, F., Meizel, D. 2012. Unscented Kalman filter for urban network travel time estimation . *Procedia – Social and Behavioral Sciences* 54, 2012: 1047-1057.

Haghani A., Masoud, H. Kaveh F.S., Young S., Tarnoff P. 2010. Freeway travel time ground truth data collection using bluetooth sensors. Presented at TRB 2010 annual meeting proceedings, Washington D.C. <http://trb.metapress.com/content/4885780436228757/>. (Pridobljeno 11.8.2012).

Hall, D., McMullen, H. 2004. *Mathematical techniques in multisensor data fusion*. Archtech house Publishers: 449 str.

Hampel, F.R. 1971. A general qualitative definition of robustness. *The Annals of Mathematical Statistics* 1971, 42, 6: 1887-1896.

Harder, K.A., Bloomfield, J.R., Levinson, D.M., Zhang, L. 2005. Route preferences and the value of travel-time information for motorists driving real-world routes. Minnesota, University of Minnesota, Department of civil engineering: 62 str.

Herman, R., Rothery, R.W. 1965. Car following and steady state flow. *Proceedings of the Second International Symposium on the Theory of Traffic Flow*, OECD, Paris: str. 1-11.

Holt, R.B., Smith, B.L., Park, B.B. 2003. An investigation of travel time estimation based on point sensors. Technical report. Smart travel Laboratory, Charlottesville, Virginia: 129 str.

Hopkin, J., Crawford, D., Catling, I. 2001. Travel time estimation. Summary of the European Workshop organized by the SERTI project. Avignon. November 2001: 76 str.

Huber, J.P., Ronchetti, E.M. 2009. Robust statistics. Available from: http://books.google.si/books?id=j1OhquR_j88C&printsec=frontcover&dq=huber+robust+statistics&hl=sl&sa=X&ei=eClqUtbJFsextAa3wICADA&ved=0CC0Q6AEwAA#v=onepage&q=huber%20robust%20statistics&f=false. (Pridobljeno 13.7.2013).

Ivan, J. N., Schofer, J. L., Koppeleman, F. S., Massone, L.E. 1995. Real time data fusion for arterial street incident detection using neural networks. *Transportation Research Record* 1497: 27-35.

Keever, D., Shimizu, M., Seplow, J. 2003. Data fusion for delivering advance traveler information systems. No. FHWA-OP-03-119. Washington, D.C.: FHWA.

Khan, A.M. 2012. Bayesian predictive travel time methodology for advanced traveller information system. *Journal of advanced transportation* 2012, 46: 67-79.

Kim, S., Lim, K., Lee, Y. 2007. A travel time fusion algorithm based on point and interval detector data. *International journal of multimedia and ubiquitous engineering* 2, 4: 67-84.

Kim, S.D., Porter, J.D., Magaña, E.M. 2012. Wireless data collection system for travel time estimation and traffic performance evaluation: končno poročilo. Oregon department of transportation and Federal highway administration: 127 str.

Klein, L.A., Ping, Y., Teng, H. 2007. Decision support system for advanced traffic management through data fusion. *Transportation Research record, Journal of the Transportation Research Board*, 1804: 173-178.

Kothuri, S.M., Tufte, K.A., Ahn, S., Bertini R.L. 2007. Using archived ITS data to generate improved freeway travel time estimates. 86th Transportation research board annual meeting, Washington D.C., ZDA: 13 str. http://www.its.pdx.edu/upload_docs/1249924684.pdf. (Pridobljeno 11.9.2012).

Kwon, J., Coifman, B., Bicikel, P. 2000. Day-to-day travel time trends and travel time prediction from loop detector data. *Transportation research record* 1717: 120-129.

Kwon, E. 2004. Development of operational strategies for travel time estimation and emergency evacuation on freeway network. Final report MN/RC-2004-49. Prepared for Minnesota department for transportation: 55 str.

Kwong, K., Kavalier, R., Rajagopal, R., Varaiya, P. 2009. Arterial travel time estimation based on vehicle re-identification using wireless magnetic sensors. *Transportation Research Part C* 17, 6: 586-606.

Lee, Y. 2009. Freeway travel time forecast using artificial neural networks with cluster method. 12.th International Conference on Information Fusion, Seattle, Washington, ZDA: 8 str. <http://www.isif.org/fusion/proceedings/fusion09CD/data/papers/0075.pdf>. (Pridobljeno 12.3.2013).

Li, R., Rose, G., Sarvi, M. 2006. Evaluation of speed-based travel time estimation models. *ASCE journal of transportation engineering* 132, 7: 540-547.

Lin, W.H., Kulkarni, A., Mirchandani, P. 2004. Short-term arterial travel time prediction for advanced traveller information systems. *Journal of intelligent transportation systems* 8, 3: 143-154.

Lin, H-E., Zito, R., Taylor, M.A.P. 2005. A review of travel-time prediction in transport and logistics. *Proceedings of the Eastern Asia Society for Transportation Studies* 5: 1433-1448.

Linauer, M., Schneider, M., Hainizta, N., Koller, H. 2006. Traveller information service based on real-time toll data in Austria. *Proceedings of 13.th ITS World congress, London, V. Britanija*: 8 str.

Lucas, D.E., Mirchandani, P.B., Verma, N. 2004. Online travel time estimation without vehicle identification. *Transportation research record: Journal of the transportation research board* 1867: 193-201.

Ma, X., Koutsopoulos, H. 2010. Estimation of the automatic vehicle identification based spatial travel time information collected in Stockholm. *IET Intelligent Transport Systems* 2010, 4, 4: 298-306.

MacCarley, A.C. 2001. Video-based vehicle signature analysis and tracking system phase 2: Algorithm development and preliminary testing. California PATH Working paper, Institute of Transportation studies (UCB), UC Berkley, ZDA: 61 str.

Makigami, Y., Newell, G.F., Rothery, R. 1971. Three-dimensional representations of traffic flow. *Transportation Science* 5: 302-313.

Malinovskiy, Y., Wu, J.Y., Lee, U.K. 2010. Field experiments on bluetooth based travel time data collection. 89th annual transportation research board meeting, Washington D.C., ZDA: 17

str. http://www.westernstatesforum.org/Documents/2010/UW_FINAL_Bluetooth_WSRTF_6-17-10.pdf. (Pridobljeno 22.3.2013).

Margulici, J.D., Ban, X. 2008. Benchmarking travel time estimates. *IET Intelligent Transport Systems* 2008, 2, 3: 228-237.

Markovič, H., Bašić, B.D., Gold, H., Dong, F., Hirota, K. 2010. GPS data based non-parametric regression for predicting travel times in urban traffic networks. *Promet – Traffic & Transportation*, 22, 1: 1-13.

Mirchandani, P.B., Gentili, M., He, Y. 2009. Location of vehicle identification sensors to monitor travel-time performance. *IET Intelligent Transport Systems*, 2009, 3, 3: 289-303.

Mitchell, H.B. 2007. *Multi-sensor data fusion: An introduction*. New York: Springer. http://www.google.si/books?hl=sl&lr=&id=2hwcFSxQ1CAC&oi=fnd&pg=PA3&dq=multi+sensor+data+fusion+mitchell&ots=eL0OC1ap-U&sig=AgWGG2JomOEwyQYggGSw3sYXang&redir_esc=y#v=onepage&q=multi%20sensor%20data%20fusion%20mitchell&f=false. (Pridobljeno 30.12.2013).

Moskowitz, K., Newman, L. 1963. Notes on freeway capacity. *Highway Research Record* 27, Highway Research board, Washington D.C., ZDA: 44-68.

Muñoz, J.C., Daganzo, C.F. 2002. The bottleneck mechanism of a freeway diverge. *Transportation research part A* 36, 6: 483-505.

Nahin, P.J., Pokoski, J.L. 1980. NCTR Plus Sensor Fusion Equals IFFN. *IEEE Transactions on Aerospace Electronic Systems* 16, 3: 320-337.

Nam, D.H., Drew, D.R. 1996. Traffic dynamics: Method for estimating freeway travel times in real time from flow measurements. *ASCE Journal of transportation Engineering* 122, 3: 185-191.

Newell, G.F. 1993. A simplified theory of kinematic waves in highway traffic, I general theory. *Transportation research Part B* 27, 1: 281-313.

Ng, G.W. 2003. *Intelligent systems – fusion, tracking and control*. Philadelphia: Research Studies Press Ltd.: 240 str.

Ni, D., Wang, H., 2008. Trajectory Reconstruction for Travel Time Estimation. *Journal of Intelligent Transportation Systems* 12, 3: 113-125.

Nordentoft, R. 2013. Talk to me. *Thinking highways*, februar 2013: 16-19.

Oh, J.S., Jayakrishnan, R., Recker, W. 2003. Section travel time estimation from point detection data. *Proceedings of the 82nd Transportation Research Board Annual Meeting*. Washington D.C., ZDA: 13 str. <http://www.its.uci.edu/its/publications/papers/CTSS/UCI-ITS-TS-WP-02-14.pdf>. (Pridobljeno 11.4.2013).

Okutani, I., Stephanedes, Y.J. 1984. Dynamic prediction of traffic volume through Kalman filtering theory. *Transportation research part B* 18, 1: 1-11.

Ouayle, S.M., Koonce, P. 2010. Arterial performance measures using MAC readers-Portland's experience. Presented at north American travel monitoring exposition and conference, Seattle, WA, ZDA. <http://onlinepubs.trb.org/onlinepubs/conferences/2010/NATMEC/Quayle.pdf>. (Pridobljeno 7.4.2012).

Palacharla, P.V., Nelson, P.C. 1999. Application of fuzzy logic and neural networks for dynamic travel time estimation. *International transactions in operational research* 6, 1: 145-160.

Palen, J. 1997. The need for surveillance in Intelligent Transportaion Systems. *Intellimotion* 6, 1: 1-3.

Park, T., Lee, S. 2004. A bayesian approach for estimating link travel time on urban arterial road network. A. Lagana et al. (Eds.), Springer-Verlag Berlin, Heidelberg: 1017-1025.

Peterson, A. 2006. Travel times - A multi-purpose issue. Proceedings of the 4.th conference of the Euro-regional projects, I2Tern. Barcelona: 8 str.

Pirc, J. 2008. Evalvacija prometnega modela sistema za nadzor in vodenje prometa na avtocestah. Magistrsko delo. Ljubljana, Univeza v Ljubljani, Fakulteta za gradbeništvo in geodezijo (samozaložba J. Pirc): 161 str.

Pirc, J. in Pretnar G. 2009. The comparison of microscopis simulation results of ITS measures with field data. World ITS Congress, Stockholm, Sweden: 7 str.

Pretnar, G. 2011. Modeliranje ukrepov ITS v mikroskopski simulaciji. Magistrsko delo. Ljubljana, Univeza v Ljubljani, Fakulteta za gradbeništvo in geodezijo (samozaložba G. Pretnar): 112 str.

Pucket, D.D., Vickich M.J. 2010. Bluetooth-based travel time speed measuring systems development. Department of Transportation, research and Innovative Technology Administration, Washington, D.C., ZDA: končno poročilo: 56 str.

Quayle, S.M., Koonce, P., 2010. Arterial performance measures using MAC readers - Portland's experience. Available from: <http://onlinepubs.trb.org/onlinepubs/conferences/2010/NATMEC/Quayle.pdf>. (Pridobljeno 28.4.2013).

Quendler, E., Kristler, I., Pohl, A., Veith, P., Kubleka H., Boxberger J. 2006. Fahrerassistenzsystem LISA intelligente infrastruktur. Vernetzungsworkshop des BMVIT 3(I2).

Rakha, H., Zhang, W. 2005. Estimating traffic stream space-mean speed and reliability from dual and single loop detectors. *Transportation research record: Journal of the transportation research board* 1925: 38-47.

Rouphil, N.M., Tarko, A., Nelson, P.C., Palacharla P. 1993. Travel Time Data Fusion in ADVANCE, Preliminary Design Concept. ADVANCE Working Paper Series, No. 21, University of Illinois at Chicago, IL, ZDA.

Sazi Murat, Y. 2006. Comparison of fuzzy logic and artificial neural networks approaches in vehicle delay modeling. *Transportation research part C* 1485: 316-334.

Scott, G. 2006. Scottish national journey system and development of data fusion. *Proceedings of the 4.th conference of the Euro-regional projects, I2 Tern. Barcelona.*

Schneider, M., Linauer, M., Hainitz, N., Koller, H. Traveller information service based on real-time toll data in Austria. *IET Intelligent Transport Systems* 2009, 3, 2: 124-137.

Sever, D. 2002. Spletna predavanja pri predmetu Dinamika prometnih tokov. Fakulteta za gradbeništvo. Maribor.
<https://www.google.com/search?q=Sever%2C+D.+2002.+Spletna+predavanja+pri+predmetu+Dinamika+prometnih+tokov&ie=utf-8&oe=utf-8>. (Pridobljeno 12.9.203).

Shengli, W. 2011. Linear combination of component results in information retrieval. *Data and knowledge engineering* 71: 114-126.

Soriguera, F., Abeijon, D, Rosas, D., Thorson, L., Robuste, F. 2007. Travel time estimation from multiple data sources. *Proceedings of the 11th World Conference on Transport Research.* University of California, Berkeley, CA: 36 str. https://upcommons.upc.edu/eprints/bitstream/2117/2638/1/FS_WCTR-07.pdf. (Pridobljeno 12.9.2012).

Soriguera, F., Abeijón, D., Thorson, L., Robusté, F. 2007. Highway travel time data fusion. *Transportation Research Board. Proceedings of the TRB 87th Annual Meeting, Washington D.C,* ZDA: 18 str. https://upcommons.upc.edu/eprints/bitstream/2117/2639/1/TRB_paper_08.pdf. (Pridobljeno 12.10.2012).

Soriguera, F., Robusté, F. 2009. Highway travel time accurate measurement and short-term prediction using multiple data sources. *Transportmetrica* 7, 1: 1-25.

Soriguera, F., Rosas D., Robusté, F. 2010. Travel time measurement in closed toll highways. *Transportation Research Part B* 44, 10: 1242-1267.

Soriguera, F., Robusté, F. 2011. Requiem for freeway travel time estimation methods based on blind speed interpolations between point measurements. *Intelligent Transportation Systems IEEE, Transactions on intelligent transportation systems* 12, 1: 291-297.

Soriguera F., Robusté, F. 2011-b. Estimation of traffic stream space-mean speed from time aggregations of double loop detector data. *Transportation Research Part C* 19, 1: 115-129.

Soriguera F., Robusté, F. 2013. Freeway travel time information: Design and real-time performance using spot-speed methods. *IEEE Transactions on Intelligent Transportation Systems* 14, 2: 731-742.

Sun, L., Yang, J., Mahmassani, H. 2008. Travel time estimation based on piecewise truncated quadratic speed trajectory. *Transportation research part A* 42, 1: 173-186.

Sunghan L., Chungwon L. 2010. Data fusion algorithm for travel time prediction improvement. *Proceedings of the 17.th ITS World Congress, Busan, J. Koreja: 16 str.* http://reaaa.vms.my/images/f/ff/%287-04%29REVISED_DATA_FUSION_ALGORITHM_Sunghan_Lim_Korea.pdf. (Pridobljeno 13.10.2013).

Sunghyun, K., Kangwon, L., Youngin L. 2007. A travel time fusion algorithm based on point and interval detector data. *International Journal of Multimedia and Ubiquitous Engineering* 2, 4: 67-84.

SwRi, 2000. TransGuide model deployment report - Design report. Report prepared for TransGuide, Texas department of Transportation, Southwest Research Institute, San Antonio, Texas, ZDA.

Szeto, M.W., Gazis, D.C. 1972. Application of Kalman filtering to the surveillance and control of traffic systems. *Transportation science* 6, 4: 419-439.

Lim, S., Lee, C. 2010. Data fusion algorithm for travel time prediction improvement. *Proceedings of 17th ITS World Congress, Busan, Korea: 16 str.*

Transportation research board. 2010. Highway Capacity Manual HCM. National Academy of Sciences. Washington, D.C., ZDA.

Travel time data collection-White paper. 2012. Cambridge Systematics Inc, Florida department of transportation, District IV: 52 str.

Treiber, M., Helbing, D. 2002. Reconstructing the spatio-temporal traffic dynamics from stationary detector data. *Cooperative transportation dynamics* 1: 3.1-3.24.

Treiber, M., Kesting, A. 2013. Traffic flow dynamics, Data, models and simulation. Springer, Berlin: 502 str.

Tserekis, T. 2006. Comment on »Short-term arterial travel time prediction for advanced traveller information systems« by Lin, W.H., Kulkarni A., Mirchandani P. *Journal of intelligent transportation systems* 10, 1: 41-43.

Turk, G. 2012. Verjetnostni račun in statistika. Ljubljana, Univerza v Ljubljani, Fakulteta za gradbeništvo in geodezijo: 214 str.

- Turner, S.M., Eisele, W.L., Benz, R.J., Holdener, D.J. 1998. Travel time data collection handbook. Research report FHWA-PL-98-035. Federal Highway Administration. Washington, D.C, ZDA: 341 str.
- Van Are, B., van der Vlist, M.J.M., Muste, M.R., Smulders, S.A. 1997. Travel time estimation in the GERIDIEN project. *International Journal of Forecasting* 13, 1: 73-85.
- Van Hinsbergen, C.P., van Lint, J.W.C., Sanders, F.M. 2007. Short term traffic prediction models. In *Proceedings of the 14th World Congress on Intelligent Transport System (CD-ROM) Beijing, China, 2007*.
- Van Hinsbergen, C.P.I., J.W.C., van Lint. 2008. Bayesian combination of travel time prediction models. Washington D.C, ZDA. *Transportation Research Record: Journal of the Transportation Research Board* 2064: 73-80.
- Van Lint, J., van der Zijpp, N. 2003. Improving a travel-time estimation algorithm by using dual loop detectors. *Transportation research record: Journal of the transportation research board* 1855: 41-48.
- Van Lint, J., van Zuylen, H.J., Tu, H. 2008. Travel time unreliability on freeways: Why measures based on variance tell only half the story. *Transportation research Part A* 42: 258-277.
- Veloso, M., Bento, C., Pereira, F.C. 2009. Multi-sensor data fusion on intelligent transport systems. Coimbra, University of Coimbra: 32 str.
- Vuadelle B. 2006. Système d'information de temps de parcours sur le réseau autoroutier AREA. *Proceedings of ASECAP meeting, Pula, Hrvaška: 105-115*. <http://www.asecap.com/english/documents/SESSION1BAREA.pdf>. (Pridobljeno 12.12.2012).
- Wardrop, J.G. 1952. Some theoretical aspects of road traffic research. *Proceedings of the Institute of Civil Engineers* 2: 325-378.
- Weizhong, Z., Lee, D.H., Shi, Q. 2006. Short-term freeway traffic flow prediction: Bayesian combined neural network approach. *Journal of transportation engineering* 132, 2: 114-121.
- Xia, J., Chen, M. 2007. Freeway travel time forecasting under incident, Razvojno raziskovalna naloga: končno poročilo. Southeastern Transportation Center: 46 str. http://stc.utk.edu/STCresearch/PDFs/S21_xia.pdf. (Pridobljeno 12.8.2013).
- Xie, C., Cheu, R.L., Der-Horng, L. 2004. Improving arterial link travel time estimation by data fusion, TRB 2004 Annual meeting, Washington, D.C., ZDA.
- Yasin, A.M., Karim, M.R. 2009. Travel time measurement in real-time using automatic number plate recognition for malaysian environment. *Journal of Eastern Asia Society For Transportation Studies* 8: 14 str.

Yeon-Sik, J., Choi, G.J. 1999. Development of travel time estimation algorithm through the data fusion of GPS probe and loop detector. Korean society of transportation journal 17, 3.

Yeon, J., Elefteriadou, L., Lawphongpanich, S. 2008. Travel time estimation on a freeway using Discrete Time Markov Chains. Transportation research part B 42, 4: 325-338.

Yildirimoglu, M., Geroliminis, N. 2013. Experienced travel time prediction for congested freeways. Transportation research part B 53: 45-63.

Zheng, W., Lee, D.H., Shi, Q. 2006. Short-term freeway traffic flow prediction: Bayesian combined neural network approach. Journal of transportation engineering 132, 2: 114-121.

Zheng, P., McDonald, M. 2009. Estimation of travel time using fuzzy clustering method. IET Intelligent Transport Systems 2009, 3, 1: 77-86.