

УНИВЕРЗИТЕТ У БЕОГРАДУ

ФАКУЛТЕТ ОРГАНИЗАЦИОНИХ НАУКА

Стефан С. Здравковић

**ИНТЕГРИСАНИ МОДЕЛ ЗА
КЛАСИФИКАЦИЈУ И ПРЕДВИЂАЊЕ
ПОНАШАЊА ВОЗАЧА**

докторска дисертација

Београд, 2022.

UNIVERSITY OF BELGRADE

FACULTY OF ORGANIZATIONAL SCIENCES

Stefan S. Zdravković

**INTEGRATED MODEL FOR
CLASSIFICATION AND PREDICTION OF
DRIVER BEHAVIOR**

Doctoral Dissertation

Belgrade, 2022.

Ментор:

др Мирослав Миновић, редовни професор
Универзитет у Београду, Факултет организационих наука

Чланови комисије:

др Милош Миловановић, ванредни професор
Универзитет у Београду, Факултет организационих наука

др Вељко Јеремић, ванредни професор
Универзитет у Београду, Факултет организационих наука

др Милан Вукићевић, ванредни професор
Универзитет у Београду, Факултет организационих наука

др Душан Младеновић, ванредни професор
Универзитет у Београду, Саобраћајни факултет

Датум одбране: _____

Дисертацију посвећујем мојој мајци Весни, оцу Срђану и сестри Ивони. Њихова љубав и подршка су ме мотивисале да истрајем у тешким тренуцима и уз пуно одрицања приведем крају веома важан корак у академској каријери.

Посебну захвалност упућујем ментору проф. др Мирославу Миновићу и члановима комисије који су својим сугестијама и коментарима немерљиво допринели да ова дисертација добије додатну димензију квалитета.

Мојим професоркама Снежани, Слађани и Ани хвала на разумевању и искреној подршци. Својим знањем и искуством допринеле су да постанем бољи предавач и научник.

Мојим дивним пријатељима и колегама неизмерно хвала на речима подршке и охрабрења које су ми пружили током писања дисертације.

У Београду,
11.03.2022.

Стефан Здравковић

ИНТЕГРИСАНИ МОДЕЛ ЗА КЛАСИФИКАЦИЈУ И ПРЕДВИЂАЊЕ ПОНАШАЊА ВОЗАЧА

Резиме:

У уводном поглављу се описује предмет и циљ истраживања, дефинишу се полазне хипотезе, методе истраживања, опис, садржај и допринос дисертације.

Друго поглавље конципирано је на детаљном прегледу литературе и анализи постојећих система помоћу којих се врши праћење и снимање параметара на возилу, као и телематским системима за евалуацију понашања возача и пружања подршке возачу у реалном времену. Разматрани су правци даљег развоја комерцијалних возила у Европској унији (ЕУ) зависно од врсте горива. Транспортна возила са дизел моторима имају значајно велики удео на тржишту ЕУ, а уједно представљају предмет посматрања у спроведном истраживању. Додатно, сагледани су тренутни развој технологија, доступна ИоТ решења и економска исплативост имплементације постојећих телематских система и уређаја за снимање параметара на возилу.

Треће поглавље посвећено је методологији и одређивању релевантних параметра еко-вожње, поред тога разматрани су модели и мерења потрошње горива. Брзина мотора, притисак педале гаса и убрзање возила представљају три параметра који су важни у процени перформанси и дефинисању стила вожње возача. Иако су спроведена многа истраживања, квантитативни ефекти понашања возача на потрошњу горива су и даље нејасни. Прегледом литературе, идентификовани су кључни проблеми који се односе на ниску енергетску ефикасност проузроковану понашањем возача. Поред тога, закључено је да је при евалуацији и класификацији понашања возача неопходно узети у разматрање услове у саобраћају, као један од важних фактора који може значајно да утиче на стил вожње. Модели потрошње горива, осим што се користе за предвиђање, могу се искористити у евалуацији понашања возача са аспекта енергетске ефикасности. Стога је у раду извршена системска анализа и класификација постојећих модела потрошње горива.

У четвртном поглављу разматрани су модели машинског учења и фази логички системи типа 2 (ФЛС2), као главне методе и технике за препознавање образаца понашања возача. Различите технике машинског учења користе се за решавање сложених проблема класификације и регресије. Анализом постојећих алгоритама машинског учења истакнуте су њихове перформансе, предности и недостаци. Архитектура предложеног модела за предвиђање и класификацију понашања возача треба да омогући примену неке од техника рударења за генерисање потрошње горива. Прегледом литературе установљено је да многи аутори дефинишу различите границе за исте посматране параметре који се односе на еко-вожњу. То се углавном дешава због лингвистичке природе при дефинисању правила еко-вожње. Фази логика сматра се адекватном методологијом за пројектовање робусних система, који треба да испуне одговарајуће перформансе у стањима неизвесности и непрецизности. Развијањем модела, користећи релевантне параметре вожње као улаз, и применом ФЛС2, може се решити недостатак у дефинисању нејасних правила еко-вожње и њених граница.

Пето поглавље конципирано је на архитектури интегрисаног модела за класификацију и предвиђање понашања возача. Главни циљ дисертације представља прављење новог методолошког оквира за евалуацију понашања и класификације возача, који је заснован на утврђивању и избору најутицајних параметара вожње помоћу којих је могуће дефинисати коначну оцену вожње. Користећи ФЛС2 модел, модел машинског учења и *Potthoff* анализу, дат је предлог модела за класификацију и предвиђање понашања возача са аспекта потрошње горива. У првој фази у оквиру ФЛС2 подмодела извршена је евалуација стила вожње. Вожња се оцењивала сваке секунде на основу снимљених вредности параметара о вожњи. Након тога, на основу добијених оцена прво се формира дневна оцена возача. По истом принципу израчунава се коначна оцена за посматрани период, којом се класификује стил вожње. За верификацију добијених оцена неопходно је измерити стварну потрошњу горива. С обзиром на различите проблеме и потешкоће у мерењу потрошње горива, у другом подмоделу врши се предикција потрошње горива која ће се након одређивања услова у саобраћају користити за верификацију оцена вожње у реалном времену. Одабиром релевантних улазних параметара о раду возила и применом алгоритама машинског учења, врши се предвиђање потрошње горива. Исти скуп параметара користи се у оба подмодела. У последњој фази применом *Potthoff* анализе, врши се предвиђање потрошње горива на основу оцена вожње зависно од услова у саобраћају. Овом анализом пружају се информације о томе да ли се регресиони модели засновани на различитим групама са истим варијаблама разликују.

У шестом поглављу описана је примена модела на основу спроведеног истраживања и приказаних резултата. Предложени интегрисани модел дао је занимљиве резултате након прве фазе, у којима коначна оцена возача може да зависи од броја посматраних улазних параметара. У спроведеном истраживању [1], Арас и Гоћеш сматрају да је могуће извршити евалуацију стила вожње на основу следећих параметара: брзина мотора и убрзање. Према томе, коначне оцене вожње које представљају излаз ФЛС2 подмодела, поређене су на основу два и три улазна параметра. Уочена је осетљивост резултата и могућност различитог рангирања возача зависно од броја посматраних параметара. Категоризацијом коначних оцена извршена је класификација понашања возача. Оне уједно представљају квантитативни израз стила вожње. У другој фази, након поређења перформанси најпопуларнијих алгоритама машинског учења, извршен је одабир алгорита који представља најбоље решење. На овај начин, решен је проблем који се односи на моделирање потрошње горива. Допринос дисертације огледа се у примени интегрисаног модела којим је утврђена могућност мерења утицаја градских услова при евалуацији стила вожње и предвиђању потрошње горива.

На основу резултата, осмо закључно поглавље садржи одговоре на питања у вези са постављеним циљевима и хипотезама докторске дисертације. Извршени су преглед и систематизација научних доприноса који су проистекли из истраживања. Изложена је актуелна проблематика и дат предлог даљег правца истраживања у посматраној области. На крају је дата литература коришћена приликом израде дисертације, која садржи релевантне референце других истраживача. У прилогу су приказани подаци и делом најзначајнији резултати емпиријског истраживања.

Кључне речи:

класификација, предвиђање, понашање возача, машинско учење, фази логика, енергетска ефикасност, потрошња горива, *Potthoff* анализа

Научна област:

Техничке науке

Ужа научна област:

Информационе технологије

УДК број:

INTEGRATED MODEL FOR CLASSIFICATION AND PREDICTION OF DRIVER BEHAVIOR

Abstract:

The introductory chapter describes the area of research and the main objectives of the paper. After that, the hypothesis and research methods are defined, with the given content and contribution of the dissertation.

The second section is based on a detailed review of the literature and analysis of existing systems used to monitor and record parameters of the vehicle, as well as telematic systems for evaluating driver behavior and providing real-time support to the driver. Directions of further development of commercial vehicles in the European Union (EU) depending on the type of fuel were discussed. Diesel transport vehicles have a significantly large market share in the EU, thus representing the subject of conducted research. The current development of technologies, available IoT solutions, and the economic cost-effectiveness of the implementation of telematics systems and devices for recording parameters on the vehicle were considered.

The third chapter is committed to the methodology and determination of relevant eco-driving parameters. In addition models and measurements of fuel consumption were discussed. Engine speed, accelerator pedal position and vehicle acceleration are three parameters that are important in assessing performance and defining driving style. Many studies have been conducted, however, the quantitative effects of driver behavior on fuel consumption are still unclear. A review of the literature identified key issues related to the reduced energy efficiency caused by driver behavior. It was concluded that when evaluating and classifying driver behavior, it is necessary to consider traffic conditions, as one of the important factors that can significantly affect driving style. In addition to being used to predict fuel consumption, consumption models can also be used to assess the energy efficiency of the vehicles. Therefore, a systematic analysis and classification of existing fuel consumption models were performed.

In the fourth section, machine learning models and type-2 fuzzy logic systems (FLS2), as the main methods and techniques for recognizing driver behavior patterns are considered. Different machine learning techniques are used to solve complex problems of classification and regression. The analysis of existing machine learning algorithms emphasizes their performance, advantages, and disadvantages. The architecture of the proposed model for the classification and prediction of driver behavior should include the application of mining techniques to generate fuel consumption. In the literature review, many authors define different limits for the same observed parameters related to eco-driving. This is mostly due to the linguistic nature of the definition of eco-driving rules. Fuzzy logic is considered to be an adequate methodology for designing robust systems that should satisfy the corresponding performance in states of uncertainty and accuracy. By developing the model using the relevant driving parameters as inputs and applying the FLS2, the shortcoming in defining the unclear rules of eco-driving and its boundaries can be solved.

In the fifth section, attention is being shifted to the architecture of an integrated model for the classification and prediction of driver behavior. The main goal of the dissertation is to create a novel methodological framework for the classification and evaluation of driver behavior. It should be based on determining the most influential driving parameters that can be used to define the final driving score. Using the FLS2 model, the machine learning model, and Potthoff analysis, a model proposal for the classification and prediction of driver behavior from the aspect of fuel consumption is given. In the first phase, the driving style was evaluated based on the FLS2 submodel. The driving score is obtained every second based on the recorded values of the driving parameters. Based on them, the daily driving score is formed first. The same principle is used to calculate the final driving result for the observed period, which classifies driving style. To verify the obtained results, it is necessary to measure real fuel consumption. Due to various problems and difficulties in measurement, the second submodel performs fuel consumption prediction. It will be used to verify real-time driving evaluation after determining traffic conditions. By selecting the relevant input driving parameters and applying machine learning algorithms, it is possible to predict fuel consumption. The same set of parameters is used in both submodels. In the last phase, using Potthoff analysis, fuel consumption was predicted based on driving scores depending on traffic conditions. This analysis provides information on whether regression models based on different groups with the same variables differ.

The sixth section describes the application of the model based on the conducted research and the presented results. The proposed integrated model gave interesting results after the first phase, in which the final driver score may depend on the number of observed input parameters. In conducted research [1], Aras & Gocer consider that it is possible to evaluate the driving style based on the engine speed and acceleration. Therefore, the final driving scores representing the output of the FLS2 submodel were compared based on two and three input parameters. The sensitivity of the results and the possibility of different drivers ranking depending on parameters were noticed. By categorizing the final scores, the classification of drivers' behavior was performed. They also represents a quantitative expression of driving style. In the second phase, after comparing the performance of the most popular machine learning algorithms, the appropriate algorithm that represents the best solution was selected. Thus, the problem related to fuel consumption modeling is solved. The contribution of the dissertation is reflected in the application of the novel integrated model which determines the possibility of measuring the influence of traffic conditions in the evaluation of driver behavior and forecasting fuel consumption.

Based on the results, the last section contains answers to questions related to the set objectives and hypotheses of the doctoral dissertation. The review and systematization of scientific contributions that resulted from the research were performed. The current issues are presented and a proposal for further direction of research in the observed area was provided. Finally, extensive literature which contains relevant references of other researchers is provided. The data and some of the most significant results of the empirical research are presented in the appendix.

Keywords:

classification, prediction, driver behavior, machine learning, fuzzy logic, energy efficiency, fuel consumption, Potthoff analysis

Scientific field:

Technical sciences

Narrow scientific field:

Information technologies

UDC number:

САДРЖАЈ

1.	УВОД.....	1
1.1.	Проблем и предмет истраживања.....	1
1.2.	Циљ истраживања и полазне хипотезе.....	3
1.3.	Методе истраживања.....	4
1.4.	Допринос докторске дисертације	5
2.	ПРЕГЛЕД ОБЛАСТИ	6
2.1.	Технологије и системи за мерење параметара вожње.....	6
2.1.1.	OBD системи	6
2.1.2.	Телематски системи	8
2.1.3.	Интернет ствари – ИоТ	11
2.2.	Преглед и правци даљег развоја комерцијалних возила у Европској унији ..	17
3.	ЕКО-ВОЖЊА И МЕРЕЊЕ ПОТРОШЊЕ ГОРИВА	21
3.1.	Методологија еко-вожње	21
3.2.	Параметри еко-вожње	25
3.2.1.	Број обртаја мотора.....	25
3.2.2.	Убрзање возила	26
3.2.3.	Притисак педале гаса	26
3.3.	Модел потрошње горива	28
3.4.	Основе и мерење потрошње горива	35
4.	МЕТОДЕ И ТЕХНИКЕ ЗА ПРЕПОЗНАВАЊЕ ПОНАШАЊА ВОЗАЧА.....	38
4.1.	Машинско учење	38
4.1.1.	Технике класификације и регресије.....	39
4.1.2.	Кластеровање	42
4.1.3.	Примена машинског учења у евалуацији понашања возача.....	44
4.1.4.	Примена машинског учења у моделирању потрошње горива.....	48
4.2.	Фази скупови и фази логички системи типа 2	50
5.	АРХИТЕКТУРА ИНТЕГРИСАНОГ МОДЕЛА ЗА КЛАСИФИКАЦИЈУ И ПРЕДВИЂАЊЕ ПОНАШАЊА ВОЗАЧА	52
5.1.	Структура ФЛС2 модела за оцену стила вожње.....	53
5.2.	Модел машинског учења у предвиђању потрошње горива.....	58
5.3.	Potthoff анализа.....	61

6.	ПРИМЕНА МОДЕЛА	63
6.1.	Опис истраживања	63
6.2.	Резултати истраживања	65
6.3.	Дискусија и кратак осврт на постојећа решења	83
7.	ПРЕДЛОГ СИСТЕМА ЗА НАГРАЂИВАЊЕ ВОЗАЧА	86
8.	ЗАКЉУЧАК	88
8.1.	Доприноси докторске дисертације	90
9.	ЛИТЕРАТУРА	94

Списак табела

Табела 1. Структура возног парка ЕУ према врсти горива за 2019. годину	19
Табела 2. Фактори који утичу на потрошњу горива и емисију гасова [70]	24
Табела 3. Преглед методологија модела потрошње горива и најзначајнији фактори	32
Табела 4. Поређење перформанси SVM, RF и ANN модела [182]	48
Табела 5. Параметри за оцену стила вожње возача	54
Табела 6. Дефинисана фази правила ФЛС2 модела	56
Табела 7. Мере перформанси за нумеричко предвиђање [156]	60
Табела 8. Остварене вредности параметара вожње код тестираних возача	66
Табела 9. Дневне и коначне оцене возача на посматраним деоницама.	70
Табела 10. Вредности параметара које карактеришу стилове вожње возача В3 и В4.	72
Табела 11. Коначне оцена возача и остварена специфична потрошња горива.....	75
Табела 12. Дескриптивна статистика параметара на скупу података за тренинг.....	76
Табела 13. Перформансе модела на сету података за тренинг	76
Табела 14. Перформансе модела на сету података за тестирање	76
Табела 15. Записи прочитаних параметара вожње возача В3 након извршене предикције услова у саобраћају на деоници 1	78
Табела 16. Предвиђени и стварни услови у саобраћају током вожње возача В3 на деоници 1	80
Табела 17. ANOVA	82
Табела 18. Model Summary	82
Табела 19. Forecasts (Предвиђање потрошње горива)	83
Табела 20. Стил вожње, коначна оцена и просечна потрошња горива по возачима ..	84

Списак графикана

Графикон 1. Функција припадности улазне промењиве УБ ФЛС2 модела	54
Графикон 2. Функција припадности улазне промењиве ППГ ФЛС2 модела.....	54
Графикон 3. Функција припадности улазне промењиве БМ ФЛС2 модела	55
Графикон 4. Временска заступљеност снимљених података о брзини мотора по возачима	66
Графикон 5. Временска заступљеност снимљених података о притиску педале гаса по возачима.....	67
Графикон 6. Временска заступљеност снимљених података о УБ возила по возачима	68
Графикон 7. Временска заступљеност снимљених података о брзини возила по возачима	68
Графикон 8. Осетљивост модела на промену улазних параметара БМ и УБ.....	69
Графикон 9. Осетљивост модела на промену улазних параметара ППГ и УБ	69
Графикон 10. Осетљивост модела на промену улазних параметара ППГ и БМ	69
Графикон 11. Дистрибуција брзина возила током периода заустављања при почетној посматраној брзини од 50 km/h.....	71
Графикон 12. Дистрибуција брзина возача В2 на деоници 1 на интервалу од 1000 секунди	72
Графикон 13. Дистрибуција брзина возача В3 на деоници 1 на интервалу од 1000 секунди	73
Графикон 14. Дистрибуција брзина возача В5 на деоници 1 на интервалу од 1000 секунди	73
Графикон 15. Вредности параметра ППГ зависно од остварене брзине возила у градским условима возача В3, В5 и В6	74
Графикон 16. Поређење коначних оцена вожње возача [200].....	75
Графикон 17. Измерена и предвиђена потрошња горива применом алгоритама М5Р и RF алгорита.	77
Графикон 18. Поређење измерене и предвиђене потрошње горива применом М5Р алгорита.....	78
Графикон 19. Поређење регресија зависно од услова у саобраћају	81

Списак слика

Слика 1. FLEETOMATIC уређај за читавање података путем OBD-II прикључка.....	6
Слика 2. Архитектура система за прикупљање параметара вожње	7
Слика 3. Концептуални оквир телематског система [27]	8
Слика 4. Архитектура телематског система [29]	9
Слика 5. Елементи ИТС-а [30]	10
Слика 6. Архитектура система VISCar [26]	11
Слика 7. GSM модул	12
Слика 8. Жироскоп са модулом сензора акцелерометра	12
Слика 9. AutoPi телематска јединица 4G/LTE [40]	13
Слика 10. AutoPi телематска јединица намењена за сопствени развој [41]	13
Слика 11. AutoPi клауд апликација за праћење податка о вожњи [40]	14
Слика 12. Покривеност Helium мреже на територији Београда [42]	15
Слика 13. Структура лаких комерцијалних транспортних возила ЕУ према врсти горива за 2019. годину	17
Слика 14. E-Force EF18 електрични камион [49]	18
Слика 15. Нови аутобуси у ЕУ по врсти горива за 2020. годину	19
Слика 16. Нови камиони у ЕУ по врсти горива за 2020. годину	20
Слика 17. Нова лака возила у ЕУ по врсти горива за 2020. годину	20
Слика 18. Методологија еко-вожње [51]	21
Слика 19. Методолошки оквир истраживања [52]	22
Слика 20. Процентуални интервали уштеде горива по факторима еко-вожње [2]	23
Слика 21. Оквир за оцењивање перформанси возача [69]	24
Слика 22. Систем контроле ЕКО педале [93]	27
Слика 23. Карактеристике модела беле, сиве и црне кутије [100]	28
Слика 24. Фактори који утичу на потрошњу горива [100]	29
Слика 25. Бежична комуникација V2I и V2V [109]	30
Слика 26. Оквир конструкције модела [112]	31
Слика 27. Оквир анализе за разумевање понашања возача [119]	34
Слика 28. Ток података машинског учења	38
Слика 29. Технике машинског учења [133]	39
Слика 30. Модел вредновања стила вожње заснован на алгоритму стабла одлучивања [168]	44
Слика 31. Дијаграм тока механизма профилисања возача [176]	45
Слика 32. Расподела добијених оцена [177]	46

Слика 33. Методологија заснована на алгоритмима машинског учења [147]	47
Слика 34. Подобност развијеног SVM и RF модела [182]	48
Слика 35. Секундарне функције припадности а) фази скупа типа 1, б) интервалног фази скупа типа 2, в) општег фази скупа типа 2 [191]	50
Слика 36. Функција припадности типа 1 (а) Функција припадности типа 2 (b)	50
Слика 37. Архитектура интегрисаног модела за класификацију и предвиђање понашања возача.....	52
Слика 38. Предложени фази логички модел типа 2 за оцену стила вожње [200].....	53
Слика 39. Категоризација евалуације стила вожње.....	57
Слика 40. Унакрсна валидација модела машинског учења за К подскупова	59
Слика 41. Renault master – комби возило коришћено у истраживању	63
Слика 42. Графички приказ предвиђених услова у саобраћају током вожње возача В3 кроз Нови Сад	79
Слика 43. Међусобна зависност између регресија зависно од услова у саобраћају.....	81
Слика 44. Доприноси система за награђивања возача	87

Списак скраћеница

OBD	<i>On-Board Diagnostics</i>
ECU	<i>Engine Control Unit</i>
ФП	<i>Функција припадности</i>
ФЛС	<i>Фази логички систем</i>
СУС мотори	<i>Мотори са унутрашњим сагоревањем</i>
ИоТ	<i>Internet of Things (интернет ствари)</i>
ИТС	<i>Интелигентни транспортни системи</i>
ЕУ	<i>Европска Унија</i>
V2V	<i>Комуникација између возила</i>
V2I	<i>Комуникација између возила и саобраћајне инфраструктуре</i>
МАФ	<i>Mass Air Flow (параметар)</i>
RPM	<i>Revolutions per minute (мерна јединица)</i>
ППГ	<i>Притисак педале гаса (параметар)</i>
БМ	<i>Брзина рада мотора (параметар)</i>
УБ	<i>Убрзање возила (параметар)</i>
SVM	<i>Support-vector machine (метод подржавајућих вектора)</i>
RF	<i>Random forest (алгоритам насумичне шуме)</i>
LVQ	<i>Learning Vector Quantization (алгоритам учења векторске квантизације)</i>
NB	<i>Naïve Bayes (Наивни Бајесов класификатор)</i>
ANNs	<i>Artificial neural networks (вештачке неуронске мреже)</i>
k-NN	<i>k-nearest neighbors (алгоритам k-најближих суседа)</i>
CAN	<i>Controller Area Network (комуникациони протокол)</i>

1. УВОД

У уводном поглављу се описује предмет и циљ истраживања, дефинишу се полазне хипотезе, методе истраживања, опис, садржај и допринос дисертације.

1.1. Проблем и предмет истраживања

Понашање возача игра важну улогу у одрживом транспорту [2]. Поред тога, има директан утицај на саобраћајни ток, потрошњу горива и загађење ваздуха. Много дефиниција везује се за појам „понашање возача“ или „стил вожње“ [3]. У овом истраживању за понашање возача усвојена је дефиниција коју су дали Лајунен и Озкан: „Стил вожње представља индивидуалне возачке навике, односно начин којим возач вози“ [4]. Последњих година вредновање и процена понашања возача постају главна тема разних истраживања [5, 6]. Друмски транспорт има посебан допринос у емисији гасова са ефектима стаклене баште. Стохастичка природа вожње, мерење, моделирање, предвиђање и оцењивање понашања возача представљају велики изазов како у транспортним компанијама, тако и у ауто-индустрији. За моторе са унутрашњим сагоревањем, те емисије су пропорционалне утрошеној количини горива [7]. Претходне студије указују да је агресивно понашање у вожњи најважнији узрок неправилне вожње, што проузрокује повећање потрошње горива и емисије штетних гасова [8-10]. Поред тога, понашање возача игра важну улогу у потрошњи горива и безбедности вожње [11]. Транспортне и логистичке компаније које поседују сопствене возне паркове сусрећу се са великим изазовима тржишне конкуренције и настоје да што више смање своје трошкове. Трошкови горива спадају у једне од главних оперативних трошкова ових компанија [12-14]. Повећање енергетске ефикасности возног парка представља један од главних подциљева који доприноси да ове компаније постигну свој главни циљ – остварење што веће профитабилности у оквиру одрживости [15].

Једно од решења за смањење трошкова горива, односно за повећање енергетске ефикасности возног парка је деловање на возаче и њихов стил управљања возилом. Понашање возача током вожње има своје специфичности и сличности које се могу генерализовати уз помоћ модела, који представља један од најважнијих аспеката у пројектовању, развоју и примени напредних телематских система и система за помоћ у вожњи. Поред тога, предвиђање понашања возача неопходно је како би се пружиле правовремене информације и преузеле одговарајуће мере у случају да возач не вози економично или тежи агресивном стилу вожње. Возачи који теже агресивном стилу вожње остварују већу специфичну потрошњу горива од возача који теже умереном стилу вожње, када користе возила истих техничко-експлоатационих карактеристика и имају исте експлоатационе и климатске услове [16].

Један од начина за процену перформанси возача преко праћења параметара на возилу је употреба савремених информационих технологија [16-18]. Применом телематских система повећава се безбедност и поузданост транспортног процеса [19]. Телематски системи на возилу пружају велику количину разних података за чију је обраду и стручну анализу неопходно извесно време. Ово представља један од

разлога због којег се руководиоци често суочавају са потешкоћама у доношењу појединих управљачких одлука [20]. Поред тога, примена одређених телематских система често захтева велика финансијска улагања у пратећу опрему и инсталацију у возилима. Међутим, потенцијал оваквих система у примени модела за класификацију и предвиђање понашања возача може бити изузетно развијена бежично комуникациона инфраструктура за прикупљање и размену података током вожње, као и развијени системи за пружање информација возачу. Досадашња истраживања указују да се прикупљени подаци о вожњи могу искористити за ефикасан приказ понашања возача током вожње и препознавање различитих стилова вожње. Повезивањем мерних уређаја за прикупљање податка о возилу преко OBD-II (енг. *On-Board Diagnostics*) прикључка, могу се добити детаљне информације о вожњи као што су: брзина рада мотора, брзина кретања возила, убрзање возила, притисак педале гаса, итд. У општем случају препознавање активности или препознавање возача огледа се у комбинацији различитих података о вожњи.

Спроведена истраживања углавном су се бавила развијањем техника одабира параметара који указују на карактеристична понашања возача. Проблем се огледа у идентификовању и мерењу релевантних параметара вожње, који могу да открију и предвиде карактеристична понашања возача. Поред тога, постоје различити спољашњи фактори (временски услови, градски, приградски услови у саобраћају или вожња на отвореном путу и ауто-путу, нагиб деонице којом се возило креће, оптерећеност возила, итд.), који директно могу да утичу на оцењивање стила вожње. Према томе, потребно је свеобухватно посматрање доступних параметара вожње, како би се одредили релевантни параметри који указују на одређено понашање возача. Прикупљање података, економска исплативост, обрада и анализа постојећих података применом одговарајућих метода треба да резултују дефинисањем карактеристичних профила, односно класификацијом понашања возача са аспекта енергетске ефикасности управљања возилом.

Сваки возач поседује одређене навике у вожњи које уједно представљају карактеристична понашања возача, односно стил вожње. У овом истраживању усвојена је дефиниција коју су дали Лајунен и Озкан: „Стил вожње представља индивидуалне возачке навике, односно начин којим возач вози“ [4]. Возачи се међусобно могу разликовати по стиловима вожње. Ови стилови се директно одражавају на ефикасност управљања возилом. Развојем информационих технологија и коришћењем GPS-а омогућава се праћење возила, док подаци о раду возила могу да се прикупе путем мерних уређаја, посредством OBD-II прикључка на возилу. У циљу постизања ефикасне обраде података и оцењивања понашања возача неопходно је откривање утицаја одређених параметара вожње на потрошњу горива, као и њихове међусобне корелације.

Предмет овог истраживања представља интеграција различитих модела за евалуацију понашања возача. Анализом постојећих модела, средстава, техника и технологија установљено је да постоји могућност њихове интеграције. На основу утврђеног стања, разматрана је могућност примене оваквог модела у развоју и имплементацији система за подршку и контролисању возних паркова транспортних компанија.

1.2. Циљ истраживања и полазне хипотезе

Главни циљ истраживања представља израду новог методолошког приступа у пројектовању система за класификацију и предвиђање понашања возача са аспекта енергетске ефикасности, односно потрошње горива. Посебан циљ истраживања је практична демонстрација примене предложеног методолошког приступа, односно евалуација понашања возача у реалним условима.

Истраживањем тренутног нивоа развоја мерних уређаја, метода и алгоритама за препознавање понашања возача треба испитати да ли постоји могућност за њихово унапређење, односно развој интегрисаног модела за класификацију и предвиђање понашања возача. На основу одређених улазних параметара прикупљених током вожње, треба извршити евалуацију, а касније и предикцију понашања возача зависно од услова у саобраћају. Добијена оцена би требало да укаже да ли посматрани возач тежи агресивном или умереном стилу вожње, који је уједно безбедан и енергетски ефикасан. На овај начин руководиоцима возних паркова би био омогућен трајни увид у начин управљања возилом и правовремено реаговање у случају неекономичног стила вожње возача. Поред директних ефеката на потрошњу горива, додатне користи развијеног модела огледале би се у потенцијално нижој емисији штетних гасова, повећању безбедности у саобраћају и нижим трошковима одржавања возила услед смањене амортизације потрошних делова.

У оквиру овог истраживања на основу постављених циљева и задатака дефинисана је главна хипотеза која гласи:

- Могуће је креирати нови интегрисани модел за класификацију и предвиђање понашања возача, као подршку у евалуацији стила вожње возача.

Остале хипотезе:

- Развој информационо-комуникационих технологија и уређаја за мерење параметара о раду возила током вожње је достигао ниво на коме омогућује економски исплативу и релативно једноставну имплементацију новог интегрисаног модела за класификацију и предвиђање понашања возача у реалним условима.
- Креирањем интегрисаног модела за класификацију и предвиђање понашања возача, који је заснован на примени машинског учења и фази логичких скупова типа 2, остварује се већа прецизност у евалуацији стила вожње возача у односу на постојеће моделе.
- Применом алгоритама машинског учења и одговарајућих статистичких метода може се утврдити и измерити утицај вожње у градским условима при евалуацији стила вожње возача.
- На основу модела за класификацију и предвиђање понашања возача могуће је развити нови приступ за награђивање возача који поштују принципе еко-вожње.

- Потрошња горива може бити значајно нижа ако се на основу евалуације и класификације стила вожње врши правовремено реаговање и предузимање одговарајућих мера према возачима са агресивним, енергетски неефикасним стилем вожње.

1.3. Методе истраживања

Као основни метод истраживања користиће се анализа постојећих теоријских резултата и емпиријско истраживање у наведеној области. Од општих научних метода, биће примењена компаративна метода. Ова метода користиће се за упоредну анализу постојећих модела за класификацију и предвиђање понашања возача. Да би се реализовала идеја истраживања и потврдиле, односно оповргле полазне хипотезе, рад ће се конципирати на:

- прегледу истраживања у области, прикупљању и сређивању података о доступним решењима на основу доступне литературе и претраживању дигиталних библиотека водећих инжењерских и научних институција релевантних за област истраживања,
- упоредној анализи постојећих модела за евалуацију понашања возача,
- анализи и систематизацији претходно прикупљених и сређених података,
- примени фази скупова и фази логике типа 2,
- примени алгоритама машинског учења,
- примени метода статистичких анализа (корелациона анализа и *Potthoff* анализа).

1.4. Допринос докторске дисертације

Најзначајнији допринос дисертације огледа се у развоју и имплементацији модела за класификацију и предвиђање понашања возача, који ће руководиоцима компанија омогућити брзо реаговање и предузимање одговарајућих мера према возачима који теже агресивном стилу вожње.

Научни допринос рада огледа се у:

- систематизацији, класификацији и компаративној анализи постојећих модела за евалуацију и класификацију понашања возача,
- систематизацији и класификацији параметара који учествују у препознавању образаца понашања возача,
- дефинисању нове примене ФЛС2 у евалуацији вожње возача у реалним условима, као и предлог архитектуре новог система,
- развоју модела машинског учења за предвиђање и евалуацију понашања возача у реалним условима,
- вредновању утицаја услова у саобраћају у предвиђању потрошње горива.

Рад на овој дисертацији резултоваће и низом стручних доприноса од којих су најважнији:

- дефинисање захтева при изради система на основу предложеног модела,
- пројектовање система који испуњава претходно дефинисане захтеве,
- потенцијално смањење штетних гасова и очување животне средине.

Најважнији резултат истраживања у оквиру ове докторске дисертације биће:

- развој и имплементација модела за класификацију и предвиђање понашања возача са аспекта енергетске ефикасности, који ће на основу најутицајнијих параметара вожње и њихове анализе у реалном времену пружити увид у понашање возача.

За ово истраживање неопходно је користити достигнућа и сазнања из неколико научних дисциплина, попут математике, статистике и економике саобраћаја. До сада није било радова који су предложили модел за класификацију и предвиђање понашања возача, заснован на фази скуповима и машинском учењу. Самим тим, материја и модел који су изложени у раду представљају својеврстан научни допринос и као такви имају посебну вредност.

2. ПРЕГЛЕД ОБЛАСТИ

Преглед области је неопходан како би се стекао увид у концепте који ће се користити у истраживању, односно служити за успостављање основе за развој интегрисаног модела за класификацију и предвиђање понашања возача и дефинисање начина његове имплементације.

У наставку следи анализа литературе која обухвата:

- OBD системе за мерење параметара вожње
- Телематске системе
- Интернет ствари
- Развој комерцијалних возила у Европској унији

Наведни концепти су детаљно истражени како би се увиделе њихове предности, недостаци и анализирали могућност развоја модела који ће бити заснован на комбиновању ових концепата.

2.1. Технологије и системи за мерење параметара вожње

2.1.1. OBD системи

Посматрање и анализа понашања возача заузима све већу пажњу у области саобраћаја. Самим тим, развијен је велики број уређаја и метода како би се идентификовало понашање возача и измерили разни параметри током вожње [21]. Развојем OBD-II стандарда омогућава се приступ подацима управљачке јединице мотора, који представља важан извор информација о раду возила. Први OBD стандард, познат као OBD-I, био је пројектован за праћење релативно мањег броја параметара у поређењу са OBD-II стандардом. Овај стандард представља технологију широке примене у возилима услед могућности повезивања путем *Bluetooth* везе. Неколико начина рада дефинисано је овим унапређеним стандардом, чиме се остварује бољи рад са системом уз могућност дефинисања разних жељених функционалности [22].



Слика 1. FLEETOMATIC уређај за читавање података путем OBD-II прикључка

Уређаји се веома једноставно постављају у возила. Пример уређаја за читавање података приказан је на Слици 1. Поред тога, оно што их чини погодним за истраживања и потенцијалну имплементацију у системима за мерење понашања возача је релативно ниска цена [23]. Код класификације и евалуације понашања возача неопходно је прикупљање GPS података како би се забележила путања кретања возила [11].

Рад OBD система огледа се у континуираном надгледању различитих сензора и слању повратних информација рачунару возила у виду електричних сигнала. Повезивањем мерних уређаја за прикупљање податка о возилу преко OBD-II прикључка, могу се добити детаљне информације о вожњи попут: брзине рада мотора, брзине кретања возила, убрзању возила, притиску педале гаса, GPS координатама, углу волана, положају клапне гаса, итд. У истраживању [24] приказан је пример како се прецизним мерењем на основу прикупљених параметара може израчунати тренутна потрошња горива.

OBD систем омогућава да се подаци прикупљају коришћењем сензора. Ово повећава тачност добијених информација, смањујући шансе да се пропусти понекад критична системска грешка у случају да се за потребе прикупљања података користе људски ресурси. Транспортне компаније обично користе генерички OBD-II уређај за прикупљање информација о својим возилима. У истраживању [25], аутори предлажу систем управљања возним парком заснован на примени OBD-II уређаја. Овакав систем укључује праћење возног парка, праћење ефикасности потрошње горива, надзор понашања возача, даљинску дијагностику и још много тога. Пример архитектуре оваког система приказан је на Слици 2. Предност ових уређаја огледа се у могућности читавања вредности параметара са периодичношћу од једне секунде. Прикупљени подаци се посредством *Bluetooth* везе преносе на развијену апликацију на мобилном телефону у возилу, одакле се путем интернета шаљу и складиште на сервер.




Слика 2. Архитектура система за прикупљање параметара вожње

На основу прикупљених податка који се складиште на серверу, анализом и применом одговарајућег модела могуће је извршити евалуацију понашања возача током вожње. С обзиром да се параметри вожње могу снимати у кратком временском интервалу од једне секунде, могуће је извршити анализу и обраду података у реалном времену. Поменута инфраструктура представља саставни део система за надгледање паметних возила [26]. Постоје компаније које пружају претходно поменуте услуге. Потенцијални проблем њиховог коришћења огледа се у

релевантности добијених резултата, тј. евалуацији понашања возача с обзиром на нетранспарентност примењених алгоритама и методологије евалуације вожње. Услуге праћења и оцењивање вожње возача се наплаћују кроз претплате за свако појединачно возило. Узимајући све претходно у обзир, дугорочно посматрано треба размотрити исплативост коришћења ових услуга у односу на самостални развој система у случају постојања већег возног парка са специфичним захтевима.

2.1.2. Телематски системи

Телематика комбинује системе бежичне комуникације и управљања информацијама, који заједно са рачунарским системом у возилу омогућавају прикупљање и размену информација током вожње. Последњих година прогресиван развој информационо-комуникационих технологија довео је до разноврсне примене телематике [27]. Поред све веће примене и значаја у аутомобилској индустрији, она представља важан део транспортне инфраструктуре. Транспортни телематски системи на основу анализе прикупљених податка и пружених информација треба да утичу на понашање возача, праћење рада возила, праћење транспортног процеса и рутирање. За безбедно и поуздано одвијање транспортног процеса, неопходно је прикупљање параметара вожње на основу којих би се применом одговарајућих метода вршила евалуација понашања возача. Анализом ових података добијају се информације значајне за доношење управљачких одлука у циљу побољшања ефикасности система и искоришћења расположивих ресурса. На Слици 3. приказан је концептуални оквир телематског система.



Слика 3. Концептуални оквир телематског система [27]

Телематски системи се могу користити у процесима управљања транспортом и операцијама транспортних система као структурна и технолошка решења [28]. Основна улога представља обезбеђивање података везаних за транспортни процес или за рад возила и возача, меморисање, обраду и пренос тих података до корисника. На Слици 4. приказана је архитектура телематског система.




Слика 4. Архитектура телематског система [29]

Предности телематских система су:

- Повећање безбедности на путевима, слањем упозорења руководиоцима и њиховим деловањем у случају да возач прекорачи дозвољену брзину на посматраној деоници.
- Одржавање возног парка, које поред трошкова горива, представља један од највећих изазова са којима се суочавају њихови руководиоци. Врло честе су неочекиване поправке услед неадекватног праћења стања возила, јер возачи понекад не пријављују грешке које се појављују на командној табли. Стил вожње возача може да утиче на интензивније хабање пнеуматика и осталих потрошних делова на возилу.
- Праћење возила које омогућава лакше одвијање транспортног процеса, смањење могућности кашњења возила, одабир алтернативне руте у случају саобраћајних гужви.
- Напредна комуникација и обавештавање возача у реалном времену.

Телематски системи чине саставни део интелигентних транспортних система (ИТС). ИТС представља широк спектар различитих алата заснованих на информационом технологијама, бежичној комуникацији и електроници возила [30]. Телематске технологије се налазе у елементима саобраћајне инфраструктуре и возилима. На Слици 5. могу се видети елементи ИТС-а.




Слика 5. Елементи ИТС-а [30]

Побољшање ефикасности возног парка и економичности пословања представља један од главних циљева транспортних телематских система [31]. Међутим, у досадашњим истраживањима у оквиру ових система није разматран утицај понашања возача на ефикасност потрошње горива узимајући у обзир услове у саобраћају попут градске вожње, приградске вожње или вожње на отвореном путу. Откривање да ли и у којој мери постоји утицај услова у саобраћају при евалуацији стила вожње возача представља један од мотива овог истраживања. Прегледом литературе установљено је да постоје значајне студије које су се бавиле понашањем возача, међутим оно је претежно посматрано са аспекта безбедности у саобраћају [32-35].

Постоје бројне предности које пружају телематски системи. Сем тога, један од значајних проблема са којим се суочава транспортна телематика односи се на трајање процеса имплементације. Сложеност оваквог система може да проузрокује да време имплементације понекад буде дуже од циклуса развоја нове технологије [36]. Одређене компаније на тржишту пружају софтверска решења, тј. услуге праћења и оцењивања возача. Недостаци ових услуга су релативно високи трошкови коришћења, утицај спољашњих фактора, нетранспарентност решења, тј. метода и алгоритама којима се оцењују возачи. Спољашњи фактори, као што су нпр. временски услови, техничко стање возила, оптерећеност возила, услови у саобраћају, имају директан утицај у евалуацији понашања возача и морају бити детаљно и свеобухватно размотрени. Транспарентност предложеног интегрисаног модела огледа се у јасно дефинисаним параметрима вожње и условима у саобраћају на основу којих ће се вршити оцењивање и класификација понашања возача. Узимајући све претходно наведено у разматрање, потенцијална предност имплементације интегрисаног модела за класификацију и предвиђање понашања возача у оквиру постојећих телематских система, огледа се у стварању основе за развијање веродостојног система за награђивање возача са веома ефикасним стилем вожње.

2.1.3. Интернет ствари – IoT

Развој рачунарства у облаку и интернета ствари пружа прилику за решавање многобројних транспортних проблема. Осим OBD-II уређаја који се користе за читавање вредности параметара вожње, постоји могућност коришћења паметних телефона. Поред поседовања одређеног броја сензора, њихова предност огледа се у могућности комуникације посредством *Bluetooth* технологије, 4G, а у блиској будућности и 5G мреже. IoT представља мрежу која повезује многобројне различите уређаје. Ова мрежа путем *RFID* технологије, IR сензора и *GPS*-а омогућава размену и дељење информација [37]. Најосновнија архитектура је трослојна архитектура [38, 39]. Она се састоји од три главна слоја: први и најнижи слој за прикупљање података тј. сензорски слој или слој опажања, чине сензори и други уређаји, затим други мрежни слој за пренос података и највиши апликативни слој обраде података. Поред примене у разним областима, IoT концепт има велики потенцијал у друмском саобраћају. На Слици 6. приказана је архитектура система VISCar заснована на примени *Bluemix* и *Raspberry Pi* платформи коју је представио Хусни са циљем праћења потрошње горива помоћу андроид апликације [26].



Слика 6. Архитектура система VISCar [26]

Bluemix платформу отвореног кода развила је компанија IBM. Ова платформа, заснована на рачунарству у облаку, омогућава прављење, покретање и управљање апликацијама. Предност оваквих система огледа се у релативно ниској цени имплементације самог система и могућности постављања великог броја различитих сензора. Постепено побољшање стандардне архитектуре је кључ за убрзање истраживања и имплементације оваквог система у домену транспорта.

Сензорски слој има главну функцију да прикупља и преноси податке, односно да на основу сензорских технологија изврши праћење промена у окружењу у реалном времену. Овај слој архитектуре се углавном састоји од различитих сензора, *RFID* технологије, камера, *GPS*-а, итд. Технологије за препознавање углавном су засноване на *RFID* и *QR* код идентификацији. Оне омогућују препознавање објеката, локације и географске позиционiranости, што представља техничку основу у примени IoT у транспорту. На Слици 7. приказан је *GSM* модул за ардуино платформу.



Слика 7. GSM модул

GSM модул прима координате путем сателита током сваке секунде, заједно са временом и датумом. Поред тога што обезбеђује велику прецизност, пружа могућност коришћења других података који се могу касније користити.

На Слици 8. приказан је жирокоп са модулом сензора акцелерометра. Жирокоп сваке секунде мери ротационо кретање изражено у степенима. На основу тих података није могуће добити информације о нагибу, већ само о кретању око осе. Међутим, уз податке о убрзању добијене помоћу акцелерометра, може се израчунати нагиб објекта одузимањем тренутних података акцелерометра од вредности за коју се сматра да је нулти нагиб.



Слика 8. Жирокоп са модулом сензора акцелерометра

Мрежни слој омогућава пренос података и међусобну повезаност сензора, мрежних уређаја и сервера, односно представља инфраструктуру система. Архитектура система и бежичне технологије обезбеђују двосмерну комуникацију у прикупљању и складиштењу података, односно пружању услуга. Бежичне технологије као што су *Bluetooth*, *Zig-bee*, *Wi-fi*, *LoRa*, итд. претежно се користе за слање прикупљених сензорских података до чворова и мобилних уређаја, након чега се путем *GSM/EDGE* и *UMTS/HSPA* шаљу до сервера.

У апликативном слоју обраде врши се различито рачунање и обрада података, која омогућава пружање услуга у оквиру интелигентног система [37]. Он дефинише разне апликације попут: пружања помоћи возачима, надгледања и праћења параметра на возилу, праћења понашања возача на путу, помоћи у вожњи, итд. Овај слој може бити део рачунарства у облаку, чије се предности огледају у великој флексибилности и скалабилности. У оквиру њега доступне су услуге које се односе на основну инфраструктуру, платформу, софтвер и складиштење података.

По овом принципу функционише платформа *AutoPi* намењена за праћење и снимање параметара возила. Ова ИоТ платформа омогућава брзо и лако прављење

наменског рачунара помоћу *Raspberry Pi* уређаја. *AutoPi* телематска јединица са пратећим софтвером на клауду представља једно од готових решења. Овај уређај заснован је на бржем *Raspberry Pi 3* рачунару и укључује 4G/LTE модем. На овај начин омогућава се даљински приступ подацима о возилу. На Слици 9. приказана је *AutoPi* телематска јединица.



Слика 9. *AutoPi* телематска јединица 4G/LTE [40]

Овај уређај поседује *Raspberry Pi3* модел A+. У случају потребе додатног напајања може се лако надоградити на *Raspberry Pi4*. Поред 512MB DDR 2 радне меморије, постоји могућност проширења од 1GB у случају надограђивања на *Raspberry Pi3 B+*, односно проширења од 2GB, 4GB или 8GB DDR4 меморије зависно од модела. Интерно складиште је 32GB, са могућношћу проширења до 128GB. Поред тога, подржава GPS, Bluetooth 4.2, WiFi 2.4GHz и 5GHz IEEE 802.11b/g/n/ac бежичне технологије и садржи модем, акцелерометар, аудио и видео излазе, улазне слотове за SD и SIM картице и оперативни систем *Raspbian OS*.



Слика 10. *AutoPi* телематска јединица намењена за сопствени развој [41]

На Слици 10. приказана је *AutoPi* телематска јединица намењена за сопствени развој и инжењеринг. Овај уређај је превасходно намењен развоју нових апликација прилагођених захтевима одређених транспортних система. Ова верзија не садржи *Raspberry Pi*, модем, GPS, нити кућиште. Међутим, сви сензори и модули се веома лако могу накнадно имплементирати.

AutoPi уређај и *AutoPi* клауд заједно са ИоТ платформом омогућавају додавање модула и инсталирање напредних функција, чиме се олакшава праћење параметара вожње и самог возила. На Слици 11. приказана је *AutoPi* клауд апликација за праћење податка о вожњи.



Слика 11. *AutoPi* клауд апликација за праћење податка о вожњи [40]

Интеграција сензора и комуникационих технологија омогућава прикупљање велике количине сензорских података у возилу, њихово слање путем интернета и обраду у реалном времену. Као релативно нова технологија која се прогресивно развија, очекује се да ће ИоТ системи понудити обећавајућа решења за трансформацију транспортних система међу којима су: пружање важних информација возачу, праћење перформанси рада возила, праћење понашања возача, аутоматизација транспортног процеса, итд.

На важност и све веће могућности примене претходно поменутих уређаја указује интензивни развој бежичних мрежа широког домета заснован на примени LoRa технологије. Ове мреже (нпр. *Helium* мрежа) представљају основу ИоТ система. Оваква мрежа омогућава међусобну комуникацију бежичних уређаја, уз релативно малу потрошњу електричне енергије. Намењена је за ИоТ уређаје и омогућава им међусобно комуницирање и размену података путем своје мреже чворова, *hotspot*-ова. Рад мреже је сличан WiFi мрежи, само што ова мрежа ради на P2P (peer-to-peer) принципу, што представља концепт умрежавања уређаја без посредника. Њихова експанзија омогућава доступност и брзо дељење велике количине података. Поред тренутних информација о кретању возила, контролном центру се посредством оваквих мрежа могу слати прикупљени подаци о вожњи, који би могли да користе осталим градским сервисима. Евалуација вожње, позиционирасност возила, међусобна комуникација возила и подаци о вожњи могу да омогуће и оптимизацију најбоље руте зависно од доступних возила, услова у саобраћају и стила вожње возача. На Слици 12. приказана је покривеност *Helium* мреже на територији Београда.



Слика 12. Покривеност Helium мреже на територији Београда [42]

Предност оваквог концепта представља комерцијално коришћење постојеће мрежне инфраструктуре, која укључује различите сензоре који генеришу податке у реалном времену. Прикупљени подаци се бежичним преносом шаљу на сервер и складиште у базу података. Анализом и обрадом ових података пружа се могућност коришћења различитих услуга, нпр. пружање информација о слободном паркингу месту, радовима на путу, саобраћајним гужвама, итд. Обрадом података и применом одговарајућих техника, пружа се могућност слања повратних информација возачу. Поред података који се прикупљају, инсталирањем различитих сензора могуће је пратити промене у окружењу. На овај начин возило може да успостави бежичну везу и комуницира са осталим возилима и инфраструктуром, чиме се остварује значајна међусобна размена података између великог броја уређаја у мрежи.

LoRa технологија подржава бежичан пренос података широког појаса до 5 км у градовима и око 15 км у ванградском подручју. У случају саобраћајних гужви или промене временских услова (киша, снег, итд.) обавештавањем контролног центра или другог возила о стању на путу, омогућиле би се значајне додатне информације које могу да утичу на оптимизацију рутирања возила. Претходно поменути услови могу значајно да утичу на ефикасност вожње, самим тим и на целокупну ефикасност возног парка. У скорој будућности већа територијална покривеност ових мрежа омогућиће велики број сервиса и повезаност великог броја возила и других паметних уређаја. Развој ове мрежне инфраструктуре директно ће утицати на интензиван развој међусобне комуникације возила и размену података са контролним центром.

Прикупљање и складиштење податка представља важну компоненту ИТС-а. Интеграцијом података омогућава се њихово коришћење за обуку алгоритама машинског учења, што је основа планираног истраживања и предвиђања понашања

возача. Постојећа ИоТ решења зависе од прикупљања и обраде података са уређаја на мрежи. Они омогућавају доношење паметних одлука као што су: обавештавање, извршавање одређених акција и калкулација у реалном времену, откривање законитости на основу историјских података [43]. Концепт ИоТ заснован је на великом броју различитих сензорских уређаја који континуирано прикупљају податке на основу којих се доносе одлуке у реалном времену. У зависности од података који се прикупљају, подаци се могу складиштити у релационе и нерелационе базе података. Нерелационе базе података осмишљене су како би одговорице на изазов складиштења неструктурираних података. У поређењу са релационим базама података, *NoSQL* базе података су скалабилније и нуде боље перформансе у случају посматрања великог броја записа [44]. С друге стране, релационе базе података се широко користе у већини апликација и имају добре перформансе када се примењују на ограниченом скупу података [45].

Зависно од транспортног проблема који се посматра, неопходно је дефинисати технолошке захтеве при изградњи архитектуре система. Претходно разматрани мерни уређаји и платформе представљају доступна и финансијски исплатива решења која могу да одговоре на такве захтеве и буду саставни део телематских система.

За потребе овог истраживања и израде интегрисаног модела за класификацију и предвиђање понашања возача, извршено је читавање и прикупљање великог броја података путем FLEETOMATIC OBD-II уређаја. У случају даљег унапређења и развоја модела постоји могућност посматрања значајно већег броја параметара и возача, где би се подаци обрађивали у реалном времену. Према томе, при одабиру модела базе податка треба размотрити и примену нерелационих база података, које поред осталог не захтевају додатна финансијска улагања.

2.2. Преглед и правци даљег развоја комерцијалних возила у Европској унији

Потрошња горива представља једну од важних карактеристика моторних возила која значајно утиче на трошкове експлоатације. Потрошња горива у друмском саобраћају значајно расте са порастом учешћа друмског транспорта у укупном транспорту. Према извештају Удружења европских произвођача аутомобила (АЦЕА) за 2019. годину, учешће лаких комерцијалних возила на дизел гориво је доминантно у скоро свим земљама Европске уније (ЕУ), чинећи скоро 90% транспортних возила, док само 0,3% комби возила у ЕУ има електрични погон [46]. На Слици 13. може се видети удео лаких комерцијалних транспортних возила ЕУ према врсти горива. Поскупљење нафтних деривата и ограничени ресурси фосилних горива утичу да проблем економичности горива постаје све израженији. Према томе, важност уштеде горива представља један од главних циљева транспортних компанија. Предмет овог истраживања су лака транспортна дизел возила са моторима са унутрашњим сагоревањем (СУС), која представљају возила са највећим уделом на тржишту комерцијалних возила ЕУ. Међутим, и остале категорије, у које се убрајају аутобуси, средња и тешка комерцијална транспортна возила, у највећој мери користе дизел гориво.



Слика 13. Структура лаких комерцијалних транспортних возила ЕУ према врсти горива за 2019. годину

Прегледом структуре транспортних моторних возила на тржишту ЕУ, може се закључити важност уштеде потрошње горива возила са СУС моторима. Електрична возила значајно утичу на смањену емисију гасова, али су поред тога тренутно неисплатива и заузимају мали удео укупног броја транспортних возила. Њихова потрошња изражава се у киловат-часовима (kWh). Животни век батерија и трошкови поновне уградње, недовољна аутономија и време пуњења представљају главне проблеме који у будућности треба да буду превазиђени. Међутим, возила на електрични погон су генерално много енергетски ефикаснија од возила на фосилна горива [47]. У поређењу са дизел комбијима, трошкови горива (енергије) су за око 62% мањи за електричне комбије, односно 37% нижи за комби возила која користе компримовани природни гас (КПГ) [48]. Структура транспортних возила ЕУ према врсти горива за 2019. годину приказана је у Табели 1. Камиони, односно возила

категорије N1 и N2 генерално нису електрифицирани, њихов удео је готово 0% у укупној структури транспортних возила ЕУ. У блиској будућности овај удео ће бити значајно већи, с обзиром на то да швајцарска компанија E-Force већ производи потпуно електричне камионе који поседују мотор од 550kw, носивости 18t, са могућом аутономијом до 450km зависно од вожње, при чему могу остварити брзину до 85km/h [49]. На Слици 14. приказан је E-Force EF18 електрични камион.



Слика 14. E-Force EF18 електрични камион [49]

Предмет истраживања у овом раду су лака комерцијална дизел возила са СУС моторима. Међутим, правац даљег развијања модела ће, поред осталог, бити и његова примена и на возила на електрични или неки други погон.


Табела 1. Структура возног парка ЕУ према врсти горива за 2019. годину

Категорија возила		Тип горива						
		Бензин	Дизел	Електрични погон	Хибридни погон	Природни гас	ЛПГ	Остало
	N1	7,8%	89,5%	0,3%	0,0%	0,5%	1,0%	0,9%
	N2 и N3	1,3%	97,8%	0,0%	0,0%	0,4%	0,2%	0,2%
	M2 и M3	0,8%	94,5%	0,6%	0,7%	2,7%	0,2%	0,4%

Преглед категорија возила Европске уније:

- N1 – категорија лаких комерцијалних возила носивости до 3,5t.
- N2 и N3 - категорија средњих (носивости од 3,5t до 12 t) и тешких (преко 12t) комерцијалних возила респективно.
- M2 и M3 – категорије аутобуса са највише 8 седишта и носивости до 5t и аутобуса са више од 8 седишта и носивости преко 5t, респективно.

У извештају АЦЕА за 2020. годину 6,1% нових аутобуса данас су возила на електрични погон, 9,5% хибридни електрични, 11,4% возила са алтернативним погоном, док је дизел гориво и даље присутно код 72,9% свих аутобуса који се продају у ЕУ [50]. Нови аутобуси у ЕУ по врсти горива приказани су на Слици 15.



Слика 15. Нови аутобуси у ЕУ по врсти горива за 2020. годину

Код камиона који имају електрични погон забележен је пораст у уделу на тржишту и он сада износи 0,4%. Међутим, возила са дизел моторима су и даље доминантна са уделом од 96,5% (Слика 16).



Слика 16. Нови камиони у ЕУ по врсти горива за 2020. годину

На Слици 17. може се видети да је слична ситуација и са лаким комерцијалним возилима где је забележен удео нових возила на електрични погон од 2% и 92,4% нових возила са дизел моторима.



Слика 17. Нова лака возила у ЕУ по врсти горива за 2020. годину

Поред прогресивног развоја електричних комерцијалних возила, према подацима са претходних графикана, може се закључити да ће и у блиској будућности примарно бити заступљена дизел лака комерцијала возила са СУС моторима. Ово представља један од мотива да се истраживање спроведе на дизел комби возилима.

3. ЕКО-ВОЖЊА И МЕРЕЊЕ ПОТРОШЊЕ ГОРИВА

Еко-вожња представља модеран и ефикасан начин вожње који значајно утиче на смањење потрошње горива, безбедност вожње и загађење животне средине. Постоји обимна литература која се односи на процену потрошње горива и енергетску ефикасност возних паркова. Основни мотиви истраживања у којима се примењује концепт еко-вожње су смањење потрошње горива, као једног од главних оперативних трошкова транспортних компанија и смањење емисије штетних гасова.

3.1. Методологија еко-вожње

У главне проблеме система еко-вожње спада препознавање релевантних фактора који утичу на енергетску ефикасност. Поред тога, установљено је да постоје истраживања која су се бавила непосредним утицајем на посматране параметре након извођења обуке еко-вожње [51, 52]. Пример такве методологије еко-вожње приказан је на Слици 18. и Слици 19.



Слика 18. Методологија еко-вожње [51]


У спроведеном истраживању [52], Ванг и Марце су извршили процену утицаја обуке еко-вожње на уштеду горива и смањење емисије угљен-диоксида. Емпиријско истраживање је било фокусирано на специфичне утицаје према врсти пута. Крајњи резултати су показали просечну уштеду горива након одржане обуке еко-вожње од 6,3% без обзира на гориво и врсту пута.



Слика 19. Методолошки оквир истраживања [52]

Различити приступи и методологије су примењиване како би се разумеле и анализирале релевантне компоненте функције уштеде горива у оквиру модела за процену стила вожње [53] и процене еколошке вожње са аспекта њеног утицаја на потрошњу горива [54]. Делгадо и сарадници [55] су предложили мултиваријациони линеарни модел за предвиђање потрошње горива на основу променљивих перформанси возила повезаних са својствима возног циклуса, док су у оквиру следећих студија [56-58] упоређиване потрошње горива пре и после обуке еко-вожње. Стокић и сарадници [59] су предложили фази логички модел као ефикасно средство у процени вештина еко-вожње. У студији [60] аутори су користили моделирање структурних једначина чији је циљ био испитивање везе између стила вожње и карактеристика возача. Тестирани возачи су вршили самоевалуацију стила вожње пре и непосредно након вожње на одређеној рути. Стил вожње дефинисан је помоћу две врсте показатеља: први је оцена коју возач одређује на скали, а која се креће од агресивног до опрезног стила. Други су посматрани кинематички параметри (*GPS*, брзина и убрзање) забележени током вожње на посматраној рути. Силва и сарадници спровели су истраживање [54] које се заснивало на дневном прикупљању информација о перформансама возача, након чега су се те перформансе возача посматрале и упоређивале са перформансама у ситуацијама појаве одређених возачких догађаја. Три мултиваријациона регресиона модела су коришћена како би се одредио утицај неколико фактора који се односе на понашање возача, карактеристике руте и укупну енергетску ефикасност возног парка.


Ефикасна потрошња горива подразумева умерено убрзање и кочење, мењање брзине при малом броју обртаја мотора, одржавање константне брзине и процењивање саобраћајног тока како би се избегло непотребно заустављање возила [61]. Возачи треба да прилагоде своју вожњу како би остварили жељену ефикасност. Она се може постићи свешћу возача [62] и посебним курсевима обуке [63]. Резултати неколико студија показују велика варирања у појединачној уштеди горива која се креће између 5% и 20% [64]. Међутим, кроз разне студије, аутори предлажу велики број параметара и правила у дефинисању еко-вожње. Хуан и сарадници [2] су у прегледном раду посматрали низ фактора који утичу на еко-вожњу и одрживи друмски транспорт. На Слици 20. могу се видети процентуални интервали уштеде горива за сваки од посматраних фактора.



Слика 20. Процентуални интервали уштеде горива по факторима еко-вожње [2]

Фактори са најмањим уделом у уштеди горива категорисани су као остали фактори. У њих се убрајају коришћење климе, аеродинамични отпор (отворени прозори), додатно тежинско оптерећење. С друге стране, фактори који највише утичу на уштеду горива су убрзање и брзина вожње. Ови параметри су важни и могу директно да утичу на остале факторе попут времена рада мотора у празном ходу. Одржавањем константе брзине, благим успорењем и убрзањем могуће је извршити добру процену саобраћајног тока, како би се избегло заустављање возила. Многе студије указују на значај наглог убрзања и успорења у потрошњи горива и повећаној емисији гасова. Колома и сарадници [65] су у спроведеном истраживању заснованом на принципима еко-вожње посматрали неколико параметара (GPS позицију, време вожње, тренутну брзину, потрошњу горива, број обртаја мотора и успорење). За остваривање уштеде у потрошњи горива, Ериксон [66] предлаже избегавања наглих убрзања и вожње великом брзином. Јохансон и сарадници [67] предлажу одржавање умереног успорења, смањујући време вожње у првом и другом степену преноса и усмеравајући се ка вожњи константне брзине у највишем степену преноса. Веома важан показатељ који утиче на потрошњу горива представља рад мотора у празном ходу. Овај параметар треба смањити на минимум јер његова вредност негативно утиче на мерење ефикасности рада мотора током вожње. При оцењивању стила вожње и предвиђању понашања возача треба посебно обратити пажњу на удео времена рада мотора у празном ходу у укупном времену вожње. У зависности од возила, величине мотора и врсте горива потрошња може да износи од 0,6 до 5,7L/h [68]. Време рада мотора у празном ходу се може смањити на много начина. На почетку је неопходно да возачи имају свест и знање о његовом утицају на потрошњу горива. У зимским временским условима многи возачи остављају мотор да ради у празном ходу како би га загрејали. Међутим, произвођачи саветују да ће се брже остварити оптимална радна температура и боља ефикасност мотора уколико се одмах започне блага вожња са нижим бројем обртаја мотора.

У циљу безбедне и економичне вожње, Симсек и сарадници [69] предлажу оквир од седам корака за оцењивање перформанси професионалних возача транспортних компанија (Слика 21).



Слика 21. Оквир за оцењивање перформанси возача [69]

Прегледом досадашњих истраживања, може се уочити да се мања потрошња горива остварује одржавањем константе брзине, благим убрзањем и кочењем. У Табели 2. приказани су неки од фактора који утичу на економичност потрошње горива и емисију штетних гасова.

Табела 2. Фактори који утичу на потрошњу горива и емисију гасова [70]

Фактор	Уочени ефекат
Убрзање	Нагла убрзања повезана су са већом потрошњом горива и емисијама возила.
Прекомерна брзина	Прекорачење брзине изван еколошког опсега повезано је са већом потрошњом горива и емисијом штетних гасова из возила.
Кочење/успорење	Честа кочења/успоравања повезана су са већом потрошњом горива и емисијом гасова.
Услови у саобраћају	Што је већи проток саобраћаја, већа је потрошња горива и емисија из возила.
Рад мотора у празном ходу	Дужи рад мотора у празном ходу повезан је са већом потрошњом горива.
Број заустављања	Већи интервали заустављања по километру повезани су са повећаном потрошњом горива.
Карактеристике пута	Вожња по равном терену повезана је са 15-20% мањом потрошњом горива од вожње у планинским подручјима.

Значајно побољшање потрошње горива и емисије штетних гасова може се постићи промовисањем возача да возе економично. Зависно од концепта система еко-вожње неопходно је извршити одговарајућу обуку и тренинг возача. Постоји могућност обуке симулацијом еко-вожње, која у појединим случајевима може да изискује значајна финансијска средства. Осим одређивања фактора који утичу на смањење потрошње горива и препознавања агресивног понашања возача, у главне проблеме убраја се његова мотивисаност за поштовање и примену принципа еко-вожње. Ефекти обуке еко-вожње се смањују временом услед природне тежње возача да се врате претходном начину понашања [71]. Овај проблем могуће је решити развијањем и применом одговарајућег система награђивања возача [72]. Награђивање возача може бити у виду новчаног стимуланса, међутим дугорочни

результати зависе од континуиране посвећености менаџмента. Награђивање представља веома осетљиво питање и мора бити у складу са културом компаније како не би дошло до стварања нежељених ефеката [73].

3.2. Параметри еко-вожње

У овом поглављу рада извршен је преглед литературе у вези са релевантним параметрима који су важни у процени перформанси и дефинисању стила еко-вожње возача. На посматране параметре возач може значајно да утиче зависно од стила вожње којем тежи. Иако су спроведена многа истраживања и развијени разни уређаји, квантитативни ефекти понашања возача на потрошњу горива су и даље нејасни, као и пружање квантитативних података и савета за еко-вожњу.

Џан и сарадници [74] су у спроведеном истраживању испитивали свесност возача о факторима који утичу на смањење потрошње горива. Добијени резултати испитаних возача указали су да просечна брзина мотора, проценат времена вожње са радом мотора у празном ходу и проценат времена вожње без оптерећења мотора представљају потцењене показатеље. Према томе, транспортне компаније би требало да обрате посебну пажњу при едукацији и обуци возача о важности просечног броја обртаја мотора. Други показатељ, време вожње са радом мотора у празном ходу, има значајну позитивну корелацију са потрошњом горива, што је у складу са истраживањима [51]. Проценат времена вожње без оптерећења мотора има негативан утицај на потрошњу горива, што су потврдили Валнум и Симонсен у свом истраживању [75]. Поред тога, из сигурносних разлога оваква вожња сматра се веома опасном јер може довести до озбиљних саобраћајних незгода. У наставку рада следи детаљан преглед и анализа најзначајних фактора који утичу на потрошњу горива како би се квантитативно дефинисале границе еко-вожње. Ови параметри ће бити основни улазни подаци модела који ће бити приказан у наредним секцијама рада.

3.2.1. Број обртаја мотора

У истраживању [58] аутори истичу да број обртаја мотора представља важан параметар који утиче на потрошњу горива и емисију CO₂. Они су узели у обзир неколико правила еко-вожње. Једно од њих је вожња у највишем могућем степену преноса како би се остварила снага до 2000 RPM. Андру и Пјер [76] сматрају да на потрошњу горива утиче стил вожње који је повезан са четири главна правила: правовремено мењање степена преноса у опсегу од 2000 до 2500 RPM, праћење саобраћајног тока, блага успорења кочењем помоћу мотора, одржавање константне брзине у највишем степену преноса и рад мотора са што нижом вредношћу броја обртаја мотора. Колома и сарадници [77] препоручују режим рада мотора у опсегу од 1500 до 2600 RPM и промену степена преноса при раду мотора на око 2000 RPM у циљу постизања еко-вожње, док Орфила и сарадници [78] сматрају да опсег енергетски ефикасног рада мотора при промени степена преноса треба да износи између 2000 и 2500 RPM. Ролим и сарадници [79] су дошли до закључка да горња граница рада мотора за постизање еко-вожње треба да износи 1800 RPM. Басарић и сарадници [80] су у оквиру система за надгледање додељивали негативне поене возачима када број обртаја мотора пређе 1500 RPM током периода дужег од једне секунде. У истраживању [81] током тестирања учесника на симулатору еко-вожње, аутори су дефинисали неколико правила. Једно од њих било је промена у виши

степен преноса пре 2500 RPM. Гилман и сарадници [16] су развили прототип система за помоћ у вожњи који би возачима помогао у остваривању што ефикасније вожње. Поред осталих параметара, користили су проценат времена проведеног у различитим RPM интервалима (мање од 1500 RPM, између 1500-2000 RPM, између 2500-3500 RPM и више од 3500 RPM). Као најефикаснији интервал броја обртаја мотора при одржавању константне брзине возила, у истраживању [71] је коришћен интервал између 1100-1700 RPM. На важност овог параметра указују многа претходно поменута истраживања. У евалуацији понашања возача овај параметар треба уврстити као основни показатељ ефикасности рада мотора.

3.2.2. Убрзање возила

Други, врло важан параметар еко-вожње који утиче на потрошњу горива и емисију штетних гасова је убрзање возила [2]. Брзину возила могуће је израчунати фузијом података о брзини свих тачкова и сензора уздужног убрзања. Међутим, у случају блокирања тачкова овај приступ постаје врло непрецизан [82]. Кретање возила углавном се мери брзинама и убрзањима возила, али у будућности се може очекивати да ће се уз помоћ сензора из околине добијати информације о кретању и положају возила наспрам објекта у окружењу [83]. У истраживањима [2, 84] аутори закључују да потрошња горива током периода убрзања може имати удео од око 56% укупне потрошње горива и да су карактеристике возачевог стила вожње током убрзања пресудне у потрошњи горива. У том смислу, возачи поред одржавања константе брзине треба да избегавају прекомерна убрзања [85-87]. Док су развијали свој модел зрелости [88], аутори су дефинисали прихватљиво убрзање између 0,5 и 1,078 m/s^2 . У спроведеним истраживањима [51], Рамирез и сарадници су за ограничења при дефинисању интензивног позитивног и негативног убрзања користили 2,78 m/s^2 и 3,89 m/s^2 респективно. Зоу и Јин су спровели истраживање [89] у којем сугеришу да максимално дозвољено убрзање сме да износи највише 4 m/s^2 . Стокић и сарадници [59] су дефинисали пет функција припадности које се односе на убрзање, у евалуацији перформанси возача у путничким возилима применом фази логике. Пожељно мало убрзање дефинисали су у интервалу од -2 m/s^2 до 2 m/s^2 . Белоуфа и сарадници [81] су у оквиру развоја система за надгледање возача додељивали негативне поене у случајевима наглог убрзања. Уколико је током периода дужег од једне секунде постигнуто позитивно убрзање чија је вредност већа од 1,7 m/s^2 или негативно убрзање од преко 1,9 m/s^2 , додељивани су негативни поени.

3.2.3. Притисак педале гаса

Следећи важан параметар који утиче на потрошњу горива је притисак педале гаса [90]. Пањеда и сарадници препоручују вожњу у највишем могућем степену преноса са лагано притиснутом педалом гаса, уместо вожње у нижем степену преноса са већим притиском педале гаса. Хајек и сарадници [91] су истраживали утицај константног притиска педале гаса на потрошњу горива и утврдили да уколико возачи у одређеним ситуацијама према препорукама склоне стопало са педале гаса, остварују смањење потрошње горива за 7,5%. Ким и Так [92] су предложили употребу еко-педале гаса засновану на дозвољеном убрзању возила, чиме је остварен мањи притисак педале гаса и смањена потрошња горива од 15% у условима градске вожње. Овакав систем развио је јапански произвођач аутомобила Нисан. Ова

компанија је развила технологију дизајнирану да помогне возачима да постану економичнији у потрошњи горива. Када је систем еко-педале укључен, сваки пут када возач притисне педалу гаса, активира се контролни механизам за поништавање притиска. Ако систем открије вишак притиска, обавештава возача да би могао да троши више горива него што је потребно. На овај начин могуће су уштеде горива од 5 до 10% зависно од услова вожње [93]. Функционисање система еко-педале приказано је на Слици 22.



Слика 22. Систем контроле ЕКО педале [93]

Балдин [94] сматра да већи притисак на педалу гаса при ниском броју обртаја мотора није погодан начин вожње за оптималан рад мотора и негативно утиче на енергетску ефикасност. Форс и сарадници [95] су применили савете о притиску педале гаса као једну од препорука у тестирању два система за подршку еко-вожње међу возачима камиона. Резултати су указали на важност овог параметра који се показао као најкориснији. Араужо и сарадници [96] су развили апликацију за паметне телефоне која помаже возачима у уштеди горива. Једна од препорука била је упозоравање возача у случајевима када су били превише агресивни на притиску педале гаса. У истраживањима [97, 98] аутори су били конкретнији истичући да педалу гаса никада не треба притискати више од пола. Суздалева и Наги [99] су користили положај педале гаса као једну од променљивих у циљу моделирања стила вожње са становишта економичне потрошње горива. У истраживању [81] аутори су испитивали утицај обавештавања возача слањем порука у реалном времену, како би се остварио еколошки ефикаснији стил вожње на симулатору у поређењу са традиционалним методама учења.

На основу прегледа литературе, у релевантне параметре вожње који веродостојно могу да укажу на стил вожње возача, а који при томе утичу на потрошњу горива, убрајају се: број обртаја мотора, притисак педале гаса и убрзање возила. Ова три параметра су јако корелисани и обично већи притисак на педалу гаса, значи већи број обртаја мотора, а то доводи до већег убрзања. Међутим, постоје изузетне ситуације у којима је могуће непрецизно оцењивање понашања возача, попут ефикасног кочења мотором које прати висок број обртаја мотора, без притиска педале гасе и потрошње горива. У истраживању је поред тога установљено да постоје радови у којима су коришћени број обртаја мотора и убрзање, што представља два од три претходно поменута параметра у евалуацији понашања возача. Међутим, за прецизније утврђивање утицаја возачевог стила вожње на потрошњу горива неопходно је свеобухватно узети у обзир сва три дефинисана параметра. Додатно разматрање и укључивање великог броја параметра вожње може довести до повећања сложености система, која се односи на отежано читавање параметара и њихову обраду. Ово може да представља проблем при функционисању посматраног система у реалном времену.

3.3. Модели потрошње горива

Модели потрошње горива, осим што се користе за предвиђање потрошње горива, могу се искористити у евалуацији понашања возача са аспекта енергетске ефикасности. Међутим, због велике комплексности система горива, веома је тешко развити тачан модел потрошње горива за прорачуне у реалном времену. Ово потенцијално може представљати проблем у случају када модел евалуације понашања возача зависи од тренутне потрошње горива. Како би се решио овај проблем, прво је неопходно извршити преглед постојећих модела потрошње горива и фактора који утичу на уштеду горива. По својој транспарентности, модели потрошње горива се могу класификовати у моделе беле кутије, моделе сиве и моделе црне кутије [100]. Карактеристике ових модела приказане су на Слици 23.



Слика 23. Карактеристике модела беле, сиве и црне кутије [100]

У истом истраживању Џоу и сарадници дошли су до закључка да структура пута, возач и услови у саобраћају представљају најутицајније факторе [100]. Фафутелис и сарадници наводе постојање три врсте модела црних кутија [101]:

- Модели засновани на раду мотора, у којима су улазне променљиве метрике повезане са мотором: брзина рада мотора (RPM), обртни момент мотора и снага.
- Модели засновани на возилима са улазним променљивим као што су тренутна или просечна брзина и убрзање.
- Модели засновани на режимима рада, са улазним променљивим: убрзање, константна брзина, успорење, рад мотора у празном ходу.

Модели црних кутија обично се заснивају на статистичким методама и методама машинског учења. У овом истраживању модел потрошње горива заснован је на примени модела црне кутије која обухвата моделе засноване на раду мотора, возилима и режимима рада.


У наредним секцијама рада при изради модела за класификацију и предвиђање понашања возача, посебно ће се анализирати утицај понашања возача и услови у саобраћају. Структура осталих фактора који утичу на потрошњу горива приказана је на Слици 24.



Слика 24. Фактори који утичу на потрошњу горива [100]

Студије су показале да економичност горива на равним путевима може бити од 5 до 20% већа од оне на брдовитим путевима [102-105]. Камал и сарадници су развили систем еколошке вожње заснован на моделу предиктивне контроле за управљање возилом на путевима са узбрдицама и низбрдицама [103]. Развијањем овог модела остварене су уштеде од 5 до 7% када се пореди еко-вожња са вожњом у којој се користила аутоматска контрола брзине. Ови резултати су остварени повећањем брзине возила непосредно пред узбрдице и искоришћавањем нагиба низбрдо.


Фактори који се односе на услове у саобраћају могу значајно да утичу на потрошњу горива. Без обзира на понашање, односно стил вожње возача, вожња у градским условима у саобраћају проузрокује значајно већу потрошњу и време путовања у односу на вожњу у приградским условима или на отвореном путу. Тилерт и сарадници су проучавали утицај комуникације између семафора и возила на потрошњу горива [106]. У спроведеном истраживању добијени резултати показали су да је могуће остварити уштеду од око 22% горива у случају примања информација о промени фазе семафора и израчунавањем оптималне брзине. Санчез и сарадници успели су да остваре уштеду од око 25% у градским условима интеракцијом између возача и семафора [107]. Асади и Вахиди су коришћењем предиктивног темпомата квантификовали ефекте долазних информација о саобраћајној сигнализацији на потрошњу горива [108]. Уштете од чак 47% потрошње горива остварене су коришћењем информација о саобраћајној сигнализацији. Претходно наведена истраживања указују на значај и могућност уштеде горива у градским условима. У наредним секцијама рада, посебно ће бити истражен утицај услова у саобраћају на потрошњу горива, као и препознавање услова у саобраћају на основу параметара вожње. У блиској будућности развој ИТС-а, заједно са интелигентним возилима омогућиће помоћ возачу и смањење потрошње горива комуникацијом V2V и V2I. На Слици 25. приказана је комуникација унутар ИТС-а између возила и инфраструктуре.



Слика 25. Бежична комуникација V2I и V2V [109]

Агресивно понашање у вожњи се типично може идентификовати одређеним профилима која често карактеришу велика убрзања. Прилагођавањем брзине како би се избегла заустављања на семафорима, смањењем наглих убрзања и успорења, искусни возачи у поређењу са неискусним возачима могу да остваре значајне уштеде у гориву. Неколико студија је указало на то да агресивна вожња у односу на еко-вожњу може проузроковати од 30 до 40% већу потрошњу горива [66, 87, 107, 110]. Камал и сарадници су проучавали систем еколошке вожње на возилу користећи модел предиктивне контроле у различитим окружењима друмског саобраћаја. Њихови резултати указују на то да је економичност потрошње горива максимизирана, када су случајеви у којима је возило убрзавало или кочило сведени на минимум [111]. Експеримент који је спровео Танигучи у форми такмичења возача у градским условима показао је да се потрошња горива може смањити до 25% [110].

У спроведеном истраживању [112], Јао и сарадници су прикупљали податке користећи OBDII уређај за добијање података о потрошњи горива у возилу и упаривали их са прикупљеним подацима путем паметног телефона. Добијени модел омогућава предвиђање потрошње горива само на основу података прикупљених помоћу паметних телефона. На Слици 26. приказан је оквир конструкције модела.



Слика 26. Оквир конструкције модела [112]

Исти аутори су у оквиру добијених резултата указали на важност следећих показатеља у процени потрошње горива: просечна брзина, просечна брзина не разматрајући рад мотора у празном ходу, просечно позитивно убрзање, просечно негативно убрзање, процентуално време убрзања, проценуално време негативног убрзања и проценуално време вожње [112].

Од статистичких метода до напредног машинског учења и рачунарске интелигенције, истраживачи су користили различите методе за ефикасно и прецизно моделирање понашања у вожњи. Прегледом литературе уочени су различити приступи који се баве моделовањем односа између еколошке вожње и потрошње горива. У Табели 3. приказане су методологије модела потрошње горива и најважнији параметри коју су разматрани у у процесу моделирања.

Табела 3. Преглед методологија модела потрошње горива и најзначајнији фактори

Аутори и година	Реф.	Методологија	Брзина	Убрзање	Нагиб пута	Услови у саобраћају	Пребени пут	Рад мотора у празном ходу	Број заустављања	Надгледање понашања возача
Sanguinetti et al. (2017)	[97]	/		*	*			*		
Ping et al. (2019)	[113]	LSTM, K-means clustering	*	*		*				
Xu et al. (2018)	[114]	Неуронске мреже, Линеарна регресија	*				*			
Gilman et al. (2015)	[16]	Линеарна регресија	*	*					*	
Walnum & Simonsen (2015)	[75]	Линеарна регресија								
Zhou et al. (2016)	[100]	/	*	*	*	*				*
Yao, Zhao, Liu, et al. (2020)	[112]	Неуронске мреже, Random forest, Support Vector Regression	*	*						
Reddy (2019)	[115]	/	*	*				*		
Yao, Zhao, Zhang, et al. (2020)	[24]	Линеарна регресија	*	*	*	*				
Hiraoka et al. (2009)	[116]	/	*	*						*
Zhao et al. (2015)	[117]	/	*	*						
Huang et al. (2018)	[2]	/	*					*		
Chen et al. (2018)	[118]	Линеарна регресија	*	*	*					

Анализом радова приказаних у Табели 3. постоје модели који се заснивају на коришћењу линеарне регресије [24, 75, 114, 118]. У овим моделима може се лако уочити утицај сваког фактора, транспарентни су и лако разумљиви. Међутим, у поређењу са сложенијим моделима не постижу високу тачност у прогнози потрошње горива. Уколико постоји јака корелација између посматраних параметара, тада треба примењивати стандардне технике попут селекције атрибута или трансформације атрибута. Како потрошња горива нема линеарно понашање, линеарном регресијом не може се довољно добро вршити њено моделирање. У

развоју линеарних модела, неопходан услов је да не постоји линеарна веза између независних променљивих [24]. Применом модела за предвиђање потрошње горива могуће је превазићи ово ограничење уз постизање задовољавајуће ефикасности у апроксимацији функција. Алгоритми који су коришћени у овим моделима су неуронске мреже, метод случајне шуме и метод подржавајућих вектора [112]. У истраживању [24] Јао и сарадници су развили модел у којем су посматрали понашање у вожњи заједно са најважнијим факторима: брзина, убрзање, геометрија пута, услови у саобраћају и временски услови. Модел је имао R^2 од 0,58. Чен и сарадници су развили сличан модел иако је скуп података био синтетички [118]. Поред понашања у вожњи, геометрија пута је била изразито важан фактор. R^2 овог модела је био приближно 0,85.

Јао и сарадници су развили различите моделе машинског учења са фокусом на понашање возача у вожњи, посматрајући следеће параметре: брзина, убрзање, време вожње константом брзином и кочење [112]. Су и сарадници су у истраживању [114] вршили поређење перформанси линеарног модела са моделом заснованим на неуронским мрежама. Закључили су да неуронска мрежа надмашује линеарни модел, при чему је $R^2=0,70$. У истраживању су коришћени параметри попут брзине, степена преноса, кочења, пређеног пута, итд. Слично истраживање [16] спровели су Гилман и сарадници у коме су поредили перформансе линеарног модела са неуронским мрежама и стаблима одлучивања. Скуп података који су користили укључивао је брзину, убрзање возила, геометрију пута и временске услове. Пинг и сарадници су развили оквир за учење користећи дубоко учење и *k-means* груписање за селекцију возача у различите профиле, а затим и за процену потрошње горива [113]. У Табели 3. приказани су најзначајни радови који се односе на моделе потрошње горива. Приказане су методологије и фактори који су коришћени. Може се приметити да је брзина возила параметар који се најчешће укључује у прорачун потрошње горива, а исто важи и за убрзање. Број заустављања и пређени пут су лако мерљиви, али нису коришћени у већини истраживања. Додатно, један од најчешћих показатеља неекономичне вожње је време рада мотора у празном ходу, који је коришћен у само неколико студија.

Последњих година у разним областима све више су заступљени модели машинског учења, па тако и у моделима процењивања потрошње горива. Ово је омогућено развојем нових технологија у возилу и прикупљањем података о потрошњи горива помоћу паметних телефона и OBD уређаја [119].

На Слици 27. приказан је оквир анализе за разумевање понашања возача и препознавање возачевих карактеристика у вожњи, заснован на прикупљању података помоћу паметног телефона.



Слика 27. Оквир анализе за разумевање понашања возача [119]

Циљ истраживања [119] које су спровели Мантука и сарадници био је преглед истраживања посвећен анализирању понашања возача у вожњи на основу токова података заснованих на сензорима паметних телефона. Франк и сарадници спровели су истраживање [120] у оквиру ког су имплементирали андроид апликацију која је прикупљала релевантне податке са CAN магистрале електричних возила, приказујући возачу репрезентативну еко-оцену у реалном времену. Еко-оцена је класификована у четири категорије: лоша, просечна, добра и веома добра. Ова оцена заснована је на фази систему, изведена из три фази променљиве: брзине, нагиба пута и потрошње енергије.

Традиционалне методе процењивања и предвиђања засноване на статистичким моделима нису најпогодније за тачну процену потрошње горива услед ограничене способности изражавања сложених веза [121].

Модели машинског учења, укључујући стабла одлучивања, скривени Маркољев модел, Гаусов мешовити модел, метод подржавајућих вектора и неуронске мреже, широко су прихваћени за моделирање индивидуалних навика возача у вожњи [122].

Поред ових метода за моделирање процене потрошње горива, возила, интернет и технологије рачунарства у облаку су променили и заменили традиционалне методе читавања података, што је додатно убрзало процес прикупљања велике количине података [123].

Претходно анализирани радови односе се на modele процене потрошње горива. Већина истраживања која су се бавила понашањем возача, претежно су се односила на оцењивање понашања возача са аспекта безбедности у саобраћају [32-35]. Ови радови су од посебног значаја за осигуравајућа друштва и безбедоносне агенције. Постоје модели који су развијени да пружају савете о еко-вожњи у реалном времену, са циљем прилагођавања понашања возача током вожње и остварења веће уштеде горива. Међутим, прегледом литературе нису уочени модели који су као крајњи излаз имали оцену вожње и предвиђање потрошње горива, који поред осталог зависе и од услова у саобраћају. Значајна истраживања која су се бавила евалуацијом и понашањем возача транспортних возила са аспекта енергетске ефикасности заснована на коришћењу фази скупова и машинском учењу нису забележена. Ово представља један од мотива за изразу модела који ће детаљно бити представљен у наредним секцијама рада.

3.4. Основе и мерење потрошње горива

У литератури треба разликовати два термина који се често погрешно тумаче, а то су економичност горива и потрошња горива. Економичност горива представља меру која показује колико ће возило прећи са галоном горива и обично се изражава у миљама по галону. Потрошња горива се рачуна супротно од економичности горива. То је количина горива која се потроши при преласку одређене удаљености. У Сједињеним Америчким Државама се мери галонима на 100 миља, а литрима на 100 километара у Европи и остатку света [124]. При оцењивању понашања возача, разматраће се потрошња горива како би се верификовала добијена оцена.

У реалним условима одвијања транспортног процеса, веома је тешко измерити стварну тренутну потрошњу горива. Постоје три главна разлога која утичу на разлику између стандардне потрошње, прописане од стране ауто-индустрије и стварне потрошње горива. Први представљају спољни фактори који укључују временске услове, температуру ваздуха, амтосферски притисак и саобраћајне гужве [125]. Пораст броја возила у друмском саобраћају проузрокује велике саобраћајне гужве које за последицу имају продужење времена рада мотора у празном ходу. Ово доводи до повећане потрошње горива, чак иако се пређена километража не мења. Други разлог представља манипулација ауто-компанија које тестирају возила у најбољим могућим условима за испитивање, ради смањења потрошње горива. Трећи разлог су возачке навике, попут коришћења климе у возилу, рада мотора у празном ходу док је возило паркирано, итд. У поређењу са искусним возачима, неискусни возачи не поседују довољно искуства како би остварили уштеде у потрошњи горива [126].

Прегледом литературе, у зависности од модела, његове примене и могућности мерења потрошње горива, примењује се неколико величина потрошње горива. Оне се могу изразити као: запреминска, масена, временска и специфична потрошња горива.

Запреминска потрошња горива дефинисана је количником запремине горива V које се утроши на пређеном путу s :

$$Q_s = \frac{V}{s} \quad (1)$$

Углавном се изражава у литрима горива на 100 км пређеног пута.

Масена потрошња горива може се дефинисати количником масе горива m утрошене на пређеном путу s :

$$M_s = \frac{m}{s} = \frac{V \cdot \rho}{s} = Q_s \cdot \rho \quad (2)$$

где ρ представља густину горива.

Временска потрошња горива може се дефинисати количником масе горива m утрошене за време рада мотора T :

$$M_T = \frac{m}{T} = \frac{V \cdot \rho}{T} \quad (3)$$

Углавном се изражава у килограмима горива по часу рада.

Специфична потрошња горива може се дефинисати количником временске потрошње горива M_T и величином снаге коју мотор разијва P_e

$$g_e = \frac{M_T}{P_e} = \frac{m}{P_e \cdot T} = \frac{V \cdot \rho}{P_e \cdot T} \quad (4)$$

Изражава се у килограмима по киловат-часу.

Специфичном потрошњом горива карактерише се економичност рада мотора. Потрошња горива се повећава са повећањем отпора кретања, насталог услед повећања брзине возила. Како би се извршила уштеда горива, пожељно је кретати се константном брзином у највећем степену преноса, уз избегавање наглих убрзања и кочења.

Поред претходно поменутих начина мерења потрошње горива, Абукхалил и сарадници предлажу систем тренутног очитавања потрошње горива на основу података добијених помоћу МАФ (енг. *Mass Air Flow*) сензора [127]. Савремени системи за убризгавање горива користе два сензора, један за ваздух постављен одмах иза усисне гране мотора, док је други постављен на издувну цев непосредно пре катализатора. Оба сензора шаљу повратне информације у рачунар возила ради процене односа ваздуха и горива. МАФ представља количину ваздуха коју мотор усисава изражену у грамама у секунди. Теоретски, потрошња горива f се може израчунати помоћу следеће једначине:

$$f = \frac{vs \times \alpha}{MAF} \times \beta \quad (5)$$

где је vs брзина возила изражена у km/h , МАФ је масени проток ваздуха у g/s , α представља константу за претварање вредности у миље по галонима (енг. *Miles per gallon - mpg*), а β је константа за претварање mpg у литре на 100 пређених километара. При разматрању ове функције треба имати у виду да брзина возила и читавања МАФ -а не могу бити довољни за прецизну процену, јер на потрошњу горива утиче и позиција клапне гаса.

На мерење потрошње горива утиче велики број фактора. При евалуацији понашања возача посматрани су фактори на које возач директно утиче: притисак педале гаса, тренутни број обртаја мотора, остварена брзина, односно убрзање или кочење. У овом истраживању коришћено је мерење тренутне потрошње горива путем управљачке јединице мотора. Количина горива која се убризгава по такту изражена је у кубним милиметрима (mm^3). На овај начин из разматрања је изузета потрошња горива у тренуцима када возило стоји, односно када возач нема директан утицај на укупну потрошњу горива. Предност оваквог приступа огледа се у прецизнијем мерењу и предвиђању понашања возача само на основу активне вожње. Међутим, разматрањем просечне брзине која укључује и стајање возила, могуће је лакше утврдити саобраћајне услове вожње током којих се возач посматра.

4. МЕТОДЕ И ТЕХНИКЕ ЗА ПРЕПОЗНАВАЊЕ ПОНАШАЊА ВОЗАЧА

У оквиру овог поглавља детаљно ће бити размотрена примена фази скупова и машинског учења, који се убрајају у погодне методе и технике за препознавање понашања возача. Методе машинског учења се користе за решавање проблема у којима веза између улаза и излаза није позната или је тешко закључива, док модел заснован на фази логици може да описује операције вожње користећи лингвистичке термине.

4.1. Машинско учење

Последњих година многи радови бавили су се применом алгоритама машинског учења у препознавању понашања возача [11]. Машинско учење уз помоћ различитих алгоритама пружа рачунарима могућност идентификације патерна (знања) у подацима [128], који се касније могу применити на нове случајеве. Постоје различите технике машинског учења за решавање сложених проблема класификације и регресије. У зависности од посматраног проблема, многи савремени модели коришћени су за моделирање понашања возача током вожње, као што су нпр. Гаусов мешани модел, скривени Марков модел, метод к-средњих вредности, метод подржавајућих вектора (енг. *Support-vector machine*, SVM), метод насумичне шуме, к-најближи сусед, фази-неуронске мреже, стабло одлучивања (енг. *Decision Tree*) [129]. За моделирање понашања возача у литератури је коришћен велики број метода класификације. Истраживање показује да већина ових метода користи алгоритме статистичке регресије како би класификовала различита стања возача. У оквиру ових метода класификације понашања возача налазе се и алгоритми кластеровања [130].

Архитектура модела за предвиђање понашања возача треба да омогући примену неке од техника машинског учења за процену потрошње горива и класификације стилова вожње, анализирајући вредности очитаних параметара током претходних вожњи возача. На Слици 28. приказан је ток података машинског учења.



Слика 28. Ток података машинског учења

Модели машинског учења нису у стању да предвиде тренутну потрошњу горива [131] са високим нивоом тачности услед немогућности идентификовања законитости у тренутно очитаним подацима. Међутим, ови модели су у стању да идентификују и науче трендове у просечној потрошњи горива са одговарајућим нивоом тачности [132].

У зависности од природе учења, задаци машинског учења обично се могу класификовати у две категорије: надгледано учење (енг. *Supervised*) и ненадгледано учење (енг. *Unsupervised*).

Код надгледаног учења уносе се улазни подаци и жељени излаз, у којем је циљ научити општа правила која мапирају улазе у излазе. Надгледано учење се примењује у случајевима када треба обучити модел за предвиђање непрекидне променљиве или у случају класификације. Класификација је задатак надгледаног учења и представља процес изградње модела који сврставају случајеве (инстанце) у предефинисане класе.

С друге стране, ненадгледано учење представља учење код којег не постоји дефинисани излазни атрибут, већ се односи на проналажење структуре улазних атрибута. Оно може бити само по себи циљ, нпр. откривање скривених законитости у подацима или средство за постизање циља нпр. учење карактеристика. Ненадгледано учење се примењује у случајевима када треба обучити модел да пронађе добру унутрашњу репрезентацију података, као што је њихова подела у кластере. На Слици 29. приказане су технике надгледаног и ненадгледаног машинског учења.



Слика 29. Технике машинског учења [133]

4.1.1. Технике класификације и регресије

Техника класификације користи се за предвиђање дискретних вредности. Модел класификације класификују улазне податке у одређене категорије. Конкретна примена може бити класификација понашања возача на основу одређених улазних параметара. У најпознатије алгоритме класификације убрајају се: SVM, k-NN, Наивни Бајес, логистичка регресија и неуронске мреже.

SVM представља модел за учење који користи простор хипотеза линеарних функција у високодимензионалном простору обележја [134]. Овај алгоритам класификује узорке проналажењем најбоље хиперравни која раздваја две класе. Најбоља хиперраван се бира тако што се генерише највећа маргина између узорка две класе. Подржавајући вектори су подаци узорка који су најближи одвајању хиперравни, а лоцирани су на граници маргине. Предности овог алгоритма су меморијска ефикасност и ефикасност у високодимензионалним просторима.

Алгоритам k-NN представља класу непараметарских метода које се користе у препознавању законитости и рударењу података. Овај алгоритам покушава да класификује непознати узорак на основу познате класификације његових суседа, где k означава број суседа које проверава [135]. Растојање са најмањом вредношћу одговара узорку у скупу за обуку који је најближи непознатом узорку. Све инстанце које одговарају подацима за обуку се чувају у n-димензионалном простору. Како се не фокусира на конструисање општег интерног модела, већ ради на чувању инстанци података за обуку, назива се још „лењи“ алгоритам.

Наивни Бајесов класификатор (енг. *Naive Bayes classifier, NBC*) представља један од најједноставнијих, али најефикаснијих алгоритама. Овај алгоритам користи Бајесово правило заједно са снажном претпоставком да су атрибути дате класе условно независни [136]. Ова претпоставка о независности се често крши у пракси, али NBC ипак често даје конкурентску тачност класификације. Мали скуп података за обуку у процењивању његових неопходних параметара и меморијска ефикасност доводе до тога да се NBC широко примењује у пракси.

Логистичка регресија представља алгоритам машинског учења развијен за проблеме класификације. Проблем класификације настаје када је циљна варијабла категоријска. Циљ логистичке регресије је мапирање функције од обележја скупа података до циљева како би се предвидела вероватноћа да нови узорак припада једној од циљних класа [137]. Ова метода се користи за проналажење модела који најбоље одговара описивању односа између зависне и независне варијабле.

Вишеслојни перцептрон (енг. *Multilayer Perceptron, MLP*) је алгоритам надгледаног учења. Он представља класу ANN-a, која се најбоље користи у случајевима када је улаз високодимензионални и дискретни, а излаз је реалне вредности [126]. Разликује се од логистичке регресије по томе што између улазног и излазног слоја може постојати један или више нелинеарних слојева, који се називају скривени слојеви [138]. MLP смањује негативан утицај евентуалних шума у подацима [139].

У најпознатије технике регресије убрајају се: линеарна регресија, ансамбл методе, стабла одлучивања и неуронске мреже.

Регресија је метода моделирања циљне вредности заснована на независним предикторима. Ова метода се углавном користи за предвиђање и утврђивање узрочно-последичне везе између варијабли. Технике регресије се углавном разликују на основу броја независних варијабли и типа везе између независних и зависних варијабли. Линеарна регресија представља врсту регресионе анализе где постоји линеарна веза између независне и зависне променљиве, међутим она исто тако може ефикасно моделирати нелинеарне односе [140].

Поред претходно поменутих алгоритама, све је веће интересовање за примену ансамбл метода (енг. *Ensemble methods*) [131]. То су технике машинског учења које за циљ имају побољшање тачности класификације која се постиже комбиновањем предвиђања већег броја класификатора. Примена ансамбл метода може се користити за апроксимацију потрошње горива, на тај начин омогућава и повећава ефикасност предвиђања јер захтева више техника машинског учења [141]. Основна идеја ових метода је стварање великог броја класификатора на основу тренинг података, односно неки вид агрегације њихових резултата у случајевима нове инстанце. Резултати добијени применом ансамбл класификатора могу бити бољи од резултата добијених коришћењем само једног класификатора ако су испуњена следећа два услова: базни класификатори треба да буду међусобно независни и бољи од случајног класификатора [142].

Две познате методе учења у ансамблима су упакивање (енг. *Bagging*) и подстицање (енг. *Boosting*) [143]. Упакивање представља технику која креира различите моделе тако што врши узорковање инстанци са понављањем. С обзиром да све инстанце имају једнаку вероватноћу да буду изабране, ова техника је мање подложна грешкама услед пре-тренирања (енг. *Overfitting*). Како се избор узорака врши са заменом, неки подаци ће бити изабрани више пута, а неки ниједном. На добијеним скуповима се тренирају класификатори. Након што се креирају сви класификатори, могуће је класификовати нове инстанце. Додељивање класе новој инстанци врши се тако што сваки базни класификатор да своју предикцију класе, након чега се новој инстанци придружује најзаступљенија класа. Подстицање представља итеративну процедуру која постепено мења расподелу тренинг података, тако да у свакој итерацији фаворизује оне податке који су лоше класификовани од стране претходног класификатора. Коефицијент тежине придружује се свакој тренинг инстанци и може се променити након завршене итерације [144]. Повећање градијента (енг. *eXtreme Gradient Boosting*, XGBoost) у облику ансамбл модела предвиђања је метода машинског учења за регресију и класификацију [145]. Алгоритам XGBoost представља ефикасну имплементацију концепта подстицања градијентног стабла, односно може се рећи да је то регулисани модел за формализовану контролу пре-тренирања [146]. У спроведеном истраживању [147], за предвиђање понашања возача аутори су користили слагање, односно генерализацију, која представља методу ансамбла која се састоји у коришћењу предвиђања излаза неколико модела машинског учења. Ови модели научени су преко датог скупа података и представљају улаз у други мета алгоритам учења, који може научити зависности између тих предвиђања и стварног излаза.

Стабла одлучивања се могу користити за решавање проблема класификације и регресије. Циљ коришћења стабла одлучивања је креирање модела који може да се користи за предвиђање класе или вредности циљне варијабле учењем једноставних правила одлучивања, која су закључена из претходних података.

RF алгоритам је првобитно увео Брајман (2001) [148]. Овај алгоритам машинског учења заснован је на стаблу одлучивања. Случајна стабла (енг. *Random Tress*, RT) припадају класи алгоритама који врше класификацију ансамбла. RF алгоритам се широко користи у класификацији и предвиђању, а такође се користи и у регресији [149]. За задатке класификације, излаз представља класа изабрана од већине стабала. За регресионе проблеме, средња вредност или просечно предвиђање појединачних

стабла представља излаз [150].

Алгоритам M5P представља унапређени алгоритам који је првобитно увео Куинлан (1992) [151] и заснован је конвенционалном стаблу одлучивања. Овај алгоритам се користи за предвиђање вредности нумеричке променљиве која одговара променљивој Y . Она представља бинарно одлучивање које има функције линеарне регресије на терминалним чворовима. Алгоритам M5P састоји се из два различита корака: фазе раста и фазе резидбе. Фаза раста се користи за раздвајање чворова на основу вредности укључених атрибута. Фаза резидбе процењује колико сваки атрибут доприноси грешци предвиђања на чвору, а затим сече непотребне гране. Алгоритам M5P се бави проблемима континуираних уместо дискретних класа, а може да се носи и са проблемима великих димензија [152].

ANN представљају један од облика вештачке интелигенције, убрајају се популарне технике машинског учења које симулирају механизам учења у биолошким организмима [153]. Неуронске мреже се састоје од више међусобно повезаних неурона који шаљу сигнале једни другима. Вештачка неуронска мрежа израчунава функцију улаза пропагирањем израчунатих вредности улазних неурона користећи тежинске коефицијенте. Ови коефицијенти представљају јачину везе којом су неурони повезани. Процес учења се дешава променом тежинских коефицијената. Различите верзије ових алгоритама користе се за препознавање скривених законитости, корелације између сирових података, класификацију, груписање и могућност креирања динамичких модела који су у стању да се прилагођавају различитим ситуацијама током времена [154, 155]. ANN су посебно погодне за препознавање и класификацију одређених понашања возача [130].

4.1.2. Кластеровање

Кластеровање или груписање представља главну технику ненадгледаног машинског учења. Користи се за анализу података, како би се пронашле скривене законитости или груписања у подацима. Технике груписања се примењују када не постоји класа коју треба предвидети, већ када случајеве треба поделити у природне групе [156]. У најпознатије алгоритме кластеровања убрајају се: k -средина (енг. *k-means*), k -медоида (енг. *k-medoids*), Гаусов мешовити модел, неуронске мреже, хијерархијско кластеровање (енг. *Hierarchical*) и Скривени Марков модел (енг. *Hidden Markov Model*, HMM).

Алгоритам k -средина представља један од најпознатијих и најчешће коришћених алгоритама за кластеровање у пракси. Рад овог алгоритма је заснован на коришћењу одстојања. Најчешће је то Еуклидско одстојање, како би се итеративно тачке података хиперпростора доделиле скупу кластера који се не преклапају [156]. Предност овог алгоритма представља брзина обраде, која рачуна само одстојање тачака од центра групе. Недостатак алгоритма односи се на случајан избор центра кластера, па је могуће добијање различитог груписања при поновном покретању алгоритма. Кластеровање алгоритмом k -медоида је варијанта алгоритма k -средина која је отпорнија на шуме и одступања [157]. Уместо коришћења средње тачке као центра кластера, алгоритам k -медоида користи стварну тачку у кластеру за његово представљање. Медоид је најближње лоциран ка центру кластера, са минималном сумом растојања до других тачака.

Гаусов мешовити модел омогућава већу флексибилност од к-средина. GMM је параметарска функција густине вероватноће представљена као пондерисана сума Гаусових компоненти [158]. У GMM претпоставља се да тачке података подлажу Гаусовој расподели. На овај начин два параметра описују облик кластера: средња вредност и стандардна девијација. GMM параметри се оцењују на основу података за тренинг коришћењем итеративног алгоритма максимизације очекиване веродостојности или оцене апостериорног максимума из добро обученог претходног модела.

Алгоритми хијерархијског кластеровања сврставају се у две категорије: одозго надоле или одоздо према горе. Алгоритми одоздо према горе третирају сваку тачку података као један кластер на почетку, а затим сукцесивно спајају (или агломерирају) парове кластера док се сви кластери не споје у један кластер који садржи све тачке података. Агломеративно хијерархијско кластеровање се разликује од кластерисања заснованог на партицијама. Оно гради бинарно стабло спајања почевши од листова који садрже елементе података, до корена који садржи цео скуп података [159]. Хијерархија се може представити као бинарно стабло које се зове дендрограм.

НММ је статистички модел који је први предложио Баум [160]. Он користи Марковљев процес који садржи скривене и непознате параметре. Основни принцип модела подразумева да посматрани догађаји немају кореспонденцију један према један са стањима, већ су повезани са стањима кроз дистрибуцију вероватноће [161]. Обично се примењује у статистичком препознавању и класификацији образаца.

У наредним потпоглављима биће разматрана примена претходно поменутих техника и алгоритама у евалуацији стила вожње и понашања возача, односно у моделирању потрошње горива.

4.1.3. Примена машинског учења у евалуацији понашања возача

При изради модела за евалуацију понашања возача, потребно је сагледати све аспекте који се узимају у обзир. Поред алата и уређаја за прикупљање података, најважније су процене метода и алгоритама за обраду и анализу релевантних параметара вожње, које карактеришу одређена понашања возача.

У литератури је коришћено неколико метода и техника за откривање понашања возача, као што су ANN, појачавање градијента [162], динамичка Бајесова мрежа, логистичке регресије и алгоритми машинског учења: стабло одлучивања, RF, k-NN, SVM и NB [163–166].

Данге и сарадници су у оцењивању понашања возача применили неколико метода и алгоритама машинског учења (Кохоненове неуронске мреже, k-NN, линеарне удаљености и динамички клизећи прозор) [167]. У истраживању [168] применом машинског учења, Ма и сарадници су развили систем за помоћ возачима аутобуса са мануелним мењачем. Овај систем је заснован на моделу вредновања стила вожње користећи алгоритме машинског учења. На Слици 30. приказан је модел вредновања стила вожње заснован на алгоритму стабла одлучивања.




Слика 30. Модел вредновања стила вожње заснован на алгоритму стабла одлучивања [168]

Исти аутори су развили алгоритам који би могао постепено да води возача ка побољшању вожње. За класификацију понашања возача у студији [169] примењиване су вештачке неуронске мреже (енг. *Artificial neural network*, ANN). У спроведеном истраживању [170] вршено је упоређивање три врсте метода

неуронских мрежа. Резултати показују да модел вишеслојног перцептрона може постићи одличне резултате класификације. Међутим, тешко је утврдити стопу учења, што резултира већом могућношћу да алгоритам буде заробљен у локалном минимуму. Алгоритам стабла одлучивања [171] и алгоритам случајне шуме (енг. *Random forest*, RF) [172] коришћени су ради откривања понашања возача током вожње, посматрајући одређене карактеристике. У спроведеном истраживању [173] Квак и сарадници предлажу модел верификације возача који анализира законитости у вожњи користећи податке добијене путем сензора у возилу. Ови аутори су користили четири различита алгоритма за класификацију (*Decision Tree*, *k-nearest neighbors algorithm*, *Random Forest* и *MLP* алгоритам). У спроведеном истраживању Месегер [174] и сарадници су оцењивали и класификовали понашање возача користећи неуронске мреже посматрајући следеће параметре: убрзање возила, број обртаја мотора, позиција педале гаса и тренутна брзина. Међутим, надгледање потрошње горива и њена корелација са агресивношћу возача у овом раду нису посматране.


Приступ заснован на машинском учењу који бележи ефекте понашања возача на емисију гасова развијен је у оквиру истраживања које су спровели Су и сарадници [175]. Они су користили метод повећања екстремног градијента (енг. *XGBoost*) за предвиђање вредности еколошких показатеља. У оквиру резултата спроведене студије утврђено је да учесталост продуженог рада мотора у празном ходу има најзначајнији утицај на интензитет емисије гасова на посматраној рути.

Минг и Тан су креирали модел за класификацију возача помоћу података прикупљених путем OBD уређаја на возилу [176]. На Слици 31. приказан је дијаграм тока механизма профилисања возача.



Слика 31. Дијаграм тока механизма профилисања возача [176]

Озгул и сарадници су развили ненадгледани оквир за бодовање стила вожње возача применом машинског учења, у оквиру којег су тестирали различите метрике удаљености и алгоритме кластеровања за поуздано груписање [177]. Груписање стилова вожње оцењивано је помоћу општег механизма бодовања, у којем су агресивни возачи добили значајно ниже оцене у односу на умерене возаче. На Слици 32. приказана је расподела оцена.




Слика 32. Расподела добијених оцена [177]

Агресивни возачи имају шири опсег расподеле оцена у односу на умерене возаче. При анализи и класификацији понашања возача, ова расподела може бити узета у разматрање у случајевима када коначана оцена не може јасно да укаже на припадност одређеној категорији понашања.

У истраживању [178], Ким и сарадници су оцењивали возаче на скали од 100 бодова. У студији је коришћено машинско учење за утврђивање доприноса улазних параметара у предвиђању потрошње горива. Његовом применом утврђен је допринос свих појединачних параметра на основу којих се формира оцена вожње.

Неколико истраживача развило је моделе у којима се на основу карактеристика понашања возача откривају различита понашања током вожње. Ови модели засновани су на примени алгоритама машинског учења [179-181]. Мореира и сарадници су применом алгоритама: учење векторске квантизације (енг. *Learning Vector Quantization*, LVQ), појачаним C4.5, SVM и RF, предложили модел за препознавање возача на основу прикупљених параметара током вожње [147]. На Слици 33. може се видети предложена методологија.



Слика 33. Методологија заснована на алгоритмима машинског учења [147]


Гандур и сарадници су спровели истраживање у којем су системском анализом вршили класификацију понашања возача са аспекта безбедности [130]. За откривање ситуација у којима је возачу ометена пажња, она су имплементирали и упоредили следеће алгоритме: логистичку регресију, ANN, класификатор повећања градијента и RF. У оквиру добијених резултата метод повећања градијента показао је најбоље резултате од осталих коришћених класификатора.

У претходно поменутих истраживањима примењивани су различити модели и алгоритми машинског учења за решавање проблема препознавања законитости понашања возача. Разматрани алгоритми се могу применити за унапређење интегрисаног модела за класификацију и предвиђање понашања возача, тј. ефикасну обраду података у реалном времену и препознавање карактеристичних понашања возача (претицање, ометена вожња, умерена вожња, опасна вожња, итд.) категорисаних у одговарајуће профиле понашања као што су: нормалан, ометен и агресиван.

4.1.4. Примена машинског учења у моделирању потрошње горива

При веродостојном оцењивању понашања возача, неопходно је верификовати добијене оцене које карактеришу одређена понашања током вожње кроз потрошњу горива. Мерење потрошње горива представља веома сложен процес, који је у појединим ситуацијама изузетно тешко спровести. Различити фактори, попут великих трошкова самог мерења (набавка и инсталација мерних уређаја), недоступност параметера о потрошњи горива на возилу, физичко присуство истраживача током вожње и његов потенцијални утицај на стил вожње возача представљају неке од потешкоћа у мерењу потрошње горива. Прегледом литературе, спроведена истраживања указују на предности и могућност примене алгоритама машинског учења, при чему се постиже висока ефикасност у моделирању потрошње горива.

Перота и сарадници су применили технике машинског учења за моделирање потрошње горива, користећи следеће алгоритме (SVM, RF, ANN) [182].



Слика 34. Подобност развијеног SVM и RF модела [182]

Исти аутори су закључили да убрзање возила има велики утицај на резултате развијених модела. Приказ перформанси посматраних модела приказан је у Табели 4.

Табела 4. Поређење перформанси SVM, RF и ANN модела [182]

Модел	RMSE	MAE	R ²
SVM	5,12	3,56	0,83
RF	4,64	3,21	0,87
ANN	4,88	3,46	0,85

Поређењем ових алгоритама долази се до закључка да RF представља технику која даје најбоље перформансе. Поред тога, SVM и ANN показали су добре перформансе, посебно у предвиђању екстремних вредности.

Естаји и сарадници су у спроведеној студији о предвиђању потрошње горива поредили резултате линеарне регресије, ансамбл дрвећа и ANN [183]. Показало се да су модели ANN и ансамбл дрвећа са сложенијим структуром модела надмашили поједностављени регресиони модел, који је имао велику пристрасност у предвиђању потрошње горива. У спроведеној студији [127] коришћен је SVM модел за процену потрошње горива користећи OBD-II уређај на возилу. Метод заснован на SVM класификатору комбинован са Лагранжовом интерполацијом, коришћен је за дефинисање односа између параметара рада мотора (брзине мотора и позиције клапне гаса) и укупне потрошње горива.

Бусонвил и сарадници су у истраживању [7] применили технике машинског учења за предвиђање потрошње горива тешких камиона. Поређење три различите технике машинског учења указује да је модел заснован на примени градијетног појачавања надмашио ANN и k-NN алгоритме. Спроведени експерименти су показали да поред осталих фактора, просечна брзина, варијација брзине и тип пута доприносе значајном побољшању прогнозе. Моради и Морено су развили модел чија је методологија била заснована на SVR и ANN алгоритмима, који су способни да обухвате сложене законитости интеракција између обележја и зависне променљиве [184].

На основу доступних параметара вожње представљених као временске серије, Викраманајаки и Бандара су поредили предиктивне способности три технике машинског учења у предвиђању потрошње горива аутобуса [131]. Компаративном анализом су закључили да техника RF даје прецизније предвиђање у поређењу са неуронским мрежама и техником појачавања градијента. У спроведеном истраживању [126], Ли и сарадници су користили MLP у процењивању стварне потрошње горива лаких возила, применивши га на подацима који можда нису линеарно одвојиви.

Процена потрошње горива представља важан део интегрисаног модела. У литератури постоји велики број радова који се тичу предвиђања потрошње горива. Анализом претходно поменутих радова и студија установљено је да се у најпогодније алгоритме за предвиђање потрошње горива могу сврстати SVM, ANN и k-NN аглоритам. Зависно од посматраних улазних параметара и методологије истраживања, ови алгоритми су показали добре перформансе у моделирању потрошње горива. У експерименталном делу рада, за креирање модела биће примењивани следећи алгоритми: LinearRegression, MLP, SMOreg, lmk, M5P, RF, Random Tree и REPTree.


4.2. Фази скупови и фази логички системи типа 2

Фази логика сматра се адекватном методологијом за пројектовање робусних система у стањима неизвесности и непрецизности. Фази логика типа 1 била је најпопуларнији облик фази логике. Међутим, последњих година сложенија фази логика показала је значајан пораст у истраживањима, посебно интервална фази логика типа 2 [185-187] и општа фази логика типа 2 [188-190].



Слика 35. Секундарне функције припадности а) фази скупа типа 1, б) интервалног фази скупа типа 2, в) општег фази скупа типа 2 [191]

Фази скупови и фази логички системи типа 2 генерализују фази скупове и ФЛС типа 1, што даље омогућава управљање већим бројем непоузданости, несигурности и неизвесности. Од развоја идеје фази скупова, постојале су критике да у фази скуповима типа 1 код функције припадности не постоји неизвесност, што противречи речи фази, будући да је конотација те речи неизвесност [192]. Поставља се питање шта урадити када постоји неизвесност у степену припадности фази скупу (функцији припадности) [193]. Задек [194] је предложио софистицираније врсте фази скупова које је назвао фази скупови типа 2. Фази скуп типа 2 омогућава да се неизвесности у вези са функцијом припадности уграде у теорију фази скупова и тиме реши претходно наведени проблем неизвесности у степену припадности фази скупу. Функција припадности фази скупу типа 2 настаје када код функције припадности типа 1 (Слика 36а), прикажемо у расплинутој форми леву и десну границу интервала поверења, као што је приказано на Сlici 36. (б).



Слика 36. Функција припадности типа 1 (а) Функција припадности типа 2 (б)

Фази скуп A типа 2 описује се функцијом припадности [195]:

$$A = \{((x, u), \mu_A(x, u)) | \forall x \in X, \forall u \in J_x \subseteq [0, 1]\} \quad (6)$$

где функција припадности фази скупа узима вредности из интервала $[0, 1]$, а $J_x \subseteq [0, 1]$ представља примарни степен припадности од x , а $\mu_A(x, u)$ представља функцију припадности фази скупа типа 1.

Фази скупови типа 2 налазе веома широку примену у ФЛС, пошто омогућавају моделовање неизвесности које не могу бити моделоване фази скуповима типа 1. ФЛС који су описани најмање једним тип 2 фази скупом, називају се још и тип 2 ФЛС. Тип 1 ФЛС немају способност да описују и процесуирају неизвесности које постоје у правилима ФЛС-а, пошто користе фази скупове типа 1 код којих је степен припадности представљен појединачним нумеричким вредностима. Са друге стране, ФЛС типа 2 су корисни за примену у условима у којима је тешко одредити врсту и поједине параметре функција припадности и омогућавају експлоатацију неизвесности које се јављају у бази правила. Фази скупови типа 2 настали су као последица немогућности крутог дефинисања припадности елемента x скупу. Веома често се дешава да не може да се одреди степен припадности елемента x скупу X са 0 или 1. За описивање наведене неизвесности користе се тип 2 фази скупови. Слично томе, у случајевима када је тешко одредити степен припадности елемента x као реалан број у интервалу $[0, 1]$, користе се фази скупови типа 2.

Као и код типа 1 ФЛС-а, и код типа 2 ФЛС улазно-излазне променљиве повезане су IF-THEN правилима код којих су консеквенце (конклузије) правила представљене фази скуповима типа 2. Генерално, тип 2 ФЛС састоји се из пет елемената: фазификатора, базе правила, алгорита апроксимативног резоновања (улазно-излазно процесуирање), тип-редуктора и дефазификатора.

Имкамо и сарадници су у спроведеном истраживању предложили систем за класификацију понашања возача користећи фази логичке скупове [196]. Међутим, Фернандез и Ито указују на неке недостатке фази логичког система, који се тичу повећања броја правила [197]. Ови аутори су сматрали да ће се тачност система унапредити уколико се у обзир узме више параметара или правила. Резултати истраживања указали су да ће систем бити мање ефикасан са повећањем броја правила. Аутори Арас и Гоћеш су применили фази скупове за препознавање стила вожње возача, при чему су користили само два улазна параметра: брзину мотора и убрзање [1]. Прегледом литературе установљено је да многи аутори дефинишу различите границе за исте посматране параметре који се односе на еко-вожњу. То се углавном дешава због лингвистичке природе при дефинисању правила еко-вожње. Нпр. у циљу остваривања ефикасне вожње аутори предлажу: благо убрзање/успорење, одржавање умерене и константне брзине [198], умерено убрзање, избегавање наглог кочења и убрзања [199], вожњу при малом броју обртаја мотора [71], лагано притиснуту педалу гаса [95]. Сви ови лингвистички појмови омогућавају ауторима субјективно одређивање границе параметара као што су благо, умерено, ниско, лагано, итд. Развијањем модела користећи претходно дефинисане параметре вожње као улаз и применом фази логичких скупова типа 2, може се решити недостатак у дефинисању нејасних правила еко-вожње и њених граница.

5. АРХИТЕКТУРА ИНТЕГРИСАНОГ МОДЕЛА ЗА КЛАСИФИКАЦИЈУ И ПРЕДВИЂАЊЕ ПОНАШАЊА ВОЗАЧА

Интегрисани модел за класификацију и предвиђање понашања возача треба да омогући руководиоцима возних паркова реалан увид у стил вожње возача који одговара потрошњи горива коју остварују. Овај модел карактерише интегрисање два подмодела који су засновани на фази скуповима и машинском учењу (Слика 37). У првој фази у оквиру ФЛС2 модела врши се евалуација стила вожње возача током вожње. Возач добија оцене за сваку секунду на основу снимљених вредности параметара о вожњи. На основу добијених оцена, формира се дневна оцена возача, а касније и коначна оцена за посматрани период. За верификацију добијених коначних оцена коришћена је стварна просечна потрошња горива. С обзиром на различите проблеме и потешкоће у мерењу потрошње горива током вожње, у другом подмоделу врши се предикција потрошње горива која ће се након одређивања услова у саобраћају користити за верификацију оцена вожње у реалном времену. Одабиром релевантних улазних параметара о раду возила и применом алгоритама машинског учења, врши се предвиђање потрошње. Исти скуп параметара користи се у оба подмодела. У последњој фази применом *Potthoff* анализе, врши се предвиђање потрошње горива на основу оцена вожње зависно од услова у саобраћају.




Слика 37. Архитектура интегрисаног модела за класификацију и предвиђање понашања возача

Прегледом литературе установљено је да постоје различити модели који се посебно баве проблемима ефикасности потрошње горива и евалуацијом понашања возача. Развијање интегрисаног модела на основу више подмодела има за циљ примену јединственог модела и методологије у предвиђању и класификацији понашања возача, коју је могуће применити независно од броја посматраних

параметара и врсте горива. Калибрацијом улазних параметара вожње одговарајућем типу возила и тестним мерењем потрошње горива, овај приступ омогућава веродостојно и ефикасно праћење стила вожње. У наставку рада следи детаљан приказ структуре оба подмодела и примене *Potthoff* анализе.

5.1. Структура ФЛС2 модела за оцену стила вожње

Предложени модел има циљ да преко снимљених вредности дефинисаних параметара (брзина рада мотора - БМ, притисак педале гаса - ППГ, убрзање-УБ) употребом ФЛС типа 2 израчуна оцену вожње возача. У овом истраживању рад мотора у празном ходу неће бити разматран како би се добила што прецизнија оцена понашања возача. Међутим, треба имати у виду да продужени рад мотора у празном ходу има велики утицај на интензитет емисије CO₂ и потрошњу горива [142]. У оквиру резултата овог рада биће разматрано и оцењивање возача са два параметра (БМ и УБ) који су били претходно истраживани и предложени у оквиру истраживања Араса и Гоћеша [1]. На основу добијених оцена извршиће се поређење модела са два и три улазна параметра, а затим и класификација возача, која руководиоцима посматраних компанија веродостојно приказује у којој мери се разликују возачеви стилови вожње и који утицај то има на енергетску ефикасност возног парка. Структура ФЛС2 модела за оцену стила вожење приказана је на Слици 38.




Слика 38. Предложени фази логички модел типа 2 за оцену стила вожње [200]

У оквиру модела, треба извршити снимање вредности три претходно дефинисана параметра (Табела 5) чије вредности утичу на потрошњу горива. У Табели 5. су поред назива, приказане мерне јединице и опсег вредности дефинисаних параметра.


Табела 5. Параметри за оцену стила вожње возача

Рб.	Назив параметра	Мерна јединица	Опсег вредности параметра
1.	Брзина мотора	(RPM)	$X_1 \in [0, 5000]$
2.	Убрзање	(m/s ²)	$X_2 \in [-8, 6]$
3.	Притисак педале гаса	(%)	$X_3 \in [0, 100]$


Снимљене вредности дефинисаних параметара (Табела 5) представљају улазне вредности у ФЛС2 модел (Слика 38). Интервали улазних параметара ФЛС-а који су приказани на Графиконима 1, 2. и 3. одређени су на основу истраживања и анализе литературе.



Графикон 1. Функција припадности улазне променљиве УБ ФЛС2 модела



Графикон 2. Функција припадности улазне променљиве ППГ ФЛС2 модела



Графикон 3. Функција припадности улазне променљиве БМ ФЛС2 модела

У почетној фази пројектовања ФЛС2 модела потребно је дефинисати скуп лингвистичких правила, врсту и параметре функција припадности, којима се описују улазно/излазне променљиве у моделу.

У ФЛС2 моделу су за опис три улазна параметра коришћене Гаусове ФП. Гаусове ФП су изабране пошто:

- добро описују улазне променљиве,
- обезбеђују задовољавајућу осетљивост ФЛС-а,
- њиховим подешавањем обезбеђује се задовољавајућа осетљивост модела
- једноставне су за манипулацију приликом подешавања ФЛС-а.

Пошто се ради о Сугено моделу нултог реда ФЛС-а, излазна променљива оцена стила вожње (Y) представљена је са пет ФП које су представљене константама ($Y = ax + by + c$, $a = b = 0$). Излазна променљива Оцена стила вожње (Y) нормирана је на интервал [1, 10] и описана са пет лингвистичких променљивих: врло лоша, лоша, средња, добра или врло добра оцена.

Након фазификације улазних параметара ФЛС типа 2 за оцену стила вожње, активирају се сва правила у бази која у својим премисама имају фази скупове улазних параметара (Слика 38). Структура базе правила ФЛС-а типа 1 и типа 2 је иста. Једина разлика је у премисама и конклузијама правила које се код ФЛС-а типа 2 описују фази скуповима типа 2. Ако посматрамо предложени ФЛС2 модел (Слика 38), који има три улазна параметра $x \in X_1 \times X_2 \times X_3$, једну излазну променљиву $y \in Y$ и 27 правила у бази, тада i -то правило можемо да прикажемо у следећој форми

$$R^l : \text{IF } x_1 \text{ is } F_1^l \text{ and } x_2 \text{ is } F_2^l \text{ and } x_3 \text{ is } F_3^l \text{ THEN } y \text{ is } G^l, (l=1,...,27)$$

где F представља фази скупове типа 2 улазних променљивих БМ, УБ, ППГ, док G представља фази скупове типа 2 излазне променљиве Y (Оцена стила вожње).

Фази правила у моделу заснована су на основу снимљених вредности дефинисаних параметра током тромесечног истраживања и граничних вредности интервала посматраних параметара које су предложене у разним студијама. У Табели 6. дат је приказ неких од дефинисаних фази правила у моделу. Предложени модел садржи укупно 27 правила.

Табела 6. Дефинисана фази правила ФЛС2 модела

Редни	Фази правило	Оцена возача
1.	Уколико је БМ ниска, УБ ниско и ППГ низак	врло добра
2.	Уколико је БМ ниска, УБ ниско и ППГ средњи	добра
3.	Уколико је БМ ниска, УБ ниско и ППГ висок	средња
4.	Уколико је БМ ниска, УБ средње и ППГ низак	врло добра
5.	Уколико је БМ ниска, УБ средње и ППГ средњи	средња
6.	Уколико је БМ ниска, УБ средње и ППГ висок	лоша
...	...	...
22.	Уколико је БМ висока, УБ средње и ППГ низак	врло добра
23.	Уколико је БМ висока, УБ средње и ППГ средњи	средња
24.	Уколико је БМ висока, УБ средње и ППГ висок	лоша
25.	Уколико је БМ висока, УБ високо и ППГ низак	врло добра
26.	Уколико је БМ висока, УБ високо и ППГ средњи	средња
27.	Уколико је БМ висока, УБ високо и ППГ висок	лоша

Након фазификације улазних података, добијени улазни фази скупови се мапирају у излазне фази скупове помоћу блока процесуирања (Слика 38). Ово се постиже тако што се врши квантификација сваког правила применом теорије фази скупова у механизму апроксимативног резоновања. Алгоритам апроксимативног резоновања се спроводи кроз фазе активације и акумулације фази скупова [201, 202]. Слагањем значајности правила (фаза акумулације) добија се резултујући фази скуп типа 2 [203].

У ФЛС типа 1, обрада излаза се зове дефазификација при чему се фази скуп типа 1 мапира у број. Међутим, код ФЛС типа 2, да би се прешло из интервалног фази скупа типа 2 на прецизан број, потребна су два корака (Слика 38). Први корак је примена тип редуктора, где се интервални фази скуп типа 2 своди на фази скуп типа 1. Постоји неколико метода за редукцију типа [195]. Најчешће се користи тип-редуктор центар скупова (енгл. *center-of-sets* - COS) [185, 204-206], који је коришћен у предложеном моделу, израз (7).

$$Y_{COS}(x) = \bigcup_{\substack{f^n \in F^n(x) \\ y^n \in Y^n}} \frac{\sum_{n=1}^N f^n y^n}{\sum_{n=1}^N f^n} = [y_l, y_r] \quad (7)$$

Вредности y_l и y_r одређују се применом израза (8) и (9)

$$y_l = \min_{k \in [1, N-1]} \frac{\sum_{n=1}^k \bar{f}^n y^n + \sum_{n=k+1}^N \underline{f}^n y^n}{\sum_{n=1}^k \bar{f}^n + \sum_{n=k+1}^N \underline{f}^n} \quad (8)$$

$$y_r = \min_{k \in [1, N-1]} \frac{\sum_{n=1}^k f^n \bar{y}^n + \sum_{n=k+1}^N \bar{f}^n \bar{y}^n}{\sum_{n=1}^k f^n + \sum_{n=k+1}^N \bar{f}^n} \quad (9)$$

На Слици 38. може се видети да дефазификација редукованог фази скупа типа 1 даје тачну нумеричку оцену стила вожње у интервалу [1,10]. Као што се стандардна девијација користи у вероватноћи и статистици за мерење непредвидиве неизвесности око средње вредности, редукцијом скупа типа 2 у тип 1 обезбеђује се мерљивост неизвесности која се односи на оцену стила вожње.

Возачи могу да се разликују по начину на који се одлучују за убрзавање и успоравање возила, држању одстојања од водећег возила, војњи коју карактерише прекорачење ограничења брзине, итд. За утврђивање стила вожње возача, који карактеришу претходно поменута понашања, извршена је анализа улазних параметара, модела и коначних оцена, и предложена категоризација евалуације стила вожње возача на основу коначних оцена (Слика 39).



Слика 39. Категоризација евалуације стила вожње

Категоризација евалуације стила вожње извршена је у 5 категорија: веома агресиван (коначна оцена 5 и мања), агресиван (коначна оцена већа од 5 и мања од 6), умерен (коначна оцена 6 и мања од 7), ефикасан (коначна оцена 7 и мања од 8) и ефикасан (коначна оцена 8 и већа). Поред класификације понашања возача, предложена категоризација може се искористити у развијању модела награђивања возача са ефикасним и веома ефикасним стилем вожње.

5.2. Модел машинског учења у предвиђању потрошње горива


У овом истраживању за предвиђање потрошње горива, биће коришћени неки од најчешће примењиваних, али и неки мање популарни алгоритми надгледаног машинског учења. Након примене модела у оквиру резултата биће извршена компаративна анализа њихових перформанси. Процес предвиђања циљне променљиве заснован је на примени машинског учења, а састоји се од неколико фаза:

- припрема података
- тренирање модела
- валидација модела
- тестирање модела
- примена модела

Након прве фазе, тј. припреме података врши се тренирање модела. Како би се извршило предвиђање циљне променљиве, тренира се више модела машинског учења који су засновани на различитим алгоритмима. За добијање хиперпараметара модела неопходно је тренирање модела, односно примена изабраног алгоритма на одређеном скупу података за учење. Валидација модела представља следећу фазу у којој се бира најбољи модел, одређује оптимална конфигурација параметара посматраног модела. Валидација представља оцену успешности предикције, која је добијена применом одређеног модела. У овом истраживању за валидацију модела примењен је приступ унакрсне валидације (енг. *cross-validation*), који користи само податке за тренинг, а састоји од неколико фаза:

- У фази тренирања модела доступан скуп података дели се на K једнаких подскупова (енг. *folds*).
- Модел се увек тренира на $K-1$ подскупова података.
- На преосталом подскупу података врши се валидација модела.
- Претходна два корака се понављају K пута. У свакој итерацији неопходно је узети један део података за потребе валидације модела, док се остатак података ($K-1$ делова) користи за учење. Увек се бира различит подскуп који ће се касније користити за валидацију посматраног модела.
- Аритметичке средине перформанси које су добијене у K итерација служе за израчунавање перформанси модела.

На Слици 40. може се видети унакрсна валидација модела машинског учења за K подскупова.



Слика 40. Унакрсна валидација модела машинског учења за К подскупова

За евалуацију успешности нумеричке предикције Витен и сарадници предлажу неколико различитих мера и то: средњу квадратну грешку, средњу апсолутну грешку, квадратни корен средње квадратне грешке, релативну квадратну грешку, квадратни корен релативне квадратне грешке, релативну апсолутну грешку и коефицијент корелације [156]. У Табели 7. приказане су мере перформанси за нумеричко предвиђање, где су пројектоване вредности циљне променљиве означене са $p_1, p_2, \dots, p_n$; док су стварне вредности променљиве означене са $a_1, a_2, \dots, a_n$.

Средња квадратна грешка (10) је главна и најчешће коришћена мера. Понекад се користи квадратни корен средње квадратне грешке (11) како би се добила иста димензија као и код предвиђене вредности. Релативна квадратна грешка (13) се рачуна у односу на оно што би било да се користи једноставни предиктор $\bar{a}$, који представља просек стварних вредности из података за тренинг. Релативна апсолутна грешка (15) представља укупну апсолутну грешку, са истом нормализацијом. Коефицијент корелације (16) мери статистичку корелацију између стварне вредности променљиве и вредности променљиве коју треба предвидети. Коефицијент корелације се креће у опсегу од 1 за савршено корелиране резултате до -1 када су резултати савршено негативно корелирани. Уколико је вредност корелације 0, тада нема корелације. Квадрат Пирсоновог коефицијента корелације назива се коефицијент детерминације (17). Ова вредност представља показатељ колико су промене једне променљиве проузроковане променама друге променљиве, а конвенција треба да се изрази као проценат.

Табела 7. Мере перформанси за нумеричко предвиђање [156]

Мере перформанси	Формула
средња квадратна грешка	$\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n} \quad (10)$
квадратни корен средње квадратне грешке	$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}} \quad (11)$
средња апсолутна грешка	$\frac{ p_1 - a_1 + \dots + p_n - a_n }{n} \quad (12)$
релативна квадратна грешка	$\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}, \text{ где је } \bar{a} = \frac{1}{n} \sum_i a_i \quad (13)$
квадратни корен релативне квадратне грешке	$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}} \quad (14)$
релативна апсолутна грешка	$\frac{ p_1 - a_1 + \dots + p_n - a_n }{ a_1 - \bar{a} + \dots + a_n - \bar{a} } \quad (15)$
коефицијент корелације	$\frac{S_{PA}}{\sqrt{S_P S_A}}, \text{ где } S_{PA} = \frac{\sum_i (p_i - \bar{p})(a_i - \bar{a})}{n-1}, \quad (16)$
	$S_P = \frac{\sum_i (p_i - \bar{p})^2}{n-1}, \text{ и } S_A = \frac{\sum_i (a_i - \bar{a})^2}{n-1}$
коефицијент детерминације	$R^2(p_i, a_i) = 1 - \frac{\sum_i (a_i - p_i)^2}{\sum_i (a_i - \bar{a})^2} \quad (17)$

После фаза тренинга и валидације модела, врши се одабир неколико модела који поседују најбоље перформансе. У следећој фази тестирања модела треба извршити процену успешности модела над скупом података за тестирање. Након оптимизације хиперпараметара техником кросвалидације, модели са најбољим перформансама су евалуирани и на тест скупу података. У случају постојања великог подударана модел ће веома добро радити на подацима за тренинг, али лоше на подацима за тестирање. Од модела који показују добре перформансе на скупу података за тренинг и скупу података за тестирање, бира се модел који поседује најбоље перформансе у обе фазе.

Циљна променљива у оквиру посматраног скупа прикупљених података у овом истраживању је непрекидна, према томе изграђени модели машинског учења базирани су на најпопуларнијим регресионим алгоритмима: к најближих суседа, линеарна регресија, метода потпорних вектора за регресију, дрво одлучивања и неуронска мрежа. За предвиђање вредности циљне променљиве, неопходно је

издвојити скуп података за предикцију. Овакав скуп података мора бити исти по формату и структури података за тренинг и тестирање. На датом скупу података примењује се модел машинског учења који је након фазе тестирања имао најбоље перформансе. Предикција потрошње горива вршена је на основу следећих улазних параметара: брзина мотора, притисак педале гаса и убрзање возила. У наставку рада претходно поменуте мере перформанси ће се користити за моделе нумеричког предвиђања и то: коефицијент корелације, коефицијент детерминације, средња апсолутна грешка, квадратни корен средње квадратне грешке, релативна апсолутна грешка и квадратни корен релативне квадратне грешке.

5.3. *Potthoff* анализа

Регресиона анализа се може дефинисати као врста техника предиктивног моделирања која истражује везу између зависне (циљне) променљиве и независне променљиве (предиктора). Ова техника се користи за предвиђање и проналажење узрочно последичне везе између променљивих. Линеарна регресија може се представити једначином облика

$$Y = a + bX \quad (18)$$

где је X независна променљива, а Y зависна променљива. Нагиб праве представљен је коефицијентом b , док коефицијент a означава пресек (тј. вредност променљиве Y , када је $X = 0$). Метрике процене које се користе се мењају зависно од посматраног проблема. Грешке указују колико модел прави грешке у свом предвиђању. Основни концепт процене тачности је упоређивање првобитне променљиве са предвиђеном, на основу одређених метрика.

У спроведеном истраживању и предложеном интегрисаном моделу за предвиђање и класификацију понашања возача, извршена је *Potthoff* анализа. Ова анализа представља једноставан начин упоређивања линеарних регресионих модела. Предност ове анализе огледа у се пружању информације о томе да ли се регресиони модели који су засновани на различитим групама са истим варијаблама разликују. Постоји могућност да је линеарни регресиони модел статистички важан за једну групу, међутим не и за неку другу групу. Додатно, различити коефицијенти могу бити статистички значајни зависно од групе. *Potthoff* анализа се састоји од неколико тестова: теста подударности, прекида и паралелизма. Према томе, тест подударности има за циљ да истражи да ли постоји разлика између нагиба и/или прекида посматраних група. Тест прекида одређује да ли су прекиди идентични по групама, док тест паралелизма пружа информацију да ли се нагиби значајно разликују [207].

Оцена возача добијена током сваке секунде вожње представља излаз из ФЛС2 модела тј. независну променљиву у овој анализи, док потрошња горива добијена моделирањем, односно применом модела машинског учења представља зависну променљиву. Поред тога, у оквиру анализе, креирани су и упоређени модели линеарне регресије у зависности од услова у саобраћају. На посматраним деоницама зависно од остварене просечене брзине у интервалу од 91 секунде, односно 45 секунди пре и 45 секунди после тренутка посматрања, извршиће се класификација услова у саобраћају који могу бити: градски (просечна брзина мања или једнака 50

km/h), приградски (просечна брзина већа од 50 km/h и мања или једнака 80 km/h) и отворени пут или ауто-пут (просечна брзина већа од 80 km/h). Класификација услова у саобраћају са пет категорија предложена је у истраживању [208]. Услови у саобраћају су израчунати на основу следећег израза:

$$\bar{v}_i = \frac{1}{91} \sum_{j=i-45}^{i+45} V_j, \quad i \in \{46, \dots, n-45\} \quad (19)$$

где је

$\bar{v}_i$ - просечна брзина у интервалу за i -ти тренутак посматрања,

V_j - остварена брзина у j -том делу интервала за i -ти тренутак посматрања,

n - укупан број записа.

Применом претходно поменуте анализе, треба утврдити да ли постоји статистички значајна разлика између регресионих модела, када се посматрају различити услови у саобраћају. На основу резултата *Potthoff* анализе, биће извршена класификација возача и предвиђање потрошње горива зависно од услова у саобраћају.

6. ПРИМЕНА МОДЕЛА

За утврђивање утицаја стила вожње на потрошњу горива и примену предложеног модела за класификацију и предвиђање понашања возача, спроведено је истраживање у постојећим транспортним компанијама у реалним условима рада. Модел је примењен на дизел транспортним возилима, међутим постоји могућност примене исте методологије у случају посматрања возила са бензинским, електричним или хибридним погоном. У том случају неопходно је прилагодити улазне параметре и дефинисати њихове опсеге. Вредновање понашања возача представља вишекласни класификацијски модел. Примена и значај модела, огледа се у оценама вожње на основу којих се може предвидети потрошња горива зависно од услова у саобраћају. Сем тога, коначна оцена вожње може се користити за увид у стил вожње возача у реалном времену, едукацију возача и примену принципа еко-вожње и развијање система награђивања возача.

6.1. Опис истраживања

Истраживање је спроведено у две фазе, прва фаза била је током периода септембар-новембар 2019. године у транспортној компанији *Delmax* која поседује возни парк за дистрибуцију аутомобилских резервних делова. Друга фаза извршена је током јуна 2021. године у курирској служби *AKS Express*. Обе компаније се налазе на територији Републике Србије. За потребе истраживања коришћена су три комби возила на дизел гориво, која припадају посматраним компанијама. Произвођач и модел свих комби возила је исти (Слика 41), карактеришу их снага мотора (96 kW), запремина мотора (2 299 cm³), нето маса (2 015 kg), носивост (1 485 kg) и приближно исти пређени пут, како би се изједначио утицај различитих техничких карактеристика и различитог стања коришћених возила на специфичну потрошњу горива.



Слика 41. Renault master – комби возило коришћено у истраживању

Посматрана возила су током истраживања превозила веома сличне количине терета, како би се изједначио утицај различите масе терета у возилу на специфичну потрошњу горива. Сва возила су током истраживања имала исте димензије

пнеуматика са прописаним притиском ваздуха. Током истраживања није било кишовитог и ветровитог времена.

У истраживању је учествовало седам возача. Шест тест возача чије је понашање у вожњи оцењивано, насумично је изабрано на основу разговора са руководиоцима компаније *Delmax*. На возилима ових возача вршено је прикупљање параметара вожње на основу којих су оцењивани стилови вожње. Услед техничких немогућности, мерења потрошње горива на возилима тест возача нису спроведена. Подаци о вожњама седмог возача курирске службе *AKS Express*, служили су за моделирање потрошње горива. Овај возач возио је неколико вожњи које одговарају вожњама тест возача, а обухватају све услове у саобраћају (градски услови, приградски услови и отворен пут). Сви возачи су мушког пола, припадају средњој или старијој старосној доби, имају више година искуства као професионални возачи за превоз терета и сви су две године пре овог истраживања имали обуку еко-вожње. Возачи нису били упознати са истраживањем како би остали доследни својим стиливима вожње.

Током истраживања одабрани возачи су управљали истим наведеним возилима у истим експлоатационим условима. За ту сврху, возачи су обављали планиране транспортне задатке на три постојеће деонице, које су следећих дужина: деоница 1 (Сомбор - 334км), деоница 2 (Панчево - 258км), деоница 3 (Звездара - 120км). Сви возачи су кретали из Старе Пазове у којој се налази централа компаније *Delmax*, она уједно представља и место повратка возила на крају радног дана. На посматраним деоницама одвијају се претежно приградски услови саобраћаја, уз одређене под-деонице са градским условима и отвореним путем. Током истраживања на коришћеним линијама није било радова на путу или саобраћајних незгода, које би довеле до већих саобраћајних загушења. Сваки возач је управљао возилом по пет дана на свакој од три наведене линије, како би се изједначио утицај различите конфигурације терена (успони и падови подужног и попречног пресека пута) и различитог стања пута посматраних линија на специфичну потрошњу горива. Сваки возач је тестиран укупно 15 дана и у том периоду је обавио 15 вожњи (транспортних задатака) током којих је извршено снимање вредности параметара.

За снимање вредности дефинисаних параметара коришћен је уређај за читавање параметара о вожњи, који се повезује преко OBD-II прикључка. Уређај током рада возила читава параметре са главног рачунара за контролу мотора. У интервалу од једне секунде снимане су тренутне вредности следећих параметара: БМ, ППГ и брзина возила, на основу које се израчунава тренутна вредност параметра УБ. У обзир су узете искључиво вредности параметра када се возило креће, односно када је брзина возила већа од нуле, како би се утврдио директан утицај возачевог начина управљања возилом на потрошњу горива. Очитане вредности наведених параметара се затим путем *Bluetooth* везе преносе и складиште на развијену апликацију на мобилном телефону у возилу. Пре снимања података извршено је тестирање овог уређаја где је утврђена исправност и осетљивост рада уређаја при читавању вредности дефинисаних параметара.

На крају сваког радног дана возачи су на бензинској станици у близини посматране компаније у резервоаре својих возила досипали гориво по систему „до пуног резервоара“ и уносили у радне документе количину досутог горива, која у

ствари представља количину утрошеног горива за тај дан. На основу података о количини утрошеног горива и о пређеном растојању на свакој од наведених линија, израчуната је специфична потрошња горива (у L/100km) за сваког возача. Наведен податак је употребљен како би се установио утицај различитих стилова вожње приказан кроз различите оцене возача на енергетску ефикасност возила, односно на специфичну потрошњу горива.

6.2. Резултати истраживања

На основу спроведеног истраживања, сваког дана добијено је између 10 000 и 30 000 снимљених података о БМ, ППГ и УБ по сваком тестираном возачу. Предложени интегрисани модел за класификацију и предвиђање понашања возача примењен је на више од 1 200 000 записа. Током периода тестирања сви возачи су прешли приближно исти укупан пут од 3 560 km, што је довољно за утврђивање њихових стилова вожње. Просечна количина терета у возилу износила је по возачима од 315 kg до 334 kg. Ова разлика у тежини нема додатног утицаја на остварене вредности параметара и специфичну потрошњу горива.


Анализом снимљених података установљено је да постоје разлике између тестираних возача у погледу остварених вредности БМ, ППГ и УБ, што може да указује да се тестирани возачи разликују по својим стиливима вожње (Табела 8). Возач В4 остварио је за 43% већу просечну вредност параметра БМ, за 38% веће просечно убрзање и за 42% веће просечно успорење у односу на возача В3. Поред тога, возач В4 има за 20% већи ППГ у односу на возача В6 и за 7% већи у односу на возача В3. Сви параметри указују да возач В4 има знатно агресивнији стил вожње у односу на све остале возаче, а посебно на возаче В3 и В6.

Возач В6 је остварио сличне просечне вредности за УБ као и возач В3. Међутим, осим чињенице што је возач В6 у просеку притискао мање педалу гаса (ППГ) за 11% у односу на возача В3, у исто време он је остварио за 25% већу просечну вредност параметра БМ и имао је скоро дупло веће стандардно одступање броја обртаја мотора у односу на возача В3. Према томе, возач В3 има нешто умеренији стил вожње у односу на возача В6. Возачи В1, В2 и В5 су остварили сличне просечне вредности у погледу параметара БМ, ППГ и УБ. Уколико се посматра просечно убрзање, може да се закључи да су стилови вожње возача В1, В2 и В5 нешто агресивнији у односу на стилове вожње возача В3 и В6, али истовремено и умеренији од стила вожње возача В4.


Табела 8. Остварене вредности параметара вожње код тестираних возача

Параметар	Возачи					
	B1	B2	B3	B4	B5	B6
БМ (RPM)						
Mean	1582	1637	1354	1931	1657	1690
StdDev	447	407	244	512	525	448
ППГ (%)						
Mean	22.15	22.72	22.17	23.69	22.27	19.76
StdDev	18.94	18.81	15.93	19.55	18.55	13.18
УБ (m/s²)						
Mean	0.52	0.58	0.45	0.62	0.51	0.46
StdDev	0.38	0.45	0.31	0.47	0.36	0.31
-УБ(m/s²)						
Mean	-0.53	-0.52	-0.45	-0.64	-0.51	-0.46
StdDev	0.46	0.48	0.34	0.56	0.42	0.38

На Графикону 4. приказана је временска заступљеност снимљених података о брзини мотора по возачима, на коме може да се уочи да је возач В4 возио током 47% времена са БМ преко 2 000 RPM, што је знатно чешће у односу на све остале возаче. Насупрот њему, возач В3 је чак 99% времена управљао возилом са БМ испод 2 000 RPM. На Графикону 5. види се да су возачи В3 и В6 притискали педалу гаса до 40% њеног хода током 91% и 96% времена вожње, респективно. Са друге стране, возач В4 притискао је педалу гаса преко 60% њеног хода током 5% времена вожње, што је знатно чешће од 0,23% и 0,62% времена код возача В3 и В6. Према анализираним подацима о ППГ, може да се закључи да су возачи В3 и В6 ближи умереном тј. ефикасном стилу вожње.




Графикон 4. Временска заступљеност снимљених података о брзини мотора по возачима




Графикон 5. Временска заступљеност снимљених података о притиску педале гаса по возачима

На Графикону 6. приказана је временска заступљеност снимљених података о убрзању возила по возачима. Најнеповољније вредности остварио је возач B4 који је интензивније убрзавао ($>0,5\text{m/s}^2$) током 20% времена и интензивније успоравао ($<-1\text{ m/s}^2$) током 7% времена вожње, што је чешће од осталих возача. Најповољније вредности интензивног позитивног и негативног убрзања је остварио возач B3. По овом параметру возач B6 је одмах иза возача B3, док су возачи B1, B2 и B5 остварили скоро идентичне вредности које су нешто лошије од вредности возача B6. Возач B3 је ближи ефикасном стилу, док возач B4 тежи агресивнијем стилу вожње. Када се посматра временска заступљеност снимљених података о брзини возила по возачима приказана на Графикону 7, уочавају се још значајније разлике између возача B3 и B4. Возач B3 током периода снимања није остварио брзину возила већу од 100km/h , док је возач B4 током чак 19% времена имао већу брзину возила од 100km/h . Остали возачи су по том аспекту остварили уједначене вредности, које износе од 9 до 13% времена вожње. Током чак 54% времена возач B3 је возио брзином у интервалу између 50 и 79km/h , што додатно указује на његов умерен стил вожње. Остали возачи су по том аспекту остварили знатно лошије вредности, пошто су дуже времена возили брзинама преко 80km/h .




Графикон 6. Временска заступљеност снимљених података о УБ возила по возачима



Графикон 7. Временска заступљеност снимљених података о брзини возила по возачима


Применом фази логике типа 2, предложени улазни параметри у ФЛС2 модел су БМ, ППГ и УБ. На основу укупно 27 правила генерисане су оцене које карактеришу понашање возача у посматраном тренутку.

Након конструисања ФЛС2 модела извршено је подешавање модела у циљу добијања задовољавајућих излазних параметара. Током подешавања, извршене су одговарајуће корекције базе фази правила и параметара функција. Постигнута је задовољавајућа осетљивост модела на промену вредности улазних параметара што се може видети на следећим графиконима.




Графикон 8. Осетљивост модела на промену улазних параметара БМ и УБ

На Графикону 8. приказана је осетљивост модела на промену улазних параметара БМ и УБ и може се закључити да висока оцена зависи од средњег убрзања и средње брзине мотора.



Графикон 9. Осетљивост модела на промену улазних параметара ППГ и УБ

На Графикону 9. може се уочити да ће возачева лоша оцена вожње бити праћена ППГ који има вредност преко 50%, или, уколико вредност параметра УБ буде ван интервала, од -2 до 2.



Графикон 10. Осетљивост модела на промену улазних параметара ППГ и БМ

Уколико се посматрају улазни параметри ППГ и БМ, на Графикону 10. се уочава да високу оцену вожње карактеришу БМ до 2000 RPM и ППГ до 40%.

На претходно приказаним Графиконима 8, 9. и 10. може се уочити утицај и значај појединачних улазних параметара на коначну оцену вожње.


Према представљеном ФЛС2 моделу, израчуната је коначна оцена за сваког тестираног возача (на скали од 1 до 10, где је 10 најбоља оцена). Коначна оцена за сваког возача у току периода тестирања од 15 дана израчуната је као средња вредност добијених оцена за сваки дан. Дневне оцене рачунају се као средња вредност оцена добијених током сваке секунде у току дана. У Табели 9. приказане су дневне и коначне оцене возача на посматраним деоницама, које представљају излаз из модела.

Табела 9. Дневне и коначне оцене возача на посматраним деоницама

Возачи	Дневне оцене															Коначна оцена	Потрошња l/100 km
	Деоница 1					Деоница 2					Деоница 3						
B1	7,0	6,6	6,7	6,8	6,7	6,4	6,7	6,5	6,9	6,6	6,1	6,0	6,1	6,0	5,9	6,5	9,2
B2	7,1	6,6	6,6	6,6	6,8	6,8	6,3	6,8	6,4	6,6	6,7	7,4	6,8	6,4	7,0	6,7	8,8
B3	7,9	7,8	7,8	7,9	7,8	7,6	7,8	8,1	8,2	7,6	8,1	7,9	7,9	8,0	7,8	7,9	7,2
B4	5,0	5,0	4,9	5,5	5,7	5,6	5,0	5,6	4,7	5,1	6,2	6,0	4,5	4,5	5,5	5,2	11
B5	6,9	6,6	6,6	6,5	6,5	7,0	6,9	6,8	5,4	7,6	6,4	5,8	6,1	5,4	6,6	6,4	9,5
B6	7,1	7,4	7,2	7,3	7,2	6,6	6,9	6,8	7,1	7,0	6,4	6,7	6,5	6,3	6,6	6,9	8,2

Возач B3 са коначном оценом 7,9 био је најефикаснији током истраживања, док је возач B4 имао најнижу коначну оцену 5,2. Остали возачи имају приближно исту коначну оцену.

На Графикону 11. приказане су брзине возила током периода зауставља, при почетној посматраној брзини од 50km/h за возаче B3 и B4. Значајно веће негативно убрзање возача B4 од -1,17 m/s² у односу на -0,58 m/s² колико је остварио возач B3, указује на претходне претпоставке да возач B4 тежи агресивном стилу вожње, које карактерише значајно мањи интервал успорења који се креће од 9 до 16 секунди. Возач B4 умерено успорава при чему се интервал успорења возила до заустављања креће од 20 до 30 секунди.



Графикон 11. Дистрибуција брзина возила током периода заустављања при почетној посматраној брзини од 50 km/h


На кретање брзине није утицало опште ограничење брзине које је мање од 50 km/h, у зони школе или зони успореног саобраћаја, при чему су посматрани возачи возили на истој деоници. Приказанао је по 10 произвољних заустављања ефикасног возача (B3) и возача који тежи агресивном стилу вожње (B4). У разматрање нису узете ситуације када возило треба да изврши одређено заустављање (утовар или истовар робе) јер у тим случајевима постоји могућност продужења интервала до коначног зауставља услед паркирања. На овај начин добијен је увид у возачево перципирање саобраћајног тока, тј. посматране ситуације представљају заустављање возила током вожње, изазвано успорењем возила које се налази непосредно испред или услед поштовања саобраћајне сигнализације (знак стоп, црвено светло на семафору, пешачки прелаз, итд.) Може се закључити да ефикасан возач има значајно дужи интервал успорења и мање просечно негативно убрзање возила у односу на возача који тежи агресивном стилу вожње.

Анализом појединачних записа у ситуацијама када возило креће из места и убрзава, односно када се креће и успорава до заустављања, утврђено је да вожњу возача B3 карактерише успорење кочењем мотором (које прати тренутно повећање БМ), док возач B4 брже убрзава са значајно већим притиском педале гаса. У Табели 10. могу се видети узастопни записи, тј. вредности параметара којима се остварују највеће и најмање оцене. Код осталих возача који теже умереном стилу вожње, нису уочени ови обрасци вожње као доминанти.

Табела 10. Вредности параметара које карактеришу стилове вожње возача В3 и В4


Возач	Брзина возила (km/h)	БМ (RPM)	ППГ (%)	УБ (m/s ²)	Оцена
В3	31	1397	0	0	10
	31	1359	0	0	10
	29	961	0	0	10
	27	1339	0	-0,56	10
	24	1667	0	-0,83	10
	21	1393	0	-0,84	10
	16	1117	0	-1,39	10
	13	917	0	-0,83	10
В4	1	957	15,02	0,28	9
	4	938	19,25	0,83	7
	9	1515	27,7	1,39	3
	14	2182	25,36	1,39	2
	18	2299	13,61	1,11	2
	20	1599	47,89	0,28	4
	26	2118	46,01	1,66	2
	33	2568	46,01	1,95	2

На Графиконима 12, 13. и 14. приказане су респективно дистрибуције брзина возача В2, В3 и В5 на деоници 1. У разматрање нису укључени сви возачи, већ претходно поменути који припадају ефикасном или умереном стилу вожње са релативно малом разликом у потрошњи горива. Посматрани су циклуси вожње које карактеришу одређен број стајања и минималне просечне брзине. Циклус вожње представља вожњу до тренутка промене услова у саобраћају.




Графикон 12. Дистрибуција брзина возача В2 на деоници 1 на интервалу од 1000 секунди

Возач В2 је у оквиру циклуса градске вожње остварио два заустављања, у приградским условима четири циклуса и минималну просечну брзину која износи 49km/h, на отвореном путу три циклуса, са оствареном минималном просечном брзина од 65 km/h (Графикон 12).




Графикон 13. Дистрибуција брзина возача В3 на деоници 1 на интервалу од 1000 секунди

На Графикону 13. може се уочити да је возач В3 остварио по један циклус вожње у градским и приградским условима у саобраћају. Минимална брзина у приградским условима износила је 36km/h, али ове услове у саобраћају не карактеришу заустављања возила. Уколико се посматрају градски услови у саобраћају, види се да је возач остварио четири заустављања.



Графикон 14. Дистрибуција брзина возача В5 на деоници 1 на интервалу од 1000 секунди

Када се посматра возач В5 (Графикон 14) у градским условима у саобраћају, остварено је шест заустављања у три посматрана циклуса. Минимална просечна брзина у циклусима приградске вожње износи 36km/h. Услове отвореног пута и приградске услове карактерише вожња без заустављања, при чему је минимална брзина на отвореном путу износила 49km/h.



Графикон 15. Вредности параметра ППГ зависно од остварене брзине возила у градским условима возача В3, В5 и В6

По њиховој потрошњи горива и коначним оценама, возња возача В3 припада ефикасном стилу возње, док су возачи В5 и В6 класификовани као возачи који теже умереном стилу возње (Табела 9.). Возач В5 има најлошију коначну оцену, док возач В6 има најбољу коначну оцену у оквиру категорије умереног стила возње. Како би се уочиле разлике и откриле законитости у возњи возача сличних стилова, посматрани су возачи В3, В5 и В6. На Графикону 15. виде се вредности параметра ППГ зависно од остварене брзине возила у градским условима. Како ове услове у саобраћају карактерише велики број кретања и заустављања, занимљиво је посматрати вредности параметра ППГ. Вредности ППГ возача В5 углавном су груписане у интервалу од 40% до 70%. Возачи В3 и В6 имају равномерније распоређење вредности у ширем опсегу интервала. Њихове вредности се крећу од 30% до 65% за возача В6 и од 25% до 60% за возача В3, што указује на нешто умеренију возњу у градским условима у односу на возача В6, чије су вредности изразито груписане од 60% до 70%.

Током периода истраживања извршено је мерење специфичне потрошње горива наведених возила по тестираним возачима (Табела 11.). Возач В3 је постигао најмању специфичну потрошњу горива од 7,20 l/100km, у односу на њега возач В4 је за 3,79 литара остварио већу потрошњу горива. Возач В6 је други по рангу енергетске ефикасности са специфичном потрошњом од 8,2 l/100km, возачи В2, В1 и В5 су остварили треће, четврто и пето место, респективно. Поред планираног улаза у модел који се састоји од три параметра, израчунате су и коначне оцене возача користећи принцип постојећег модела у литератури са два улазна параметра који предлажу Арас и Гоћеш [1]. У Табели 11. може се видети да модел са три улазна параметра успешније вреднује перформансе возача у погледу потрошње горива у


односу на улаз модела са два параметра.

Анализом коначних оцена возача добијених на основу два улазна параметра, уочава се да нису све добијене оцене у истој корелацији са вредностима специфичне потрошње горива. Када се користе два улазна параметра, возач В6 има лошију коначну оцену од возача В2 и поред чињенице што је у односу на њега у исто време остварио мању специфичну потрошњу горива (Табела 11).

Табела 11. Коначне оцена возача и остварена специфична потрошња горива

Возачи	В1	В2	В3	В4	В5	В6
Специфична потрошња горива (l/100 km)	9,2	8,8	7,2	11,0	9,5	8,2
Коначна оцена возача – 2 улазна параметра (БМ, УБ)	6,0	6,2	7,5	4,7	5,9	6,1
Коначна оцена возача – 3 улазна параметра (БМ, УБ, ППГ)	6,5	6,7	7,9	5,2	6,4	6,9

На Графикону 16. приказане су остварене коначне оцене по возачима добијене на основу предложеног модела са три улазна параметра и принципа постојећег модела са два улазна параметра (БМ, УБ) у раду који предлажу Арас и Гоћеш [1]. Уколико се упореде рангови специфичне потрошње горива са ранговима коначних оцена са два улазна параметра, код возача В2 и В6 уочава се неслагање. Према томе, предност модела и улаза са три дефинисана параметра (БМ, УБ, ППГ) утиче на осетљивост формирања коначне оцена возача, која треба веродостојно да опише његов стил вожње и остварену специфичну потрошњу горива.



Графикон 16. Поређење коначних оцена вожње возача [200]

Након што су добијене коначне оцене вожње возача, које уједно представљају излаз из ФЛС2 модела, у следећем кораку неопходно је извршити предикцију потрошње горива применом модела машинског учења.

Подаци о потрошњи горива снимани су током тест вожње, заједно са параметрима БМ, ППГ и УБ. Потрошња горива изражена је у количини горива која се утроси по једном такту (mm^3/cp). Прво је извршена припрема и сређивање снимљених података, затим је извршена подела података на скупове података за тренирање (2/3 од укупног броја записа) и тестирање (1/3 од укупног броја записа).

У Табели 12. приказана је Дескриптивна статистика параметара на скупу података за тренинг. Применом алгоритама машинског учења у софтверком алату Weka, у Табелама 13. и 14. могу се видети перформансе најбољих модела предикције потрошње горива на скуповима података за тренинг и тестирање. У унакрсној валидацији коришћено је 10 подскупова.

Табела 12. Дескриптивна статистика параметара на скупу података за тренинг

Параметар	Средња вредност	Стандардна девијација
БМ	1613	320
ППГ	22,3296	17,2970
УБ	0,2984	0,3957


Табела 13. Перформансе модела на сету података за тренинг

Алгоритам	R	R ²	Средња апсолутна грешка	Квадратни корен средње квадратне грешке	Релативна апсолутна грешка (%)	Квадратни корен релативне квадратне грешке (%)
LinearRegression	0,8896	0,7914	4,6643	7,6015	35,1446	45,6571
MultilayerPerceptron	0,7669	0,5881	7,7281	11,3989	58,2299	68,4658
SMOreg	0,8893	0,7908	4,3386	7,9157	32,6904	47,5445
IBk	0,8886	0,7896	3,9455	7,8734	29,7285	47,2905
M5P	0,9252	0,8560	3,2153	6,3138	24,2268	37,9228
Random Forest	0,9212	0,8486	3,3501	6,4856	25,2426	38,9552
Random Tree	0,8652	0,7485	4,3658	8,661	32,8954	52,0212
REPTree	0,9093	0,8268	3,6985	6,9319	27,8675	41,6356

Табела 14. Перформансе модела на сету података за тестирање

Алгоритам	R	R ²	Средња апсолутна грешка	Квадратни корен средње квадратне грешке	Релативна апсолутна грешка (%)	Квадратни корен релативне квадратне грешке (%)
LinearRegression	0,8724	0,7611	3,7024	5,7103	42,8214	49,3432
MultilayerPerceptron	0,8912	0,7942	3,1468	5,2654	36,3958	45,4985
SMOreg	0,8690	0,7551	3,7159	6,1902	42,9776	53,4901
IBk	0,8156	0,6650	4,34	7,162	50,196	61,8875
M5P	0,8904	0,7928	2,8593	5,2025	33,0701	44,9554
Random Forest	0,8764	0,7681	3,2388	5,4887	37,4601	47,4285
Random Tree	0,7789	0,6067	4,5874	7,6002	53,0579	65,6742
REPTree	0,8687	0,7546	3,4882	5,7124	40,3441	49,3613

Одличне перформансе остварио је М5Р алгоритам са високим коефицијентима детерминације и то 0,8560 на скупу података за тренинг и 0,7928 на скупу података за тестирање. У односу на њега вишеслојни перцептрон има тек нешто мало бољи коефицијент детерминације на скупу података за тестирање (0,7942), али знатно мањи коефицијент детерминације (0,5881) на скупу података за тренинг. Алгоритам Random forest на скупу података за тренинг има другу најмању средњу апсолутну грешку. На Графикаону 17. приказано је расипање вредности измерене и предвиђене потрошње горива користећи алгоритме М5Р и Random Forest, на скупу података за тестирање.



Графикон 17. Измерена и предвиђена потрошња горива применом алгоритама М5Р и RF алгоритма

На Графикаону 17. се јасно види позитивна јака корелација између две посматране променљиве (предвиђена и измерена потрошња горива). При предвиђању екстремних вредности о потрошњи горива на графикону се може видети веће расипање вредности применом RF алгоритма, што указује на већу прецизност коришћења М5Р алгоритма уколико се предвиђају вредности потрошње горива преко 40 mm³/ср. Уколико се посматрају све метрике, најбољи модел заснован је на алгоритму М5Р. У наставку истраживања за предвиђање зависне променљиве, тј. потрошње горива, биће коришћен овај модел машинског учења. На Графикаону 18. види се поређење и предвиђање потрошње на тест скупу података применом М5Р алгоритма.



Графикон 18. Поређење измерене и предвиђене потрошње горива применом М5Р алгоритма


Применом М5Р алгоритма извршена је предикција потрошње горива на скупу података од 1 189 912 инстанци. У последњој фази модела треба извршити предикцију потрошње горива на основу добијених оцена возача зависно од услова у саобраћају. Одређивање саобраћајних услова није укључено у другој фази модела због комплексности система и његове примене у реалном времену. У Табели 15. приказани су записи којима су поред вредности очитаних параметара вожње придружени предвиђени услови у саобраћају, израчунати на основу израза (19). Градске услове у саобраћају карактерише просечна брзина мања или једнака 50 km/h (Г), приградске услове у саобраћају просечна брзина већа од 50 km/h и мања или једнака 80 km/h (П) и отворени пут или ауто-пут кретање просечном брзином већом од 80 km/h (О).

Табела 15. Записи очитаних параметара вожње возача ВЗ након извршене предикције услова у саобраћају на деоници 1

Редни број	Датум	Време очитавања брзине	Брзина возила (km/h)	БМ (RPM)	ППГ (%)	УБ (m/s ²)	Просечна брзина у посматраном интервалу (km/h)	Услови у саобраћају
...	...	...	...	...	...	...	...	...
184	31.10.2019	10:24:11	55	1360	36,62	0,28	49,15	Г
185	31.10.2019	10:24:12	56	1374	36,62	0,28	49,29	Г
186	31.10.2019	10:24:13	56	1399	36,62	0	49,35	Г
187	31.10.2019	10:24:15	57	1421	37,09	0,13	49,40	Г
188	31.10.2019	10:24:16	58	1441	36,15	0,28	49,45	Г
189	31.10.2019	10:24:18	59	1464	28,64	0,14	49,51	Г
190	31.10.2019	10:24:19	60	1469	0	0,28	49,62	Г
191	31.10.2019	10:24:20	59	1437	0	-0,28	49,73	Г
192	31.10.2019	10:24:21	58	1422	17,84	-0,28	49,82	Г

193	31.10.2019	10:24:22	57	1409	30,98	-0,28	49,95	Г
194	31.10.2019	10:24:23	57	1422	30,98	0	50,09	П
195	31.10.2019	10:24:24	58	1430	30,98	0,28	50,25	П
196	31.10.2019	10:24:25	58	1425	0	0	50,43	П
197	31.10.2019	10:24:26	57	1406	0	-0,28	50,59	П
198	31.10.2019	10:24:27	56	1378	0	-0,27	50,76	П
199	31.10.2019	10:24:28	55	1348	18,78	-0,28	50,92	П
200	31.10.2019	10:24:29	55	1356	32,4	0	51,09	П
201	31.10.2019	10:24:30	55	1352	29,1	0	51,24	П
202	31.10.2019	10:24:31	55	1361	28,64	0	51,38	П
203	31.10.2019	10:24:32	55	1370	31,46	0	51,53	П
204	31.10.2019	10:24:35	56	1388	30,05	0,09	51,66	П
205	31.10.2019	10:24:36	56	1384	15,96	0	51,80	П
206	31.10.2019	10:24:37	56	1382	22,06	0	51,93	П
207	31.10.2019	10:24:38	56	1374	22,06	0	52,05	П
208	31.10.2019	10:24:39	55	1366	23,01	-0,28	52,16	П
...	...	...	...	...	...	...	...	...

Током прикупљања података снимане су и координате возила на основу којих се касније вршило проверавање стварних и предвиђених услова у саобраћају. На Слици 42. види се графички приказ предвиђених и стварних услова у саобраћају током одређене позиције возача ВЗ кроз Нови Сад.



Слика 42. Графички приказ предвиђених услова у саобраћају током војње возача ВЗ кроз Нови Сад

На рути којом се кретао возач приказана је позиција у којој су предвиђени градски услови у саобраћају. Црвена боја означава већи број читавања на приближно истој локацији, који углавном указује на градске услове у саобраћају. Жута и наранџаста боја представљају читавања са умереним застојом, који је углавном изражен код приградских услова у саобраћају. Зелена боја представља читавање параметара без застоја и односи се на отворени пут или ауто-пут у случају дужег интервала посматрања.


Поделом главне руте на више краћих деоница за тестирање, омогућено је лакше праћење и одређивање услова у саобраћају. Приликом спровођења тест вожње, бележени су стварни услови у саобраћају уз напомене тренутног стања на путевима које укључује саобраћајне гужве изазване успореним кретањем тешких теретних возила, уласцима и изласцима из градског подручја, прелазак преко моста, итд. На овај начин решен је потенцијални проблем непоклапања предвиђених и стварних услова у саобраћају.

Ово су ситуације када постоји могућност да одређена деоница не одговара географски предвиђеним условима у саобраћају, тј. остварена брзина возила може да буде мања или већа од предвиђене просечне брзине за ту категорију пута. Анализом података, уочена неслагања стварних и предвиђених услова у саобраћају дешавају се на преласку, тј. промени услова у саобраћају, изазваних дужином трајања интервала. С друге стране, време интервала од 91 секунде у значајној мери тачно приказује просечну брзину којом се возило креће, а која је карактеристична за препознавање услова у саобраћају. Посматрањем првих 10 записа у Табели 15. може се уочити да се предвиђени услови у саобраћају не поклапају са стварним условима. У тој ситуацији возило се кретало брзином од 55km/h до 57km/h, међутим због дужине интервала просечна брзина је износила приближно 50km/h. Када се посматрају сви записи током вожње возача В3, успешност поклапања предвиђених и стварних услова у саобраћају износи 94%.

Табела 16. Предвиђени и стварни услови у саобраћају током вожње возача В3 на деоници 1


Услови у саобраћају	Поклапање предвиђених и стварних услова у саобраћају (%)
Градски услови	98%
Приградски услови	93%
Отворен пут или ауто-пут	95%
Укупно	94%

Претходно описан поступак предвиђања услова у саобраћају коришћен је како би се у *Potthoff* анализи извршила предикција потрошње горива зависно од услова у саобраћају. У софтверском алату *Statgraphics* извршено је поређење регресија зависне променљиве предвиђене потрошње горива (*PredictedFuelFlow*) и предикторске променљиве оцена (*Score*), зависно од претходно предвиђених услова у саобраћају (*TrafficConditions*). Приликом обраде података разматрано је укупно 1 189 911 инстанци. На Слици 43. све посматране p – вредности су мање од 0,01 и може се закључити да постоји статистички значајна разлика у предвиђању потрошње горива зависно од услова у саобраћају.



Слика 43. Међусобна зависност између регресија зависно од услова у саобраћају.

На Графикону 19. приказане су регресионе криве зависно од услова у саобраћају. Јасно се види негативна корелација између зависне и предикционе променљиве, тј. што је оцена вожње већа, предвиђена потрошња горива ће бити мања и обрнуто.



Графикон 19. Поређење регресија зависно од услова у саобраћају

У Табели 17. види се да је регресија према оцени веома значајна, на шта указује мала p вредност ($p < 0,01$).

Табела 17. ANOVA

Item	Sum of Squares	df	Mean Square	F	p
Score	1,10573e8	1	1,10573e8	784002,40	0,0000
Intercepts	4,75496e6	2	2,37748e6	16857,26	0,0000
Slopes	235763	2	117882	835,83	0,0000
Model					
Regression	1,15563e8	5	2,31127e7	163877,72	0,0000
Residual	1,6782e8	1189905	141,036		
Total	2,83383e8	1189910			

Поред тога, F вредност у Табели 17. тестира да ли је регресиони модел погодан за посматране вредности. Приказане су суме квадрата и F статистика модела чија вредност указује да је модел бољи предиктор у предвиђању потрошње горива у односу на просечну вредност, $F(5, 1189905)=163877,72$, $p<0,01$. Вредности у табели показују да независна променљива добро статистички предвиђа зависну променљиву, тј. да је регресиони модел добар. Према томе, може се закључити да постоји статистичка значајна веза између посматраних променљивих на 99% интервалу поверења. Уколико се посматра p вредност пресека (intercepts) која је мања од 0,01, закључује се постојање статистички значајне разлике између пресека на 99% интервалу поверења. Исти резултат је добијен и код нагиба посматраних регресија.

Табела 18. Model Summary

Model	R ²	Adjusted R ²	RMSE	Durbin-Watson
1	40,7799	40,7797	11,8759	1,130

У Табели 18. приказана вредност R² представља коефицијент детерминације, који указује да 40,78% варијабилитета зависне променљиве може бити објашњен независном променљивом. Стандардна грешка процене показује стандардну девијацију резидуала која износи 11,8759. Дарбин-Вотсонова статистика тестира да ли постоји корелација међу резидуалима која може да поништи целу регресиону анализу. Вредност 1,130 је прихватљива јер се налази у пожељном интервалу од 1 до 3, при чему је 2 идеална вредност.

Табела 19. приказује предвиђене вредности променљиве потрошње горива (*PredictedFuelflow*) користећи предложени модел. Поред најбољих предвиђања приказани су респективно 95% доњи и горњи интервали предвиђања и 95% доњи и горњи интервали поверења за средње вредности нових опсервација.

Табела 19. Forecasts (Предвиђање потрошње горива)

Score / TrafficConditions	Predicted Y	Lower 95% Pred. Limit	Upper 95% Pred. Limit	Lower 95% Conf. Limit	Upper 95% Conf. Limit
1					
Градски услови	39,6473	16,3708	62,9238	39,5513	39,7434
Приградски услови	46,0743	22,7977	69,3508	45,9772	46,1713
Отворен пут	39,6486	16,3722	62,925	39,5784	39,7187
10					
Градски услови	9,42227	-13,8541	32,6986	9,37758	9,46697
Приградски услови	12,0636	-11,2128	35,34	12,005	12,1222
Отворен пут	8,05924	-15,2174	31,3358	7,94062	8,17786

Претходно извршена *Potthoff* анализа открива да постоји разлика у регресионим моделима, њиховим нагибима и пресецима у предвиђању потрошње горива зависно од дефинисаних услова у саобраћају. Ово може бити значајна информација при даљем развијању модела евалуације стила вожње који се заснива на потрошњи горива.

6.3. Дискусија и кратак осврт на постојећа решења

Различити приступи и методологије су примењиване како би се разумеле и анализирале релевантне компоненте функције уштеде горива у оквиру модела за процену стила вожње. Прегледом литературе установљено је да постојећи модели углавном нису примењивани у реалним условима, при чему се главни недостаци огледају у сложености примене модела зависно од услова у саобраћају (градска вожња, временски услови, оптерећење возила, карактеристике возила, различити експлоатациони услови, конфигурација терена, итд.). Развој телематских система омогућава пружање жељених информација, међутим проблем са којим се суочава транспортна телематика, односи се на трајање процеса имплементације. Сложеност оваквог система проузрокује да је време развоја и имплементације често дуже од циклуса развоја нове технологије, при чему захтева значајна финансијска улагања. Недостатак постојећих решења којим су се бавиле поједине студије огледа се у недовољно прецизној процени стила вожње. Стога, пре израде модела потребно је детаљно истражити који параметри вожње имају највећи утицај на потрошњу горива, при чему најбоље описују понашање возача, односно његов стил вожње.

Решавање претходно поменутих проблема представља главну мотивисаност за развијање новог интегрисаног модела за класификацију и предвиђање понашања возача. Овакав модел заснован је на примени алгоритама машинског учења и фази логичких скупова типа 2. Предност развијеног модела огледа се у процени стила вожње заснованој на прикупљеним параметрима искључиво током кретања возила. Време празног хода мотора се не разматра. На овај начин добијена оцена веродостојно описује стил вожње возача, на коју не би утицало могуће загушење у саобраћају у градским условима вожње.

Предложени интегрисани модел применом ФЛС2 методе у оквиру прве фазе, сагледава остварене вредности посматраних параметара (УБ, ППГ, БМ) на возилу. Применом ове методе квантификује се утицај стила вожње на потрошњу горива кроз израчунату коначну оцену возача. Поред тога, уочено је да у оквиру истих

експлоатационих, саобраћајних и климатских услова и употребом истих комби возила постоје значајне разлике у стиливима вожње тестираних возача. У Табели 20. приказани су категорисани стилови вожње возача на основу коначних оцена.

Табела 20. Стил вожње, коначна оцена и просечна потрошња горива по возачима

Возач	Коначна оцена	Потрошња горива ($l/100km$)	Стил вожње
B1	6,5	9,2	умерен
B2	6,7	8,8	умерен
B3	7,9	7,2	ефикасан
B4	5,2	11	агресиван
B5	6,4	9,5	умерен
B6	6,9	8,2	умерен

Сагледавајући истовремено остварене вредности сва три посматрана параметра, у Табели 20. уочава се да је возач B3 остварио најбољу коначну оцену 7,9. Његова вожња је најближа веома ефикасном стилу. Таквим стилем вожње, возач B3 остварио је најмању вредност специфичне потрошње горива ($7,20 l/100km$) у односу на остале тестиране возаче. Возачи B1, B2, B5 и B6 припадају категорији умерен стил вожње, коју карактеришу приближно исте коначне оцене (Табела 20). B4 је према оствареној најлошијој оцени од 5,2 најближи веома агресивном стилу вожње у односу на остале тестиране возаче. Поред тога, овај возач је и најлошији по оствареној вредности специфичне потрошње горива ($10,99 l/100km$). Може се закључити да је агресиван стил вожње возача B4 допринео изузетно ниској енергетској ефикасности возила којим је управљао.

Уколико се упореде вожње најефикаснијег возача B3 и возача возача B4 чији је стил вожње категорисан као агресиван, може да се уочи да је возач B4 због свог стила вожње остварио већу потрошњу горива за чак 52% у односу на возача B3. Комби возила посматраних компанија која се баве дистрибуцијом робе или курирске службе, зависно од подручја које покривају, у просеку годишње прелазе растојање од око 55 000 км. У том случају, разлика у утрошеној количини горива између возача B3 и B4 износила би око 2084 литара на годишњем нивоу. Уколико би преосталих пет тестираних возача имали стил вожње по узору на стил најефикаснијег возача, годишња уштеда у потрошњи горива износила би приближно 5 830 литара, односно 23% од њихове укупно остварене потрошње горива.

За верификацију коначних оцена у моделу, неопходни су подаци о стварној потрошњи горива. У овом истраживању вршена су мерења о стварној потрошњи, међутим, до ових података је генерално тешко доћи услед закључаности параметара од стране произвођача возила, недоступности мерних уређаја, сложене обраде података, итд. У другој фази модела, користе се алгоритми машинског учења за предвиђање потрошње горива. Када се посматрају параметри БМ, ППГ и УБ, одабиром М5Р алгоритма над подацима о потрошњи горива који су прикупљени на тест вожњи, може се извршити предвиђање потрошње горива са високом тачношћу $R^2=0,7928$. На основу ових података и израчунате просечне потрошње, врши се верификација претходно добијених оцена вожње и категоризација стила вожње. За праћење и оцењивање возача у реалном времену, неопходно је извршити предвиђање потрошње горива током сваке секунде вожње. Зависно од услова у

саобраћају, просечна потрошња горива добро указује на стил вожње возача, али се не може користити за откривање законитости понашања у краћем временском интервалу.

У трећој фази модела, мерен је утицај услова у саобраћају у предвиђању потрошње горива. Применом *Potthoff* анализе, на основу добијених резултата установљено је да постоји статистички значајна разлика у предвиђању потрошње горива зависно од услова у саобраћају. Препознавање услова у саобраћају може бити основа за даља истраживања у области предвиђања потрошње горива и понашања возача у реалном времену.

Креирањем предложеног модела, потврђена је главна хипотеза истраживања која се односи на могућност израде новог интегрисаног модела за класификацију и предвиђање понашања возача, као подршку у евалуацији стила вожње возача. Уколико се посматрају остале хипотезе, изведени су следећи закључци:

- Прегледом литературе и компаративном анализом, установљено је да је развој информационо-комуникационих технологија и уређаја за мерење параметара о раду возила током вожње достигао ниво на коме омогућује економски исплативу и релативно једноставну имплементацију новог интегрисаног модела за класификацију и предвиђање понашања возача у реалним условима. Полазна хипотеза је потврђена.
- Поређењем предложеног модела са три улазна параметра (брзина мотора, убрзање и притисак педале гаса) и постојећег модела у литератури са два улазна параметра (брзина мотора и убрзање), потврђена је полазна хипотеза, тј. закључено је да се остварује већа прецизност у евалуацији стила вожње возача интегрисаним моделом у односу на постојеће моделе. Добијене коначне оцене стила вожње свих возача одговарају ранговима према оствареној потрошњи горива.
- Добре перформансе модела на сету података за тестирање остварио је М5Р алгоритам машинског учења, $R^2=0,7928$. Узимајући у обзир и *Potthoff* анализу потврђена је полазна хипотеза која се односи на могућност утврђивања и мерења утицаја вожње у градским условима при евалуацији потрошње горива. У истраживању су добијене p – вредности мање од 0,01, па се може закључити да постоји статистички значајна разлика у предвиђању потрошње горива зависно од услова у саобраћају.
- На основу модела за класификацију и предвиђање понашања возача могуће је развити нови приступ за награђивање возача који поштују принципе еко-вожње. Током овог истраживања, компаративном анализом уочена је разлика од чак 52% потрошње горива између најефикаснијег возача и возача који тежи веома агресивном стилу вожње. Овакав резултат указује на могућност развијања система за награђивање возача, са бенефитима смањења трошкова горива и потенцијалног смањења емисије штетних гасова. Сем тога, овим резултатом потврђена је хипотеза да потрошња горива може бити значајно нижа ако се на основу евалуације и класификације стила вожње врши правовремено реаговање и предузимање одговарајућих мера према возачима са агресивним, енергетски неефикасним стилу вожње.

7. ПРЕДЛОГ СИСТЕМА ЗА НАГРАЂИВАЊЕ ВОЗАЧА

Руководиоци возних паркова имају задатак да воде рачуна о перформансама возача, са циљем остваривања што веће ефикасности свих возила. Утврђено је да успешно управљање возним парком зависи од перформанси возача, које могу у великој мери да утичу на уштеду горива и смањену амортизацију потрошних делова на возилу. Праћењем њиховог понашања могуће је идентификовати стилове вожње који могу да смање трошкове горива.

Прегледом литературе нису уочени модели награђивања возача засновани на оцењивању вожње, који интегрисано користе фази логичке скупове и машинско учење. Постоје истраживања која су се бавила развојем модела и апликација за оцењивање вожње и пружање подршке возачу [209-213]. Међутим, ова истраживања се углавном односе на вредновање понашања возача са аспекта безбедности у саобраћају. Резултати вожње, тј. остварене вредности посматраних параметара омогућавају возачу указивање на критичне ситуације, које могу директно да утичу на повећање вероватноће за дешавање саобраћајне незгоде. Све ово указује на важност безбедоносног аспекта вожње, који треба да буде један од мотива у развоју система награђивања возача.

Једна од мера за повећање енергетске ефикасности возног парка је спровођење тренинга еко-вожње. Након одржане обуке еко-вожње, возачи поштују препоруке и савете о ефикасној вожњи, али се убрзо враћају старим навикама. Систем за награђивање возача треба да буде одржив и да мотивише возаче, како би се остварили дугорочни ефекти у усвајању умереног и ефикасног стила вожње. Током овог истраживања уочена је разлика од чак 52% потрошње горива између најефикаснијег возача и возача који тежи веома агресивном стилу вожње. Ово представља један од главних мотива за додатно унапређење предложеног интегрисаног модела за класификацију и предвиђање понашања возача. На основу овог модела могуће је развити систем награђивања који би био заснован на већ израчунатим оценама током вожње. Вредновањем понашања током вожње, омогућило би се пружање директне повратне информације возачу о тренутном начину управљања возилом. Исто тако, оцена вожње би служила као основа за рачунање потрошње горива. На крају сваког радног дана, формирала би се дневна оцена вожње, која би зависила од начина вожње, пређене километраже, услова у саобраћају. При њеном формирању негативно би се бодовали следећи параметри који указују на агресиван и неефикасан стил вожње: прекомеран рад возила у празном ходу, превелико убрзање, нагло кочење, прекомеран број обртаја мотора и прекорачења брзине. Током развоја система, дефинисала би се бодовна скала на основу које би се вршило вредновање вожње. Лош резултат остварен током једног радног дана, можда не би имао значајан утицај на коначну оцену на недељном или месечном нивоу. Међутим, развој апликације која би била заснована на оваквом систему, треба возачу да омогући увид у ситуације које су утицале на лоше резултате. На тај начин возач би могао да тежи да коригује вредности појединих параметара, како би се његов стил вожње побољшао. Основни стимуланс возачу може да буде поређење сопствених оцена вожње и напредак на кварталном нивоу. Поред тога, поређењем свих возача на ранг листи током периода од месец дана, може се вршити награђивање најбољих возача у виду новчане накнаде или

добивањем додатних дана одмора. У случају великог броја возача, треба водити рачуна о мотивисаности возача који нису били најефикаснији у посматраном периоду. За развијање позитивног такмичарског духа предлог је да сваки возач учествује користећи жељени псеудоним, како би остао анониман међу осталим возачима.

За поређење возача, ранговна табела би била значајан алат који би омогућио руководиоцима возног парка да лако уоче возаче са ефикасним или агресивним стилем вожње. Овакав систем би представљао једну од мера за побољшање перформанси возача. Поред тога, саветима за економичну вожњу могу се пружити значајне информације возачима како би се подстакло економичније понашање у вожњи. На Слици 44. приказани су доприноси система за награђивање возача.



Слика 44. Доприноси система за награђивања возача

Сви возачи би пре имплементације система, требало да прођу одговарајућу обуку еко-вожње и да се упознају са начином награђивања. Важно је напоменути да систем треба истаћи као награду возачу за ефикасан стил вожње како возачи не би страховали у случају да не остваре најбоље резултате. На овај начин руководици возног парка могу директно да утичу на возаче. Сем тога, имали би перманентан увид у стил вожње свих возача. Возачи би били мотивисани да остваре ефикасан стил вожње који би био награђен. Доприноси компанији огледали би се у смањеној потрошњи горива и амортизацији потрошних делова на возилу, док би се позитиван утицај на друштво и околину огледао у смањеној емисији CO₂. Овакав систем омогућио би прикупљање додатних података о понашању возача, на основу којих би било занимљиво истражити препознавање нових образаца понашања у вожњи попут претицања возила, разлога прекорачења дозвољене брзине, наглог кочења, итд.

8. ЗАКЉУЧАК

Транспортне и логистичке компаније са сопственим возним парком суочавају се са великим изазовима тржишне конкуренције, што их приморава на смањење трошкова што је више могуће. Повећање енергетске ефикасности возног парка представља један од дугорочних циљева за одржање корпоративне одрживости. Додатни циљ огледа се у потенцијалном смањењу емисије CO₂ који представља главни проблем у друмском саобраћају. Могуће решење за претходно поменуте проблеме, јесте правовремено деловање на возаче и њихов стил вожње, како би се смањила потрошња горива. Да би се ово остварило, неопходно је развити модел на основу којег би се вршила класификација и предвиђање понашања возача. Развијени модел омогућио би менаџерима компанија трајни и непосредан увид у стил вожње возача.

У овој дисертацији истраживан је утицај понашања професионалних возача на енергетску ефикасност возног парка. Извршена је и приказана систематизација и класификација решења за евалуацију понашања возача, као и технике и методе које се у ту сврху користе. Сем тога, истраживан је утицај саобраћајних услова у предвиђању потрошње горива. На основу приказане систематизације истраживања која се односе на евалуацију вожње, може се закључити да је остварено довољно научних резултата у којима је помоћу OBD-II уређаја за читавање параметара вожње могуће извршити оцењивање стила вожње возача. Економска исплативост и релативно једноставна имплементација мерних уређаја и примена рачунарства у облаку, омогућава тестирање и имплементацију модела у реалним условима без ометања радног процеса. Технолошки развој претходно поменутих уређаја и развој информационо-комуникационих технологија достигао је ниво на коме омогућује развијање предложеног интегрисаног модела.

У раду је представљен интегрисани модел за вредновање и класификацију понашања возача дизел транспортних возила са аспекта потрошње горива. Прегледом литературе истражено је да су брзина мотора, притисак педале гасе и убрзање најзначајнији параметри вожње у предвиђању понашања возача. Ови параметри веродостојно указују на понашање возача и могу да дефинишу стил вожње. Модел истовремено узима у разматрање снимљене вредности дефинисаних параметра током рада возила и применом ФЛС2 израчунава оцену вожње. Развијени ФЛС2 подмодел је примењен у транспортној компанији *Delmax*, где је тестирано шест насумично изабраних возача на истим комби возилима. Услед техничких немогућности, мерења потрошње горива на возилима тест возача нису спроведена. Подаци о вожњама седмог возача курирске службе *AKS Express*, служили су за моделирање потрошње горива. На основу израчунатих оцена возача установљено је да постоје значајне разлике у стилу вожње. Понашање возача зависно од остварене оцене категорисано је неким од следећих стилова вожње: веома агресиван, агресиван, умерен, ефикасан и веома ефикасан. Утврђене разлике утицале су на остварене разлике у потрошњи горива код тестираних возача. Поред тога, утврђено је да је возач са најлошијом оценом остварио већу потрошњу горива за чак 52% од потрошње горива коју је остварио возач са најбољом оценом. Највећу просечну потрошњу горива остварио је возач чија коначна оцена представља најнижу оцену у истраживању. Овај возач уједно тежи веома агресивном стилу вожње. С друге стране,

возач са најбољом оценом најближи је веома ефикасном стилу вожње и остварио је најмању потрошњу горива. Ово потврђује полазну хипотезу да возачев стил вожње представља значајан потенцијал за остваривање додатних уштеда у трошковима горива. Утврђено је да када би осталих пет тестираних возача имали стил вожње као и најефикаснији возач са најбољом оценом, остварила би се уштеда у потрошњи горива од 23% од њихове укупно остварене потрошње горива. Развојем модела и применом алгоритама надгледаног машинског учења омогућено је предвиђање потрошње горива на основу оцена вожње. Сем тога, установљено да постоји статистички значајна разлика у потрошњи горива зависно од услова у саобраћају.

Развијен модел омогућује руководиоцима посматраних компанија једноставан и правовремени увид у возачев стил вожње. Руководиоци на основу увида у добијене оцене возача имају могућност да довољно брзо реагују и предузму одговарајуће мере према возачима са агресивним, енергетски неефикасним стилем вожње, као што су упозорење или додатне обуке. На тај начин директно утичу на возаче са лошијом оценом да постану енергетски ефикаснији, чиме се остварују уштеде у потрошњи горива.

Како би возачи били мотивисани и тежили ефикасном стилу вожње, неопходно је развити систем за награђивање возача. У дисертацији је дат предлог система за награђивање возача. Такав систем заснивао би се на предложеном интегрисаном моделу. Даљи развој система уједно представља правац даљег истраживања аутора у овој области. Поред тога, будућа истраживања биће усмерена ка утврђивању утицаја стила вожње на већем броју возача који су имали тренинг обуке еко-вожње и оних који нису.

Управљање возним парком остаје један од важних показатеља успешности транспортних компанија. Према томе, праћење возила и понашања возача у реалном времену постаје стандард коме све компаније теже. Будући развој телематских система и приступ интернету ствари олакшаће праћење возила, смањиће трошкове одржавања возила и трошкове горива, уз истовремено повећање безбедности возача.

8.1. Доприноси докторске дисертације

Најзначајнији допринос докторске дисертације представља развој новог интегрисаног модела за класификацију и предвиђање понашања возача са аспекта енергетске ефикасности. Овај модел карактерише интегрисање два подмодела који су засновани на фази скуповима и машинском учењу. Додатан допринос докторске дисертације огледа се у свеобухватном прегледу постојећих модела за евалуацију и класификацију понашања возача.

На основу резултата који су проистекли из истраживања у овој дисертацији остварено је неколико доприноса и закључака:

- Интегрисани модел за класификацију и предвиђање понашања возача може се користити као подршка у евалуацији стила вожње возача.
- Развој информационо-комуникационих технологија и OBD уређаја за мерење параметара о раду возила током вожње је достигао ниво на коме омогућује економски исплативу и релативно једноставну имплементацију новог интегрисаног модела за класификацију и предвиђање понашања возача у реалним условима.
- Креирањем интегрисаног модела за класификацију и предвиђање понашања возача који је заснован на примени машинског учења и фази логичких скупова типа 2 могуће је квантитативно вредновање понашања возача, чиме се остварује већа прецизност у евалуацији стила вожње.
- Применом алгоритама надгледаног машинског учења и *Potthoff* анализом може се утврдити и измерити утицај вожње у градским условима при предвиђању потрошње горива.
- Потрошња горива може бити значајно нижа ако се на основу евалуације и класификације стила вожње врши правовремено реаговање и предузимање одговарајућих мера према возачима са агресивним, енергетски неефикасним стилем вожње.

Поред тога, научни допринос докторске дисертације огледа се и у:

- Мултидисциплинарном приступу истраживању који се заснива на интегрисаној примени фази скупова и машинског учења, који до сада нису били евалуирани у довољној мери.
- Потврди постављених хипотеза и приказаним резултатима добијеним предложеним интегрисаним моделом.
- Предложеном новом приступу за награђивање возача који поштују принципе еко-вожње.

ПРИЛОГ

Записи након генерисаних оцена за возача В1 на деоници 1 током једног радног дана. Сви сетови података коришћени у анализама доступни су на захтев.

Редни број	Датум	Време очитавања брзине	Брзина	БМ (RPM)	ППГ	Интервал	УБ	Оцена
1	1.11.2019	05:39:28	1	1459	23,01	1	0,28	8,02332
2	1.11.2019	05:39:29	4	1291	27,24	1	0,83	5,865137
3	1.11.2019	05:39:30	8	1346	39,43	1	1,11	3,365572
4	1.11.2019	05:39:31	14	2080	0	1	1,67	2,883316
5	1.11.2019	05:39:32	15	1212	26,29	1	0,28	8,192241
6	1.11.2019	05:39:33	17	1272	26,76	1	0,55	7,401589
7	1.11.2019	05:39:35	19	1437	21,13	2	0,28	8,262812
8	1.11.2019	05:39:36	20	1507	6,11	1	0,28	9,179068
9	1.11.2019	05:39:38	19	1382	0	2	-0,14	9,782019
10	1.11.2019	05:39:39	18	1256	0	1	-0,28	9,805147
11	1.11.2019	05:39:40	16	1167	0	1	-0,56	9,623223
12	1.11.2019	05:39:41	15	1077	0	1	-0,27	9,807348
13	1.11.2019	05:39:42	14	1002	0	1	-0,28	9,806641
14	1.11.2019	05:39:43	13	932	13,61	1	-0,28	9,660587
15	1.11.2019	05:39:44	12	893	33,81	1	-0,28	8,309196
16	1.11.2019	05:39:45	13	1039	27,7	1	0,28	8,171696
17	1.11.2019	05:39:46	17	1292	23,48	1	1,11	4,84379
18	1.11.2019	05:39:47	19	1418	19,72	1	0,56	7,723842
19	1.11.2019	05:39:48	20	1474	17,84	1	0,28	8,61716
20	1.11.2019	05:39:49	20	1499	17,84	1	0	8,828931
...	...	...	...	...	...	...	...	...
13474	1.11.2019	11:23:38	20	954	26,76	1	0	8,603826
13475	1.11.2019	11:23:39	23	1068	23,94	1	0,83	5,958171
13476	1.11.2019	11:23:40	25	1096	0	1	0,55	9,042379
13477	1.11.2019	11:23:42	18	904	21,6	2	-0,97	7,97214
13478	1.11.2019	11:23:43	19	1150	17,37	1	0,28	8,976013
13479	1.11.2019	11:23:45	19	906	17,37	2	0	9,27753
13480	1.11.2019	11:23:46	20	953	0	1	0,28	9,569033
13481	1.11.2019	11:23:47	21	836	0	1	0,27	9,576834
13482	1.11.2019	11:23:48	22	863	0	1	0,28	9,569036
13483	1.11.2019	11:23:49	21	863	0	1	-0,28	9,806643
13484	1.11.2019	11:23:50	19	860	0	1	-0,55	9,630095
13485	1.11.2019	11:23:51	17	858	0	1	-0,56	9,623467
13486	1.11.2019	11:23:52	15	846	0	1	-0,55	9,630097
13487	1.11.2019	11:23:53	13	841	0	1	-0,56	9,623469
13488	1.11.2019	11:23:54	10	848	0	1	-0,83	9,442017
13489	1.11.2019	11:23:55	8	835	0	1	-0,56	9,62347
13490	1.11.2019	11:23:56	7	820	0	1	-0,28	9,80665
13491	1.11.2019	11:23:57	7	814	0	1	0	9,782282

Приказ појединих записа скупа података за обучавање модела машинског учења.

Редни број	БМ (RPM)	ППГ (%)	УБ(m/s ²)	Потрошња горива (mm ³ /ср)
1	824	0	-1,67	8,5
2	828	0	-0,28	8,5
3	822	0	-1,94	8,5
4	820	0	0,00	10,9
5	1084	19	-0,28	19,5
6	1109	18	0,28	26,6
7	1493	26	1,39	23,6
8	1569	28	0,28	32,1
9	2088	32	1,67	31,5
10	2175	33	0,28	38,9
11	2900	40	2,50	40,9
12	2890	14	0,28	19,9
13	1903	32	1,11	22,6
14	1979	34	0,00	20,2
15	2064	14	0,83	14,3
16	2062	13	0,00	7,1
17	2011	11	-0,28	7,5
18	1996	11	0,00	6,7
19	1973	15	-0,28	7,9
20	1931	16	0,00	13,9
21	1930	23	-0,28	14,9
22	1946	26	0,00	22,8
23	2017	19	0,56	21,7
24	2018	19	0,00	11
25	1957	13	-0,28	10,7
26	1941	11	0,00	4,3
27	1830	6	-0,56	5,2
28	1796	6	-0,28	6,9
29	1635	18	-0,83	12,2
30	1608	18	-0,28	27
31	1596	29	-0,28	22,8
32	1609	30	0,00	32,5
33	1738	31	0,56	33,3
34	1755	31	0,28	32,2
35	1934	22	0,83	31,4
36	1957	32	0,28	30,8
37	2127	32	1,11	31,1
38	2143	32	0,00	28,7
39	2278	32	0,83	29,4
40	2287	32	0,00	29,7

Дефинисана фази правила ФЛС2 модела

Редни	Фази правило	Оцена возача
1.	Уколико је БМ ниска, УБ ниско и ППГ низак	врло добра
2.	Уколико је БМ ниска, УБ ниско и ППГ средњи	добра
3.	Уколико је БМ ниска, УБ ниско и ППГ висок	средња
4.	Уколико је БМ ниска, УБ средње и ППГ низак	врло добра
5.	Уколико је БМ ниска, УБ средње и ППГ средњи	средња
6.	Уколико је БМ ниска, УБ средње и ППГ висок	лоша
7.	Уколико је БМ ниска, УБ високо и ППГ низак	врло добра
8.	Уколико је БМ ниска, УБ високо и ППГ средњи	добра
9.	Уколико је БМ ниска, УБ високо и ППГ висок	средња
10.	Уколико је БМ средња, УБ ниско и ППГ низак	добра
11.	Уколико је БМ средња, УБ ниско и ППГ средњи	лоша
12.	Уколико је БМ средња, УБ ниско и ППГ висок	врло лоша
13.	Уколико је БМ средња, УБ средње и ППГ низак	врло добра
14.	Уколико је БМ средња, УБ средње и ППГ средњи	добра
15.	Уколико је БМ средња, УБ средње и ППГ висок	средња
16.	Уколико је БМ средња, УБ високо и ППГ низак	врло добра
17.	Уколико је БМ средња, УБ високо и ППГ средњи	добра
18.	Уколико је БМ средња, УБ високо и ППГ висок	средња
19.	Уколико је БМ висока, УБ ниско и ППГ низак	врло добра
20.	Уколико је БМ висока, УБ ниско и ППГ средњи	средња
21.	Уколико је БМ висока, УБ ниско и ППГ висок	врло лоша
22.	Уколико је БМ висока, УБ средње и ППГ низак	врло добра
23.	Уколико је БМ висока, УБ средње и ППГ средњи	средња
24.	Уколико је БМ висока, УБ средње и ППГ висок	лоша
25.	Уколико је БМ висока, УБ високо и ППГ низак	врло добра
26.	Уколико је БМ висока, УБ високо и ППГ средњи	средња
27.	Уколико је БМ висока, УБ високо и ППГ висок	лоша

Захвалност аутора компанијима Delmax d.o.o. и AKS EXPRESS KURIR d.o.o. за обезбеђивање неопходних возача и возила за ово истраживање и компанији Inova Tech d.o.o. за обезбеђивање неопходних уређаја и техничку подршку.

9. ЛІТЕРАТУРА

1. Cisel Aras, A., & Gocer, I. (2016). Driver Rating based on Interval Type-2 Fuzzy Logic System. *IFAC-PapersOnLine*, 49(11), 95–100. doi: 10.1016/j.ifacol.2016.08.015
2. Huang, Y., Ng, E. C. Y., Zhou, J. L., Surawski, N. C., Chan, E. F. C., & Hong, G. (2018). Eco-driving technology for sustainable road transport: A review. *Renewable and Sustainable Energy Reviews*, 93, 596–609. doi: 10.1016/j.rser.2018.05.030
3. Sagberg, F., Selpi, Bianchi Piccinini, G. F., & Engström, J. (2015). A review of research on driving styles and road safety. *Human Factors*, 57(7), 1248–1275. doi: 10.1177/0018720815591313
4. Lajunen, T., & Özkan, T. (2011). Self-report instruments and methods. *Handbook of Traffic Psychology*, 43–59. doi: 10.1016/B978-0-12-381984-0.10004-9
5. Engelbrecht, J., Booysen, M. J., Van Rooyen, G. J., & Bruwer, F. J. (2015). Survey of smartphone-based sensing in vehicles for intelligent transportation system applications. *IET Intelligent Transport Systems*, 9(10), 924–935. doi: 10.1049/iet-its.2014.0248
6. Elamrani Abou El Assad, Z., Mousannif, H., Al Moatassime, H., & Karkouch, A. (2020). The application of machine learning techniques for driving behavior analysis: A conceptual framework and a systematic literature review. *Engineering Applications of Artificial Intelligence*, 87, 103312. doi: 10.1016/j.engappai.2019.103312
7. Bousonville, T., Dirichs, M., & Kruger, T. (2019). Estimating truck fuel consumption with machine learning using telematics, topology and weather data. *Proceedings of the 2019 International Conference on Industrial Engineering and Systems Management, IESM 2019*. doi: 10.1109/IESM45758.2019.8948175
8. Shridhar Bokare, P., & Kumar Maurya, A. (2013). Study of Effect of Speed, Acceleration and Deceleration of Small Petrol Car on Its Tail Pipe Emission. *International Journal for Traffic and Transport Engineering*, 3(4), 465–478. doi: 10.7708/ijtte.2013.3(4).09
9. LeBlanc, D. J., Sivak, M., & Bogard, S. (2010). Using Naturalistic Driving Data to Assess Variations in Fuel Efficiency among Individual Drivers. *Technical Report of the University of Michigan Transportation Research Institute, UMTRI-2010*.
10. Tanvir, S., Chase, R. T., & Roupahil, N. M. (2021). Development and analysis of eco-driving metrics for naturalistic instrumented vehicles. *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, 25(3), 235–248. doi: 10.1080/15472450.2019.1615486
11. Xue, Q., Wang, K., Lu, J. J., & Liu, Y. (2019). Rapid Driving Style Recognition in Car-Following Using Machine Learning and Vehicle Trajectory Data. *Journal of Advanced Transportation*, 2019(1). doi: 10.1155/2019/9085238
12. Kot, S. (2015). Cost Structure in Relation to the Size of Road Transport Enterprises. *PROMET – Traffic & Transportation*, 27(5), 387–394. doi: 10.7307/ptt.v27i5.1687
13. Kovács, G. (2017). Optimization method and software for fuel cost reduction in case of road transport activity. *Acta Polytechnica*, 57(3), 201–208. doi: 10.14311/AP.2017.57.0201

14. Gohari, A., Matori, A. N., Yusof, K. W., Toloue, I., & Sholagberu, A. T. (2018). The effect of fuel price increase on transport cost of container transport vehicles. *International Journal of GEOMATE*, 15(50), 174–181. doi: 10.21660/2018.50.30814
15. Schall, D. L., Wolf, M., & Mohnen, A. (2016). Do effects of theoretical training and rewards for energy-efficient behavior persist over time and interact? A natural field experiment on eco-driving in a company fleet. *Energy Policy*, 97, 291–300. doi: 10.1016/j.enpol.2016.07.008
16. Gilman, E., Keskinarkaus, A., Tamminen, S., Pirttikangas, S., Röning, J., & Riekk, J. (2015). Personalised assistance for fuel-efficient driving. *Transportation Research Part C: Emerging Technologies*, 58(PD), 681–705. doi: 10.1016/j.trc.2015.02.007
17. Magana, V. C., & Munoz-Organero, M. (2016). Artemisa: A Personal Driving Assistant for Fuel Saving. *IEEE Transactions on Mobile Computing*, 15(10), 2437–2451. doi: 10.1109/TMC.2015.2504976
18. Eftekhari, H. R., & Ghatee, M. (2018). Hybrid of discrete wavelet transform and adaptive neuro fuzzy inference system for overall driving behavior recognition. *Transportation Research Part F: Traffic Psychology and Behaviour*, 58, 782–796. doi: 10.1016/j.trf.2018.06.044
19. Neumann, T. (2018). The Importance of Telematics in the Transport System. *TransNav, the International Journal on Marine Navigation and Safety of Sea Transportation*, 12(3), 617–623. doi: 10.12716/1001.12.03.22
20. Said, H., Nicoletti, T., & Perez-Hernandez, P. (2016). Utilizing Telematics Data to Support Effective Equipment Fleet-Management Decisions: Utilization Rate and Hazard Functions. *Journal of Computing in Civil Engineering*, 30(1). doi: 10.1061/(ASCE)CP.1943-5487.0000444
21. Ziakopoulos, A., Tselentis, D., Kontaxi, A., & Yannis, G. (2020). A critical overview of driver recording tools. *Journal of Safety Research*, 72, 203–212. doi: 10.1016/j.jsr.2019.12.021
22. Zaldivar, J., Calafate, C. T., Cano, J. C., & Manzoni, P. (2011, October 4-7). Providing accident detection in vehicular networks through OBD-II devices and android-based smartphones. Proceedings of the 36th IEEE Conference on Local Computer Networks, LCN, 813–819, Bonn, Germany. doi: 10.1109/LCN.2011.6115556
23. Xiao, Z., Li, F., Wu, R., Jiang, H., Hu, Y., Ren, J., Cai, C., & Iyengar, A. (2020). TrajData: On Vehicle Trajectory Collection with Commodity Plug-and-Play OBU Devices. *IEEE Internet of Things Journal*, 7(9), 9066–9079. doi: 10.1109/JIOT.2020.3001566
24. Yao, Y., Zhao, X., Zhang, Y., Chen, C., & Rong, J. (2020). Modeling of individual vehicle safety and fuel consumption under comprehensive external conditions. *Transportation Research Part D: Transport and Environment*, 79, 102224. doi: 10.1016/j.trd.2020.102224
25. Malekian, R., Moloisane, N. R., Nair, L., Maharaj, B. T., & Chude-Okonkwo, U. A. K. (2017). Design and Implementation of a Wireless OBD II Fleet Management System. *IEEE Sensors Journal*, 17(4), 1154–1164. doi: 10.1109/JSEN.2016.2631542
26. Husni, E. (2017). Driving and fuel consumption monitoring with internet of things.

International Journal of Interactive Mobile Technologies, 11(3), 78–97. doi: 10.3991/ijim.v11i3.6473

27. Chang, S. H., & Fan, C. Y. (2016). Identification of the technology life cycle of telematics a patent-based analytical perspective. *Technological Forecasting and Social Change*, 105, 1–10. doi: 10.1016/j.techfore.2016.01.023
28. Janecki, R., Krawiec, S., & Sierpinski, G. (2010). Telematics and the transportation system's value. *IFAC Proceedings Volume*, 43(23), 43–49. doi: 10.3182/20101005-4-ro-2018.00017
29. Masternaut. (n.d.). The Benefits Of Telematic. Dostupno na <https://www.masternaut.com/benefits-of-telematics/>, (Pristupljeno 21 Avgusta, 2021).
30. Brzozowska, A., Bubel, D., & Kalinichenko, A. (2019). Analysis of the road traffic management system in the neural network development perspective. *Eastern-European Journal of Enterprise Technologies*, 2(3–98), 16–24. doi: 10.15587/1729-4061.2019.160049
31. Mikulski, J. (2012, May 21–22). Introduction of telematics for transport. *Proceedings of 9th International Conference, ELEKTRO 2012*, 336–340, Žilina, Slovakia. doi: 10.1109/ELEKTRO.2012.6225616
32. Öz, B., Özkan, T., & Lajunen, T. (2010). An investigation of the relationship between organizational climate and professional drivers' driver behaviours. *Safety Science*, 48(10), 1484–1489. doi: 10.1016/j.ssci.2010.07.009
33. Ellison, A. B., Greaves, S. P., & Bliemer, M. C. J. (2015). Driver behaviour profiles for road safety analysis. *Accident Analysis and Prevention*, 76, 118–132. doi: 10.1016/j.aap.2015.01.009
34. Farooq, D., Moslem, S., & Duleba, S. (2019). Evaluation of driver behavior criteria for evolution of sustainable traffic safety. *Sustainability*, 11(11). doi: 10.3390/su11113142
35. Kaçan, B., Findik, G., Üzümcüoğlu, Y., Azık, D., Solmazer, G., Ersan, Ö., Özkan, T., Lajunen, T., Öz, B., Pashkevich, A., Pashkevich, M., Danelli-Mylona, V., Georgogianni, D., Berisha Krasniqi, E., Krasniqi, M., Makris, E., Shubenkova, K., & Xheladini, G. (2019). Driver profiles based on values and traffic safety climate and their relationships with driver behaviors. *Transportation Research Part F: Traffic Psychology and Behaviour*, 64, 246–259. doi: 10.1016/j.trf.2019.05.010
36. Mikulski, J. (2010). Using telematics in transport. *Communications in Computer and Information Science*, 104 CCIS, 175–182. doi: 10.1007/978-3-642-16472-9-19
37. Chunli, L. (2012). Intelligent transportation based on the Internet of Things. *2012 2nd International Conference on Consumer Electronics, Communications and Networks, CECNet 2012 - Proceedings*, 11457255, 360–362. doi: 10.1109/CECNet.2012.6201865
38. Said, O., & Masud, M. (2013). Towards internet of things: Survey and future vision. *International Journal of Computer Networks*, 5(1), 1–17.
39. Mashal, I., Alsaryrah, O., Chung, T. Y., Yang, C. Z., Kuo, W. H., & Agrawal, D. P. (2015). Choices for interaction with things on Internet and underlying issues. *Ad Hoc Networks*, 28, 68–90. doi: 10.1016/j.adhoc.2014.12.006
40. AutoPi Telematics Unit - 4G/LTE Edition. (n.d.). [Online image]. Dostupno na

- <https://shop.autopi.io/en/products/autopi-telematics-unit-4glte-edition-2/>, (Pristupljeno 17 Aprila, 2021).
41. AutoPi Telematics Unit - DIY Edition. (n.d.). [Online image]. Dostupno na <https://shop.autopi.io/en/products/autopi-telematics-unit-diy-edition-4/>, (Pristupljeno 18 Aprila, 2021).
 42. Helium network. (2021). Dostupno na <https://explorer.helium.com/> (Pristupljeno 2 Decembra, 2021).
 43. Kumar, R. (2018). 4 Steps to Select the Right Database for Your Internet of Things System. Dostupno na <https://thenewstack.io/4-steps-to-select-the-right-database-for-your-internet-of-things-system/>, (Pristupljeno 10 Oktobra, 2021).
 44. Janković, O. (2015, March 18-20). NoSQL dokument baza podataka : prikaz skladištenja podataka sa osvrtom na podatke sa senzora. XIV International Scientific-Professional Symposium, INFOTEH, 14, 561–566, Jahorina, Bosna i Hercegovina.
 45. Gyorodi, C., Gyorodi, R., Pecherle, G., & Olah, A. (2015, June 11-12). A comparative study: MongoDB vs. MySQL. *2015 13th International Conference on Engineering of Modern Electric Systems*, Oradea, Romania. doi: 10.1109/EMES.2015.7158433
 46. ACEA. (2021). ACEA REPORT - *Vehicles in use, Europe, January 2021*. Dostupno na <https://www.acea.auto/files/report-vehicles-in-use-europe-january-2021-1.pdf>, (Pristupljeno 15 Juna, 2021).
 47. EEA. (2017). European Environment Agency. Dostupno na <https://www.eea.europa.eu/signals/signals-2017/articles/driving-to-an-electric-future>, (Pristupljeno 21 Septembra, 2021).
 48. Cenex. (n.d.). The Low Emission Van Guide. Dostupno na <https://www.cenex.co.uk/resources/low-emission-van-guide/>, (Pristupljeno 19 Jula, 2021).
 49. EForce. (2021). E-Force One AG. Dostupno na <https://www.eforce.ch/products/ef18-szm>, (Pristupljeno 17 Septembra, 2021).
 50. ACEA. (2020). European Automobile Manufacturers' Association: ACEA. Dostupno na <https://www.acea.auto/figure/buses-eu-fuel-type/>, (Pristupljeno 12 Juna, 2021).
 51. Díaz-Ramirez, J., Giraldo-Peralta, N., Flórez-Ceron, D., Rangel, V., Mejía-Argueta, C., Huertas, J. I., & Bernal, M. (2017a). Eco-driving key factors that influence fuel consumption in heavy-truck fleets: A Colombian case. *Transportation Research Part D: Transport and Environment*, 56, 258–270. doi: 10.1016/j.trd.2017.08.012
 52. Wang, Y., & Boggio-Marzet, A. (2018). Evaluation of eco-driving training for fuel efficiency and emissions reduction according to road type. *Sustainability*, 10(11). doi: 10.3390/su10113891
 53. Delhomme, P., Cristea, M., Paran, F. (2013). Self-reported frequency and perceived difficulty of adopting eco-friendly driving behavior according to gender, age, and environmental concern. *Transportation Research Part D: Transport and Environment*, 38, 55–58. doi: 10.1016/j.trd.2013.02.002
 54. De Abreu e Silva, J., Moura, F., Garcia, B., & Vargas, R. (2015). Influential vectors in fuel consumption by an urban bus operator: Bus route, driver behavior or vehicle type? *Transportation Research Part D: Transport and Environment*, 38, 94–104. doi:

55. Delgado, O. F., Clark, N. N., & Thompson, G. J. (2011). Modeling Transit Bus Fuel Consumption on the Basis of Cycle Properties. *Journal of the Air and Waste Management Association*, 61(4), 443–452. doi: 10.3155/1047-3289.61.4.443
56. Goes, G., Bandeira, R., Gonçalves, D., D'Agosto, M. de A., & Oliveira, C. (2019). The effect of eco-driving initiatives toward sustainable urban waste collection. *International Journal of Sustainable Transportation*, 1–10. doi: 10.1080/15568318.2019.1584933
57. Strömberg, H. K., & Karlsson, I. C. M. A. (2013). Comparative effects of eco-driving initiatives aimed at urban bus drivers - Results from a field trial. *Transportation Research Part D: Transport and Environment*, 22, 28–33. doi: 10.1016/j.trd.2013.02.011
58. Ho, S. H., Wong, Y. D., & Chang, V. W. C. (2015). What can eco-driving do for sustainable road transport? Perspectives from a city (Singapore) eco-driving programme. *Sustainable Cities and Society*, 14(1), 82–88. doi: 10.1016/j.scs.2014.08.002
59. Stokic, M., Momcilovic, V., & Vujanovic, D. (2019). Evaluation of driver's eco-driving skills based on fuzzy logic model – A realistic example of vehicle operation in real-world conditions. *Journal of Applied Engineering Science*, 17(2), 217–223. doi: 10.5937/jaes17-22106
60. Eboli, L., Mazzulla, G., & Pungillo, G. (2017). How drivers' characteristics can affect driving style. *Transportation Research Procedia*, 27, 945–952. doi: 10.1016/j.trpro.2017.12.024
61. Barkenbus, J. N. (2010). Eco-driving: An overlooked climate change initiative. *Energy Policy*, 38(2), 762–769. doi: 10.1016/j.enpol.2009.10.021
62. Ecowill. (2013). *The Golden Rules of Eco-Driving*. Dostupno na http://cieca.eu/sites/default/files/%0Adocuments/projects_and_studies/ECOWILL_FINAL_REPORT.pdf, (Pristupljeno 16 Avgusta, 2021).
63. IDAE. (2015). *Conducción Eficiente*. Dostupno na https://www.idae.es/uploads/documentos/documentos_10297_TREATISE_ConduccionEficiente_A2005_A_f3817bad.pdf (Pristupljeno 24 Jula, 2021).
64. Garcia-Castro, A., & Monzon, A. (2014). Using floating car data to analyse the effects of ITS measures and Eco-driving. *Sensors*, 14(11), 21358–21374. doi: 10.3390/s141121358
65. Coloma, J. F., García, M., Wang, Y., & Monzón, A. (2017). Green eco-driving effects in non-congested cities. *Sustainability*, 10(1), 1–16. doi: 10.3390/su10010028
66. Ericsson, E. (2001). Independent driving pattern factors and their influence on fuel-use and exhaust emission factors. *Transportation Research Part D: Transport and Environment*, 6(5), 325–345. doi: 10.1016/S1361-9209(01)00003-7
67. Johansson H., Gustafsson P., Henke M., Resengren M., (2003, June 16-18). Impact of Ecodriving on emissions. *12th International Symposium "Transport and Air Pollution" Avignon*, 92(1), 113-120, Arcueil. France.
68. Argonne National Laboratory. (2018). Idling Reduction Savings Calculator Calculate Savings from IR. Dostupno na <https://www.anl.gov/>, (Pristupljeno 8 Jula, 2021).

69. Şimşek, B., Pakdil, F., Dengiz, B., & Testik, M. C. (2013). Driver performance appraisal using GPS terminal measurements: A conceptual framework. *Transportation Research Part C: Emerging Technologies*, 26, 49–60. doi: 10.1016/j.trc.2012.07.006
70. Singh, H., & Kathuria, A. (2021). Analyzing driver behavior under naturalistic driving conditions: A review. *Accident Analysis and Prevention*, 150(May 2020), 105908. doi: 10.1016/j.aap.2020.105908
71. Beusen, B., Broekx, S., Denys, T., Beckx, C., Degraeuwe, B., Gijssbers, M., Scheepers, K., Govaerts, L., Torfs, R., & Panis, L. I. (2009). Using on-board logging devices to study the longer-term impact of an eco-driving course. *Transportation Research Part D: Transport and Environment*, 14(7), 514–520. doi: 10.1016/j.trd.2009.05.009
72. Gardelis, K., Lalos, A. S., & Moustakas, K. (2018, January 27-29). Development of an eco-driving simulation training system with natural and haptic interaction in virtual reality environments. *VISIGRAPP 2018 - Proceedings of the 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, Funchal*, 94–101, Madeira, Portugal. doi: 10.5220/0006619500940101
73. RECODRIVE, P. (n.d.). *Rewarding and Recognition Schemes for Energy Conserving Driving, Vehicle procurement and maintenance*. Dostupno na <http://fleet-eu.geonardo.com/downloads/Alessandra%20Moizo.pdf> (Pristupljeno 3. jula, 2021).
74. Zhang, C., He, J., Bai, C., Yan, X., Gong, J., & Zhang, H. (2021). How to Use Advanced Fleet Management System to Promote Energy Saving in Transportation: A Survey of Drivers' Awareness of Fuel-Saving Factors. *Journal of Advanced Transportation*, 2021. doi: 10.1155/2021/9987101
75. Walnum, H. J., & Simonsen, M. (2015). Does driving behavior matter? An analysis of fuel consumption data from heavy-duty trucks. *Transportation Research Part D: Transport and Environment*, 36, 107–120. doi: 10.1016/j.trd.2015.02.016
76. Andrieu, C., & Pierre, G. Saint. (2012). Comparing Effects of Eco-driving Training and Simple Advices on Driving Behavior. *Procedia - Social and Behavioral Sciences*, 54(0), 211–220. doi: 10.1016/j.sbspro.2012.09.740
77. Coloma, J. F., García, M., & Wang, Y. (2018). Eco-Driving Effects Depending on the Travelled Road. Correlation between Fuel Consumption Parameters. *Transportation Research Procedia*, 33, 259–266. doi: 10.1016/j.trpro.2018.10.101
78. Orfila, O., Saint Pierre, G., & Messias, M. (2015). An android based ecodriving assistance system to improve safety and efficiency of internal combustion engine passenger cars. *Transportation Research Part C: Emerging Technologies*, 58(PD), 772–782. doi: 10.1016/j.trc.2015.04.026
79. Rolim, C., Baptista, P., Duarte, G., Farias, T., & Pereira, J. (2017). Real-Time Feedback Impacts on Eco-Driving Behavior and Influential Variables in Fuel Consumption in a Lisbon Urban Bus Operator. *IEEE Transactions on Intelligent Transportation Systems*, 18(11), 3061–3071. doi: 10.1109/TITS.2017.2657333
80. Basarić, V. B., Jambrović, M., Miličić, M. B., Savković, T. M., Basarić, D. M., & Bogdanović, V. Z. (2017). Positive effects of eco-driving in public transport: A case study of the city Novi Sad. *Thermal Science*, 21(1), 683–692. doi: 10.2298/TSCI150219160B
81. Beloufa, S., Cauchard, F., Vedrenne, J., Vailleau, B., Kemeny, A., Mérienne, F., &

- Boucheix, J. M. (2017). Learning eco-driving behaviour in a driving simulator: Contribution of instructional videos and interactive guidance system. *Transportation Research Part F: Traffic Psychology and Behaviour*, 61, 201–216. doi: 10.1016/j.trf.2017.11.010
82. Kiencke, U., & Nielsen, L. (2005). Vehicle Parameters and States. *Automotive Control Systems*, 351–408. doi: 10.1007/3-540-26484-1_9
 83. Treiber, M., Kesting, A., Treiber, M., & Kesting, A. (2013). Car-Following Models Based on Driving Strategies. *Traffic Flow Dynamics*, 181–204. doi: 10.1007/978-3-642-32460-4_11
 84. Ma, H., Xie, H., Huang, D., & Xiong, S. (2015). Effects of driving style on the fuel consumption of city buses under different road conditions and vehicle masses. *Transportation Research Part D: Transport and Environment*, 41, 205–216. doi: 10.1016/j.trd.2015.10.003
 85. Jeffreys, I., Graves, G., & Roth, M. (2018). Evaluation of eco-driving training for vehicle fuel use and emission reduction: A case study in Australia. *Transportation Research Part D: Transport and Environment*, 60, 85–91. doi: 10.1016/j.trd.2015.12.017
 86. Nègre, J., & Delhomme, P. (2017). Drivers' self-perceptions about being an eco-driver according to their concern for the environment, beliefs on eco-driving, and driving behavior. *Transportation Research Part A: Policy and Practice*, 105, 95–105. doi: 10.1016/j.tra.2017.08.014
 87. Berry, I. M. (2010). *The Effects of Driving Style and Vehicle Performance on the Real-World Fuel Consumption of U.S. Light-Duty Vehicles*. [Master's thesis, Massachusetts Institute of Technology]. Dostupno na https://web.mit.edu/sloan-auto-lab/research/beforeh2/files/IreneBerry_Thesis_February2010.pdf, (Pristupljeno 8 Maja, 2021).
 88. Pozueco, L., Pañeda, X. G., Tuero, A. G., Díaz, G., García, R., Melendi, D., Pañeda, A. G., & Sánchez, J. A. (2017). A methodology to evaluate driving efficiency for professional drivers based on a maturity model. *Transportation Research Part C: Emerging Technologies*, 85, 148–167. doi: 10.1016/j.trc.2017.09.017
 89. Zhou, M., & Jin, H. (2017). Development of a transient fuel consumption model. *Transportation Research Part D: Transport and Environment*, 51, 82–93. doi: 10.1016/j.trd.2016.12.001
 90. Pañeda, X. G., Garcia, R., Diaz, G., Tuero, A. G., Pozueco, L., Mitre, M., Melendi, D., & Pañeda, A. G. (2016). Formal characterization of an efficient driving evaluation process for companies of the transport sector. *Transportation Research Part A: Policy and Practice*, 94, 431–445. doi: 10.1016/j.tra.2016.10.004
 91. Hajek H., Popiv D., Just M., Bengler K. (2011) Influence of a Multimodal Assistance Supporting Anticipatory Driving on the Driving Behavior and Driver's Acceptance. In: Kurosu M. (eds) Human Centered Design. HCD 2011. Lecture Notes in Computer Science, vol 6776. Springer, Berlin, Heidelberg. doi: 10.1007/978-3-642-21753-1_25
 92. Kim, J. S., & Tak, T. O. (2016). Design and performance validation of tactile force generating type eco-pedal to improve fuel economy. *Transactions of the Korean Society of Mechanical Engineers, A*, 40(11), 963–970. doi: 10.3795/KSME-A.2016.40.11.963
 93. Nissan Motor Corporation (N.d.). [Online image]. Dostupno na

https://www.nissan-global.com/EN/TECHNOLOGY/OVERVIEW/eco_pedal.html (Pristupljeno 8 Oktobra, 2021).

94. Baldean, D. (2019). Research of fuel injection duty on a spark ignited engine. *Applied Mathematics, Mechanics, and Engineering*, 62(IV), 577–582.
95. Fors, C., Kircher, K., & Ahlström, C. (2015). Interface design of eco-driving support systems - Truck drivers' preferences and behavioural compliance. *Transportation Research Part C: Emerging Technologies*, 58(PD), 706–720. doi: 10.1016/j.trc.2015.03.035
96. Araújo, R., Igreja, Â., De Castro, R., & Araújo, R. E. (2012, June 3-7). Driving coach: A smartphone application to evaluate driving efficient patterns. *IEEE Intelligent Vehicles Symposium, Proceedings*, 1(1), 1005–1010, Alcala de Henares, Spain. doi: 10.1109/IVS.2012.6232304
97. Sanguinetti, A., Kurani, K., & Davies, J. (2017). The many reasons your mileage may vary: Toward a unifying typology of eco-driving behaviors. *Transportation Research Part D: Transport and Environment*, 52, 73–84. doi: 10.1016/j.trd.2017.02.005
98. Birrell, S., Taylor, J., McGordon, A., Son, J., & Jennings, P. (2014). Analysis of three independent real-world driving studies: A data driven and expert analysis approach to determining parameters affecting fuel economy. *Transportation Research Part D: Transport and Environment*, 33, 74–86. doi: 10.1016/j.trd.2014.08.021
99. Suzdaleva, E., & Nagy, I. (2018). An online estimation of driving style using data-dependent pointer model. *Transportation Research Part C: Emerging Technologies*, 86, 23–36. doi: 10.1016/j.trc.2017.11.001
100. Zhou, M., Jin, H., & Wang, W. (2016). A review of vehicle fuel consumption models to evaluate eco-driving and eco-routing. *Transportation Research Part D: Transport and Environment*, 49(5), 203–218. doi: 10.1016/j.trd.2016.09.008
101. Fafoutellis, P., Mantouka, E. G., & Vlahogianni, E. I. (2021). Eco-driving and its impacts on fuel efficiency: An overview of technologies and data-driven methods. *Sustainability*, 13(1), 1–17. doi: 10.3390/su13010226
102. Boriboonsomsin, K., & Barth, M. (2009). Impacts of road grade on fuel consumption and carbon dioxide emissions evidenced by use of advanced navigation systems. *Transportation Research Record*, 2139, 21–30. doi: 10.3141/2139-03
103. Kamal, M. A. S., Mukai, M., Murata, J., & Kawabe, T. (2011). Ecological vehicle control on roads with up-down slopes. *IEEE Transactions on Intelligent Transportation Systems*, 12(3), 783–794. doi: 10.1109/TITS.2011.2112648
104. Carrese, S., Gemma, A., & La Spada, S. (2013). Impacts of Driving Behaviours, Slope and Vehicle Load Factor on Bus Fuel Consumption and Emissions: A Real Case Study in the City of Rome. *Procedia - Social and Behavioral Sciences*, 87, 211–221. doi: 10.1016/j.sbspro.2013.10.605
105. Wang, J. Q., Yu, Q. W., & Li, S. B. (2014). Economic speed optimization based on real-time information of road gradient. *Journal of Automotive Safety and Energy*, 5(3), 257–262. doi: 10.3969/j.issn.1674-8484.2014.03.006
106. Tielert, T., Killat, M., Hartenstein, H., Luz, R., Hausberger, S., & Benz, T. (2010). The impact of traffic-light-to-vehicle communication on fuel consumption and emissions. *2010 Internet of Things (IoT)*. doi: 10.1109/IOT.2010.5678454

107. Sánchez, M., Cano, J. C., & Kim, D. (2006, June 21-23). Predicting traffic lights to improve urban traffic fuel consumption. *ITST 2006 - 2006 6th International Conference on ITS Telecommunications, Proceedings*, 331–336, Chengdu, China. doi: 10.1109/ITST.2006.288906
108. Asadi, B., & Vahidi, A. (2011). Predictive cruise control: Utilizing upcoming traffic signal information for improving fuel economy and reducing trip time. *IEEE Transactions on Control Systems Technology*, 19(3), 707–714. doi: 10.1109/TCST.2010.2047860
109. USDOT - United States Department of Transportation. (n.d.). [Online image]. Dostupno na <https://www.its.dot.gov/index.htm>, (Pristupljeno 14. jula, 2021).
110. Van Mierlo, J., Maggetto, G., Van De Burgwal, E., & Gense, R. (2004). Driving style and traffic measures - Influence on vehicle emissions and fuel consumption. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 218(1), 43–50. doi: 10.1243/095440704322829155
111. Hellström, E., Ivarsson, M., Åslund, J., & Nielsen, L. (2009). Look-ahead control for heavy trucks to minimize trip time and fuel consumption. *Control Engineering Practice*, 17(2), 245–254. doi: 10.1016/j.conengprac.2008.07.005
112. Yao, Y., Zhao, X., Liu, C., Rong, J., Zhang, Y., Dong, Z., Su, Y., & Chen, F. (2020). Vehicle Fuel Consumption Prediction Method Based on Driving Behavior Data Collected from Smartphones. *Journal of Advanced Transportation*, 2020. doi: 10.1155/2020/9263605
113. Ping, P., Qin, W., Xu, Y., Miyajima, C., & Takeda, K. (2019). Impact of driver behavior on fuel consumption: Classification, evaluation and prediction using machine learning. *IEEE Access*, 7, 78515–78532. doi: 10.1109/ACCESS.2019.2920489
114. Xu, Z., Wei, T., Easa, S., Zhao, X., & Qu, X. (2018). Modeling Relationship between Truck Fuel Consumption and Driving Behavior Using Data from Internet of Vehicles. *Computer-Aided Civil and Infrastructure Engineering*, 33(3), 209–219. doi: 10.1111/mice.12344
115. Reddy, N. R. (2019). *Driving Behaviour Classification: An Eco-driving Approach*. [Master's Thesis. University of Twente, TEEMCS: Electrical Engineering, Mathematics and Computer Science]. Dostupno na http://essay.utwente.nl/80158/1/FinalVersion_Thesis.pdf, (Pristupljeno 4. aprila, 2021).
116. Hiraoka, T., Terakado, Y., Matsumoto, S., & Yamabe, S. (2009, September 21-25). Quantitative evaluation of eco-driving on fuel consumption based on driving simulator experiments. *16th ITS World Congress*, Stockholm, Sweden.
117. Zhao, F., Pereira, F. C., Ball, R., Kim, Y., Han, Y., Zengras, C., & Ben-Akiva, M. (2015). Exploratory analysis of a smartphone-based travel survey in Singapore. *Transportation Research Record*, 2494, 45–56. doi: 10.3141/2494-06
118. Chen, C., Zhao, X., Yao, Y., Zhang, Y., Rong, J., & Liu, X. (2018). Driver's eco-driving behavior evaluation modeling based on driving events. *Journal of Advanced Transportation*, 2018. doi: 10.1155/2018/9530470
119. Mantouka, E., Barmounakis, E., Vlahogianni, E., & Golias, J. (2020). Smartphone sensing for understanding driving behavior: Current practice and challenges.

120. Frank, R., Castignani, G., Schmitz, R., & Engel, T. (2013, December 2-6). A novel eco-driving application to reduce energy consumption of electric vehicles. 2013 *International Conference on Connected Vehicles and Expo, ICCVE 2013 - Proceedings*, 283–288, Las Vegas, Nevada. doi: 10.1109/ICCVE.2013.6799807
121. Zhang, J. Y., & Pan, G. Y. (2013). Comparison and application of multiple regression and BP neural network prediction model. *Journal of Kunming University of Science and Technology*, 38(6), 61–67.
122. Zheng, J., & Wu, Y. (2020). Development of a Practical Method to Estimate the Eco-Level of Driver Performance. *Journal of Advanced Transportation*, 2020. doi: 10.1155/2020/8151720
123. Duan, Z.-T., Kang, J., Tang, L., Fan, N., Liu, Y., & Dai, J.-T. (2014). Traffic information service cooperation architecture based on vehicular network big data. *Journal of Chang'an University*, 34(2), 108–114.
124. National Research Council. 2011. *Assessment of Fuel Economy Technologies for Light-Duty Vehicles*. Washington, DC: The National Academies Press. doi: 10.17226/12924
125. Shi, Q., & Abdel-Aty, M. (2015). Big Data applications in real-time traffic operation and safety monitoring and improvement on urban expressways. *Transportation Research Part C: Emerging Technologies*, 58, 380–394. doi:10.1016/j.trc.2015.02.022
126. Li, Y., Tang, G., Du, J., Zhou, N., Zhao, Y., & Wu, T. (2019). Multilayer Perceptron Method to Estimate Real-World Fuel Consumption Rate of Light Duty Vehicles. *IEEE Access*, 7, 63395–63402. doi: 10.1109/ACCESS.2019.2914378
127. Abukhalil, T., Almahafzah, H., Alksasbeh, M., & Alqaralleh, B. A. Y. (2020). Fuel Consumption Using OBD-II and Support Vector Machine Model. *Journal of Robotics*, 2020, 1-9. doi: 10.1155/2020/9450178
128. Mitchell, T. M. (1999). Machine learning and data mining. *Communications of the ACM*, 42(11). doi: 10.1533/9780857099440
129. Zhang, J., Wu, Z. C., Li, F., Xie, C., Ren, T., Chen, J., & Liu, L. (2019). A deep learning framework for driving behavior identification on in-vehicle CAN-BUS sensor data. *Sensors*, 19(6), 6–8. doi: 10.3390/s19061356
130. Ghandour, R., Potams, A.J., Boulkaibet, I., Neji, B., & Al Barakeh, Z. (2021). Driver Behavior Classification System Analysis Using Machine Learning Methods. *Applied Sciences*, 11, 10562. doi: 10.3390/app112210562
131. Wickramanayake, S., & Bandara, D. H. M. N. (2016, April 5-6). Fuel consumption prediction of fleet vehicles using Machine Learning: A comparative study. *2nd International Moratuwa Engineering Research Conference, MERCon 2016*, 90–95, Moratuwa, Sri Lanka. doi: 10.1109/MERCon.2016.7480121
132. Wang, L., Duran, A., Gonder, J., & Kelly, K. (2015). Modeling Heavy/Medium-Duty Fuel Consumption Based on Drive Cycle Properties. *SAE Technical Papers*. doi: 10.4271/2015-01-2812
133. Mathworks. (n.d.). What Is Machine Learning? 3 things you need to know. Dostupno na <https://www.mathworks.com/discovery/machine-learning.html>, (Pristupljeno

17 Juna, 2021).

134. Cristianini, N., & Shawe-Taylor, J. (2000). *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge: Cambridge University Press. doi:10.1017/CBO9780511801389
135. Mucherino, A., Papajorgji, P.J., & Pardalos, P.M. (2009). k-Nearest Neighbor Classification. In: *Data Mining in Agriculture. Springer Optimization and Its Applications*, 34. Springer, New York, NY. doi: 10.1007/978-0-387-88615-2_4
136. Webb, G.I. (2011). Naïve Bayes. In: Sammut C., & Webb G.I. (eds) *Encyclopedia of Machine Learning*. Springer, Boston, MA. doi: 10.1007/978-0-387-30164-8_576
137. Bisong, E. (2019). Logistic Regression. In: *Building Machine Learning and Deep Learning Models on Google Cloud Platform*. Apress, Berkeley, CA. doi: 10.1007/978-1-4842-4470-8
138. SCIKT LEARN (n.d.). *Neural network models (supervised)*. Dostupno na https://scikit-learn.org/stable/modules/neural_networks_supervised.html#multi-layer-perceptron (Pristupljeno 12 Februara, 2022).
139. Ma, Z., Xue, J.-H., Leijon, A., Tan, Z.-H., Yang, Z., & Guo, J. (2016). Decorrelation of Neutral Vector Variables: Theory and Applications. *IEEE Transactions on Neural Networks and Learning Systems*, 29(1), 129–143. doi: 10.1109/tnnls.2016.2616445
140. Lederer, J. (2022). Linear Regression. In: *Fundamentals of High-Dimensional Statistics*. Springer Texts in Statistics. Springer, Cham. doi: 10.1007/978-3-030-73792-4_2
141. Anandamurugan, S., Deenadhayalan, R., Venkatesan, B., Sakthivel, S., & Rajesh, S. (2022). An Efficient Method of Predicting the Average Fuel Consumption in Automobiles Using Ensemble Stacking in Python. In: Borah, S., Mishra, S.K., Mishra, B.K., Balas, V.E., & Polkowski, Z. (eds) *Advances in Data Science and Management. Lecture Notes on Data Engineering and Communications Technologies*, 86. Springer, Singapore. doi: 10.1007/978-981-16-5685-9_19
142. Tan, P.-N., Steinbach, M., & Kumar, V. (2005). *Introduction to Data Mining*. Addison-Wesley Longman Publishing Co., Inc. Dostupno na <https://www-users.cs.umn.edu/~kumar001/dmbook/sol.pdf> (Pristupljeno 13 Aprila, 2021).
143. Liaw, A., & Wiener, M. (2002). Classification and Regression by randomForest. *R News*, 2(3), 18–22.
144. Vidič, N. (2019). *Primena mašinskog učenja u verifikaciji softvera*. [Master rad, Univerzitet u Beogradu, Matematički fakultet]. Dostupno na http://www.racunarstvo.matf.bg.ac.rs/MasterRadovi/2016_05_06_Nikola_Vidic/rad.pdf, (Pristupljeno 7 Jula, 2021).
145. Bühlmann, P., & Hothorn, T. (2007). Boosting algorithms: Regularization, prediction and model fitting. *Statistical Science*, 22(4), 477–505. doi: 10.1214/07-STS242
146. Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *R Package Version 0.71-2*, 1–4. doi: 10.1145/2939672.2939785
147. Moreira-Matias, L., & Farah, H. (2017). On Developing a Driver Identification Methodology Using In-Vehicle Data Recorders. *IEEE Transactions on Intelligent Transportation Systems*, 18(9), 2387–2396. doi: 10.1109/TITS.2016.2639361

148. Breiman, L. (2001). Random Forests. *Machine Learning* 45, 5–32 (2001). doi: 10.1023/A:1010933404324
149. Liu, Y., Wang, Y., & Zhang, J. (2012). New Machine Learning Algorithm: Random Forest. In: Liu, B., Ma, M., & Chang, J. (eds) *Information Computing and Applications. ICICA 2012. Lecture Notes in Computer Science, 7473*. Springer, Berlin, Heidelberg. doi: 10.1007/978-3-642-34062-8_32
150. Kam, H. T. (1995). Random decision forest. In *Proceedings of the 3rd international conference on document analysis and recognition, Montreal, Canada, 278-282*. doi: 10.1109/ICDAR.1995.598994
151. Quinlan, R.J. (1992). Learning with continuous classes. In: *5th Australian Joint Conference on Artificial Intelligence, Singapore, 343–348*.
152. Sihag, P., Mohsenzadeh Karimi, S. & Angelaki, A. (2019). Random forest, M5P and regression analysis to estimate the field unsaturated hydraulic conductivity. *Applied Water Science* 9, 129(2019), doi: 10.1007/s13201-019-1007-88_20
153. Aggarwal, C.C. (2018). An Introduction to Neural Networks. In: *Neural Networks and Deep Learning*. Springer, Cham. doi: 10.1007/978-3-319-94463-0_1
154. Said, S., Boulkaibet, I., Sheikh, M., Karar, A.S., Alkork, S., & Nait-Ali, A. (2020). Machine-Learning-Based Muscle Control of a 3D-Printed Bionic Arm. *Sensor*, 20 (11), 3144. doi: 10.3390/s20113144
155. Hassoun, M.H. (1995). *Fundamentals of Artificial Neural Networks*. MIT Press: Cambridge, MA, USA.
156. Witten, I. H., Frank, E., Hall, A. M., & Pal, C. (2017). *Data Mining: Practical Machine Learning Tools and Techniques(4th)*. Morgan Kaufmann. doi: 10.1016/C2015-0-02071-8
157. Jin, X., & Han, J. (2011). K-Medoids Clustering. In: Sammut C., Webb G.I. (eds) *Encyclopedia of Machine Learning*. Springer, Boston, MA. doi: 10.1007/978-0-387-30164-8_426
158. Reynolds, D. (2015). Gaussian Mixture Models. In: Li S.Z., Jain A.K. (eds) *Encyclopedia of Biometrics*. Springer, Boston, MA. doi: 10.1007/978-1-4899-7488-4_196
159. Nielsen, F. (2016). Hierarchical Clustering. In: *Introduction to HPC with MPI for Data Science. Undergraduate Topics in Computer Science*. Springer, Cham. doi: 10.1007/978-3-319-21903-5_8
160. Baum, L.E., & Petrie, T. (1966). Statistical Inference for Probabilistic Functions of Finite State Markov Chains. *The Annals of Mathematical Statistics*, 37(6), 1554-1563. doi: 10.1214/aoms/1177699147
161. Lan, Y., Zhou, D., Zhang, H., & Lai, S. (2017). Early Warning for Infectious Disease Outbreak. In: *Early Warning for Infectious Disease Outbreak. Development of Early Warning Models*. Academic Press, London, United Kingdom. 35–74. doi: 10.1016/B978-0-12-812343-0.00003-5
162. Huynh, X.P., Park, S.M., & Kim, Y.G. (2017). Detection of Driver Drowsiness Using 3D Deep Neural Network and Semi-Supervised Gradient Boosting Machine. In: Chen, C.S., Lu, J., & Ma, K.K. (eds) *Computer Vision – ACCV 2016 Workshops. ACCV 2016. Lecture Notes in Computer Science, 10118*. Springer, Cham. doi:

163. Azman, A., Ibrahim, S.Z., Meng, Q., & Edirisinghe, E.A. (2014). Physiological measurement used in real time experiment to detect driver cognitive distraction. In *Proceedings of the International Conference on Electronics, Information, and Communication (ICEIC)*, Kota Kinabalu, Malaysia, 1–5. doi: 10.1109/ELINFOCOM.2014.6914389
164. Jiao, Y., Peng, Y., Lu, B.L., Chen, X., Chen, S., & Wang, C. (2014). Recognizing slow eye movement for driver fatigue detection with machine learning approach. In *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, Beijing, China, 4035–4041. doi: 10.1109/IJCNN.2014.6889615
165. Jo, J., Lee, S.J., Kim, J., Gi Jung, H., & Park, K.R. (2011). Vision based method for detecting driver drowsiness and distraction in driver monitoring system. *Optical Engineering*, 50(12), 1–24. doi: 10.1117/1.3657506
166. Alizadeh, V., & Dehzangi, O. (2016). The impact of secondary tasks on drivers during naturalistic driving: Analysis of EEG dynamics. In *Proceeding of the IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, Rio de Janeiro, Brazil, 2493–2499. doi: 10.1109/ITSC.2016.7795957
167. Dange, G. R., Paranthaman, P. K., Bellotti, F., Samaritani, M., Berta, R., & De gloria, A. (2017). Assessment of driver behavior based on machine learning approaches in a social gaming scenario. *Lecture Notes in Electrical Engineering*, 409, 205–218. doi: 10.1007/978-3-319-47913-2_24
168. Ma, H., Xie, H., & Brown, D. (2018). Eco-Driving Assistance System for a Manual Transmission Bus Based on Machine Learning. *IEEE Transactions on Intelligent Transportation Systems*, 19(2), 572–581. doi: 10.1109/TITS.2017.2775633
169. Hashemi, A., Saba, V., & Resalat, S. N. (2014). Real time driver's drowsiness detection by processing the EEG signals stimulated with external flickering light. *Basic and Clinical Neuroscience*, 5(1), 22–27.
170. Srinivasan, D., Jin, X., & Cheu, R. L. (2005). Adaptive neural network models for automatic incident detection on freeways. *Neurocomputing*, 64(1-4 SPEC. ISS.), 473–496. doi: 10.1016/j.neucom.2004.12.001
171. Bejani, M. M., & Ghatee, M. (2018). A context aware system for driving style evaluation by an ensemble learning on smartphone sensors data. *Transportation Research Part C: Emerging Technologies*, 89 (February), 303–320. doi: 10.1016/j.trc.2018.02.009
172. Li, G., Li, S. E., Cheng, B., & Green, P. (2017). Estimation of driving style in naturalistic highway traffic using maneuver transition probabilities. *Transportation Research Part C: Emerging Technologies*, 74, 113–125. doi: 10.1016/j.trc.2016.11.011
173. Kwak, B. Il, Woo, J. Y., & Kim, H. K. (2016, December 12-14). Know Your master: Driver Profiling-based Anti-theft Method. *14th Annual Conference on Privacy, Security and Trust (PST)*, Auckland, New Zealand, 211–218, doi: 10.1109/PST.2016.7906929
174. Meseguer, J. E., Calafate, C. T., Cano, J. C., & Manzoni, P. (2013, July 7-10). DrivingStyles: A smartphone application to assess driver behavior. *Proceedings - International Symposium on Computers and Communications*, 535–540. doi: 10.1109/ISCC.2013.6755001

175. Xu, J., Saleh, M., & Hatzopoulou, M. (2020). A machine learning approach capturing the effects of driving behaviour and driver characteristics on trip-level emissions. *Atmospheric Environment*, 224, 117311. doi: 10.1016/j.atmosenv.2020.117311
176. Ming, L. J., Tan, I. K. T., & Hoong, P. K. (2017, May 17-19). Classifying drivers using electronic logging devices. *5th International Conference on Information and Communication Technology, ICoICT 2017*, Malacca, Malaysia. doi: 10.1109/ICoICT.2017.8074705
177. Ozgul, O. F., Cakir, M. U., Tan, M., Amasyali, M. F., & Hayvaci, H. T. (2018, September 25-27). A Fully Unsupervised Framework for Scoring Driving Style. *9th International Conference on Intelligent Systems 2018: Theory, Research and Innovation in Applications, IS 2018 - Proceedings*, 228–234, Madeira Island, Portugal. doi: 10.1109/IS.2018.8710574
178. Kim, K., Park, J., & Lee, J. (2021). Fuel economy improvement of urban buses with development of an eco-drive scoring algorithm using machine learning. *Energies*, 14(15). doi: 10.3390/en14154471
179. Lin, N., Zong, C., Tomizuka, M., Song, P., Zhang, Z., & Li, G. (2014). An overview on study of identification of driver behavior characteristics for automotive control. *Mathematical Problems in Engineering*, 2014(2). doi: 10.1155/2014/569109
180. Sanchez, K. J., Chan, A. S., Baker, M. R., Zettinger, M., Fields, B. M., & Nepomuceno, J. A. (2014). Systems and methods to identify and profile a vehicle operator. (U.S. Patent No. 8,738,523 B2)
181. Silver, A., & Lewis, L. (2015). Automatic identification of a vehicle driver based on driving behavior. (U.S. Patent No. 9,201,932 B2) Dostupno na <https://patentimages.storage.googleapis.com/bf/d4/f3/6431a84ffc1f71/US9201932.pdf>, (Pristupljeno 12 Maja, 2021).
182. Perrotta, F., Parry, T., & Neves, L. C. (2017, December 11-14). Application of machine learning for fuel consumption modelling of trucks. *Proceedings - 2017 IEEE International Conference on Big Data*, 3810–3815, Boston, MA. doi: 10.1109/BigData.2017.8258382
183. Estaji, M., Harvey, J. T., & Coleri, E. (2020). Evaluation of Different Machine Learning Tools in End-to-End Prediction of Vehicle Fuel Consumption in California. *International Conference on Transportation and Development 2020: Emerging Technologies and Their Impact*. 74–84. doi: 10.1061/9780784483138.007
184. Moradi, E., & Miranda-Moreno, L. (2020). Vehicular fuel consumption estimation using real-world measures through cascaded machine learning modeling. *Transportation Research Part D: Transport and Environment*, 88(October), 102576. doi: 10.1016/j.trd.2020.102576
185. M. Mendel, J. (2001). Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions, (2nd ed.). Prentice-Hall.
186. Mendel, J. M., & John, R. I. B. (2002). Type-2 fuzzy sets made simple. *IEEE Transactions on Fuzzy Systems*, 10(2), 117–127. doi: 10.1109/91.995115
187. Hagrass, H. A. (2004). A hierarchical type-2 fuzzy logic control architecture for autonomous mobile robots. *IEEE Transactions on Fuzzy Systems*, 12(4), 524–539. doi: 10.1109/TFUZZ.2004.832538

188. Coupland, S., & John, R. (2007). Geometric Type-1 and Type-2 Fuzzy Logic Systems. *IEEE Transactions on Fuzzy Systems*, 15(1), 3–15. doi: 10.1109/tfuzz.2006.889764
189. Liu, F. (2008). An efficient centroid type-reduction strategy for general type-2 fuzzy logic system. *Information Sciences*, 178(9), 2224–2236. doi: 10.1016/j.ins.2007.11.014
190. Wagner, C., & Hagra, H. (2008, June 1-6). ZSlices - Towards bridging the gap between interval and general type-2 fuzzy logic. *IEEE International Conference on Fuzzy Systems*, 489–497. doi: 10.1109/FUZZY.2008.4630413
191. Wagner, C., & Hagra, H. (2010). Toward general type-2 fuzzy logic systems based on zSlices. *IEEE Transactions on Fuzzy Systems*, 18(4), 637–660. doi: 10.1109/TFUZZ.2010.2045386
192. Liang, Q., & Mendel, J. M. (2000). Interval type-2 fuzzy logic systems: Theory and design. *IEEE Transactions on Fuzzy Systems*, 8(5), 535–550. doi: 10.1109/91.873577
193. N. Karnik, N., & M. Mendel, J. (2001). Operations on type-2 fuzzy sets. *Fuzzy Sets and Systems*, 122(2), 327–348. doi: 10.1016/S0165-0114(00)00079-8
194. Zadeh, L. A. (1975). The concept of a linguistic variable and its application to approximate reasoning-I. *Information Sciences*, 8(3), 199–249. doi: 10.1016/0020-0255(75)90036-5
195. Khosravi, A., & Nahavandi, S. (2014). Effects of type reduction algorithms on forecasting accuracy of IT2FLS models. *Applied Soft Computing Journal*, 17, 32–38. doi: 10.1016/j.asoc.2013.12.007
196. Imkamon, T., Saensom, P., Tangamchit, P., & Pongpaibool, P. (2008, May 14-17). Detection of hazardous driving behavior using fuzzy logic. *5th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, ECTI-CON 2008*, 2, 657–660, Krabi, Thailand. doi: 10.1109/ECTICON.2008.4600519
197. Fernandez, S., & Ito, T. (2016). Driver classification for intelligent transportation systems using fuzzy logic. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, 1212–1216. doi: 10.1109/ITSC.2016.7795711
198. Barla, P., Gilbert-Gonthier, M., Lopez Castro, M. A., & Miranda-Moreno, L. (2017). Eco-driving training and fuel consumption: Impact, heterogeneity and sustainability. *Energy Economics*, 62, 187–194. doi: 10.1016/j.eneco.2016.12.018
199. Schall, D. L., & Mohnen, A. (2017). Incentivizing energy-efficient behavior at work: An empirical investigation using a natural field experiment on eco-driving. *Applied Energy*, 185, 1757–1768. doi: 10.1016/j.apenergy.2015.10.163
200. Zdravković, S., Vujanović, D., Stokić, M., & Pamučar, D. (2021). Evaluation of professional driver's eco-driving skills based on type-2 fuzzy logic model. *Neural Computing and Applications*, 33(18), 11541–11554. doi: 10.1007/s00521-021-05823-z
201. Wu, D., & Mendel, J. M. (2007). Uncertainty measures for interval type-2 fuzzy sets. *Information Sciences*, 177(23), 5378–5393. doi: 10.1016/j.ins.2007.07.012
202. Yeh, C. Y., Jeng, W. H. R., & Lee, S. J. (2011). Data-based system modeling using a type-2 fuzzy neural network with a hybrid learning algorithm. *IEEE Transactions on Neural Networks*, 22(12 PART 2), 2296–2309. doi: 10.1109/TNN.2011.2170095

203. Zhou, S. M., Garibaldi, J. M., John, R. I., & Chiclana, F. (2009). On constructing parsimonious type-2 fuzzy logic systems via influential rule selection. *IEEE Transactions on Fuzzy Systems*, 17(3), 654–667. doi: 10.1109/TFUZZ.2008.928597
204. Precup, R.-E., Preitl, S., Petriu, E., Bojan-Dragos, C.-A., Szedlak-Stinean, A.-I., Roman, R.-C., & Hedrea, E.-L. (2020). Model-based fuzzy control results for networked control systems. *Reports in Mechanical Engineering*, 1(1), 10–25. doi: 10.31181/rme200101010p
205. Vilela, M., Oluyemi, G., & Petrovski, A. (2019). Fuzzy logic applied to value of information assessment in oil and gas projects. *Petroleum Science*, 16(5), 1208–1220. doi: 10.1007/s12182-019-0348-0
206. Vilela, M., Oluyemi, G., & Andrei, P. (2020). A holistic approach to assessment of value of information (VOI) with fuzzy data and decision criteria. *Decision Making: Applications in Management and Engineering*, 3(2), 97–118. doi: 10.31181/dmame2003097v
207. Wuensch, K.L. (2016). Comparing Regression Lines Fom Independent Samples. Dostupno na <https://core.ecu.edu/wuensch/MV/multReg/Potthoff.pdf>, (Pristupljeno 5 Maja, 2021).
208. Vujanović, D., Janković, S., Stokić, M. & Zdravković, S. (in press). Evaluation of the influence of terrain and traffic road conditions on the driver's driving performances by applying machine learning. *Thermal Science*, doi: 10.2298/TSCI211019355V
209. Abdelrahman, A., Hassanein, H. S., & Abu-Ali, N. (2018, December 9-13). Data-driven Robust Scoring Approach for Driver Profiling Applications. *IEEE Global Communications Conference, GLOBECOM 2018 - Proceedings*, 1–6, Abu Dhabi, UAE. doi: 10.1109/GLOCOM.2018.8647971
210. Lopez, J. R., Gonzalez, L. C., Wahlstrom, J., Montes Y Gomez, M., Trujillo, L., & Ramirez-Alonso, G. (2018). A Genetic Programming Approach for Driving Score Calculation in the Context of Intelligent Transportation Systems. *IEEE Sensors Journal*, 18(17), 7183–7192. doi: 10.1109/JSEN.2018.2856112
211. Júnior, J. F., Carvalho, E., Ferreira, B. V., De Souza, C., Suhara, Y., Pentland, A., & Pessin, G. (2017). Driver behavior profiling: An investigation with different smartphone sensors and machine learning. *PLoS ONE*, 12(4), 1–16. doi: 10.1371/journal.pone.0174959
212. Waltereit, M., Zdankin, P., Matkovic, V., Uphoff, M., & Weis, T. (2020, May 2-4). Online driving behavior scoring using wheel speeds. *VEHITS 2020 - Proceedings of the 6th International Conference on Vehicle Technology and Intelligent Transport Systems, Vehits*, 417–424. doi: 10.5220/0009215604170424
213. Martinelli, F., Marulli, F., Mercaldo, F., & Santone, A. (2021). Neural networks for driver behavior analysis. *Electronics*, 10(3), 1–23. doi: 10.3390/electronics10030342

Биографија

Стефан Здравковић је рођен 3. децембра 1990. године у Београду. Дипломирао је на Факултету организационих наука 2013. године, смер информациони системи и технологије. На истом факултету уписује мастер академске студије на студијском програму Операциона истраживања и рачунарска статистика. Звање мастер инжењера организационих наука стиче 2014. године положивши све испите са просечном оценом 10. Докторске академске студије уписује 2015. године – студијски програм Информациони системи и квантитативни менаџмент. До сада је положио све испите са просечном оценом 10 и успешно одбранио приступни рад са називом теме „Интегрисани модел за класификацију и предвиђање понашања возача“

У летњем периоду 2013. и 2014. године обавио је стручне праксе у Управи за заједничке послове републичких органа у Сектору за информационо-комуникационе технологије.

У периоду 2014-2016. године био је ангажован као сарадник у настави на Саобраћајном факултету Универзитета у Београду за ужу научну област информатика. У звање асистента изабран је 2016. и 2019. године. Ангажован је у извођењу и организовању неколико предмета на основним студијама: Основи програмирања, Програмирање и Базе података, као и предмету Пројектовање оптимизационих апликација на мастер студијама. Посебно је заинтересован за истраживања у области паметних транспортних система. Жеља му је да у научном домену што више напредује, да се посвети истраживању примене технологија *Big Data* и машинског учења у решавању саобраћајних проблема.

Био је учесник пројекта TP36012 финансираног од стране Министарства просвете, науке и технолошког развоја. Аутор и коаутор је преко 30 радова објављених на међународним конференцијама, домаћим и међународним часописима. Посебно се истичу радови који су објављени на SCI листи:

- **Zdravković, S.**, Vujanović, D., Stokić, M., & Pamučar, D. (2021). Evaluation of professional driver's eco-driving skills based on type-2 fuzzy logic model. *Neural Computing & Applications*, 33, 11541–11554. DOI: 10.1007/s00521-021-05823-z, IF(2020) – 5.606
- Vujanović, D., Janković, S., Stokić, M. & **Zdravković, S.** (in press). Evaluation of the influence of terrain and traffic road conditions on the driver's driving performances by applying machine learning. *Thermal Science*. DOI: 10.2298/TSCI211019355V, IF(2020) – 1.574
- Mladenović, S., **Zdravković, S.**, Vesković, S., Janković, S., Đorđević, Ž., & Đalić, N. (2019). Development of a Novel Freight Railcar Load Planning and Monitoring System. *Symmetry*, 11, 756. DOI: 10.3390/sym11060756 IF(2019) - 2.645
- Marković, M., **Zdravković, S.**, Mitrović, M., & Radojičić, A. (2016) An Iterative Multivariate Post Hoc I-Distance Approach in Evaluating OECD Better Life Index. *Social Indicator Research*, 126, 1–19. DOI: 10.1007/s11205-015-0879-8 IF(2016) - 1.743

ИЗЈАВА О АУТОРСТВУ

Име и презиме аутора Стефан Здравковић

Број индекса 5005/2015

Изјављујем

да је докторска дисертација под насловом

„Интегрисани модел за класификацију и предвиђање понашања возача“

- резултат сопственог истраживачког рада;
- да дисертација у целини ни у деловима није била предложена за стицање друге дипломе према студијским програмима других високошколских установа;
- да су резултати коректно наведени и
- да нисам кршио ауторска права и користио интелектуалну својину других лица.

Потпис аутора

У Београду, _____

ИЗЈАВА О ИСТОВЕТНОСТИ ШТАМПАНЕ И ЕЛЕКТРОНСКЕ ВЕРЗИЈЕ ДОКТОРСКОГ РАДА

Име и презиме аутора Стефан Здравковић

Број индекса 5005/2015

Студијски програм Информациони системи и квантитавни менаџмент

Наслов рада Интегрисани модел за класификацију и предвиђање понашања возача

Ментор др Мирослав Миновић, редовни професор

Изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао ради похрањивања у Дигиталном репозиторијуму Универзитета у Београду.

Дозвољавам да се објаве моји лични подаци везани за добијање академског назива доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

У Београду,

Потпис аутора

ИЗЈАВА О КОРИШЋЕЊУ

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

„Интегрисани модел за класификацију и предвиђање понашања возача“

која је моје ауторско дело.

Дисертацију са свим прилозима предао сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похрањену у Дигиталном репозиторијуму Универзитета у Београду и доступну у отвореном приступу могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио.

1. Ауторство (CC BY)
2. Ауторство – некомерцијално (CC BY-NC)
3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)
4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)
5. Ауторство – без прерада (CC BY-ND)
- ⑥. Ауторство – делити под истим условима (CC BY-SA)

(Молимо да заокружите само једну од шест понуђених лиценци. Кратак опис лиценци је саставни део ове изјаве).

Потпис аутора

У Београду, _____

1. **Ауторство.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце, чак и у комерцијалне сврхе. Ово је најслободнија од свих лиценци.
2. **Ауторство – некомерцијално.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела.
3. **Ауторство – некомерцијално – без прерада.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца не дозвољава комерцијалну употребу дела. У односу на све остале лиценце, овом лиценцом се ограничава највећи обим права коришћења дела.
4. **Ауторство – некомерцијално – делити под истим условима.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца не дозвољава комерцијалну употребу дела и прерада.
5. **Ауторство – без прерада.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, без промена, преобликовања или употребе дела у свом делу, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце. Ова лиценца дозвољава комерцијалну употребу дела.
6. **Ауторство – делити под истим условима.** Дозвољаваате умножавање, дистрибуцију и јавно саопштавање дела, и прераде, ако се наведе име аутора на начин одређен од стране аутора или даваоца лиценце и ако се прерада дистрибуира под истом или сличном лиценцом. Ова лиценца дозвољава комерцијалну употребу дела и прерада. Слична је софтверским лиценцама, односно лиценцама отвореног кода.