



UNIVERZITET U NIŠU
ELEKTRONSKI FAKULTET



Marko M. Milivojčević

**KLASIFIKACIJA MOTORA AUTOMOBILA SA
UNUTRAŠNjim SAGOREVANJEM PREMA POGONSKOM
GORIVU NA OSNOVU GENERISANOG ZVUKA**

DOKTORSKA DISERTACIJA

Niš, 2025.



UNIVERSITY OF NIŠ
FACULTY OF ELECTRONIC ENGINEERING



Marko M. Milivojčević

**CLASSIFICATION OF INTERNAL COMBUSTION VEHICLE
ENGINES ACCORDING TO FUEL BASED ON GENERATED
SOUND**

DOCTORAL DISSERTATION

Niš, 2025.

Zahvalnica

Zahvaljujem se mom mentoru prof. dr Dejanu Ćiriću na izuzetnoj saradnji i strpljenju kako u toku studija tako i tokom izrade ove doktorske disertacije. Vaša podrška i posvećenost bili su mi od neprocenjive vrednosti, a svaki savet i smernica koje ste mi pružili pomogli su mi da napredujem i ostvarim svoje ciljeve.

Zahvaljujem se i svim ostalim članovima komisije na dobronamernim komentarima i sugestijama u toku završne faze ove disertacije.

Najznačajniju i najveću podršku tokom pisanja ove disertacije i školovanja dobio sam od članova moje porodice. Posebno se zahvaljujem mojoj deci i supruzi na svakodnevnom razmevanju i pomoći. Zahvaljujem se i mojoj sestri, roditeljima, tetki i tašti na velikoj podršci.

Disertaciju posvećujem ćerki Katarini, sinu Đorđu i supruzi Milici.

Autor

Podaci o doktorskoj disertaciji

Mentor:

Prof. dr Dejan Ćirić, redovni profesor
Univerzitet u Nišu, Elektronski fakultet

Naslov:

Klasifikacija motora automobila sa unutrašnjim sagorevanjem prema
pogonskom gorivu na osnovu generisanog zvuka

Rezime:

Zagađenje bukom i emisije izduvnih gasova predstavljaju značajne ekološke izazove, pri čemu klasifikacija vozila prema vrsti pogonskog goriva može doprineti smanjenju aerozagađenja i poboljšanju upravljanja urbanim prostorima. Ovo istraživanje razvija originalni sistem za akviziciju zvuka motora putničkih vozila u realnim uslovima, omogućavajući autonomnu detekciju vozila, minimalan uticaj okoline i kompatibilnost sa budućim IoT sistemima. Ključni izazovi uključivali su optimizaciju pozicije mikrofona tako da ne ometa prolazak vozila, kao i izbor režima rada motora koji nosi najrelevantnije akustičke informacije. Sistem je testiran na 350 vozila, formirajući bazu od 475 zvučnih uzoraka, uz implementaciju metode za automatsko izdvajanje akustički relevantnog režima rada.

Izdvojene su dve grupe audio obeležja pogodnih za razlikovanje pogonskih goriva: spektrogramske reprezentacije (mel-spektrogrami, gamatonegrami) i psihoakustičke karakteristike (glasnost, hrapavost, oštrina, krest faktor). Klasifikacija je realizovana metodama dubokog učenja (CNN) i nenadgledanog učenja (SOM), pri čemu je CNN postigao F1 rezultat do 97%, a SOM do 96,7% eliminacijom tehnički neispravnih vozila.

Doprinos istraživanja ogleda se u razvoju inovativnog sistema za akviziciju, identifikaciji ključnih akustičkih obeležja i demonstraciji primene mašinskog i dubokog učenja u analizi zvuka motora. Kreirana baza zvučnih uzoraka predstavlja vredan resurs za naučnu zajednicu i buduća istraživanja

u oblasti analize buke, prepoznavanja pogonskih goriva i detekcije kvarova. Rezultati su potvrdili da je moguće uspešno klasifikovati vozila prema pogonskom gorivu na osnovu zvuka, što otvara mogućnosti za monitoring saobraćaja, smanjenje buke i razvoj standarda za ocenu zvučnog kvaliteta motora.

Naučna oblast:

Elektrotehničko i računarsko inženjerstvo

Naučna
disciplina:

Akustika

Ključne reči:

Klasifikacija vozila, motori sa unutrašnjim sagorevanjem, analiza zvuka, akvizicija akustičkih signala, spektralna analiza, psihoakustička obeležja, duboko učenje, mašinsko učenje

UDK:

(534.87+534.836):004.85

CERIF
klasifikacija:

T 121 - Obrada signala

Tip licence
Kreativne
zajednice:

CC BY-NC-ND

Data on Doctoral Dissertation

Doctoral
Supervisor:

PhD Dejan Ćirić, full professor
University of Niš, Faculty of Electronic Engineering

Title:

Classification of internal combustion vehicle engines according to fuel based on generated sound

Abstract:

Noise pollution and exhaust emissions represent significant environmental challenges, with vehicle classification based on the type of fuel contributing to the reduction of air pollution and improvement of urban space management. This research develops an original system for acquiring engine sounds of passenger vehicles under real-world conditions, enabling autonomous vehicle detection, minimal environmental impact, and compatibility with future IoT systems. Key challenges included optimizing the microphone position to avoid obstructing vehicle passage, as well as selecting the engine operating mode that carries the most relevant acoustic information. The system was tested on 350 vehicles, forming a database of 475 sound samples, along with the implementation of a method for automatic extraction of acoustically relevant operating modes.

Two groups of audio features suitable for distinguishing fuel types were identified: spectrogram representations (mel-spectrograms, gammatonegrams) and psychoacoustic characteristics (loudness, roughness, sharpness, crest factor). Classification was carried out using deep learning methods (CNN) and unsupervised learning (SOM), with CNN achieving an F1 score of up to 97%, and SOM reaching 96.7% after eliminating technically faulty vehicles.

The contribution of this research lies in the development of an innovative acquisition system, the identification of key acoustic features, and the demonstration of machine and deep learning applications in engine sound analysis. The created sound sample database represents a valuable

resource for the scientific community and future research in noise analysis, fuel type recognition, and fault detection. The results confirmed that it is possible to successfully classify vehicles based on fuel type using sound, opening opportunities for traffic monitoring, noise reduction, and the development of standards for assessing engine sound quality.

Scientific Field:

Electrical and Computer Engineering

Scientific
Discipline:

Acoustics

Key Words:

Vehicle classification, Internal combustion engines, Sound analysis, Acoustic signal acquisition, Spectral analysis, Psychoacoustic features, Deep learning, Machine learning

UDC:

(534.87+534.836):004.85

CERIF
Classification:

T 121 – Signal processing

Creative
Commons
License Type:

CC BY-NC-ND

Sadržaj

Spisak korišćenih skraćenica.....	iii
Spisak slika.....	vi
Spisak tabela.....	xi
1. Uvod.....	1
1.1 Motivacija istraživanja	2
1.2. Pregled naučne literature	3
1.3 Predmet, cilj i doprinos istraživanja	5
1.4 Organizacija disertacije	6
2. Akustika motora sa unutrašnjim sagorevanjem	8
2.1. Konstrukcija motora sa unutrašnjim sagorevanjem.....	8
2.1.1 Podela klipnih motora	10
2.2. Izvori zvuka u motorima sa unutrašnjim sagorevanjem	12
2.3. Metode za snimanje zvuka SUS motora.....	15
2.3.1. Snimanje zvuka stacionarnih vozila.....	16
2.3.2 Snimanje zvuka vozila u pokretu.....	18
3. Klasifikacija zvučnih zapisa vozila	20
3.1 Akustička karakterizacija vozila.....	21
3.1.1 Karakterizacija vozila na osnovu akustičkog potpisa	21
3.1.2 Klasifikacija vozila prema tipu goriva.....	21
3.2 Skupovi podataka, obeležja i algoritmi	23
3.2.1 Skupovi podataka.....	23
3.2.2 Obeležja korišćena kao ulaz za modele veštačke inteligencije.....	24
3.2.3 Modeli klasifikacije	26
4. Dizajn i hardverska realizacija akvizicionog sistema za prikupljanje uzoraka	29
4.1 Prenosni sistem za formiranje nove banke audio uzoraka.....	29
4.1.1 Pozicioniranje mikrofona u odnosu na motorni prostor vozila i izbor režima rada motora za analizu	30
4.1.2 Izbor lokacije za prikupljanje uzoraka.....	45
4.2 Realizacija automatizovanog sistema za prikupljanje uzoraka zvuka.....	46
4.2.1 Detekcija prisustva vozila	47

4.2.2 Snimanje audio signala	54
4.2.3 Procedura akvizicije.....	56
4.2.4 Izdvajanje režima praznog hoda	57
4.2.5 Analiza snimljenih audio signala	61
5. Izdvajanje akustičkih karakteristika SUS motora značajnih za klasifikaciju pogonskog goriva	65
5.1 Primena predefinisanih funkcija za izračunavanje audio obeležja SUS motora	66
5.1.1 Obeležja u vremenskom domenu.....	67
5.1.2 Obeležja u frekvencijskom domenu.....	72
5.2 Mapiranje audio signala motora sa unutrašnjim sagorevanjem u slike bazirane na spektrogramu	78
5.2.1 Spektrogram	78
5.2.2 Mel-spektrogram.....	81
5.2.3 Hromagram	82
5.2.4 Gamatonegram	83
5.2.5 Tempogram	85
5.3 Psihoakustička obeležja.....	87
5.3.1 Glasnost.....	87
5.3.2 Hrapavost	88
5.3.3 Oštrina.....	88
5.3.4 Tonalitet	89
5.3.5 Rezultati izdvajanja psihoakustičkih obeležja SUS motora.....	89
5.4. Sličnost zvukova motora sa unutrašnjim sagorevanjem bazirana na mel-spektrogramu ...	92
6. Klasifikacija SUS motora na osnovu zvuka.....	103
6.1 Evaluacija klasifikacionog modela.....	103
6.2 Klasifikacija bazirana na mapiranju zvučnih signala u slike.....	106
6.3. Klasifikacija bazirana na psihoakustičkim obeležjima.....	110
6.3.1 Metodologija	110
6.3.2 Rezultati klasifikacije primenom SOM algoritma.....	113
7. Zaključak	119
Literatura	124
Biografija autora.....	137
Izjave autora	138

Spisak korišćenih skraćenica

SUS – sa unutrašnjim sagorevanjem

CNN – *convolutional neural network* – konvoluciona neuronska mreža

SOM – *self-organizing maps* – algoritam samoorganizujućih mapa

SMT – spoljna mrtva tačka

UMT – unutrašnja mrtva tačka

Hz – *Herz* – herc

WOT – *wide open throttle* – režim potpunog opterećenja

DNN – *deep neural networks* - duboke neuronske mreže

IDMT – *Institute for Digital Media Technology* – institut za tehnologiju digitalnih medija

MFCC – *mel-frequency cepstral coefficients* – mel-frekvencijski kepsralni koeficijenti

GFCC – *gammatone-frequency cepstral coefficients* – gammatone frekvencijski kepsralni koeficijenti

FFT – *fast Fourier transform* – brza Furijeova transformacija

ZCR – *zero crossing rate* - broj prolazaka kroz nulu

STFT – *short-term Fourier transform* – kratkoročna Furijeova transformacija

WPD – *wavelet packet decomposition* – dekompozicija talasnih paketa

RMS – *root mean square* – srednja kvadratna vrednost

SVM – *support vector machine* – metod zasnovan potpornim vektorima

k-NN – *k-nearest neighbors* – metod k-najbližih suseda

QDA – *quadratic discriminant analysis* – kvadratna diskriminantna analiza

LPC – *linear predictive coding* – linearno prediktivno kodiranje

TDNN – *time delay nerual network* – neuronska mrežu sa vremenskim kašnjenjem

FLDA – *Fisher's linear discriminant analysis* – Fišerova linearna diskriminantna analiza

RA – *regression analysis* – regresiona analiza

LSTM – *long short-term memory* – duga kratkoročna memorija

kW – kilovat

ccm³ – kubni centimetar

16v – šesnaest ventila

CDTI – *common rail diesel turbo injection* – akumulatorsko dizel ubrizgavanje sa turbo nadpunjenjem

mm – milimetar

CD – *compact disc* – kompakt disk

Ω – om

dB – decibel

dBu – *decibel unloaded* – decibel u odnosu na 0,775 V

m – metar

obr./min – obrtaja u minuti

cm – centimetar

s – sekunda

μ s – mikrosekunda

Sha – Šora

°C – stepen po Celzijusovoj skali

A/D – analogno-digitalni

USB – *universal serial bus* – univerzalna serijska magistrala

SD – *secure digital*

wav – wave format datoteke

kB – kilobajt

GB – gigabajt

Ah – amper-sat

CPU – *central processing unit* – centralna procesorska jedinica

ms – milisekunda

DFT – *discrete Fourier transform* – diskretna Furijeova transformacija

ERB – *equivalent rectangular bandwidth* – ekvivalentna pravougaona širina opsega

CQT – *Constant-Q Transform* – Konstantno-Q transformacija

BPM – *beat per minute* – otkucaji u minuti

W – vat

m² – metar kvadratni

BkB – benzinski motori klasifikovani kao benzinski motori

DkD – dizel motori klasifikovani kao dizel motori

DkB – dizel motori klasifikovani kao benzinski motori

BkD – benzinski motori klasifikovani kao dizel motori

BpB – benzinski motori percipirani kao benzinski motori

DpD – dizel motori percipirani kao dizel motori

BpD – benzinski motori percipirani kao dizel motori

DpB – dizel motori percipirani kao benzinski motori

2-D – dvodimenzionalni

BMU - best matching unit – neuron sa najvećim stepenom podudarnosti

1-D – jednodimenzionalni

10-D – desetodimenzionalni

Spisak slika

Slika 1. Presek četvorocilindričnog četvorotaktnog SUS motora	9
Slika 2. Poprečni presek jednog cilindra četvorotaktnog SUS motora	9
Slika 3. Idealizovana promena pritisaka u cilindru a) benzinskog i b) dizel motora	11
Slika 4. Način sagorevanja i pritisci u cilindru za a) dizel i b) benzinski motor [38]	13
Slika 5. Pozicioniranje mikrofona u oblasti iznad motornog prostora sa otvorenim poklopcem motora.....	32
Slika 6. Pozicioniranje mikrofona u oblasti ispod motornog prostora.....	32
Slika 7. Zvuk benzinskog motora u vremenskom domenu	34
Slika 8. Usrednjeni spektar zvuka benzinskog motora u režimu praznog hoda.....	35
Slika 9. Usrednjeni spektar zvuka dizel motora u režimu praznog hoda	35
Slika 10. Usrednjeni spektar zvuka benzinskog motora pri 1500 obrtaja kolenastog vratila u minuti	36
Slika 11. Usrednjeni spektar zvuka dizel motora pri 1500 obrtaja kolenastog vratila u minuti ...	36
Slika 12. Usrednjeni spektar zvuka benzinskog motora pri 2500 obrtaja kolenastog vratila u minuti	36
Slika 13. Usrednjeni spektar zvuka dizel motora pri 2500 obrtaja kolenastog vratila u minuti ...	37
Slika 14. Usrednjeni spektar zvuka benzinskog motora pri 3000 obrtaja kolenastog vratila u minuti	37
Slika 15. Usrednjeni spektar zvuka dizel motora pri 3000 obrtaja kolenastog vratila u minuti ...	37
Slika 16. Usrednjeni spektar zvuka benzinskog motora u različitim režimima rada, snimljenog kada je otvoren poklopac motora.....	39
Slika 17. Usrednjeni spektar zvuka dizel motora u različitim režimima rada, snimljenog kada je otvoren poklopac motora.....	39
Slika 18. Položaj i raspored mernih tačaka za vozilo sa poprečno postavljenim motorom	41
Slika 19. Položaj i raspored mernih tačaka za vozilo sa uzdužno postavljenim motorom	42
Slika 20. Prikaz odstupanja RMS vrednosti nivoa zvuka u dB za vozila sa poprečno (levo) i uzdužno (desno) postavljenim motorom	43

Slika 21. Uporedni prikaz RMS nivoa kod vozila sa poprečno i uzdužno postavljenim motorom u odnosu na položaj izduvnog sistema.....	44
Slika 22. Pozicija mikrofona za vozila sa motorom postavljenim pozadi (slika gore), odnosno u sredini (slika dole).....	44
Slika 23. Blok dijagram prenosivog sistema za akviziciju zvuka.....	46
Slika 24. Postavka senzora u odnosu na pravac kretanja vozila.....	48
Slika 25. Prikaz ravni detekcije ultrazvučnih senzora.....	49
Slika 26. Princip rada ultrazvučnih senzora za merenje rastojanja.....	50
Slika 27. Algoritam rada mikrokontrolera za određivanje prisustva vozila.....	52
Slika 28. Frekvencijska karakteristika mikrofona AKG C562CM.....	54
Slika 29. Zaštita mikrofona i ultrazvučnog senzora od slučajnog prelaska točkom.....	54
Slika 30. Upadni ugao prevodnice u odnosu na pravac nailaska točka.....	55
Slika 31. Princip rada konačno relizovanog samostalnog, prenosivog sistema za prikupljanje uzoraka zvuka rada motora u režimu praznog hoda.....	57
Slika 32. Audio signal u vremenskom domenu (a) benzinskog i (b) dizel motora u režimu praznog hoda, bez promene režima.....	58
Slika 33. Audio signal u vremenskom domenu benzinskog motora sa (a) ranom i (b) kasnom promenom režima rada.....	58
Slika 34. Audio signal u vremenskom domenu dizel motora sa (a) ranom i (b) kasnom promenom režima rada.....	59
Slika 35. Anvelopa audio signala u vremenskom domenu (a) benzinskog i (b) dizel motora u praznom hodu, bez promene režima rada.....	60
Slika 36. Anvelopa audio signala u vremenskom domenu benzinskog motora sa (a) ranom i (b) kasnom promenom režima rada.....	61
Slika 37. Anvelopa audio signala u vremenskom domenu dizel motora sa (a) ranom i (b) kasnom promenom režima rada.....	61
Slika 38. Audio obeležje „energija“ audio zapisa vozila pokretanog na benzin (levo) i na dizel (desno) za intervale kratke dužine.....	68
Slika 39. Audio obeležje „energija“ audio zapisa vozila pokretanog na benzin, uvećani prikaz za intervale srednje dužine.....	69

Slika 40. Audio obeležje „energija“ audio zapisa vozila pokretanog na dizel, uvećani prikaz za intervale srednje dužine.....	69
Slika 41. Audio obeležje „entropija energije“ vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine.....	70
Slika 42. Audio signal (slika gore) i obeležje „entropija energije“ (dole) zvuka vozila pokretanog na benzin dobijena za intervale kratke dužine	71
Slika 43. Audio signal (slika gore) i obeležje „entropija energije“ (dole) zvuka vozila pokretanog na dizel dobijena za intervale kratke dužine	71
Slika 44. Audio obeležje „broj prolaza kroz nulu“ (ZCR) zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine	72
Slika 45. Audio obeležje „spektralni centroid“ vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine	73
Slika 46. Audio obeležje „spektralno širenje“ zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine	74
Slika 47. Audio obeležje „spektralna entropija“ zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine	75
Slika 48. Audio obeležje „MFCC“ broj 8 zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine	76
Slika 49. Audio obeležje MFCC broj 9 zvuka vozila pokretanog na benzin (levo) i dizel (desno)	76
Slika 50. Spektrogrami signala u linearnoj razmeri (linearni spektrogrami snage)	80
Slika 51. Spektrogrami signala u logaritamskoj razmeri (logaritamski spektrogrami snage)	80
Slika 52. Mel-spektrogram benzinskog (slika gore) i dizel motora (slika dole)	82
Slika 53. Hromagrami benzinskog (slika gore) i dizel motora (slika dole)	83
Slika 54. Gamatonegram benzinskog (slika gore) i dizel motora (slika dole)	85
Slika 55. Tempogram benzinskog (slika gore) i dizel motora (slika dole)	86
Slika 56. Dobijene vrednosti definisanog skupa obeležja (gornji red grafika) i derivata ovih obeležja (donji red grafika)	91
Slika 57. Raspodela vrednosti tonaliteta i derivata tonaliteta za benzinska i dizel vozila	91
Slika 58. Mel-spektrogrami reprezentativnog benzinskog (B224) (slika gore) i dizel (D37) motora (slika dole).....	94

Slika 59. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koji zvuče kao benzinski motori (BpB)	94
Slika 60. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koji zvuče kao dizel motori (DpD)	95
Slika 61. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koji zvuče kao dizel motori (BpD)	95
Slika 62. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koji zvuče kao benzinski motori (DpB)	95
Slika 63. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koje je algoritam klasifikovao kao dizel motori (BkD)	96
Slika 64. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koje je algoritam klasifikovao kao benzinski motori (DkB)	96
Slika 65. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe benzinskih motora BpB u odnosu na referentni benzinski motor	98
Slika 66. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe benzinskih motora BpB u odnosu na referentni dizel motor	98
Slika 67. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BpD u odnosu na referentni benzinski motor	99
Slika 68. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BpD u odnosu na referentni dizel motor	99
Slika 69. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DpB u odnosu na referentni benzinski motor	100
Slika 70. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DpB u odnosu na referentni dizel motor	100
Slika 71. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BkD u odnosu na referentni benzinski motor	101
Slika 72. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BkD u odnosu na referentni dizel motor	101
Slika 73. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DkB u odnosu na referentni benzinski motor	102

Slika 74. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DkB u odnosu na referentni dizel motor.....	102
Slika 75. Blok šema evaluacije klasifikacionog modela primenom F1 rezultata.....	105
Slika 76. Struktura konvolucione mreže korišćene u [108] za binarnu klasifikaciju industrijskih zvukova	106
Slika 77. Modifikovana struktura konvolucione mreže za klasifikaciju vozila prema pogonskom gorivu na osnovu zvuka mapiranog u slike bazirane na spektrogramu.....	109
Slika 78. 1-D SOM izlazna mreža kreirana od 10-D ulaznog vektora obeležja	112
Slika 79. Dobijanje ulaznog vektora obeležja za SOM algoritam	113
Slika 80. Tačnost predikcije u zavisnosti od strukture SOM mreže	115

Spisak tabela

Tabela 1. Karakteristike putničkih vozila korišćenih za merenja	31
Tabela 2. Specifikacije mernog mikrofona DBX RTA-M	32
Tabela 3. Specifikacije audio interfejsa Behringer UMC404HD	33
Tabela 4. Relativno odstupanje RMS-a u zoni ispod motornog prostora za različite orijentacije motora.....	43
Tabela 5. Uporedni pregled tri različita načina detekcije vozila (A, B i C) u smislu broja i upotrebljivosti prikupljenih uzoraka	63
Tabela 6. Statističke vrednosti Euklidovog rastojanja mel-spektrograma u okviru podgrupa.....	97
Tabela 7: Matrica konfuzije stvarnih i predviđenih vrednosti	104
Tabela 8. Rezultati primene konvolucione neuronske mreže sa slike 76 za klasifikaciju zvukova motora pokretanih na benzin i dizel mapiranih u spektrogram, mel-spektrogram, gamatonegram i tempogram.....	108
Tabela 9. Rezultati primene modifikovane konvolucione neuronske mreže za klasifikaciju zvukova motora pokretanih na benzin i dizel mapiranih u spektrogram i gamatonegram	110
Tabela 10. Matrica podudaranja i metrika evaluacije inicijalnog klasifikacionog modela sa dve klase.....	114
Tabela 11. Matrica podudaranja i metrika evaluacije modela sa devet klasa	115
Tabela 12. Rezultati klasifikacije unutar svake pojedinačne klase i njihov udeo u bazi podataka	117
Tabela 13. Matrica podudaranja i metrika evaluacije metode pojedinačnih vozila	117
Tabela 14. Matrica podudaranja i metrika evaluacije metode pojedinačnih vozila bez specifičnih slučajeva.	118

1. Uvod

Razlikovanje zvukova koji generišu motori sa unutrašnjim sagorevanjem (SUS motori) u zavisnosti od pogonskog goriva se može vršiti na osnovu subjektivnog utiska slušaoca koji je u korelaciji sa prethodno stečenim iskustvom. Uspešno razlikovanje pogonskog goriva na osnovu zvuka je najčešće izraženo kod onih osoba koje se bave održavanjem vozila i koji neretko dobro poznaju princip rada ovih motora, što ukazuje na složenost celokupnog procesa. Akustička metoda, bazirana na zvuku koji generišu vozila, predstavlja jednu od osnovnih metoda za dijagnostiku vozila [1, 2] pri čemu se u servisnim uputstvima pojedini zvuci ne mogu predstaviti opisno, već se sve svodi na iskustvo servisera. Iskusnom dijagnostičaru razlikovanje pogonskih goriva predstavlja najjednostavniji zadatak koji je uobičajeno polazna tačka ka otkrivanju anomalija u radu motora akustičkom metodom. Pored detektovanja anomalija, slušanjem se često može odrediti i broj cilindara motora, kao i da li je u pitanju dvotaktni ili četvorotaktni motor.

U kontekstu razlika uzrokovanih pogonskim gorivom kod SUS motora, značajna tema u savremenom svetu, pogotovu u poslednje vreme, je i zagađenje vazduha koje potiče od vozila pokretanih ovim motorima. Postoji veliki broj ponuđenih rešenja sa ciljem da se smanji uticaj izduvnih gasova na životnu okolinu. Napori da se smanji emisija štetnih gasova se ogledaju u zakonskim normativima i standardima za homologaciju i proizvodnju [3, 4], odnosno za maksimalno dozvoljenu emisiju štetnih gasova novih vozila, dok se za vozila koja su već u upotrebi mogu definisati ograničenja pristupa određenim zonama [5, 6] kako bi se distribucija štetnih gasova izmestila iz sredina sa velikim brojem ljudi. Ova ograničenja pristupa mogu biti realizovana kao potpuna zabrana kretanja u pojedinim zonama [5-7], ili kao delimična ograničenja kretanja bazirana na pogonskom gorivu [5-7]. Obzirom da količina i sastav izduvnih gasova zavise prvenstveno od pogonskog goriva, zakonske regulative su različito definisane za vozila sa SUS motorima pokretanih na benzin odnosno na dizel gorivo [3-6] nezavisno od proizvođača i tržišne klase vozila.

1.1 Motivacija istraživanja

Prethodno pomenute činjenice jasno ukazuju na potrebu da se vozila sa SUS motorima klasifikuju na osnovu pogonskog goriva, što se teorijski gledano može uraditi samo na osnovu zvuka motora. Ukoliko bi ovakva klasifikacija bila dovoljno uspešna, omogućio bi se alternativni ili komplementaran pristup postojećim sistemima za klasifikaciju koji su zasnovani na vizuelnoj identifikaciji registarske oznake vozila [8, 9]. Ove vizuelne sisteme odlikuje složenost i nemogućnost primene u privatne svrhe jer narušavaju privatnost vozača, kao i potreba za pristupom centralnoj bazi registrovanih vozila, koja nije javna u svim državama sveta. Ukoliko bi klasifikacija bila realizovana bez narušavanja privatnosti i potrebe da se pristupa bazi registrovanih vozila, to bi omogućilo dodatne primene koje bi unapredile kvalitet života, pre svega u urbanim sredinama. Naime, ovakav način klasifikacije bi potencijano mogao da bude integrisan u sisteme podzemnih garaža, gde bi na osnovu zastupljenosti vozila sa većim stepenom zagađenja funkcija ventilacije bila adaptivna, što bi rezultovalo manjom koncentracijom štetnih gasova i većom energetsom efikasnošću. Klasifikacija samo na osnovu zvuka bi potencijalno mogla da se primeni i u okviru benzinskih stanica gde bi se identifikacijom pogonskog goriva realizovao neki od vidova signalizacije kako bi se smanjila mogućnost sipanja pogrešnog goriva u vozilo.

Pored navedenih potencijalnih primena, integracijom ovakvog vida klasifikacije u “pametne gradove” bila bi moguća kontrola i smanjenje buke u urbanim sredinama gde bi se kretanje vozila sa višim nivoom buke ili tipom buke koja je neprijatnija po čoveka izmeštala iz kritičnih zona, kao što su bolnice i škole, a iz gusto naseljenih ili oblasti sa visokim nivoom refleksije zvuka preusmeravala u zone sa višim nivoom apsorpcije. Ovakav sistem bi pored identifikacije pogonskog goriva za pomenute primene, mogao da se integriše u već postojeće sisteme za monitoring saobraćaja, koji bi tada raspolagali sa dodatnim informacijama o broju vozila na različita pogonska goriva u okviru pojedinih mikrolokacija. Na ovaj način bi monitoring saobraćaja bio dodatno unapređen, što pruža mogućnost preciznijeg praćenja i kontrole zagađenja vazduha.

Postupku klasifikacije pogonskog goriva samo na osnovu zvuka posebno ide u prilog činjenica da je poslednjih godina audio klasifikacija privukla značajnu pažnju zbog svoje potencijalne primene u različitim oblastima, u rasponu od prepoznavanja govora do analize

zvukova okoline. Tehnološki napredak u razvoju hardvera i obradi podataka je posebno pogodovao razvoju složenih algoritama mašinskog i dubokog učenja koji se, između ostalog, mogu primeniti i na audio signale. Međutim, uprkos rastućem interesovanju, ostaje mnogo neistraženih oblasti gde se još uvek traga za izdvajanjem značajnih obeležja zvuka kako bi se postigla visoka tačnost klasifikacije (u literaturi na engleskom jeziku *accuracy* u kontekstu veštačke inteligencije), posebno kada su predmet klasifikacije podaci iz stvarnog sveta. Čovekovo čulo sluha i obrada percipiranog zvuka su još uvek neuporedivo složeniji u odnosu na bilo koji algoritam koji se realizuje na računaru, pa je kao preduslov za klasifikaciju upotrebom algoritama potrebno izdvojiti ona obeležja audio signala koja će za konkretnu primenu dati najbolje rezultate.

1.2. Pregled naučne literature

Pregled naučne literature može se podeliti u dve celine. Prva celina analizira postojeće primene akustičkih metoda koje se odnose na rad SUS motora, uzimajući u obzir i način akvizicije zvuka generisanog tokom njihovog rada. Druga celina se odnosi na primenu algoritama mašinskog i dubokog učenja za klasifikaciju audio signala, sa posebnim osvrtom na izdvajanje značajnih akustičkih obeležja rada SUS motora u zavisnosti od primene.

U okviru prve celine pregledanih naučnih radova može se zaključiti da akvizicija zvuka motora vozila sa unutrašnjim sagorevanjem i analiza karakteristika nije široko zastupljena tema. Prethodna istraživanja koja se odnose na akustičku analizu motora sa unutrašnjim sagorevanjem bila su prvenstveno usmerena na dijagnostiku anomalija [10-14], gde su, pored akustičkih merenja, korišćeni i drugi tipovi podataka, koji su zatim kombinovani kako bi se dobili najtačniji rezultati. Međutim, određeni broj istraživanja koristi isključivo akustičku analizu performansi SUS motora, prvenstveno za testiranje izolacionih materijala u motoru [15], ili za akustičku karakterizaciju pojedinih elemenata motora [16], dok je za potrebe primene ekoloških zahteva neophodno identifikovati vrstu pogonskog goriva motora. Pokušaji dijagnostifikovanja anomalija u radu SUS motora rezultovali su određenim komercijalnim rešenjima poput pametnog mikrofonskog niza proizvođača automobilskih komponenti *Magneti Marelli* [17, 18] koji se u motornom prostoru pozicionira čvrstom vezom u oblasti usisnog voda. Kod navedenih primena se pozicioniranje mikrofona vrši u samom motornom prostoru, što nije primenljivo za potrebe disertacije, obzirom da prikupljanje uzoraka zvuka ne bi trebalo da ometa kretanje vozila.

Prikupljanje zvučnih uzoraka rada SUS motora vozila realizovano je i za analizu buke u saobraćaju, pri čemu je cilj bilo određivanje kategorije vozila (teretno, putničko ili motocikl) [19-21], bez osvrta na pogonsko gorivo datih vozila. Prilikom analize buke, korišćeni mikrofoni su pozicionirani pored saobraćajnice, što takođe nije pogodno za potrebe disertacije, posebno ako se uzme u obzir evidentni napredak u zvučnoj izolaciji proizvođača vozila i razdaljina u odnosu na izvor zvuka.

Druga celina istražene naučne literature se odnosi na izdvajanje značajnih akustičkih obeležja rada SUS motora i na primenu algoritama mašinskog i dubokog učenja za klasifikaciju audio signala. Istraživanja čija su tema značajne karakteristike zvuka SUS motora pretežno su fokusirana na industrijsku primenu i na detekciju nepravilnosti u radu motora pokretanih na jedno od fosilnih goriva, benzin ili dizel [22-24]. U [25] je korišćena kompleksna kepsstralna analiza za istraživanje percepcije grubosti (*roughness*) u zvucima automobilskih motora. Iako kepsstralna analiza nije standardna metoda za direktno izračunavanje grubosti, autori su je koristili za izdvajanje relevantnih karakteristika signala koje su zatim analizirane sa stanovišta psihoakustike. Ova disertacija će takođe pokazati da je grubost jedno od ključnih obeležja pri analizi zvuka motora.

Značaj i efikasnost klasifikacije zasnovane na veštačkim neuronskim mrežama za akustičku karakterizaciju vozila prikazana je u mnogim novijim studijama [26-29]. U istraživanju [30] je prepoznata važnost klasifikacije vozila na osnovu zvuka kao prihvatljive alternative klasifikaciji vozila zasnovanoj na vizuelnim metodama. U ovom istraživanju, generisan je skup podataka sa snimcima zvuka vozila u prolazu u realnim uslovima saobraćaja. Ocena uspešnosti klasifikacije izražena je kao F1 rezultat, koji predstavlja harmonijsku sredinu preciznosti i osetljivosti. Za klasifikaciju je korišćena neuronska mreža sa nadgledanim učenjem i postignut je F1 rezultat od 83% pri razlikovanju dizel i benzinskih motora. U [31] je predstavljena integracija dubokog učenja i zvučnih podataka prikupljenih mobilnim uređajima kako bi se realizovala akustička karakterizacija vozila u pogledu ispravnosti. Jedan od ciljeva je bila i predikcija tipa pogonskog goriva. Iako je u ovom radu validacioni skup dao visoku tačnost od 98% za benzinske i 84% za dizel motore, performanse na skupu uzoraka za testiranje bile su značajno lošije. Važno je napomenuti za ovaj rad da je skup podataka sniman pod specifičnim uslovima, poput pozicioniranja mikrofona iznad motornog prostora sa otvorenom haubom, iznad zatvorene haube

i sa izduvne cevi na zadnjem delu vozila. Pored toga, skup podataka je augmentiran (proširen) kako bi se dobilo preko 2500 minuta audio signala. S druge strane, u [32] su postignuti bolji rezultati sa F1 vrednostima od 96,2% za dizel motore i 96% za benzinske motore. Međutim, podaci u ovom radu su bili ograničeni na određen broj specifičnih vozila i prikupljeni su u laboratorijskim uslovima. Ipak, prezentovani pristup i dobijeni rezultati smatraju se najsavremenijim za ovako složen zadatak, gde se suočavamo sa suptilnim razlikama u zvuku koju proizvode motori, koji su često slične zapremine, imaju isti broj taktova i koriste slične izduvne sisteme.

1.3 Predmet, cilj i doprinos istraživanja

Ova disertacija se bavi novim pristupom za prikupljanje zvukova vozila u realnim uslovima, izdvajanjem značajnih akustičkih obeležja i primenom adekvatnih algoritama mašinskog i dubokog učenja u cilju klasifikacije, sa posebnim fokusom na pravljenju razlike između vozila na benzin i dizel. Krajnji cilj istraživanja u okviru disertacije je razvoj samostalnog automatizovanog sistema za prikupljanje, analizu i klasifikaciju zvučnih zapisa SUS motora automobila u realnim uslovima na osnovu pogonskog goriva bez narušavanja privatnosti uzorkovanih vozila.

Posmatrano u celini, razvoj ovakvog sistema može se podeliti u tri etape. Prva etapa obuhvata prikupljanje zvučnih zapisa rada SUS motora, njihovu obradu i analizu kako bi se izvršila priprema zvučnih zapisa iz realnog okruženja za naredne dve etape. Druga etapa obuhvata izdvajanje relevantnih obeležja zvuka i njihovo mapiranje u odgovarajući format koji se koristi kao ulaz za pomenute algoritme klasifikacije, dok treća etapa obuhvata odabir, kreiranje arhitekture, prilagođenje i implementaciju odgovarajućih algoritama radi uspešne klasifikacije zvukova.

U fazi prikupljanja zvučnih zapisa, kako bi se dobili što verniji zvuci SUS motora sa minimalnim uticajem spoljnih faktora, definisan je novi pristup prikupljanja zvukova vozila, sa mikrofonom postavljenim na tlu [33], u okviru koga je ispitan uticaj položaja mikrofona ispod vozila u odnosu na motor kao izvor zvuka [34]. Analiza prikupljenih zapisa pokazala je da se najveće razlike između tipova goriva manifestuju u režimu praznog hoda motora [35], što je dovelo do postavljanja dodatnog cilja u razvoju akvizicionog sistema - izdvajanja tog režima rada [36]. U drugoj etapi, nakon identifikacije i izdvajanja željenog režima, istraživanje je usmereno na

pronalaženje ključnih obeležja zvuka koja omogućavaju razlikovanje između pogonskih goriva [37- 40], i njihovu upotrebu u algoritmima mašinskog i dubokog učenja. U trećoj etapi cilj je bio realizovati adekvatne metode mašinskog i dubokog učenja koje daju najbolje rezultate u klasifikaciji [41].

Ključni doprinos ovog istraživanja je formiranje nove banke uzoraka koja sadrži zvučne zapise rada SUS motora putničkih vozila u režimu praznog hoda snimljenih u realnim uslovima. Doprinos se ogleda i u identifikaciji i izdvajanju različitih obeležja zvuka kroz opsežnu analizu, postavljajući osnovu za dva napredna sistema klasifikacije, koji pre svega verifikuju zasnovanost pristupa disertacije. Prvi način klasifikacije je baziran na slikama sličnim spektrogramu (mel-spektrogrami, gamatonegrami i tempogrami) i koristi konvolucionu neuronsku mrežu (*convolutional neural network* - *CNN*) za klasifikaciju. Drugi sistem koristi psihoakustička obeležja i primenjuje algoritam samoorganizujućih mapa (*self-organizing maps* - *SOM*) za klasifikaciju. Oba sistema su pokazala izuzetne performanse, pri čemu je *CNN* algoritam postigao F1 rezultat od 95%, a *SOM* algoritam 97%. Originalnost ovog rada se pored dizajna novog namenskog sistema za prikupljanje uzoraka zvuka i kreiranja jedinstvene, visokokvalitetne baze zvukova SUS motora vozila, ogleda i u istraživanju pristupa klasifikaciji koji do sada nisu primenjivani u ovom kontekstu. Rezultati mogu značajno doprineti polju audio klasifikacije, nudeći novi pristup uzorkovanju zvukova vozila, povezujući percepciju slušaoca i ulazne formate za algoritme mašinskog i dubokog učenja, ostavljajući prostor za dodatno istraživanje i povećanje uspešnosti klasifikacije.

1.4 Organizacija disertacije

Izuzimajući uvod, doktorska disertacija je organizovana u još šest poglavlja. U drugom poglavlju je predstavljena akustika SUS motora. U ovom poglavlju je detaljno opisana konstrukcija SUS motora pokretanih na različita pogonska goriva, režimi rada motora, izvori zvuka prilikom rada motora, osnovne karakteristike zvuka generisanog radom motora, kao i pojmovi koji se odnose na SUS motore, a koriste se u nastavku disertacije. Nakon analize izvora zvuka prikazane su metode za snimanje zvuka SUS motora. Ovde su pobrojane primene različitih metoda snimanja i opisane odgovarajuće tehnike snimanja za svaku od metoda, obzirom da postoje velike razlike u

postavci snimanja ukoliko se radi npr. o dijagnostici vozila ili o monitoringu nivoa buke u okruženju.

Treće poglavlje predstavlja metode klasifikacije zvučnih zapisa. U ovom poglavlju su dati pregled i primene najčešće korišćenih algoritama mašinskog i dubokog učenja u audio klasifikaciji sa osvrtom na princip rada algoritma i na vrstu ulaznih podataka u algoritam.

Četvrto poglavlje u celosti opisuje dizajn i hardversku realizaciju akvizicionog sistema za prikupljanje uzoraka. U ovom poglavlju se prezentuje i obrada audio signala u vremenskom domenu za izdvajanje režima praznog hoda.

Tema petog poglavlja je izdvajanje akustičkih karakteristika zvuka SUS motora značajnih za klasifikaciju pogonskog goriva. Ovo poglavlje predstavlja opsežnu analizu dva pristupa: pristupa baziranog na mapiranju snimljenih zvukova u slike u formi spektrograma (spektrogram, mel-spektrogram, gamatonegram, tempogram itd.) i pristupa gde se vrši izdvajanje psihoakustičkih obeležja (glasnost, hrapavost, oštrina itd.).

Šesto poglavlje se odnosi na primenu klasifikacije SUS motora na osnovu zvuka. Kao završni korak disertacije u ovom poglavlju je opisan način primene i dati su konačni rezultati dva različita algoritma mašinskog i dubokog učenja koja za ulaz koriste drugačije reprezentacije audio signala opisane u šestom poglavlju.


U poslednjem, sedmom poglavlju izveden je zaključak sa pregledom najznačajnijih doprinosa za budući rad u oblasti klasifikacije vozila pokretana SUS motorima na osnovu zvuka prema pogonskom gorivu.

2. Akustika motora sa unutrašnjim sagorevanjem

Predmet istraživanja u disertaciji su zvukovi generisani motorima putničkih vozila, kao kategorije vozila koja je najviše prisutna u urbanim sredinama. Kod ove kategorije takođe postoje najveće razlike u zastupljenosti pogonskih goriva, dok se za pokretanje lakih komercijalnih i teretnih vozila pretežno upotrebljava dizel kao pogonsko gorivo. U ovom poglavlju je opisana konstrukcija, princip rada i izvori zvuka u motorima putničkih vozila pokretanih na različita pogonska goriva.


2.1. Konstrukcija motora sa unutrašnjim sagorevanjem

Klipni motori sa unutrašnjim sagorevanjem (SUS) predstavljaju pogonske mašine kod kojih se toplotna energija koja nastaje kao rezultat sagorevanja nekog od goriva koristi za realizaciju mehaničkog rada [42]. Ovi motori se mogu podeliti na “strujne” (raketne i mlazne) motore i motore promenljive zapremine radnog prostora. Obzirom na zastupljenost u putničkim vozilima [42], u ovoj disertaciji su od interesa motori promenljive radne zapremine, gde se dobijanje mehaničkog rada realizuje na račun ekspanzije produkata sagorevanja. Sagorevanje se odvija u komori za sagorevanje čija zapremina varira u zavisnosti od položaja klipa. U zavisnosti od klipnog mehanizma ovi motori se dele na “klasične” motore sa oscilujućim klipovima i “rotacione” motore sa obrtnim klipovima. Kako se upotreba rotacionih motora, zbog svojih praktičnih mana [42], u putničkim vozilima može smatrati zanemarljivom, a zvuk koji generišu tokom rada je gotovo identičan benzinskom motoru, u okviru ove disertacije nije relizovana posebna analiza ovog tipa motora. Klasični klipni SUS motor ostvaruje promenljivost zapremine radnog prostora uz pomoć klipa, klipnjače i kolenastog vratila - radilice gde se cilindrični klip kreće u radnom prostoru prinudno oscilirajući vođen kolenastim vratilom. Na slici 1 [43] je prikazan presek jednog takvog četvorocilindričnog motora zajedno sa pozicijom senzora broja obrtaja kolenastog vratila.



Slika 1. Presek četvorocilindričnog četvorotaktnog SUS motora

Klipni mehanizam se kreće unutar osnovne nepokretne strukture motora koja se sastoji od korita motora (kartera), bloka cilindara i cilindarske glave (slika 2) [44].



Slika 2. Poprečni presek jednog cilindra četvorotaktnog SUS motora

Pored ovih delova, na klipnom motoru se nalazi još niz elemenata i podsistema koji omogućavaju njegov rad poput sistema razvoda radne materije (bregasto vratilo, elementi

njegovog pogona, ventili, klackalice), sistema napajanja gorivom, sistema paljenja, sistema hlađenja, sistema podmazivanja, sistema startovanja itd.

Prostor ograničen cilindrom, klipom i cilindarskom glavom predstavlja radni prostor jednog cilindra, dok ukupnu zapreminu motora čini zbir zapremina radnih prostora pojedinačnih cilindara. Zapremina motora putničkih vozila je najčešće višestruko manja od zapremine motora transportnih vozila i radnih mašina. Proces energetske transformacije se odvija u radnom prostoru motora u više faza: izmena radne materije, sabijanje sveže radne materije, paljenje, sagorevanje i širenje produkata sagorevanja čiji je rezultat razvijanje mehaničkog rada.


2.1.1 Podela klipnih motora

Opšta podela klipnih motora može se izvršiti prema načinu odvijanja procesa sagorevanja, načinu izmene radne materije i konstrukcijskom izvođenju. Prema načinu odvijanja procesa sagorevanja, klipni motori se dele na oto motore i dizel motore. Kod oto motora paljenje smeše goriva i vazduha se obavlja stranom energijom tj pomoću varnice, pri čemu je smeša koja ispunjava radni prostor homogena. Pored drugih prednosti i mana, koje nisu od interesa u ovoj disertaciji, oto motore odlikuju relativno mali pritisci u cilindru i mogućnost brze promene režima rada [42]. Ovi motori se uobičajeno nazivaju i benzinski motori zbog najčešće korišćene vrste goriva. Kod dizel motora, paljenje goriva se vrši na račun energije sabijenog vazduha. Smeša kod dizel motora je heterogena, pa se u radnom prostoru nalaze zone smeše, čistog goriva i čistog vazduha. Dizel motore odlikuju viši pritisci u cilindrima što ima za posledicu znatno veću masu delova motora u odnosu na benzinske motore.

Prema načinu izmene radne materije, klipni motori se dele na četvorotaktne i dvotaktne motore. Kod četvorotaktnog motora radni ciklus se realizuje u četiri takta, što za posledicu ima četiri hoda klipa i dva obrtaja kolenastog vratila u toku jednog ciklusa. Prvi takt je usisavanje gde se cilindar kreće od krajnje gornje tačke (spoljne mrtve tačke - SMT) do krajnje donje tačke (unutrašnje mrtve tačke - UMT) povećavajući zapreminu i stvarajući depresiju tako da dolazi do usisavanja čistog vazduha, ako se radi o dizel motoru ili smeše benzina i vazduha ukoliko se radi o benzinskom motoru. Drugi takt je sabijanje gde se cilindar kreće od krajnje donje tačke do krajnje gornje tačke sabijajući čist vazduh ili smešu. Pri kraju sabijanja dolazi do paljenja smeše koja se

kod benzinskih motora pali varnicom, dok se kod dizel motora tada vrši ubrizgavanje i samozapaljivanje goriva.

Proces sagorevanja nije poseban takt već zahvata kraj sabijanja i početak širenja. Sagorevanjem smeše naglo se povećavaju pritisak i temperatura u cilindru i dolazi do konverzije toplotne energije u mehaničku. Treći takt je širenje i u toku ovog takta se klip, usled naglog povećanja pritiska kao posledice sagorevanja, kreće od gornje krajnje tačke ka donjoj krajnoj tački. Četvrti takt je izduvavanje i u ovom taktu dolazi do pražnjenja radnog prostora. Dolaskom klipa blizu donje krajnje tačke otvara se izduvni ventil na vrhu radnog prostora pa se najpre pod dejstvom pritiska u cilindru (usled nepotpune ekspanzije) produkti sagorevanja izbacuju iz radnog prostora, a zatim i sam klip svojim kretanjem od donje krajnje tačke ka gornjoj krajnjoj tački izbacuje preostali gas. Promena pritiska u cilindru za benzinski i dizel motor u toku celokupnog procesa rada motora je prikazana na slici 3.



Slika 3. Idealizovana promena pritiska u cilindru a) benzinskog i b) dizel motora

Dvotaktni motori proces usisavanja, sabijanja, sagorevanja i izduvavanja realizuju u dva takta. Vremenom je primena ovih motora kod putničkih vozila isčezla, pa se sada ovakvi motori mogu pronaći samo kod putničkih vozila od istorijskog značaja. Razlog za to je visok stepen zagađenja koji je rezultat sagorevanja smeše goriva i ulja neophodne za funkcionisanje ovakvog tipa motora.

Prema konstrukcijskom izvođenju, motori mogu biti konstruisani na više načina u zavisnosti od konkretne primene. Podela može biti na osnovu broja cilindara, rasporeda cilindara, broja radnih klipova u cilindru, načina izvođenja klipnog mehanizma, načina dejstva, brzohodnosti motora, namena, vrste hlađenja, vrste korišćenog goriva (gasni, sa tečnim gorivom i višegorivi


motori). Obzirom da se u putničkim vozilima koriste brzohodni motori sa jednim klipom po cilindru, značajne razlike u konstrukcijskom izvođenju se uglavnom odnose na broj cilindara, položaj cilindara i raspored cilindara. Broj cilindara u ovim vozilima uglavnom varira od tri do šesnaest, pri čemu su motori sa četiri cilindra najzastupljeniji. Položaj cilindara kod putničkih vozila može biti vertikalni (najčešće u upotrebi zbog najjednostavnije konstrukcije), horizontalni ili pod uglom (vertikalni motor prilagođen motornom prostoru). Raspored cilindara može biti linijski (ose cilindara su međusobno paralelne i u istoj ravni), V-motor (ose cilindara zaklapaju određeni ugao i seku se u osi motora), bokser motor (horizontalni motor - cilindri su jedan naspram drugog), dok ostale konfiguracije motora nisu karakteristične za putnička vozila.

2.2. Izvori zvuka u motorima sa unutrašnjim sagorevanjem

Obzirom da se kod putničkih vozila motori sa unutrašnjim sagorevanjem smatraju dominantnim izvorom buke (zvuka koji generiše vozilo i koji se kao neželjeni zvuk smatra bukom) [45] u odnosu na sve druge izvore poput buke generisane kotrljanjem guma po podlozi ili buke nastale strujanjem vazduha usled kretanja vozila, identifikacija porekla buke predstavlja osnov za unapređenje dizajna vozila, smanjenje negativnog uticaja na životnu sredinu i poboljšanje komfora vozača. Pregledna istraživanja, koja daju istorijski prikaz identifikacije izvora buke motora [46, 47], ukazuju kako su se percepcija i merenje buke razvijali tokom vremena. U ranim fazama razvoja SUS motora, buka je smatrana neizbežnim nusproduktom mehaničkog rada, pa stoga njena kontrola ili smanjenje nisu predstavljali prioritet u toku projektovanja vozila. Kako je dizajn motora postajao složeniji, a upotreba automobila rasla, javila se zabrinutost zbog negativnog efekta buke po zdravlje što je podstaklo detaljnija istraživanja o izvorima buke.

Primarni izvori buke kod SUS motora potiču od procesa sagorevanja, mehaničkih sklopova u radu i izduvnog sistema [45]. Buka sagorevanja prvenstveno nastaje usled brze promene pritiska u cilindru prilikom paljenja i sagorevanja smeše goriva i vazduha, pri čemu postoje značajne razlike između benzinskih i dizel motora zbog samog načina sagorevanja (slika 4). Naime, kod benzinskih motora, zbog nižih pritisaka u cilindru, paljenje smeše se ostvaruje varnicom, dok su kod dizel motora pritisci znatno viši, što dovodi do zagrevanja vazduha usled naglog sabijanja i rezultira samozapaljivanjem smeše. Dodatno se kod dizel motora, sa ciljem ravnomernog sagorevanja, oblikom klipa i/ili mehanizmima u usisnom kolektoru ostvaruje vrtloženje

vazduha. Buka sagorevanja se javlja pri kraju takta kompresije i tokom narednog takta ekspanzije. Brza promena pritiska usled sagorevanja prenosi se kroz strukture motora i postaje deo buke koja se širi kroz vazduh. Kod benzinskih motora, sagorevanje je, usled upotrebe varnice, kontrolisanije i odvija se pod nižim pritiscima, što rezultira tišim i ujednačenijim radom. S druge strane, dizel motori imaju viši stepen kompresije i smeša se pali samozapaljivanjem, pa dolazi do naglih promena pritiska tokom sagorevanja, što dovodi do intenzivnije buke i posebno karakterističnog "kuckanja". Istorijski gledano, ovo "kuckanje" kod dizel motora bio je jedan od prvih oblika buke koji je identifikovan i meren, posebno kako je dizel motor postajao sve popularniji u komercijalnim i teškim vozilima [46]. Mogućnost merenja i kontrole brzine porasta pritiska, koju je omogućio tehnološki napredak poslednjih decenija, postala je ključna u smanjenju buke sagorevanja, naročito kod dizel motora.



Slika 4. Način sagorevanja i pritisci u cilindru za a) dizel i b) benzinski motor [47]

Buka koju generišu mehanički sklopovi u radu se takođe značajno razlikuje kod dizel i benzinskih motora. Kod oba tipa motora, mehanička buka potiče od pokretnih delova, kao što su klipovi, klipnjače, kolenasto vratilo, elementi pumpe visokog pritiska (ukoliko motor ima takav

sistem ubrizgavanja), sistema ventila i razvoda itd. Međutim, kao što je napomenuto ranije u ovom poglavlju, zbog robusnijih i težih komponenti dizel motori obično generišu viši nivo mehaničke buke. Viši pritisci i veće sile koje se generišu u toku sagorevanja kod dizel motora zahtevaju jače materijale, što za rezultat ima viši nivo vibracija i mehaničkih zvukova. Sa druge strane, buka mehaničkih sklopova kod benzinskih motora je manja jer su komponente motora lakše, rad motora je preciznije kontrolisan i u najvećem broju slučajeva ubrizgavanje benzinskih motora karakteriše odsustvo pumpe visokog pritiska.

U značajne izvore buke SUS motora spada i buka izduvnog sistema, iako su razlike između benzinskih i dizel motora manje izražene. Oba tipa motora zahtevaju izduvne sisteme za kontrolu i smanjenje buke, ali sastav izduvnih gasova i njihove karakteristike protoka ne utiču dominantno na percepciju zvuka. Dizel motori, sa svojim višim obrtnim momentom i radom sa nižim brojem obrtaja radilice, uobičajeno proizvode dublji, rezonantniji zvuk na izduvnom sistemu u poređenju sa višim zvukom kod benzinskih motora (izraženije komponente na višim frekvencijama). Identifikacija buke izduvnog sistema kao značajnog izvora dovela je do razvoja različitih sistema prigušivanja, dizajniranih da smanje jake i neprijatne zvukove koji potiču od SUS motora.

Iako se pomenutim izvorima buke motora mogu izdvojiti specifične vremenske instance u procesu rada motora gde su njihovi doprinosi veći, i dalje je teško precizno ih razdvojiti samo na osnovu merenja buke. Razlog za to je što je emitovanje zvuka svakog od izvora buke i vremenski i prostorno jako blizu jedan drugog. Različite metode obrade signala, uključujući statističku analizu, spektralnu analizu, vremensko-frekvencijsku analizu i transformaciju talasićima (*wavelet*), korišćene su za analizu buke motora [48-50]. Ove metode zasnovane su na prikazu energije koju generišu komponente motora kako bi se dobile informacije o buci motora. Signali se prvo predstavljaju u određenom domenu, na primer vremenskom, frekvencijskom ili zajedničkom vremensko-frekvencijskom domenu. Izvori buke se zatim identifikuju na osnovu raspodele energije signala. Međutim, izvori buke sa nižim nivoom energije često ostaju neidentifikovani ovim metodama, jer one prenose informacije o energiji signala tokom transformacije između domena, ali ne pružaju dovoljno detaljnu separaciju tih izvora. Tako, izvori buke sa niskim nivoom energije mogu biti maskirani bukom sagorevanja (njihov nivo može biti ispod praga detekcije). Stoga, ove metode zasnovane na prikazu energije pokazuju izvesnu ograničenost za detaljnu identifikaciju zvukova koji su generisani ubrizgavanjem goriva ili pokretima ventila.

Primenom metoda baziranih na prikazu energije signala i koristeći principe rada SUS motora, do sada je uočeno da se buka sagorevanja uobičajeno nalazi u opsegu do 500 Hz [51]. Kod dizel motora je karakteristično da značajan izvor buke predstavlja sistem ubrizgavanja, pre svega pumpa za gorivo, čija je funkcija da generiše visok pritisak goriva, ali i brizgači čija je funkcija da rasprše gorivo pod visokim pritiskom. Motore koji koriste nadpunjenje vazduhom u vidu mehaničkog ili turbo kompresora karakteriše zvuk visoke frekvencije, koji je poznat kao turbo zviždanje „*whine*“. Ovaj zvuk karakteriše dominantna frekvencija koja je rezultat frekvencije generisane rotacijom turbine i ukupnog broja lopatica kompresora turbo punjača. U motorima sa velikom radnom zapreminom prisutna je i buka generisana usisavanjem veliki količine vazduha u usisni kolektor.

SUS motori putničkih vozila takođe generišu različitu vrstu i nivoe buke u zavisnosti od režima rada. Tipični režimi rada su režim praznog hoda, režim delimičnog opterećenja i režim potpunog opterećenja (*wide open throttle - WOT*), pa je tako nivo buke najniži u režimu praznog hoda, kada je i broj obrtaja kolenastog vratila najmanji, zatim je nivo buke viši u režimu delimičnog opterećenja, a najviši u režimu potpunog opterećenja.

2.3. Metode za snimanje zvuka SUS motora

Obzirom da je tema ovog istraživanja snimanje i klasifikacija zvukova generisanih radom SUS motora putničkih vozila, što preciznije i vernije snimanje ovakvih zvukova predstavlja osnovni preduslov za ostvarivanje tog cilja. Pozicioniranje mikrofona za ovakvu namenu zahteva pažljivo razmatranje jer se snimaje ne realizuje za motore koji se nalaze van vozila, na testnom stolu, već na krajnji rezultat snimanja utiču konstrukcija vozila, položaj motora i različiti tipovi zvučne izolacije koju proizvođači ugrađuju sa ciljem povećanja komfora putnika i smanjenja buke okoline.

U ovom poglavlju su analizirani dosadašnji pristupi i metode pozicioniranja mikrofona za snimanje zvuka SUS motora koji se nalaze u vozilima. Za ovakav način snimanja prisutna su dva scenarija, jedan se odnosi na vozila koja su u stanju mirovanja, a drugi na vozila u pokretu.

Aдекватno pozicioniranje mikrofona je za svaki od scenarija veoma važno jer direktno utiče na kvalitet i zvučni sadržaj zabeleženog zvučnog signala.

2.3.1. Snimanje zvuka stacionarnih vozila

Snimanje zvuka stacionarnih vozila pruža mogućnost relativno kontrolisanog okruženja za dobijanje zvučnih zapisa u različitim režimima rada motora. Tipično pozicioniranje mikrofona u ovom scenariju se razlikuje zavisno od svrhe snimanja. Ukoliko se vrše snimanja koja se odnose na komfor putnika, mikrofoni ili mikrofoni se najčešće pozicioniraju u kabini vozila [52-54], dok se za detekciju anomalija u radu motora mikrofoni pozicioniraju u motornom prostoru vozila [18][55, 56].

2.3.1.1 Pozicioniranje mikrofona u kabini vozila

Snimanje zvuka SUS motora u kabini vozila predstavlja postupak koji omogućava da se izvrši procena kako putnici percipiraju buku motora. Konstrukcija kabine se u praksi ponaša kao filter koji u zavisnosti od veličine kabine, ugrađenih materijala i nivoa zvučne izolacije modifikuje izvorni zvuk motora. Pozicioniranje mikrofona unutar kabine je veoma zastupljena tema u istraživanjima gde su [52-54] samo neki od primera kako se mikrofoni ili mikrofoni mogu pozicionirati. Na osnovu ovih i sličnih istraživanja moguće je doći do zaključka da ne postoji jedinstveni idealan položaj mikrofona unutar kabine vozila već se pozicija prilagođava konkretnom istraživanju.

Prema istraživanju [52] mikrofoni bi trebalo da budu postavljeni u blizini tvrdih površina ili u uglovima kabine, gde su stojeći talasi i refleksije zvuka najizraženiji. Razlog za to je što buka motora na niskim frekvencijama može izazvati osećaj nelagode, pa je efikasno beleženje ovih frekvencija ključno za unapređenje kvaliteta zvuka, koristeći tehnike poput aktivne kontrole buke.

U [53] je istaknut značaj automatske lokalizacije mikrofona unutar kabine za prezentovanu akustičku analizu, koja omogućava precizno merenje zvuka u realnim uslovima. Mikrofoni se uobičajeno pozicioniraju blizu naslona za glavu kako bi simulirali ljudsku percepciju zvuka ili na

mestima gde dolazi do prodiranja zvuka, kao što su prozori ili vrata. Ove pozicije omogućavaju sveobuhvatno beleženje interakcije zvuka sa unutrašnjim površinama kabine, što se odražava na ukupni profil vozila sa akustičkog aspekta.

Pored snimanja zvuka SUS motora u kabini, mikrofoni se mogu pozicionirati i za ispitivanje uticaja drugih komponenti i sistema na vozilima. Istraživanje [54] analizira uticaj buke sistema klima uređaja na putnike u vozilu. Konkretno u ovom istraživanju mikrofoni su postavljeni blizu otvora kroz koje struji vazduh, što dodatno ukazuje na činjenicu da je pozicija mikrofona unutar kabine relativna i da ju je potrebno prilagoditi konkretnom snimanju zvuka.

2.3.1.2 Pozicioniranje mikrofona u motornom prostoru

Snimanje zvuka direktno u motornom prostoru omogućava znatno precizniju analizu buke samog motora i razdvajanje mehaničke i buke koja potiče od procesa sagorevanja. Mikrofoni pozicionirani iznad motornog prostora idealni su za snimanje direktnog zvuka motora, jer ova pozicija pruža nefiltrirani zvuk bez ometajućih efekata i refleksija. U zavisnosti od cilja istraživanja, mikrofoni se mogu pozicionirati i u neposrednoj blizini pojedinačnih izvora buke, poput izduvnog sistema, pumpe visokog pritiska, bloka motora, ventila itd. Postavljanjem mikrofona u različite tačke oko motora moguće je formirati detaljnu akustičku mapu koja pomaže u proceni kako različite komponente motora doprinose ukupnom nivou buke.

U cilju otkrivanja anomalija rada SUS motora putem analize zvuka, u okviru istraživanja opisanog u [55], mikrofoni su pozicionirani u više tačaka blizu komponenti kao što su usisni i izduvni sistem, kao i blok motora. Na ovaj način se prikupljaju akustički podaci koji omogućavaju treniranje modela mašinskog učenja za detekciju neispravnosti poput lošeg rada ventila ili nepravilnog sagorevanja.

Značaj preciznog pozicioniranja mikrofona prilikom dijagnostikovanja kvarova motora na bazi spektrograma i veštačkih neuronskih mreža je detaljno opisan u [56]. Ovde se takođe mikrofoni postavljaju blizu komponenti sa visokim nivoom buke, poput izduvnog kolektora i glave motora, čime se obezbeđuje detaljno snimanje kompleksnih zvučnih signala motora.

Dobijeni snimci se koriste za kreiranje spektrograma, koji se potom obrađuju neuronskim mrežama u cilju identifikacije potencijalnih kvarova.

U [18] se istražuje dijagnostika sistema za ubrizgavanje i sagorevanje na osnovu akustičke emisije motora sa direktnim ubrizgavanjem goriva i turbo punjačem. Mikrofonu su pozicionirani blizu usisnog i izduvnog sistema kako bi snimili zvuke koji ukazuju na nepravilnosti u sagorevanju ili neregularnosti u regulaciji smeše goriva i vazduha. Ovi zvučni podaci omogućavaju identifikaciju odstupanja u radu sistema, što doprinosi unapređenju dijagnostike.

2.3.2 Snimanje zvuka vozila u pokretu

Za razliku od vozila u stacionarnom stanju, snimanje zvuka vozila u pokretu zahteva postavljanje mikrofona u dinamičnim okruženjima. Glavni izazov u ovoj situaciji je snimanje zvuka motora zajedno sa spoljnim faktorima, kao što su buka guma, vetar i buka drugih vozila u saobraćaju. Adekvatno pozicioniranje mikrofona predstavlja ključni faktor u dobijanju kvalitetnog audio zapisa i razlikovanju ovih izvora zvuka.

2.3.2.1 Pozicioniranje mikrofona pored putanje kretanja vozila

Za vozila u pokretu, jedna od najčešće korišćenih postavki za snimanje je postavljanje mikrofona pored puta. Ovakvo pozicioniranje mikrofona omogućava analizu buke pri prolasku vozila, što je važno za procenu akustičke emisije vozila koja je predmet različitih propisa o nivou buke. Istraživanja poput [57] se bave korišćenjem većeg broja mikrofona, koji formiraju mrežu, postavljenih na predefinisanoj rastojanju od puta kako bi se zabeležile i izdvojile detaljne akustičke karakteristike vozila dok prolaze. Postavka mikrofona u vidu mreže omogućava merenje promena nivoa zvuka dok se vozilo približava i prolazi, pružajući sveobuhvatan uvid u to kako buka varira u funkciji vremena i rastojanja.

Visina na kojoj se pozicionira mikrofoni ili mikrofoni, kao i udaljenost od površine puta, su takođe faktori koji znatno utiču na kvalitet i vernost prikupljenih zvučnih signala. Uobičajeni pristup podrazumeva postavljanje mikrofona na visini od 1,2 do 1,5 metara kako bi se simulirala

visina ljudskog uha, omogućavajući uvid u to kako pešaci pored puta percipiraju buku. Značaj pozicioniranja mikrofona u visini ljudskog uha, između ostalog, analiziran je u okviru istraživanja [58] gde je detaljno razmatran akustički potpis za klasifikaciju vozila.

2.3.2.2 Adaptivno pozicioniranje mikrofona

U slučajevima gde je potrebno da mikrofoni prate vozilo, kao što su kontrolisani testovi na stazama, koriste se adaptivne postavke mikrofona. Mikrofon se može postaviti na vozilo koje se kreće konstantnom brzinom paralelno sa testnim vozilom kako bi se zabeležio zvuk motora pod različitim uslovima vožnje u realnom vremenu. U istraživanju [59] analizirano je kako adaptivne postavke mogu poboljšati detekciju i klasifikaciju vozila u realnom okruženju, pružajući potrebne podatke o akustici vozila tokom kretanja.

Alternativno, mikrofoni se mogu postaviti na visoke stubove ili letelice, poput dronova, kako bi se zabeležili zvuci iz ptičje perspektive [60]. Ova metoda pruža široku primenu i korisna je za studije o životnoj sredini ili procenu kako se zvuci koji potiču iz različitih izvora, uključujući i vozila, manifestuju u različitim okruženjima. Uloga takvih naprednih postavki mikrofona je analizirana u [61], diskutujući o njihovoj primeni u inteligentnim transportnim sistemima za praćenje buke i saobraćaja.

3. Klasifikacija zvučnih zapisa vozila

Razvoj algoritama koji omogućavaju mašinama da koriste, memorišu i samostalno kombinuju različite podatke (od “sirovih” pa do obrađenih kompleksnih podataka), u savremenoj terminologiji poznatih pod nazivom “veštačka inteligencija”, omogućio je da mašine u skupovima podataka “uoče” karakteristike koje su apstraktne ili na višem nivou, kao i da donose odluke bez učešća čoveka [62, 63]. Paralelno sa tehnološkim napretkom hardvera, ovi algoritmi su omogućili da se razviju tehnike čiji je spektar primena veoma širok, od prepoznavanja slika do obrade prirodnog jezika, što se odrazilo na različite domene, kao što su zdravstvo, robotika itd. Veštačka inteligencija je značajno unapredila i druge oblasti, poput obrade akustičkih signala, zamenjujući tradicionalne metode savremenim pristupima koji koriste mogućnost brze obrade velike količine podataka i sofisticirane algoritme.

Među različitim tehnikama veštačke inteligencije, duboke neuronske mreže (*deep neural networks* - *DNN*) su postale veoma zastupljene zbog svoje sposobnosti da imitiraju neuronsku strukturu ljudskog mozga i autonomno otkriju složene obrasce u velikim skupovima podataka [64, 65]. Jedna od najzastupljenijih primena veštačke inteligencije u oblasti akustike je automatsko prepoznavanje govora gde se modeli, poput *DNN*-a i *transformera* (*transformer*), koriste za transkripciju izgovorenog jezika u tekst, kao što je prikazano u [66]. Veštačka inteligencija se takođe primenjuje za potrebe klasifikacije zvuka, poput prepoznavanja muzičkih žanrova i detekcije zvukova iz okoline, pri čemu su se konvolucione neuronske mreže (*CNN*) pokazale kao posebno efikasne [21]. Pored ovih primena, unapređenje razumljivosti govora i smanjenje uticaja šuma/buke u telekomunikacijama takođe predstavljaju polja primene veštačke inteligencije za obradu zvučnih signala [67]. Algoritmi veštačke inteligencije u analizi zvuka primenjuju se i za segmentaciju zvuka, anotaciju i izdvajanje karakteristika audio signala [68], gde se složeni zadaci koji su prethodno zahtevali manuelni pristup automatizuju.

3.1 Akustička karakterizacija vozila

3.1.1 Karakterizacija vozila na osnovu akustičkog potpisa

U oblasti gde se mogu primeniti različiti algoritmi veštačke inteligencije spadaju i akustička karakterizacija vozila na osnovu čujnih zvukova koje oni proizvode, detekcija vozila, klasifikacija i dijagnostika kvarova. Kao što je navedeno u prethodnom poglavlju, zvuci vozila nastaju kao kombinacija zvuka motora, zvuka izduvnog sistema, interakcije između guma i podloge po kojoj se vozilo kreće i strujanja vazduha oko karoserije. Analiza ovih karakterističnih „akustičkih potpisa“ može, na primer, pružiti uvid u tip vozila, brzinu i režim rada. Značajan broj istraživanja se fokusira na klasifikaciju vozila prema kategoriji (npr. automobil, autobus, kamion), međutim postoje i pristupi koji imaju za cilj klasifikaciju tipa motora na osnovu pogonskog goriva [69-75].

Cilj istraživanja [70], koje se odnosi na klasifikaciju vozila na osnovu zvuka koji emituju dok su u pokretu, je razlikovanje kategorije vozila, kao što su autobusi, automobili, motocikli i kamioni. Ovako dobijeni audio signali su složeni jer zvuci imaju različito poreklo, kao što su gume, motor i trenje. U okviru istraživanja [72] je istaknut potencijal akustičkih senzora za klasifikaciju vozila, pri čemu se u obzir uzimaju faktori, kao što su tip motora, veličina vozila, brzina i stanje podloge po kojoj se vozilo kreće. Studije poput [73] pokazale su da vremensko-frekvencijske reprezentacije složene prirode zvukova vozila u vidu talasića (*wavelet*) mogu povećati efikasnost klasifikacije. Ova studija takođe pokazuje mogućnost razlikovanja kategorije vozila, kao što su automobili i kamioni sa zadovoljavajućom tačnošću, koristeći samo akustičke osobine i modele mašinskog učenja. U novijoj studiji [74] koriste se napredne tehnike za izdvajanje obeležja i klasifikaciju vozila upotrebom modela mašinskog učenja. Rad poput [66] prikazuje pristup koji analizira i izdvaja značajne frekvencijske komponente na osnovu kojih se zatim vrši klasifikacija vrste vozila.

3.1.2 Klasifikacija vozila prema tipu goriva

Klasifikacija vozila prema tipu goriva, na osnovu zvukova koje emituju, fokusira se na prepoznavanje vozila sa različitim vrstama motora i goriva, kao što su benzinska, dizel, hibridna i

električna vozila. Svaka od ovih vrsta vozila proizvodi specifične akustičke potpise zbog razlika u načinu rada motora, konstrukcijama izduvnih sistema i celokupnoj konstrukciji. Kao što je već obrazloženo u prethodnom poglavlju, dizel motori uobičajeno generišu zvukove koji imaju nižu frekvenciju i intenzivniji su u poređenju sa benzinskim motorima, što se često koristi u modelima klasifikacije. S druge strane, hibridna i električna vozila karakterišu znatno niži nivoi generisanog zvuka (buke), naročito pri manjim brzinama, gde su električna vozila gotovo nečujna osim zvukova nastalih interakcijom između guma i podloge i pomoćnih sistema, tj. veštački generisanim zvukom, koji je obavezan kako bi se pešaci upozorili na prisustvo vozila [76].

Automatska klasifikacija vozila i tipova motora prema pogonskom gorivu na osnovu zvukova koje vozila proizvode, a koji zavise od faktora kao što su brzina, tip motora, uslovi na putu itd, predstavljena je u [32]. Drugi sistem za klasifikaciju vozila (motora vozila) na osnovu akustičkih podataka prikazan je u [30], sa fokusom na dve osnovne klasifikacije: razlikovanje dizel i benzinskih motora i razlikovanje teretnih i putnička vozila. U akustičkoj karakterizaciji vozila, jedan od ključnih problema je što zvuci sličnih vozila mogu varirati u zavisnosti od faktora, kao što su buka okoline, model vozila i godina proizvodnje [77]. Da bi se realizovali efikasni klasifikatori, ova studija naglašava važnost raznovrsnih skupova podataka koji uzimaju u obzir varijacije u nivoima buke, modele vozila i različite uslove snimanja. Značajan pad tačnosti klasifikacije uočen je u slučajevima kada se pozadinska buka (pod kojom se podrazumeva ambijentalna buka i električni šum opreme za akviziciju) tokom testiranja razlikuje od seta podataka za obuku klasifikacionog modela.

Različite tehnike obrade audio signala i modeli mašinskog učenja za klasifikaciju tipova motora vozila prema pogonskom gorivu na osnovu zvuka analizirane su u [69]. Ovo istraživanje realizovano je upotrebom baze uzoraka zvuka od 80 snimaka, gde su ravnomerno zastupljeni benzinski i dizel motori. Akustički potpisi vozila, uključujući zvuk guma i motora, snimljeni usmerenim mikrofonom, korišćeni su u [78] za klasifikaciju vozila na osnovu tipa goriva i drugih karakteristika. Pristup je zasnovan na sposobnosti slušalaca da razlikuju zvukove vozila, a metodologija se oslanja na tehnike iz prepoznavanja govora.

3.2 Skupovi podataka, obeležja i algoritmi

3.2.1 Skupovi podataka

Skupovi podataka imaju ključnu ulogu u mašinskom i dubokom učenju, jer predstavljaju osnov za obuku modela koji kasnije treba da ostvare što „tačniju“ predikciju. Kvalitetan i reprezentativan skup podataka omogućava algoritmima da uče na osnovu postojećih obrazaca, odnosa i karakteristika u podacima, što doprinosi boljoj generalizaciji modela i njegovom uspehu u predviđanju novih, nepoznatih informacija. Raznovrsni i ravnopravno zastupljeni podaci takođe su od suštinskog značaja za smanjenje „pristrasnosti“ u modelima, jer omogućavaju ravnomerno predstavljanje različitih scenarija i time smanjuju verovatnoću donošenja pristrasnih ili netačnih odluka.

Pravilno označeni podaci unutar skupa omogućavaju modelima da prepoznaju ključne karakteristike koje utiču na izlazne rezultate, čime se pojednostavljuje proces izdvajanja važnih obeležja. Optimalna podela skupa podataka na delove za trening, validaciju i testiranje dodatno omogućava pravilnu procenu performansi modela, osiguravajući da on ne samo dobro funkcioniše na poznatim podacima, već ima i sposobnost tačne predikcije novih nepoznatih uzoraka. Standardizovani skupovi podataka često služe kao referentne tačke u istraživačkim radovima, jer omogućavaju da se različiti algoritmi uporede i da se u kontrolisanim uslovima unaprede metode. Skupovi podataka se u zavisnosti od oblasti primene još nazivaju baze uzoraka, banke uzoraka, setovi ili skupovi podataka (datasetovi - *dataset*-ovi) itd.

Usled važnosti skupa podataka, formiranje različitih baza uzoraka predstavlja bitan doprinos unapređenju klasifikacije u oblasti akustike. Do vremena u kome je pisana ova disertacija, broj dostupnih baza uzoraka koje se odnose na zvuke automobila, u odnosu na druge tipove zvukova, je veoma mali. Baza uzoraka *IDMT Traffic* [79] je specifično formirana za akustičku klasifikaciju vozila predstavljenu u istraživanju [74]. U [69] su korišćeni snimci 21 različitog proizvođača vozila, čime je unapređena sposobnost modela da generalizuje rezultate na različite vrste vozila. Audio uzorci korišćeni za kategorizaciju zvukova vozila u [32] prikupljeni su snimanjem vozila u saobraćaju i iz testova na ispitnim stolovima. Sistem u radu [30] testiran je na skupu podataka prikupljenih iz različitih stvarnih urbanih okruženja.

3.2.2 Obeležja korišćena kao ulaz za modele veštačke inteligencije

Izdvojene karakteristike audio signala iz baze uzoraka direktno utiču na uspešnost klasifikacije. Ove izdvojene karakteristike, poput spektra, energije, entropije, glasnosti i ostalih, nazivaju se obeležja, atributi, parametri ili na engleskom *features*. U zavisnosti od primenjenog algoritma, skup obeležja koji će se koristiti se može „manuelno“ definisati (npr. unapred se definiše pre treniranja), dok se kod druge vrste algoritama automatski vrši izdvajanje obeležja koja su najznačajnija za preciznu klasifikaciju.

Uslovi snimanja uzoraka, sadržaj baze, i sam algoritam klasifikacije spadaju u ključne faktore koji utiču na izbor audio obeležja. Modeli veštačke inteligencije se oslanjaju na ona akustička, odnosno audio obeležja koja će najviše oslikati specifičnosti svake od klasa. Na primer, kao što je navedeno u prethodnom poglavlju, dizel motori obično imaju izraženije komponente signala na nižim frekvencijama, kao i naglašeniji harmonijski sadržaj u poređenju sa benzinskim motorima. Uobičajena akustička svojstva korišćena u dosadašnjim istraživanjima koja se odnose na klasifikaciju vozila su spektralni sadržaj, harmonijska struktura, varijacije u vremenu i karakteristike zasnovane na energiji. Tako su mel-spektrogrami, mel-frekvencijski kepralni koeficijenti (*mel-frequency cepstral coefficients* - *MFCC*) i gammatone frekvencijski kepralni koeficijenti (*gammatone-frequency cepstral coefficients* - *GFCC*) primenjeni u istraživanju [74] za akustičku klasifikaciju vozila. *MFCC* koeficijenti, jedno od najčešće korišćenih obeležja, takođe su primenjeni u drugim studijama [80, 81]. Obeležja akustičkih signala su dodatno analizirana u istraživanju [81] kako bi se eliminisala buka koja nije povezana sa radom vozila, npr. zvuci sirena, pre nego što se izvrši klasifikacija. U [31] je poboljšana tačnost razlikovanja tipova vozila i dijagnostike kvarova integrisanjem *MFCC* karakteristika i karakteristika zasnovanih na brznoj Furijeovoj transformaciji (*fast Fourier transform* - *FFT*).

Izdvajanjem ključnih obeležja iz frekvencijskog domena audio signala vozila u [69], kao što su spektralni centroid, visina tonova i koeficijent tonaliteta, formirani su vektori obeležja koji su poslužili za različite klasifikacione modele. Spektralne karakteristike zvuka motora, kao što su prirodna frekvencija motora i njeni harmonici, kao i nove akustičke karakteristike, poput tristimulus-a i M-stimulus-a, su osnovne komponente koje se koriste u klasifikaciji zvuka vozila u

istraživanju [75]. Sa ciljem da se postigne sveobuhvatnija reprezentacija akustičkog potpisa vozila, u [82] je predložena metoda koja integriše dva skupa karakteristika: harmonijske komponente i ključne frekvencijske komponente, koje sadrže druge važne akustičke karakteristike, kao što je zvuk trenja guma.

Raspoloživi hardver za obradu signala i njegove performanse neretko utiču i na izbor audio obeležja, obzirom da se neka obeležja relativno jednostavno računaju, dok su druga veoma zahtevna u pogledu resursa. Obeležja u vremenskom domenu, kao što su kratkoročna energija, broj prolazaka kroz nulu (*zero crossing rate* - *ZCR*) i osnovna frekvencija (frekvencija tona), koja su jednostavnija za računanje, primenjena su u [70]. Metoda iz ove studije koristi vektore obeležja izračunate u regionima veće energije, uklanjajući pomoću filtera regione manje energije koji obično odgovaraju pozadinskoj buci, čime se poboljšava tačnost klasifikacije. Fokusiranjem samo na delove signala sa velikom energijom, koji imaju manje šuma, kod ove metode se pravi kompromis između zahtevnosti proračuna i tačnosti klasifikacije. Pristup predstavljen u [81] opisuje snimanje zvuka vozila u kontrolisanim uslovima i analizu obeležja, kao što su kratkoročna energija, energija u logaritamskoj raspodeli i *MFCC*.

Obeležja poput kratkoročne Furijeve transformacije (*short-term Fourier transform* - *STFT*) i *MFCC* koriste se sa različitim modelima mašinskog i dubokog učenja u [77]. Ovo istraživanje je pokazalo da kombinovanje visokokvalitetnih skupova podataka i robusnih metoda za izdvajanje karakteristika signala, kao što je dekompozicija talasnih paketa (*wavelet packet decomposition* - *WPD*), poboljšava tačnost klasifikacije. Međutim, tačnost klasifikacije opada kada se testira na vozilima različite starosti ili na uzorcima koji su snimljeni različitim mikrofonomima. Ovo dodatno ukazuje na potrebu za što većom i reprezentativnijim bazom uzoraka koja bi omogućila razvoj klasifikacionih modela korišćenjem akustike iz realnog okruženja.

Obeležja čije su funkcije za proračun razvijene na osnovu percepcije slušaoca nazivaju se psihoakustička obeležja. U ovu kategoriju spadaju obeležja poput tonaliteta (*tonality*), hrapavosti (*roughness*), glasnosti (*loudness*), oštine (*sharpness*) itd. Studije [83, 84] upoređuju psihoakustička obeležja kao što su glasnost, oština, hrapavost, stepen fluktuacije (*fluctuation strength*) i tonalitet sa statističkim obeležjima akustičkog signala, kao što su koren srednje kvadratne vrednosti (*root mean square* - *RMS*), kurtozis i krest faktor, u pogledu efikasnosti u klasifikaciji kvarova vozila. Pokazano je da su psihoakustička obeležja za ovu primenu nadmašila

statistička obeležja. Psihoakustička obeležja, kao što su glasnost i oštrina, upoređuju se sa tradicionalnim obeležjima, poput *RMS* vrednosti i kurtozisa, za dijagnostifikovanje kvarova mašina upotrebom prikupljenih signala vibracija u [85]. Rezultati pokazuju da psihoakustičke metrike pružaju uporediv nivo tačnosti detekcije kvarova (oko 82%) u odnosu na tradicionalne metode. Međutim, kombinovanjem oba pristupa, rezultati detekcije kvara su poboljšani na približno 90%, dok je smanjen udeo lažno pozitivnih detekcija.

3.2.3 Modeli klasifikacije

Modeli klasifikacije su algoritmi mašinskog i dubokog učenja čija je svrha razvrstavanje podataka, između ostalog i u vidu uzoraka, u unapred definisane kategorije na osnovu određenih obeležja. Ovi modeli analiziraju vektore obeležja (ulazne podatke), izračunate iz baze uzoraka, kako bi naučili obrasce i veze između tih obeležja i ciljnih klasa. Nakon faze učenja, formirani klasifikacioni modeli mogu primenjivati naučene obrasce na nove podatke, praveći predikciju kojoj klasi novi uzorci pripadaju. To im omogućava donošenje automatizovanih odluka na osnovu korišćenih podataka.

Sa ciljem obrade i analize akustičkih obeležja za klasifikaciju vozila, pristup iz istraživanja [73] koristi različite klasifikacione modele, kao što je metod zasnovan na potpornim vektorima (*support vector machine* - *SVM*) i metod *k*-najbližih suseda (*k-nearest neighbors* - *k-NN*). Sistem za klasifikaciju tipova motora vozila postigao je tačnost od 91,7%, upotrebom linearnog *SVM* algoritma [69]. Performanse klasifikatora kao što su *SVM*, stabla odlučivanja (*random forest*) i *k-NN* su upoređene u [77]. Modeli učenja, kao što su duboke neuronske mreže (*DNN*) i *k-NN*, primenjeni su za klasifikaciju vozila prema njihovim akustičkim signalima, pri čemu je *DNN* pokazao veću uspešnost u identifikaciji kategorija vozila poput lakih, srednjih i teških vozila u [81]. Zajedničko za sve ove modele je da zahtevaju što veće skupove uzoraka kako bi se postigla visoka tačnost i robusnost klasifikacije.

U [70] je predložena upotreba kvadratne diskriminantne analize (*quadratic discriminant analysis* - *QDA*) za klasifikaciju vozila na osnovu akustičkih obeležja. Rad takođe upoređuje ovaj pristup sa postojećim metodama, kao što je *SVM* uz različite tehnike izdvajanja obeležja. Rezultati simulacije pokazuju da *QDA* pristup postiže tačnost klasifikacije od 68,75%, što je konkurentno sa

drugim pristupima veće kompleksnosti, ali je još uvek niže od *SVM* pristupa sa mel-koeficijentima koji postiže tačnost od 80%. Istraživanje [78] koristi linearno prediktivno kodovanje (*linear predictive coding - LPC*) za predobradu snimljenih uzoraka zvuka i neuronsku mrežu sa vremenskim kašnjenjem (*time delay neural network - TDNN*) za klasifikaciju. *TDNN* je bila obučena i testirana na snimcima nastalim u kontrolisanom okruženju i snimcima sa ulica u urbanom okruženju. Istraživanje je pokazalo visoku tačnost klasifikacije, 96% za set podataka za obuku i 84% za testni set podataka u urbanom okruženju. Bez obzira što je je pozadinska buka u urbanoj sredini prisutna, model daje obećavajuće rezultate za standardne uslove u realnom okruženju.

Modeli mašinskog učenja poput Fišerove linearne diskriminantne analize (*Fisher's linear discriminant analysis - FLDA*) i regresione analize (*regression analysis - RA*) testirani su na audio snimcima različitih tipova vozila (laka vozila, srednja vozila, teška vozila i motocikli) snimljenim u različitim vremenskim uslovima [72]. Rezultati su pokazali da algoritmi mašinskog učenja efikasno razlikuju kategorije vozila na osnovu generisanog zvuka, pri čemu *RA* postiže tačnost od 97,8%, a *FLDA* 96,8%. Pored toga, detekcija stanja kolovoza (suvo, mokro ili sneg) bila je još jedna testirana primena, pri čemu je *FLDA* postigla tačnost od 93%.

Konvolucione neuronske mreže (*CNN*) su, prema [71], posebno istaknute zbog svoje sposobnosti da automatski izdvoje relevantna obeležja iz zvukova vozila. Istraživanje [31] dodatno potvrđuje ove tvrdnje gde je postignuta visoka tačnost (preko 92%) u klasifikaciji vozila na osnovu više obeležja upotrebom *CNN*-a.

Neuronske mreže duge kratkoročne memorije (*long short-term memory - LSTM*) koriste se za klasifikaciju zbog svoje sposobnosti da efikasno obrađuju sekvencijalne podatke, što ih čini pogodnim za klasifikaciju audio signala [80]. Citirano istraživanje [80] je postiglo tačnost klasifikacije u rasponu od 82% do 86,2%, sa mogućnošću dobrog razlikovanja automobila, ali sa manje uspeha u klasifikaciji kamiona i motocikala. Rezultati sugerišu da su potrebna dalja poboljšanja, posebno u prepoznavanju složenijih akustičkih potpisa kamiona i motocikala. Istraživanje ističe potencijal kombinovanja *MFCC*-a i *LSTM*-a za akustičku klasifikaciju vozila. Ova kombinacija je korišćena i u istraživanju [86] gde je ovaj hibridni model takođe pokazao mogućnosti *CNN*-a za efikasno uočavanje obrazaca unutar skupa uzoraka i potencijal *LSTM*-a u obradi podataka na velikom broju uzoraka.

Duboke neuronske mreže (*DNN*) u kombinaciji sa psihouakustičkim obeležjima pružaju pouzdanu metodu za automatsko otkrivanje grešaka u menjaču, gde je u [83] postignuta tačnost od 99% u identifikaciji ispravnih menjača i 98% u otkrivanju neispravnih. Na sličan način, u radu [84] koji predstavlja nastavak ovog istraživanja, klasifikacioni model koji koristi takođe *DNN* i psihoakustička obeležja demonstrira sposobnost da klasifikuje neispravnosti u menjaču sa tačnošću od 95,93%. Visoka tačnost klasifikacije od preko 96% postignuta je u [82] gde je korišćena dvoslojna *feed-forward* neuronska mreža (neuronska mreža sa prosleđivanjem unapred) sa 20 skrivenih neurona za razlikovanje tipova motora, kao što su linijski motori sa četiri cilindra, V6 i dizel motori u kamionetima.

Analiza literature pokazala je da su dosadašnja istraživanja klasifikacije vozila na osnovu zvuka primarno koristila podatke snimljene u laboratorijskom okruženju ili pomoću mikrofona postavljenih pored saobraćajnica. Ovakvi pristupi često rezultiraju snimcima sa značajnim uticajem okruženja, što otežava izdvajanje relevantnih audio karakteristika motora. Problem klasifikacije tipa pogonskog goriva razmatran je u radovima [69-75], ali postojeći pristupi nisu u potpunosti rešili izazove povezane sa tačnošću i pouzdanošću klasifikacije u realnim uslovima. Ova disertacija nastoji da unapredi klasifikaciju razvijanjem sistema koji omogućava prikupljanje visokokvalitetnih audio snimaka, sa mikrofonom postavljenim bliže izvoru zvuka – motoru, ali uz minimalan uticaj ambijentalne buke. Time će se omogućiti preciznije izdvajanje akustičkih karakteristika relevantnih za razlikovanje između benzinskih i dizel motora. Takođe, značajno proširenje baze podataka kroz prikupljanje većeg broja uzoraka doprinosi boljoj generalizaciji modela klasifikacije. Ovakav pristup omogućava prevazilaženje pomenutih ograničenja postojećih metoda i predstavlja osnovu za dalja istraživanja u oblasti akustičke klasifikacije vozila.

4. Dizajn i hardverska realizacija akvizicionog sistema za prikupljanje uzoraka

Usled specifičnosti i obima ovog istraživanja koje je iziskivalo formiranje nove banke uzoraka prikupljanjem audio signala iz realnog okruženja, a zatim i razvoj odgovarajućeg postupka za analizu i klasifikaciju istih, u ovom radu je celokupan postupak podeljen u dve celine. Prva celina obuhvata razvoj i implementaciju nezavisnog akvizicionog sistema čiji je krajnji rezultat formiranje banke audio uzoraka pogodnih za dalju analizu i klasifikaciju, dok druga celina obuhvata izdvajanje značajnih audio obeležja i postupak klasifikacije audio zapisa. U ovom poglavlju je opisan razvoj akvizicionog sistema radi formiranja banke audio zapisa koji sadrže zvuk motora sa unutrašnjim sagorevanjem u režimu praznog hoda.

4.1 Prenosni sistem za formiranje nove banke audio uzoraka

U cilju klasifikacije pogonskog goriva na osnovu zvuka generisanog radom motora sa unutrašnjim sagorevanjem bilo je potrebno prikupiti što veći broj audio uzoraka rada motora. Kako na samom početku, u nedostatku sličnih istraživanja, nije bilo poznato koji režim rada motora će dati najbolje rezultate prilikom klasifikacije, sistem je razvijan i modifikovan paralelno sa pokušajima da se izvrši klasifikacija. Početna tačka u formiranju sistema je bio psihoakustički utisak autora da je subjektivno najlakše klasifikovati pogonsko gorivo slušajući rad motora u praznom hodu na što manjem broju obrtaja radilice. Pored zvučno jasnije razlike dok se vozilo nalazi u režimu praznog hoda, ovaj režim je u realnim uslovima pogodniji za prikupljanje uzoraka. U najvećem broju slučajeva vozilo u ovom režimu rada stoji mirno što pruža mogućnost beleženja audio uzoraka sa manje ometajućih zvukova u odnosu na režim kada se vozilo nalazi u pokretu gde pored zvuka generisanog radom motora postoje i zvuci generisani bukom guma, strujanjem vazduha oko vozila, kao i okolnim vozilima.

Beleženje audio snimaka zahteva postavljanje mikrofona u blizini izvora zvuka, u ovom slučaju motornog prostora automobila. Kao što je navedeno u poglavlju 2, postoji značajan broj objavljenih radova u kojima se analizira zvuk generisan radom motora sa unutrašnjim

sagorevanjem pri čemu se uzorci priključuju ili mikrofonom postavljanim pored prostora kuda vozila prolaze ili neposredno u motornom prostoru. Postavljanje mikrofona u motornom prostoru ne ispunjava cilj da akvizicioni sistem bude mobilan i da prilikom prikupljanja audio uzoraka nema uticaj na kretanje i putanju vozila, dok je pozicioniranje mikrofona pored putanje kretanja vozila poslužilo kao polazna tačka na početku ovog istraživanja gde je bilo potrebno odrediti najbolju poziciju mikrofona u odnosu na motorni prostor vozila. Pri tome, cilj je bio da prikupljeni audio snimci budu validni u pogledu kvaliteta i da sadrže samo željeni režim rada motora u odnosu na okolne zvuke. Dodatno je prilikom određivanja najpogodnijeg položaja mikrofona, realizovano beleženje i analiza audio signala dobijenih na većem broju obrtaja radilice u odnosu na režim praznog hoda bez opterećenja motora kako bi se ispitao uticaj takvog režima rada u slučaju da se zabeleži taj scenario koji može da se javi usled eventulane neispravnosti regulacije broja obrtaja radilice motora. Cilj je takođe bio da se proverí perceptivni utisak da je razlikovanje pogonskih goriva jednostavnije ukoliko je broj obrtaja radilice manji.

4.1.1 Pozicioniranje mikrofona u odnosu na motorni prostor vozila i izbor režima rada motora za analizu

4.1.1.1 Pozicioniranje mikrofona u odnosu na motorni prostor vozila

Za određivanje adekvatnog položaja mikrofona u odnosu na izvor zvuka, tj. motorni prostor vozila, korišćena su dva putnička vozila približno istih karakteristika, pri čemu jedno vozilo koristi benzin kao pogonsko gorivo, dok drugo vozilo koristi dizel. Dodatno je vođeno računa da su vozila iz istog tržišnog segmenta i približno iste starosti kako različiti nivoi zvučne izolacije i konstrukcija izduvnog sistema ne bi uticali na verodostojnost ispitivanja, pre svega zbog uobičajene prakse da vozila iz višeg tržišnog segmenta, kao i novija vozila, najčešće imaju znatno bolju zvučnu izolaciju u cilju postizanja većeg komfora. Uzimajući u obzir da na zvučnu sliku utiče radna zapremina motora, broj taktova motora, broj ventila po cilindru kao i broj tačaka za ubrizgavanja goriva, izabrana su vozila kod kojih su ove karakteristike identične bez obzira na pogonsko gorivo. Karakteristike vozila su date u tabeli 1.

Tabela 1. Karakteristike putničkih vozila korišćenih za merenja

	Vozilo 1	Vozilo 2
Proizviđač i model vozila	Renault Clio 1.2 16v	Opel Corsa 1.3 CDTI
Pogonsko gorivo	benzin	dizel
Radna zapremina motora (ccm ³)	1149	1248
Broj ventila po cilindru	4	4
Broj cilindara	4	4
Tip menjača	Manuelni	Manuelni
Ubrizgavanje goriva	<i>Multipoint</i>	<i>Multipoint</i>
Snabdevanje vazduhom	Atmosferski	Turbo
Snaga (kW)	55	55
Dimenzije vozila DxŠxV(mm)	3773x1639x 1417	4021x1736x 1479

Kao što se može videti u tabeli 1, jedina suštinska razlika između ova dva motora, osim pogonskog goriva, je u tome što vozilo koje koristi dizel koristi turbo punjač koji prinudno dovodi dodatni vazduh u motor. Međutim, u uslovima merenja koja su sprovedena, a koja podrazumevaju rad motora bez opterećenja, pomenuta razlika ne bi trebalo da utiče na generisani zvuk, jer turbo punjač tada nema funkciju. Rad motora bez opterećenja postiže se zaustavljanjem automobila i postavljanjem menjača u neutralni položaj, a izbor broja obrtaja radilice u minutu položajem papučice gasa.

Beleženi su i analizirani snimci dobijeni mikrofonom pozicioniranim iznad motornog prostora vozila za slučajeve sa otvorenim, odnosno zatvorenim poklopcem motora i mikrofonom postavljenim na tlo neposredno ispod motornog prostora, slike 5 i 6. Prilikom beleženja zvuka motora u oblasti iznad motornog prostora, mikrofoni je bio postavljen na udaljenosti 1 m od izvora zvuka tj. motora, slika 5.



Slika 5. Pozicioniranje mikrofona u oblasti iznad motornog prostora sa otvorenim poklopcem motora



Slika 6. Pozicioniranje mikrofona u oblasti ispod motornog prostora

Za akviziciju zvuka je korišćen merni mikrofoni DBX RTA-M u kombinaciji sa Behringer UMC404HD audio interfejsom čije su specifikacije date u tabelama 2 i 3, respektivno. Za beleženje audio snimaka izabrana je frekvencija odmeravanja od 44100 odmeraka u sekundi sa dinamičkom rezolucijom od 16 bita po uzorku odnosno tzv. CD kvalitet zvuka.

Tabela 2. Specifikacije mernog mikrofona DBX RTA-M

Tip mikrofona	Elektret
Usmerenost	Omnidirekcioni (neusmereni)
Frekvencijski opseg	20 Hz – 20000 Hz
Impedansa	$250 \Omega \pm 30\%$ (na 1kHz)
Radni napon	9~52V jednosmerno fantomsko napajanje
Osetljivost	-63 dB $\pm$ 3 dB

Tabela 3. Specifikacije audio interfejsa *Behringer UMC404HD*

Ulaz	
Frekvencijski opseg	10 Hz – 50 kHz (0/-3 dB)
Impedansa	Mikrofonski ulaz: 3 k Ω
Maksimalni ulazni nivo signala	Mikrofon: -4 dBu
Fantomsko napajanje	+48 V
Izlaz	
Frekvencijski opseg	10 Hz – 43 kHz (0/-0,3 dB)
Maksimalni izlazni nivo signala	+3 dBu
Sistemske karakteristike	
Dinamički opseg	100 dB
Frekvencijski opseg	10 Hz – 43 kHz (0/-0,3 dB)
Digitalna obrada signala	
Podržane frekvencije odabiranja	44,1/48/88,2/96/176,4/192 kHz


Sa ciljem da se pronade odgovarajuća pozicija mikrofona u odnosu na motorni prostor vozila u realnim uslovima gde postoji i okolni saobraćaj, kao i dodatne refleksije, beleženje audio uzoraka je realizovano u prostoru na udaljenosti od približno 15 metara od prometne ulice. Automobili koji su učestvovali u testu su postavljeni na čvrstu betonsku podlogu, ograđenu sa tri bočna zida. Najbliži bočni zid bio je udaljen oko 2 m od karoserije automobila. Prostor ispred i iznad automobila bio je otvoren (slike 5 i 6). Apsolutni nivo ambijentalne buke je u toku snimanja meren uređajem *NTI Audio XL2* na osnovu čega je utvrđeno da se zabeleženi nivo buke nalazio u opsegu 44,8-51 dB. Ovaj postupak je pokazao da je uticaj ambijentalne buke na prikupljene audio uzorke rada motora zanemarljiv, obzirom da je najniži nivo zvuka koji generiše motor svojim radom u režimu praznog hoda 76,4 dB za benzinski motor i 76,7 dB za dizel motor.

Ulazno pojačanje audio interfejsa tokom svih merenja je bilo na istom nivou tako da se snimljeni signali mogu međusobno porediti. U slučaju dizel motora sa otvorenim poklopcem motora, došlo je do izobličenja signala (klipinga), zbog visokog nivoa zvučnog pritiska. Zbog ovoga, merenje je ponovljeno za ovaj slučaj aktiviranjem prigušenja (taster pad) na audio interfejsu. Aktiviranjem ovog tastera nivo signala se smanjuje za 16 dB.

Merenja su vršena posebno za svako vozilo u devet slučajeva. Osam slučajeva uključivalo je pomenutu poziciju merenog mikrofona na rastojanju 1 m od izvora zvuka, dok je u jednom slučaju mikrofon postavljen na tlo direktno ispod motora, kako bi se izbegao mogući uticaj

refleksije od čvrstog tla i time eliminisao efekat češljastog filtra. Svaki merni položaj mikrofona podrazumevao je četiri merenja: u režimu praznog hoda, pri 1500 obr./min, pri 2500 obr./min i pri 3000 obr./min sa otvorenim ili zatvorenim poklopcem za svaki od modova. Obr./min se odnosi na broj obrtaja radilice motora u jednom minutu. U slučaju mikrofona postavljenog direktno ispod vozila, zbog pojave izobličenja signala (klipinga) usled visokog nivoa zvuka koje motor generiše u drugim režimima rada, signali su snimani samo u režimu praznog hoda.

Prvi korak u analizi snimljenih audio sekvenci bila je spektralna analiza snimljenih signala. Za spektralnu analizu korišćen je programski jezik *Python*, prvenstveno izabran zbog mogućnosti daljeg rada u istom okruženju i složenije analize u narednim etapama ispitivanja. Spektralna analiza je prvobitno obavljena za celu snimljenu audio sekvencu u trajanju od 30 sekundi za svaki od slučaja, međutim, kako se signal ponaša kao stacionaran ili bar pseudostacionaran (slika 7), zbog brzine izračunavanja spektra, analiza je potom nastavljena u intervalima od 15 sekundi.




Slika 7. Zvuk benzinskog motora u vremenskom domenu


U programskom jeziku *Python* napisan je kod koji izračunava i prikazuje usrednjeni spektar za dati signal kako bi se eliminisali kratkotrajni ambijentalni zvukovi koji nisu bili predmet analize kao što su govor, prolazak tramvaja i sl. koji su se mogli čuti tokom merenja, ali ih nije bilo moguće prepoznati u vremenskom domenu signala. Parametri koji su korišćeni za izračunavanje spektra su *FFT* veličina: 16384 tačaka i Hemingova prozorska funkcija. Ova podešavanja su izabrana prema minimalnoj vrednosti koja je potrebna da se dobije vizuelno jasan spektar, s jedne strane, i da se sve komponente spektra mogu identifikovati, s druge strane, jer veličina *FFT*-a ne zavisi direktno od ukupne dužine signala, već od željene spektralne rezolucije i vremenskog prozora analize.

Dužina signala od 15 sekundi je dovoljno velika da obuhvati veliki broj prozora za analizu, što omogućava dobru statističku reprezentaciju spektralnih komponenti.


Preslušavanjem dobijenih audio snimaka uočeno je da se audio signali zabeleženi u tri pozicije (sa zatvorenim poklopcem motora, sa otvorenim poklopcem motora i u prostoru ispod motora) bez obzira na režim rada motora i tip pogonskog goriva razlikuju. Spektralnom analizom prikazanom na slikama 8-15 jasno je moguće uočiti da je audio signal snimljen u oblasti ispod motornog prostora najmanje prigušen, odnosno da ima jasno izražene sve frekvencijske komponente. Signal snimljen na rastojanju od 1 metra sa otvorenim poklopcem motora je u odnosu na signal snimljen ispod motora nešto nižeg nivoa, dok je kod signala snimljenog sa zatvorenim poklopcem motora evidentno slabljenje na celom opsegu, a posebno na višim frekvencijama tj. poklopac motora se ponaša kao filter propusnik niskih učestanosti.




Slika 8. Usrednjeni spektar zvuka benzinskog motora u režimu praznog hoda




Slika 9. Usrednjeni spektar zvuka dizel motora u režimu praznog hoda




Slika 10. Usrednjeni spektar zvuka benzinskog motora pri 1500 obrtaja kolenastog vratila u minuti




Slika 11. Usrednjeni spektar zvuka dizel motora pri 1500 obrtaja kolenastog vratila u minuti




Slika 12. Usrednjeni spektar zvuka benzinskog motora pri 2500 obrtaja kolenastog vratila u minuti



Slika 13. Usrednjeni spektar zvuka dizel motora pri 2500 obrtaja kolenastog vratila u minuti



Slika 14. Usrednjeni spektar zvuka benzinskog motora pri 3000 obrtaja kolenastog vratila u minuti



Slika 15. Usrednjeni spektar zvuka dizel motora pri 3000 obrtaja kolenastog vratila u minuti

Ukoliko se uporede oblici spektra signala za prazan hod na slikama 8 i 9, za režim rada motora pri 1500 obrtaja kolenastog vratila u minuti na slikama 10 i 11, za režim rada motora pri 2500 obrtaja kolenastog vratila u minuti na slikama 12 i 13 i za režim rada motora pri 3000 obrtaja kolenastog vratila u minuti na slikama 14 i 15, može se uočiti da je prirodna (osnovna) frekvencija dizel motora izraženija u odnosu na benzinski motor, posebno u režimu praznog hoda. Izraz prirodna frekvencija motora se odnosi na osnovnu frekvenciju rotacije SUS motora i zavisi od brzine rotacije kolenastog vratila, broja radnih taktova i broja cilindara motora [87]. Ako je brzina rotacije kolenastog vratila data kao N , gde N predstavlja broj obrtaja u toku jednog minuta tada se osnovna frekvencija rotacije radilice f_{kv} računa kao:

$$f_{kv} = \frac{N}{60} \quad (1)$$

pa se za četvorotaktni motor, kod koga se paljenje događa jednom u dva obrtaja kolenastog vratila, prirodna frekvencija f_p računa na sledeći način:

$$f_p = \frac{\text{broj cilindara} \cdot f_{kv}}{2} \quad (2)$$

U konkretnim merenjima za dva četvorotaktna, četvorocilindrična motora prema datim izrazima očekivana prirodna frekvencija motora za režim praznog hoda, pri kome su obrataji kolenastog vratila približno 700 obrtaja u minuti, iznosi 23,4 Hz. Za režime rada od 1500, 2500 i 3000 obrtaja kolenastog vratila u minuti, očekivane prirodne frekvencije su 50 Hz, 83,3 Hz i 100 Hz respektivno.


Pored izražene prirodne frekvencije, kod dizel motora je uočljivo prisustvo harmonika, tj. komponenti na celobrojnom umnošku prirodne frekvencije motora. Sa povećanjem broja obrtaja kolenastog vratila, kod dizel motora se povećava i broj harmonika. Sa druge strane može se primetiti da zvučna izolacija, usled zatvaranja poklopca motora, ima znatno manju efikasnost kod dizel motora, i da harmonici u opsegu do 300 Hz gotovo da nisu oslabljeni bez obzira na režim rada.

Ovim postupkom je utvrđeno da je za analizu zvuka generisanog radom motora sa unutrašnjim sagorevanjem, bez obzira na pogonsko gorivo, najpogodnije koristiti snimke koji su zabeleženi bez uticaja poklopca motora, odnosno snimke dobijene postavljanem mikrofona na podlogu u oblasti ispod motornog prostora kako se ne bi ometalo kretanje vozila.


4.1.1.2 Određivanje najpogodnijeg režima rada motora za analizu zvuka

U delu istraživanja koje se odnosi na određivanje optimalne pozicije mikrofona istovremeno su analizirani i spektralni oblici snimljenih zvučnih zapisa u različitim režimima rada motora. Zbog viskog nivoa zvuka u oblasti ispod motornog prostora koji motor generiše pri radu u režimima pri 1500 obr./min, 2500 obr./min i 3000 obr./min za poziciju mikrofona na tlu dolazi do izobličenja signala (klipinga). Zbog ove pojave i činjenice da je spektralna analiza zvučnih signala pokazala da snimci dobijeni sa otvorenim poklopcem motora i u oblasti ispod motornog prostora nisu filtrirani (oslabljeni) na frekvencijama preko 1 kHz (slike 8-15), za određivanje optimalnog režima rada korišćeno je merenje sa otvorenim poklopcem haube na rastojanju 1 metar od motora kao izvora zvuka.

Uporedni prikaz usrednjenih spektara zvuka snimljenog kada je otvoren poklopac motora za različite režime rada prikazan je na slici 16 za benzinski motor, odnosno na slici 17 za dizel motor.



Slika 16. Usrednjeni spektar zvuka benzinskog motora u različitim režimima rada, snimljenog kada je otvoren poklopac motora



Slika 17. Usrednjeni spektar zvuka dizel motora u različitim režimima rada, snimljenog kada je otvoren poklopac motora


Na osnovu dobijenih prikaza za različite režime rada motora može se zaključiti da režim praznog hoda rada motora sadrži veliki broj spektralnih komponenti kao i ostali režimi rada motora, kao i da je sam oblik spektra veoma sličnog oblika. Moguće je uočiti da su nivo signala i dinamički opseg signala kod ovog režima rada manji u odnosu na druge režime pa je ovaj režim pogodniji za beleženje u cilju detaljne analize, jer je manja verovatnoća da će doći do odescanja (klipovanja) signala prilikom snimanja. Ovaj zaključak se poklapa sa percepcijom slušaoca, koji u režimu praznog hoda motora lakše i tačnije razlikuje tip pogonskog goriva. Dodatno, izbor režima praznog hoda, kao što je već navedeno, omogućava pozicioniranje mikrofona na tlu u oblasti ispod motornog prostora, što predstavlja najpogodniju poziciju u cilju neremećenja putanje vozila i prikupljanja velikog broja zvučnih zapisa.

4.1.1.3 Ispitivanje uticaja varijacija pozicije izvora zvuka u odnosu na mikrofonski postavljen na tlu


Određivanje optimalne pozicije mikrofona u odnosu na motorni prostor vozila, pozicioniranjem na tlu, stvorilo je mogućnost prikupljanja velikog broja uzoraka zvuka rada motora bez ometanja kretanja vozila. Međutim zbog željene primene akvizicionog sistema u realnim uslovima, prilikom prelaska i kratkotrajnog zadržavanja vozila iznad mikrofona, nije moguće uvek imati identičan položaj mikrofona u odnosu na izvor zvuka. Ispitivanjem uticaja varijacija pozicije izvora zvuka u odnosu na mikrofonski postavljen na tlu bilo je potrebno utvrditi

kolika su odstupanja u nivou i obliku zabeleženog signala u različitim tačkama u oblasti ispod motornog prostora, odnosno da li su prikupljeni uzorci validni za dalju analizu ukoliko je mikrofoni u oblasti ispod motornog prostora, ali se ne nalazi direktno ispod motora.

Ispitivanje je realizovano tako što je mikrofoni postavljan u fiksne tačke geometrijski ravnomerno raspoređene u oblasti ispod motornog prostora. Simulacija realnih uslova prikupljanja velikog broja uzoraka je podrazumevala rad vozila u režimu praznog hoda, odnosno neopterećenog motora sa stabilnim brojem obrtaja radilice. Za prikupljanje audio zapisa u oblasti ispod motornog prostora, korišćena su dva vozila, jedno vozilo je imalo uzdužno (longitudinalno) postavljen motor, dok je drugo vozilo imalo poprečno (transverzalno) postavljen motor: Razlog ovakvog izbora vozila je da bi se dodatno uvideo mogući uticaj orijentacije motora na dobijene rezultate. Prilikom određivanja pozicije mikrofona utvrđeno je da motori pokretani na dizel imaju viši nivo zvuka, pa je ovo ispitivanje realizovano samo za benzinske motore gde bi potencijalno moglo da dođe do nedovoljnog nivoa zvuka neophodnog za validan zvučni zapis. Vozila su pokretana motorima sa unutrašnjim sagorevanjem koji koriste benzin kao pogonsko gorivo i identičan sistem ubrizgavanja, kako bi zvučni zapisi bili što približnijih karakteristika. Za svako od vozila je merni mikrofoni postavljan u devet tačaka. Tačke u kojima su prikupljeni audio uzorci su izabrane tako da pokrivaju celokupan motorni prostor, pri čemu je oblast ispod motornog prostora procenjena na dimenzije “1,2 m × 1,2 m”, a zatim izdvojena na zone kvadratnog oblika i veličine “40 cm × 40 cm”, merne tačke su zatim pozicionirane u centrima kvadrata. Tačka “1” se nalazi u centru prvog kvadrata, odnosno na koordinatama “x=20 cm, y=20 cm” posmatrano u odnosu na prednju stranu vozila. Položaj mernih tačaka je prikazan na slikama 18 i 19.



Slika 18. Položaj i raspored mernih tačaka za vozilo sa poprečno postavljenim motorom



Slika 19. Položaj i raspored mernih tačaka za vozilo sa uzdužno postavljenim motorom


Merenje je vršeno u zatvorenoj prostoriji koja nije potpuno zvučno izolovana od okolnih uticaja. U svakoj od mernih tačaka snimani su audio uzorci trajanja 5 s. Uzimajući u obzir da motor sa unutrašnjim sagorevanjem ima četiri radna takta u praznom hodu, da radi na približno 700 obrtaja kolenastog vratila u minutu, i da su za četiri radna ciklusa sva četiri cilindra potrebna dva obrtaja radilice u sekundi, može se zaključiti da je potrebno približno 0,2 s kako bi motor prošao kroz sve radne cikluse u ovom režimu [87].

Izabrano vreme trajanja audio uzoraka je produženo zbog nesavršenosti mernog okruženja i mogućnosti usrednjavanja i lakše obrade u slučaju da se na snimku pojavi neki neželjeni zvuk. Opremu korišćenu za merenje činio je merni mikrofoni *DBX RTA-M* [88] i audio interfejs *Behringer UMC404HD* [89]. Nivo zvučnog pritiska snimaka je računat u okviru softvera *SoundForge*, dok je frekvencijska analiza rađena u *Matlab*-u. Kao početni korak u analizi zabeleženih audio uzoraka izvršeno je izračunavanje srednje kvadratne vrednosti (*RMS-a*) amplitude audio signala za svaki od snimaka. Postupak analize dobijenih vrednosti je podrazmevao dva slučaja: slučaj uzdužno postavljenog motora i slučaj poprečno postavljenog motora. Kako su se zbog razlike u orijentaciji motora, apsolutni nivoi zvuka dva različita vozila razlikovali, prikazani rezultati su predstavljeni u tabeli 4 kao relativni nivoi - relativni u odnosu na mernu tačku sa najvišim nivoom *RMS-a* za to vozilo.

Tabela 4. Relativno odstupanje *RMS*-a u zoni ispod motornog prostora za različite orijentacije motora

	Poprečno postavljen motor	Uzdužno postavljen motor
Relativno odstupanje nivoa zvučnog polja		
Merna pozicija 1	-0,893 dB	-0,919 dB
Merna pozicija 2	-0,717 dB	-1,946 dB
Merna pozicija 3	-1,446 dB	-2,603 dB
Merna pozicija 4	-1,38 dB	-0,029 dB
Merna pozicija 5	0 dB	-0,386 dB
Merna pozicija 6	-2,353 dB	-0,918 dB
Merna pozicija 7	-1,246 dB	-1,116 dB
Merna pozicija 8	-0,888 dB	0 dB
Merna pozicija 9	-3,791 dB	-0,809 dB


Na slici 20 su grafički prikazana odstupanja *RMS*-a u zoni ispod motornog prostora za različite orijentacije motora.



Slika 20. Prikaz odstupanja *RMS* vrednosti nivoa zvuka u dB za vozila sa poprečno (levo) i uzdužno (desno) postavljenim motorom

U slučaju vozila sa poprečno postavljenim motorom može se zaključiti da je najviši *RMS* nivo zvuka zabeležen u mernoj tački “5”, pri čemu su relativna odstupanja u granicama od 0 dB do -3.791 dB dok je za vozilo sa uzdužno postavljenim motorom najviši *RMS* nivo zvuka zabeležen u mernoj tački “8”, pri čemu su relativna odstupanja u granicama od 0 dB do -2.603 dB.


Mapa zvučnog polja za obadva vozila nema velikih varijacija u *RMS* nivou, ali se može uočiti izvestan karakterističan oblik višeg nivoa koji se poklapa sa konstrukcijom i položajem izduvnog sistema vozila (označenog crvenom bojom), što je prikazano na slici 21.



Slika 21. Uporedni prikaz *RMS* nivoa kod vozila sa poprečno i uzdužno postavljenim motorom u odnosu na položaj izduvnog sistema

Male varijacije u *RMS* nivoima zvuka, kao i relativno uniformna raspodela zvučnog polja ispod centralnog dela motornog prostora u frekvencijskom opsegu od interesa ukazuju da položaj mikrofona u oblasti ispod motornog prostora nema veliki uticaj na parametre zvuka. Ovo pruža mogućnost postavljanja mikrofona na podlogu iznad koje prelaze i kratko se zadržavaju vozila (naplatna rampa, ulazna rampa parkinga, benzinska pumpa) radi snimanja zvuka motora.

Prilikom određivanja položaja mikrofona koji minimizuje uticaj ometajućih efekata analizirani su i scenariji koji uključuju vozila za motor pozicioniran u sredini ili pozadi slika 22. Ova analiza je rezultirala položajem mikrofona na tlu iza prednjeg točka umesto ispred vozila, gde je ovaj položaj mikrofona označen crvenom bojom na slici 22.



Slika 22. Pozicija mikrofona za vozila sa motorom postavljenim pozadi (slika gore), odnosno u sredini (slika dole)

Merenja sprovedena ispod vozila, bez obzira na položaj motora, nisu pokazala značajne razlike u snimljenom zvuku koje bi uticale na klasifikaciju korišćenih goriva. Jedina primetna razlika bila je u nivou zvučnog pritiska, bez drugih primetnih varijacija. Kod postavljanja mikrofona na tlo ispod vozila, mikrofoni se nalaze u prostoru relativno male visine - očekivana visina vozila je između 10-30 cm, a najčešće oko 10-15 cm, pri čemu je tipična širina automobila 1,5 m ili više. Udaljenost mikrofona od motora kretala se od približno 0,5 m do 3 m (rastojanje d_1 na slici 22), pri čemu je zabeleženi nivo zvuka bio iznad predefinisane praga (najnižeg nivoa zvuka izmerenog na uzorku od dvadeset vozila sa motorom postavljenim napred). Ovaj reflektivni prostor sa akustičke tačke gledišta, čija osnova ima oblik sličan pravougaoniku približnih dimenzija $4 \times 1,5$ m i visine 0,1-0,3 m, gotovo potpuno poništava uticaj spoljnih faktora poput ventilacije ili glasne muzike generisane unutar vozila. Za neke druge, ekstremne, slučajeve gde su u pitanju vozila duža od putničkih vozila (kombi, autobus, kamion itd.) moguće je postojeći mikrofoni zameniti mikrofonskim nizom koji bi bio u stanju da zabeleži direktni zvuk ispod motora vozila.

4.1.2 Izbor lokacije za prikupljanje uzoraka

U cilju prikupljanja što većeg broja uzoraka za najkraći vremenski period bilo je potrebno izabrati lokaciju koja ima veliki protok vozila koja će se naći u režimu praznog hoda motora. Mogućih lokacija gde se događa takav scenario je nekoliko, kao što su benzinske stanice, naplatne rampe (u sistemima gde se ne primenjuje vinjeta), semafori, *drive in* restorani, ulazi na različita parkirališta.


Činjenice da je prilikom ulaska na parkirališta, a posebno u podzemne garaže, potrebno kratkotrajno zadržavanje vozila u režimu praznog hoda prilikom uzimanja kartice ili žetona, da broj vozila koje cirkulišu može biti veoma veliki, da su uslovi za snimanje pogodni jer je smanjen uticaj spoljašnje buke i drugih vozila, kao i da je pozicioniranje mikrofona na tlo moguće bez ugradnje u podlogu jer je putanja vozila takva da se uvek kreću gotovo identičnim tragom, pa je mogućnost gaženja mikrofona svedena na minimum, su korišćene da se ova lokacija izabere kao najpogodnija za prikupljanje uzoraka. Pozicioniranje mikrofona na neku drugu lokaciju bi zahtevalo i zaštitnu konstrukciju koja bi mogla da utiče na kvalitet snimljenog zvuka jer putanja

ketanja vozila nije toliko usmerena kao na ulaznoj rampi gde je vozač prinuđen da rukom uzme karticu ili žeton.

4.2 Realizacija automatizovanog sistema za prikupljanje uzoraka zvuka

Posle izbora lokacije, pozicije mikrofona i provere uticaja pozicije mikrofona u odnosu na izvor zvuka, pristupilo se realizaciji sistema za akviziciju zvuka. Postavljeni zahtevi da je početak snimanja uzorka zvuka iniciran detekcijom prisustva vozila iznad mikrofona, da je dužinu audio snimka moguće prilagoditi u zavisnosti od lokacije gde se vrši prikupljanje, jer vreme zadržavanja nije identično na svim ulazima u garažu, da je sistem prenosiv i da ne zahteva fiksnu instalaciju na lokaciji za merenje, uslovili su da celokupan sistem bude organizovan na sledeći način: Centralni deo sistema zahvaljujući softveru generisanom u programskom jeziku *Python* vrši obradu signala i čuvanje zvučnih zapisa u zavisnosti od parametara koje dobija od podsistema za detekciju prisustva vozila i analogno-digitalnog konvertora signala sa mikrofona, dok se svi elementi sistema napajaju energijom koja se skladišti u prenosivoj bateriji.

Sistem je, u konačnom obliku, realizovan nakon nekoliko faza testiranja sprovedenih na ulazu u podzemnu garažu jednog od hipermarketa, a blok dijagram sistema je prikazan na slici 23. U svakoj od narednih faza testiranja su otklonjeni uočeni nedostaci prethodne faze. Uočeni nedostaci su detaljno diskutovani u opisu odgovarajućih celina sistema.



Slika 23. Blok dijagram prenosivog sistema za akviziciju zvuka

4.2.1 Detekcija prisustva vozila


Za detekciju prisustva vozila su izabrani ultrazvučni senzori pomoću kojih je moguće meriti rastojanje. Na ovaj način je izbegnuto narušavanje privatnosti korisnika upotrebom vizuelne identifikacije kamerama, kao i složene procedure dobijanja dozvola za postavljanje kamera, za čiji rad je dodatno potrebno više električne energije u odnosu na druge načine detekcije. Princip detekcije prisustva objekta baziran na fotemitujućim diodama je takođe razmatran, međutim, ovaj vid detekcije bi zahtevao barem dva para dioda/reflektor, što bi za detekciju vozila iziskivalo instalaciju u ukupno četiri tačke kako bi se izbegla detekcija drugih objekata poput ljudi, motocikala itd. Optički senzori koji detektuju promenu inteziteta osvetljenja bi bili upotrebljivi samo u svetlom ambijentu, jer bi samo tada došlo do veće promena nivoa osvetljenja prelaskom vozila preko senzora. Dodatno ovakvi senzori su osetljivi na prljanje, koje je u oblasti ispod motornog prostora zastupljeno, posebno u slučaju atmosferskih padavina, kada vozila sa mokrih saobraćajnica ulaze u garažu.

Ultrazvučni senzori pored manje kompleksnosti u konstrukciji u odnosu na druge tipove senzora za merenje rastojanja imaju nekoliko puta nižu cenu i mogu se smatrati robusnijim. Površina za emitovanje i prijem ultrazvučnih talasa je nekoliko puta veća od površine fotoemitujuće diode, što omogućava merenje distance, čak i ukoliko je deo senzora zaprljan kapljicom vode ili ulja. Široko rasprostranjeni indukciono senzori koji detektuju prisustvo vozila su odbačeni na samom početku istraživanja zbog načina instalacije koji zahteva fiksnu ugradnju u podlogu, međutim ukoliko su već instalirani na lokaciji gde se prikupljaju uzorci zvuka, primena ultrazvučnih senzora neće ometati njihov rad jer ne postoji mogućnost interferencije.

Kako detekcija prisustva vozila prethodi početku snimanja zvuka rada motora, prvi korak ka eliminaciji mogućnosti da se na snimku nađe neki drugi zvuk, u toku samostalnog rada sistema, je da ne dođe do lažne detekcije vozila. U cilju izbegavanja lažne detekcije vozila, korišćena su dva ultrazvučna senzora, jedan za merenje vertikalnog (y-osa) i drugi za merenje horizontalnog (x-osa) rastojanja od senzora do objekta.

Senzor za merenje vertikalnog rastojanja se nalazi pored mikrofona, na tlu, i detektuje prisustvo objekta (vozila) iznad mikrofona. Senzor za merenje horizontalnog rastojanja, u daljem

tekstu, bočni senzor, ima funkciju provere da je objekat koji je detektovan merenjem vertikalnog rastojanja tolike veličine da odgovara vozilu. Naime, u prostoru gde je realizovana akvizicija, pored vozila, postoji mogućnost prolaska motocikala, ljudi i kućnih ljubimaca. Upotrebom samo jednog senzora koji detektuje prisustvo objekta iznad mikrofona lako može doći do lažne pobude sistema odnosno do inicijacije snimanja što bi kasnije otežalo prepoznavanje zvuka rada motora i izdvajanje željenog režima rada. Postavljanjem drugog senzora uslov za početak snimanja je da svaki od senzora istovremeno detektuje objekat na rastojanju manjem od predefinisanih. Predefinisane vrednosti rastojanja je moguće softverski prilagoditi konkretnim uslovima na mestu gde se vrši prikupljanje uzoraka što stvara mogućnost primene akvizicionog sistema na različitim lokacijama. Raspored senzora u odnosu na pravac kretanja vozila je dat na slici 24.



Slika 24. Postavka senzora u odnosu na pravac kretanja vozila


Analizom lokacije mernog mesta, uočeno je da se može javiti slučaj da se dva ili više pešaka kreću jedan pored drugog, u liniji, i da teoretski postoji mogućnost da jedna osoba kratkotrajno zadovolji uslov minimalne razdaljine senzora koji meri vertikalno rastojanje, a druga osoba uslov senzora koji meri bočno rastojanje, usled čega bi došlo do lažne pobude sistema. Kako bi se ovaj slučaj izbegao, bočni senzor je pomeren van ravni normalne na pravac kretanja vozila iznad senzora na tlu, slika 25 (označeno crvenom bojom). U konkretnoj konfiguraciji ulaza u podzemnu garažu, bočni senzor je pomeren ispred senzora na tlu (ako se posmatra iz smera nailaska vozila), tako da formira svoju ravan normalnu na pravac kretanja vozila, slika 25 (označeno plavom bojom).



Slika 25. Prikaz ravni detekcije ultrazvučnih senzora

Kontrola rada senzora i izračunavanje rastojanja ostvareni su upotrebom mikrokontrolera *Atmega 328p* na *Arduino Nano* platformi. Na ovaj način omogućeno je kontinuirano “nadgledanje” prostora, bez obzira da li se neki od procesa obrade signala prethodno uzorkovanog vozila i dalje odvija na centralnom *Raspberry Pi* računar. Kontinuirana detekcija objekta (vozila) pruža mogućnost razdvajanja uzorkovanih vozila prema kriterijumu detekcije i prekida prisustva. Naime, dovoljno brzim cikličnim proverama zadovoljenja uslova predefinisanih rastojanja eliminiše se mogućnost da su se dva vozila smenila prilikom uzorkovanja. Komunikacija sa *Raspberry Pi* računarom je unidirekciona serijska tj. tek ukoliko se detektuje prisustvo vozila, mikrokontroler tu informaciju šalje centralnom računar.

Uzorci korišćeni u ovom istraživanju prikupljeni su na istoj lokaciji i za tu lokaciju korišćena su rastojanja od 40 cm za senzor na podlozi i 80 cm za bočni senzor, odnosno bilo je potrebno da istovremeno senzor na tlu detektuje objekat na rastojanju manjem od 40 cm, a bočni senzor na rastojanju manjem od 80 cm. Princip rada ultrazvučnih senzora se bazira na slanju ultrazvučnog impulsa koji se reflektuje o prepreku nakon čega se vraća do ultrazvučnog prijemnika, videti sliku 26.



Slika 26. Princip rada ultrazvučnih senzora za merenje rastojanja

Rastojanje je izračunato prema jednačini 3:

$$Rastojanje = \frac{T_{eha} * v_{zvuka}}{2} \quad (3)$$

pri čemu je T_{eha} vreme proteklo od emitovanja signala do prijema reflektovanog signala u sekundama, a v_{zvuka} brzina prostiranja zvuka (emitovanog ultrazvuka) u vazduhu.

Korišćeni su široko rasprostranjeni vodootporni ultrazvučni moduli *JSN-SR04T* čija je karakteristika data u [90]. Ovi moduli pored senzora sadrže namenski izlazni stepen za pobudu senzora na osnovu komande sa mikrokontrolera i set filtara za zabeleženi reflektovani talas, tj eho. Algoritam rada mikrokontrolera koji upotrebom dva *JSN-SR04T* modula meri rastojanja dat je na slici 27. U jednačinama 4 i 5 za proračun bočnog i vertikalnog rastojanja koje su implementirane u kod mikroprocesora:


$$Bočno\ rastojanje\ (cm) = Vreme\ eha\ 1 * 0,034/2 + 2 \quad (4)$$

$$Vertikalno\ rastojanje\ (cm) = Vreme\ eha\ 2 * 0,034/2 + 2 \quad (5)$$

može se uočiti dodatni sabirak 2 koji predstavlja kalibracioni faktor.

Kalibracioni faktor je posledica fizičkih dimenzija senzora kao i njihove instalacije gde je senzor na tlu bilo potrebno delimično ukopati u gumenu prevodnicu kako ne bi došlo do fizičkog oštećenja ukoliko vozilo točkom pređe neposredno preko senzora. Takođe se u prikazanom algoritmu može uočiti da je izabrano vreme trajanja emitovanja ultrazvučnog talasa 10 μs što se pokazalo kao adekvatan izbor uzimajući u obzir merenja rastojanja i veličinu detektovanog objekta tj potrebnu preciznost merenja. Kraći interval daje preciznije merenje na malim rastojanjima, dok duži interval omogućava merenje na većim rastojanjima. Izabrani interval je rezultirao preciznošću od ± 1 cm što se za objekat veličine putničkog vozila može smatrati zanemarljivim.

Prikazani algoritam pored detekcije prisustva vozila i komande za početak snimanja ima funkciju i kontinuiranog „nadgledanja“ da li je došlo do smene vozila iznad mikrofona, tj. da li je detektovano vozilo napustilo prostor iznad mikrofona, a na njegovo mesto stiglo drugo vozilo. Korišćenjem promenljive „brojač prazno“ se broji koliko puta su ultrazvučni senzori detektovali prazan prostor, tj. situaciju da se vozilo ne nalazi iznad mikrofona. U realnom okruženju, prilikom testiranja sistema, utvrđeno je da je potrebno postaviti uslov da se dogode dve uzastopne „prazne“ detekcije kako ne bi došlo do lažne detekcije da je neko vozilo napustilo prostor iznad mikrofona, što je detaljnije objašnjeno u nastavku ovog poglavlja.



Slika 27. Algoritam rada mikrokontrolera za određivanje prisustva vozila


Prvobitna instalacija sistema na ulaznoj rampi podzemne garaže pokazala je da je sistem detektovao samo vozila i da su audio snimci zabeleženi nakon detekcije sadržali samo signale koji potiču od motora sa unutrašnjim sagorevanjem. Međutim, vreme čekanja vozila iznad mikrofona značajno je variralo od slučaja do slučaja. Zbog ove pojave primenjena su tri različita pristupa za snimanje audio signala (A, B i C) na osnovu aktivnosti ultrazvučnih senzora. U prvom slučaju (A) definisano je da nakon detekcije objekta (vozila) ultrazvučni senzori ostaju neaktivni 5 s dok ostatak sistema ne završi snimanje audio uzorka. U pristupu B, fiksno vreme neaktivnosti senzora od 5 s nakon detekcije zamenjeno je vremenom od 8 s. Treći pristup (C) se odnosi na situaciju u kojoj su senzori bili stalno aktivni kako bi detektovali kada je vozilo napustilo prostor iznad mikrofona, ne šaljući naredbu ostatku sistema da započne sledeće snimanje. Ako su senzori u dve uzastopne iteracije razdvojene u vremenu od 50 mikrosekundi detektovali odsustvo vozila, sistem je tumačio ovu situaciju kao da je vozilo napustilo poziciju. Ovo je važno jer je praćenjem merenja rastojanja uočeno da povremeno neki od senzora izmeri veću udaljenost do vozila u odnosu na realno rastojanje. Ova pojava je uzrokovana refleksijama ultrazvučnih talasa višeg reda, koja se javlja zbog dugog prisustva vozila u stanju mirovanja što se posledično u akvizicionom sistemu tumači kao neispunjavanje uslova prisustva. Takav fenomen se pripisuje disperziji ultrazvučnih talasa koji može nastati usled oblika karoserije vozila. Tokom testiranja sistema pokazalo se da je ova pojava veoma retka. Više detalja o ova tri pristupa dato je kasnije u poglavlju 4.2.5.

U pogledu negativnih efekata konstantnog izlaganja pešaka ultrazvučnim talasima, korišćeni ultrazvučni senzori su veoma male snage, projektovani za merenje udaljenosti do 4,5 m, što znači da nivo signala može biti zanemarljiv na većim udaljenostima zbog disperzije. Ako pogledamo konfiguraciju ulaza u podzemne garaže, širina prolaza za vozila mora biti najmanje 3 m. Na ovaj način, ako postoji pešački prolaz, on se može naći samo na udaljenosti većoj od 3 m od senzora. Osim toga, u roku od nekoliko sati prikupljanja uzoraka, primećeno je manje od 10 prolaznika, koji su bili na rastajunju većem od 5 m u odnosu na senzore.

Detekcija prisustva vozila je ispitana prilikom svakog prikupljanja uzoraka koje je realizovano iz četiri sesije. U toku prvog prikupljanja od 50 uzorkovanih vozila detektovano je 50 vozila bez lažnih pobuda za započinjanje snimanja, a u toku drugog, trećeg i četvrtog snimanja uzorkovano je po 100 vozila gde je takođe detektovano prisustvo svakog vozila bez lažnih pobuda.

4.2.2 Snimanje audio signala

Za akviziciju zvuka rada motora izabran je omnidirekcionni mikrofonski *AKG C562CM* čija je karakteristika data na slici 28, a specifikacija u [91]. Razlog za izbor ovog mikrofona je pored dobre frekvencijske karakteristike i njegova konstrukcija gde je proizviđač mikrofonski smestio u izuzetno čvrsto metalno kućište sa odgovarajućim navojem za ugradnju, što eliminiše potrebu za izradom zaštitnog kućišta koje bi moglo da utiče na frekvencijsku karakteristiku.




Slika 28. Frekvencijska karakteristika mikrofona *AKG C562CM*

Mikrofon je postavljen na tlo, u prostoru iznad kojeg se zaustavlja vozilo prilikom čekanja da se ulazna rampa otvori. Kako bi ceo sistem bio prenosiv i kako ne bi zahtevao trajnu instalaciju na svakom mernom mestu, mikrofonski je, zajedno sa ultrazvučnim senzorom koji meri vertikalno rastojanje, smešten u namenski razvijenu gumenu prevodnicu koja je u celosti prikazana na slikama 24 i 25, dok je na slici 29 prikazan izgled samog mikrofona i njegova pozicija u okviru prevodnice koja ga štiti od slučajnog prelaska točkom.



Slika 29. Zaštita mikrofona i ultrazvučnog senzora od slučajnog prelaska točkom

Gumena prevodnica je izrađena od industrijske gume tvrdoće 90 Sha (mereno na $+23^{\circ}\text{C} \pm 2^{\circ}\text{C}$ prema ISO-48-4 standardu). Ova prevodnica zbog svoje težine, i materijala koji ima dovoljnu silu trenja sa podlogom je pokazala da nema potrebe za trajnim pričvršćivanjem za podlogu, obzirom da nijedno od 350 uzorkovanih vozila nije promijenilo njenu poziciju. Dodatno je bilo potrebno prilagoditi upadni ugao ivica na koje nailazi i sa kojih silazi točak, kako se ne bi u zabeleženim uzorcima zvuka pojavili dodatni, nepoželjni, zvuci prelaska točka preko prevodnice. Ovaj ugao je određen empirijski i iznosi približno 150° u odnosu na ravan nailaska točka, slika 30.



Slika 30. Upadni ugao prevodnice u odnosu na pravac nailaska točka

Parametri za snimanje audio signala, koji su značajni za kvalitet uzoraka zvuka u naknadnoj detaljnoj analizi, jesu prvobitno izabrani da budu: frekvencija odmeravanja 44100 Hz i rezolucija 16 bita. Ceo sistem je zamišljen da ima mogućnost beleženja i višeg kvaliteta do maksimalnih 96 kHz u sekundi i kvantizacijom od 24 bita ukoliko to bude potrebno za analizu. Kako ovako visok kvalitet zvuka, odnosno analogno digitalne konverzije signala zabeleženog mikrofonom, nije moguće realizovati upotrebom samo *Raspberry Pi* računara bez dodatnih modula, za analogno digitalnu konverziju je izabran uređaj *iRIG PRE HD* čija je specifikacija data u [92]. Ovaj uređaj pored visokog kvaliteta analogno-digitalne konverzije, ima mogućnost fantomskog napajanja, potrebnog za kondenzatorski mikrofoni, kao i mogućnost podešavanja nivoa analognog signala koji će biti konvertovan u digitalni (*gain-a*).

Napajanje uređaja je baterijsko što se u potpunosti uklapa u koncepciju prenosivog sistema, a izlazni niz podataka (*stream*), koji predstavlja konvertovani signal sa mikrofona, se putem USB porta prenosi na *Raspberry Pi* računar. Pored toga, upotreba eksternog A/D konvertora omogućava *Raspberry Pi* računaru da radi sa nižom procesorskom snagom i manjom potrošnjom energije.

Na *Raspberry Pi* računar, razvijeni *Python* kod se pokreće nakon priključenja na napajanje. U okviru ovog koda se vrši monitoring (“osluškuje se”) serijske komunikacije preko USB porta kako bi se od mikrokontrolera na *Arduino* platformi primile informacije o prisustvu vozila. Kada se vozilo detektuje, realizuje se niz procesa koji su opisani u sledećem poglavlju.

4.2.3 Procedura akvizicije


Kako bi se obezbedili audio snimci koji sadrže isključivo željeni režim rada motora, tj. režim praznog hoda, i kako bi se ostvarila minimalna potrošnja energije, *Raspberry PI 3+* računar je programiran tako da tek nakon uspešne detekcije vozila (prvog nivoa provere) aktivira audio interfejs tj mikrofona. Nakon toga, kroz višestruke namenski razvijene funkcije, *Raspberry PI 3+* vrši proveru digitalnog niza podataka dobijenog preko USB porta sa audio interfejsa pre nego što u memoriju (SD karticu) upiše novi audio zapis zvuka rada motora u *wav* formatu.

Tek kada je detektovani nivo zvuka iznad predefinisane praga od 74 dB, počinje skladištenje *stream*-a u baferu (drugi nivo provere). Nivo praga od 74 dB je utvrđen empirijski, na uzorku od 20 vozila u realnim uslovima. Na ovaj način je eliminisana mogućnost slučajne pobude senzora i beleženja audio snimka koji ne sadrži zvuk rada motora.

Trajanje audio snimka je prvobitno podešeno na 5 s, a nakon isteka vremena *stream* se zaustavlja. Da bi se izbegla slučajna pobuda potencijalno izazvana prolaskom motocikla, *stream* se dodatno proverava nakon zaustavljanja. Naime, na lokaciji na kojoj su uzeti uzorci, i u većini podzemnih garaža, motociklima je dozvoljen ulaz bez ikakvih prepreka pored rampe, tako da se ne zaustavljaju na ulazu. Pomenuta provera se vrši jednostavno – nakon 0,8 s od početka zabeleženog *stream*-a proverava se nivo signala u odnosu na postavljeni nivo praga (treći nivo provere).

Ako je uslov praga ispunjen u tom segmentu toka podataka, audio signal se čuva kao *wav* datoteka na SD kartici. Izabrani vremenski interval je rezultat uočene pojave da se kod vozila sa start-stop sistemom rad motora zaustavlja nakon 1 s mirovanja i da bi kasnija provera eliminisala takve audio zapise, koji su se po svom obliku pokazali kao korisni, bez obzira što su kraćeg trajanja. Zvanični podaci o vremenu prestanka rada motora kod vozila opremljenih start-stop sistemom


predstavljaju diskreciju proizvođača i nisu javno dostupni. Celokupan postupak od detekcije vozila do zabeleženog audio snimka u wav formatu prikazan je na slici 31.




Slika 31. Princip rada konačno relizovanog samostalnog, prenosivog sistema za prikupljanje uzoraka zvuka rada motora u režimu praznog hoda

4.2.4 Izdvajanje režima praznog hoda


Četvrti nivo provere je posebno razvijen algoritam gde se iz postojeće wav datoteke izdvaja samo režim praznog hoda rada motora (stacionarni signal). Postupak izdvajanja režima praznog hoda motora je realizovan u vremenskom domenu, kako bi se upotreba resursa svela na minimum i omogućila što veća autonomija rada akvizicionog sistema. Da bi se obradom signala u vremenskom domenu izdvojio stacionarni deo svakog snimljenog audio signala koji odgovara praznom hodu motora, bilo je potrebno odrediti prag (vremenski momenat) posle kojeg nestacionarni deo signal treba elininisati. Zbog načina detekcije i beleženja zvučnih zapisa, stacionarni deo signala se uvek pojavljuje na početku signala, videti slike 32, 33 i 34. U toku testiranja sistema uočeno je da nema slučajeva da se prazan hod dogodi kasnije (u sredini ili na kraju signala). Dakle, jasno je da je prag potrebno pronaći u određenom vremenskom trenutku nakon stacionarnog dela signala, odnosno u prvom trenutku kada signal postane nestacionaran.



Slika 32. Audio signal u vremenskom domenu (a) benzinskog i (b) dizel motora u režimu praznog hoda, bez promene režima



Slika 33. Audio signal u vremenskom domenu benzinskog motora sa (a) ranom i (b) kasnom promenom režima rada



Slika 34. Audio signal u vremenskom domenu dizel motora sa (a) ranom i (b) kasnom promenom režima rada


Na osnovu analize oblika snimljenih signala u vremenskom domenu, primećuje se da u trenutku kada signal prestane da bude stacionaran, njegova amplituda naglo raste. Ideja za izdvajanje stacionarnog dela snimljenog signala zasniva se na generisanju anvelope signala i izračunavanju razlike između trenutne i prethodne vrednosti duž anvelope. Dok je signal stacionaran, očekuje se da će razlika između trenutne i prethodne vrednosti anvelope biti mala. S druge strane, u trenutku kada signal prestane da miruje, razlika između trenutne i prethodne vrednosti anvelope mora biti znatno veća od razlike u vremenskim trenucima pre tog trenutka. Prvi vremenski trenutak od početka do kraja signala gde postoji značajno povećanje razlike između trenutne i prethodne vrednosti anvelope je kandidat za postavljanje praga pa je ovo značajno povećanje potrebno kvantifikovati. Ako je anvelopa signala označena kao $Env(t)$, a prag koji predstavlja gornju vremensku granicu stacionarnog dela signala kao t_L , sam prag se može odrediti kao:

$$t_L = \min\{Env(t) - Env(t - 1) > A\} \cdot \left(\frac{t_s}{N_f}\right) \quad (6)$$


gde t_s označava trajanje signala, a N_f je broj okvira (segmenata) u kojima se u postupku generisanja anvelope signala izračunavaju maksimumi signala. A je konstanta čija je vrednost 0,1 određena empirijski. Za vrednosti konstante A ispod 0,1 dobijeni su uzorci zvuka kod kojih je izostavljen deo stacionarnog signala praznog hoda (uzorci su kraći nego sam stacionarni deo), dok su za vrednosti veće od 0,1 dobijeni uzorci zvuka koji sadrže i početni trenutak promene režima rada što za posledicu može imati lošu normalizaciju u daljoj analizi. Pošto je potrebno podesiti prag u prvom vremenskom trenutku nakon skoka anvelope gledajući od početka signala do

njegovog kraja, za prag t_L uzima se najmanja vrednost koja zadovoljava uslov $Env(t) - Env(t - 1) > 0,1$. Tačnije, pošto je vremenska promenljiva t data u okvirima u vremenskom domenu (segmentima) koji se koriste za generisanje anvelope signala, uslov $\min\{Env(t) - Env(t - 1) > A\}$ daje okvir anvelope u kojem postoji skok koji ukazuje na prelazak sa stacionarnog na nestacionarni deo signala. Da bi se dobio tačan vremenski trenutak za postavljanje praga, potrebno je normalizovati dobijenu vrednost okvira anvelope sa t_s/N_f . U slučaju analiziranih signala, veličina okvira za generisanje anvelope je 4000 odmeraka sa preklapanjem okvira od 1000 odmeraka. To znači da je rezolucija za postavljanje praga t_L određena veličinom okvira, koja se može izabrati u skladu sa prirodom analiziranog signala.


Dobijeni vremenski trenuci koji označavaju prag (trenutak do koga se izdvaja deo signala praznog hoda motora koji se koristi za banku uzoraka) je na slikama 35, 36 i 37 označen ljubičastom vertikalnom linijom. Na snimljenim uzorcima gde nema promene režima rada motora, vremenski trenutak odsecanja nije mogao biti određen na opisani način. U tom slučaju, čitav audio zapis se koristi kao prazan hod motora i koristi se za dalje analize i obradu. Za slučaj kada vozilo koristi dizel i kada se dogodio rani odlazak vozila gotovo na samom početku snimka, definisana tačka sečenja je bila veoma blizu početka signala (slika 37(a)) što znači da nije detektovan dovoljno dugačak stacionarni režim rada motora, pa je odgovarajućom funkcijom provere trajanja stacionarnog režima ovaj snimak odbačen bez izdvajanja signala.



Slika 35. Anvelopa audio signala u vremenskom domenu (a) benzinskog i (b) dizel motora u praznom hodu, bez promene režima rada



Slika 36. Anvelopa audio signala u vremenskom domenu benzinskog motora sa (a) ranom i (b) kasnom promenom režima rada



Slika 37. Anvelopa audio signala u vremenskom domenu dizel motora sa (a) ranom i (b) kasnom promenom režima rada

4.2.5 Analiza snimljenih audio signala

Pozicioniranjem akvizicionog sistema na ulazu u podzemnu garažu sa rampom na kojoj je potrebno zaustaviti vozilo radi uzimanja žetona dalo je rezultate iznad očekivanja u pogledu kvaliteta i broja audio snimaka. Ovi snimci imaju sledeće parametre: brzinu odmeravanja od 44,1 kHz, rezoluciju 16 bita po odmerku, fiksno trajanje od 5 s, tj. veličinom datoteke od približno 431 kB, što pruža mogućnost skladištenja približno 67800 audio uzoraka pod pretpostavkom efektivnog prostora za skladištenje od 28 GB na SD kartici od 32 GB. Za napajanje je korišćena eksterna baterija (*power bank*) kapaciteta 10 Ah, koja je potrošena za oko 20% kapaciteta za 2 sata snimanja, što pokazuje da je sistem u stanju da sa ovim napajanjem funkcioniše barem 10 sati na potpuno autonoman način.

Paralelno sa autonomnim radom sistema vođena je i manuelna evidencija tipa pogonskog goriva za svako od uzorkovanih vozila, što znači da su uzorci „ručno“ obeležavani. Ovo je urađeno da bi se identifikovala moguća greška, npr. audio snimak koji bi bio neupotrebljiv zbog prevelike buke okoline koja bi mogla biti prisutna u zatvorenom prostoru, a koja obično dolazi od ventilacije garaže, kao i zbog kasnije verifikacije uspešnosti različitih klasifikacionih metoda. Ovaj slučaj (prevelika buka okoline) se u praksi nije dogodio kao rezultat pravilno postavljenog praga koji određuje početak snimanja. Uzimajući u obzir tri gore pomenuta pristupa (A, B i C), nakon analize snimaka, veoma važan zaključak je da nijedno vozilo nije prošlo pored akvizicionog sistema, a da nije aktiviralo sistem da snimi zvuk rada njegovog motora. Takođe, događaji osim prolaska putničkih vozila nisu lažno aktivirali sistem, a nije dobijen nijedan potpuno prazan snimak.

Tabela 5 daje uporedni pregled ova tri pristupa u pogledu broja prikupljenih uzoraka kao i upotrebljivosti uzoraka. Vredi napomenuti da je tokom prikupljanja audio uzoraka veoma mali procenat vozila pripadao starijoj generaciji vozila. Većina dizel vozila pripadala je generaciji *common rail* tipa ubrizgavanja, dok je većina benzinskih vozila imala višestruko indirektno ubrizgavanje.

U tabeli 5 dat je ukupan broj zvučnih zapisa i broj korisnih zvučnih zapisa pri čemu se broj korisnih zvučnih zapisa odnosi na čist zvuk rada motora u praznom hodu, dok ostali snimci i dalje sadrže zvukove motora vozila, ali koji pored režima rada u praznom hodu sadrže i zvuk vozila prilikom napuštanja pozicije (dakle ovde se ne radi isključivo o režimu praznog hoda). Velika većina snimaka su korisni snimci, a njihov procenat u odnosu na ukupan broj snimaka je iznad 90%, pri čemu je ovaj procenat najveći za pristup ultrazvučne detekcije C i iznosi blizu 97%.

Tabela 5. Uporedni pregled tri različita načina detekcije vozila (A, B i C) u smislu broja i upotrebljivosti prikupljenih uzoraka

	A (senzori neaktivni 5 s nakon detekcije vozila)	B (senzori neaktivni 8 s nakon detekcije vozila)	C (kontinualna detekcija prisustva vozila)
Broj vozila koja su prošla kroz akvizicioni sistem	50	100	100
Broj detektovanih vozila	50	100	100
Ukupan broj uzoraka zvuka	111	143	122
Ukupan broj korisnih uzoraka zvuka	101	133	118
Broj uzoraka zvuka koji sadrže režim praznog hoda (bez dodatnog izdvajanja)	69	97	109
Procenat detektovanih vozila	100%	100%	100%
Procenat korisnih uzoraka zvuka u odnosu na ukupan broj prikupljenih uzoraka	90,99%	93%	96,72%
Procenat korisnih uzoraka zvuka u odnosu na broj uzorkovanih vozila	202%	133%	118%
Procenat uzoraka zvuka koji sadrže režim praznog hoda (bez dodatnog izdvajanja) u odnosu na broj uzorkovanih vozila	138%	97%	109%
Procenat uzoraka zvuka koji ne zahtevaju četvrti nivo provere u odnosu na ukupan broj uzoraka	62,16%	67,83%	89,34%

Upoređivanjem tri pristupa ultrazvučne detekcije iz tabele 5, može se primetiti da je pristup A sa fiksnim vremenskim intervalom detekcije (neaktivnosti senzora) od 5 s dao najviše audio uzoraka, čak 202% korisnih snimaka u odnosu na broj vozila. Ovaj pristup je prvenstveno pogodan za generisanje najvećeg mogućeg skupa podataka, ali nije pogodan sa stanovišta efikasnog korišćenja resursa za skladištenje. Ako se sistem koristi na ovaj način za detekciju i prepoznavanje tipa motora u realnim uslovima, biće slučajeva da se isto vozilo detektuje više puta. Strogo govoreći, ovaj povećani broj snimljenih audio signala za neka vozila mogao bi imati određene štetne efekte na algoritme mašinskog/dubokog učenje zbog prevelike zastupljenosti u odnosu na druga. Sistem omogućava, ukoliko je potrebno, da se suvišni snimci za isto vozilo mogu lako ukloniti iz skupa podataka prema vremenu snimanja.

Pristup B (vremenski interval neaktivnosti senzora od 8 s o detekciji vozila) takođe je dao dobre rezultate u pogledu broja detektovanih vozila i količine zvučnih zapisa. Međutim, ima najmanji procenat snimaka samo u praznom hodu bez dodatne obrade u poređenju sa brojem

uzorkovanih vozila. Ovaj pristup ima efikasnije korišćenje memorijskih resursa u poređenju sa prvim pristupom, ali je zbog najmanjeg broja „čistih“ snimaka odbačen.

Najkompleksniji pristup (C), kontinuirana detekcija uz prepoznavanje slučaja ukoliko je došlo do smene vozila u toku intervala snimanja, dao je najmanje audio zapisa u odnosu na broj detektovanih vozila. S druge strane, ovaj pristup je najefikasniji u pogledu iskorišćenja memorije, čime se postiže visok procenat „čistih“ snimaka. Na ovaj način je dobijena najmanja redundantnost među uzorcima i najveći procenat korisnih snimaka u odnosu na ukupan broj snimaka. Ovo poslednje je dovelo do najmanje potrebe za dodatnom obradom (ušteda *CPU* resursa) i dodatnom energijom iz izvora napajanja. Preostali procenat od 22% ponovljenih snimaka, kod ovog pristupa, može se pripisati pre svega komunikaciji između *Arduino* platforme i koda koji se kontinuirano izvršava na *Raspberry Pi* računaru, usled čega se može javiti višestruka detekcija istog vozila. Dodatno, karakteristike saobraćaja, poput veoma sporog kretanja umesto potpunog zaustavljanja ili veoma dugog zadržavanja vozila u zoni akvizicije, doprinose povećanoj verovatnoći ponovljenih snimaka. Ipak, u poređenju sa preostala dva pristupa, ovaj metod značajno smanjuje redundantnost podataka.

U okviru sva tri pristupa (od A do C), za većinu vozila dobijen je jedan ili dva audio snimka po vozilu, pri čemu je prvi snimak predstavljao stacionarni režim rada motora u praznom hodu bez izuzetaka. U većini uzoraka, drugi snimak (u nekim slučajevima poslednji) delimično je sadržao režim praznog hoda motora praćen povećanjem brzine radilice i režim delimičnog opterećenja motora u cilju ubrzanja vozila, kao što je prikazano na slikama 33 i 34. Nije bilo slučajeva da se na snimcima pojavio režim delimičnog opterećenja motora pre režima praznog hoda. Primenom algoritma za izdvajanje režima praznog hoda iz zvučnih uzoraka koji su pored režima praznog hoda sadržali i promenu režima određeni su trenuci do kojih je signal stacionaran, slike 36 i 37, a nakon izdvajanja tog režima dobijeni su kraći uzorci, pogodni za dalju analizu.

Kako je kontinuirana detekcija (pristup C) dala naoptimalnije rezultate u pogledu iskorišćenja memorije, sadržaja snimaka, kao i najveći procenat korisnih snimaka za dalju analizu, realizovano je još jedno prikupljanje uzoraka za još sto vozila na identičnom mernom mestu. Kao rezultat primene razvijenog akvizicionog sistema formirana je banka uzoraka zvuka za 350 uzorkovanih vozila koja sadrži ukupno 475 uzoraka zvuka rada motora sa unutrašnjim sagorevanjem u režimu praznog hoda.

5. Izdvajanje akustičkih karakteristika SUS motora značajnih za klasifikaciju pogonskog goriva

Postupak izdvajanja akustičkih karakteristika (audio obeležja) SUS motora uključuje upotrebu odgovarajućih metoda analize audio signala koji sadrže zvuk generisan tokom rada SUS motora. Pri tome, u literaturi se za obeležja izdvojena iz zvučnih zapisa ili audio signala koriste i pridevi akustička i audio, gde se pridev akustička češće koristi u obradi govora, dok se audio koristi češće generalno u obradi svih audio signala. Zbog prethodno navedenog, u ovoj disertaciji će se koristiti izrazi akustička karakterizacija (bazirana na zvuku motora) i audio obeležja.

Klasifikacija pogonskog goriva na osnovu audio signala (zvuka motora) se bazira na pravilno izdvojenim akustičkim karakteristikama (audio obeležjima) rada motora, primeni neke od tehnika za obradu signala, ukoliko je to potrebno, a zatim upotrebu algoritama mašinskog i dubokog učenja. Ovakav pristup omogućava identifikaciju specifičnih obrazaca i karakteristika u zvuku koje su jedinstvene za različite tipove pogonskih goriva, kao što su benzin i dizel. Razumevanje ovih akustičkih karakteristika ne samo da može pomoći u preciznom određivanju vrste goriva, već se može koristiti i za druge namene, poput optimizacije rada motora, čime se postiže efikasnija potrošnja goriva i smanjenje emisije štetnih gasova. Pravilan izbor najznačajnijih obeležja zvučnih signala generisanih radom motora sa unutrašnjim sagorevanjem je ključan za efikasnost i preciznost klasifikacije nekom od metoda zvanom na algoritmima mašinskog ili dubokog učenja.

Uzimajući u obzir činjenicu da do trenutka kada je sprovedeno ovo istraživanje, klasifikacija motora prema zvuku na osnovu pogonskog goriva gotovo da nije zastupljena u dostupnoj literaturi, kao i da je istraživanje zasnovano na činjenici da čovek može da čulom sluha razlikuje tip pogonskog goriva na osnovu zvuka, u ovom poglavlju su predstavljena dva pristupa u izdvajanju audio obeležja zvuka generisanog radom SUS motora. Jedan pristup predstavlja izdvajanje obeležja na osnovu mapiranja audio signala u slike, dok drugi pristup predstavlja izračunavanje psihoakustičkih obeležja. U prethodno pomenutom kontekstu, kao prvi naredni korak u istraživanju nakon kreiranja baze uzoraka rada motora, izvršna je analiza dobijenih audio signala, na osnovu koje je realizovana softverska podrška (biblioteka funkcija) za izdvajanje

značajnih audio obeležja SUS motora. Krajnji cilj je pronalaženje skupa obeležja koji će primenom algoritama mašinskog i dubokog učenja dati što tačniju klasifikaciju.

5.1 Primena predefinisanih funkcija za izračunavanje audio obeležja SUS motora

U okviru ovog istraživanja kao početna tačka u pronalaženju najznačajnijih audio obeležja prikupljenih uzoraka rada SUS motora u praznom hodu, pre nego što su i definisana dva različita pristupa, poslužila je analiza sprovedena pri određivanju najpogodnije pozicije mikrofona, koja je opisana u prethodnom poglavlju. Spektralna analiza signala dobijenog radom benzinskog, odnosno dizel motora, je pokazala da postoje izvesne razlike frekvencijskog sadržaja zvuka ovih motora. Sa ciljem isticanja razlika u karakteristikama audio signala koji potiču od motora na benzin i dizel, izvršena je analiza predefinisanih skupa audio obeležja, koja se odnose na određeni broj obeležja u vremenskom i frekvencijskom domenu, a koja su prvobitno primenjena na govorne signale, muzičke signale i klasifikaciju muzičkih žanrova [93]. Referenca [93] predstavlja objedinjeni skup matematičkih funkcija za izdvajanje audio obeležja, pre svega govornih signala, ali bez ograničenja i na druge tipove audio signala. U svakom od ovih domena su, za svaki tip pogonskog goriva, posmatrana obeležja koja bi imala veći potencijal iz ugla mašinskog učenja i klasifikacije audio signala. Kako postoji veliki broj ovih obeležja, krajnji cilj analize je definisanje najznačajnijih, odnosno obeležja čijim poređenjem se mogu uočiti najveće razlike između motora tj. pogonskih goriva.

Za inicijalu detaljniju analizu su korišćena dva karakteristična audio signala. Ovi signali sadrže zvuk generisan SUS motorima putničkih vozila sa četiri cilindra približno iste zapremine unutar istog tržišnog segmenta, konkretno identičnih vozila koja su korišćena za određivanje optimalne pozicije mikrofona. Dužina analiziranih audio sekvenci iznosi 5 sekundi, odabrana tako da ne zahteva previše vremena za obradu, a da pritom obezbedi dovoljno ponavljanja karakterističnih delova signala.

Proces izdvajanja obeležja započinje deljenjem originalnog snimka zvuka motora na segmente kraćeg i fiksnog vremenskog trajanja, koji se zatim pojedinačno obrađuju odgovarajućim matematičkim funkcijama. Rezultat ovakve obrade je vektor obeležja koji se dobija nakon obrade u kraćim vremenskim intervalima (*short-term analysis*). Obradom u intervalima srednje dužine


trajanja (*mid-term analysis*) se dobijaju statistički parametri, odnosno varijacije obeležja po ovim parametrima - srednja vrednost (*mean*), medijana (*median*), standardna devijacija (*std*), standardna devijacija podeljena srednjom vrednošću (*stdbymean*), maksimalna i minimalna vrednost (*max*, *min*), itd.

U funkcijama za podelu ulaznog signala na segmente postoji mogućnost definisanja trajanja (veličine) segmenta, kao i vremenskog koraka pomeranja segmenata duž signala (preklapanja, u engleskoj literaturi *overlap* ili *hop size*). Prilikom inicijalne primene predefinisanih funkcija za izdvajanje obeležja korišćene su preporučene vrednosti iz [93] za *short-term* i *mid-term* analizu, odnosno dužina segmenta *short-term* analize od 50 ms sa korakom od 25 ms i dužina segmenta 2 s sa korakom od 1 s za *mid-term* analizu. Rezultat upotrebe preporučenih parametara je dao zadovoljavajuće rezultate koji su se mogli jasno grafički predstaviti, bez obzira što se nije radilo o govornim signalima. Na ovaj način je potvrđena mogućnost primene izračunavanja predefinisanih obeležja na širi spektar signala u odnosu na signale opisane u [93]. Rezultati izdvajanja audio obeležja su predstavljani grafički, pri čemu je x-osa, za svako od obeležja iz vremenskog domena, vreme kako bi se uočile varijacije odgovarajućih obeležja na celokupnom trajanju audio uzorka.

5.1.1 Obeležja u vremenskom domenu


Obeležja u vremenskom domenu se često koriste u audio analizi, i u njih spadaju: energija, entropija energije i broj prolaza kroz nulu (*ZCR*).

Energija predstavlja meru ukupne snage audio signala, koja se dobija kao srednje kvadratna vrednost amplitude signala unutar određenog vremenskog segmenta. Na slici 38 je prikazan rezultat izračunatih statističkih parametara za intervale kratke dužine (*short-term*) za audio obeležje koje predstavlja energiju audio zapisa vozila pokretanih na benzin (levo) i na dizel (desno). Uporednim pregledom za dve vrste pogonskih goriva može se uočiti da se po vrednosti izdvaja standardna devijacija podeljena srednjom vrednošću vektora energije dobijenog pojedinačnim izračunavanjem energije za svaki od audio segmenata analiziranog uzorka. Ovaj parametar je za benzinski motor približno konstantan dok je za dizel motor višeg nivoa i ima veće varijacije na celokupnom trajanju audio uzorka. Ostali statistički parametri obeležja „energija“ su približno jednaki nuli i gotovo se ne razlikuju za različita pogonska goriva.




Slika 38. Audio obeležje „energija“ audio zapisa vozila pokretanog na benzin (levo) i na dizel (desno) za intervale kratke dužine

Detaljnijom analizom izračunatih statističkih parametara iz intervala srednje dužine (*mid-term*) koji se odnose na energiju signala (maksimalna i minimalna vrednost, medijana, standardna devijacija, srednja vrednost i standardna devijacija podeljena srednjom vrednošću), koje su prikazane na slikama 39 i 40, jasno se može uočiti razlika u maksimalnim i minimalnim vrednostima energije, koja su kod vozila pokretanog na dizel približno deset puta veće u odnosu na vozilo pokretano na benzin. Posmatrajući srednju vrednost i medijanu, takođe se može uočiti da su vrednosti kod dizel motora znatno veće što je posledica višeg nivoa signala koje ovakav motor generiše. Standardna devijacija, kao mera disperzije u određenom skupu, je na obadva uzorka gotovo konstantna, ali je kod dizel motora približno deset puta veća, što se u realnosti može percipirati “grubljim” radom motora.



Slika 39. Audio obeležje „energija“ audio zapisa vozila pokretanog na benzin, uvećani prikaz za intervale srednje dužine




Slika 40. Audio obeležje „energija“ audio zapisa vozila pokretanog na dizel, uvećani prikaz za intervale srednje dužine

Posmatrajući vrednosti audio obeležja „energije“ za intervale kratke dužine na slikama 39 i 40, može se takođe uočiti određena razlika kod dva analizirana motora. Naime, kod motora pokretanog na benzin postoji veći broj izraženijih pikova čije su vrednosti slične, dok se kod

motora pokretanog na dizel pojavljuje manji broj ovakvih pikova u odnosu na ostale vrednosti obeležja (vrednosti u ostalim segmentima).


„Entropija energije“ je statistička mera raspodele ili koncentracije energije unutar segmenta audio signala [93] što omogućava da ovo obeležje bude upotrebljeno za detekciju značajnih promena u energiji signala kao što su pucnji, detonacije, buka iz okruženja itd. Ovo obeležje izdvojeno iz audio sekvenci zvuka motora sa unutrašnjim sagorevanjem je prikazano na slici 41.




Slika 41. Audio obeležje „entropija energije“ vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine

Na osnovu prikazanih rezultata se može uočiti da su „entropije energije“ motora sa unutrašnjim sagorevanjem pokretanih na benzin i dizel i po vrednosti i po obliku veoma slične, što odgovara “ujednačenom” radu motora u praksi. Perceptivno je moguće zapaziti da je rad konkretnog dizel motora nešto manje “ujednačen”.

Sa druge strane, oblik audio obeležja „entropija energije“ za intervale kratke dužine se nešto razlikuje kod benzinskih i dizel motora. Ovaj oblik je nešto “hrapaviji” (sa više zubaca) kod benzinskog motora nego kod dizel motora. Ovo je dodatno ilustrovano na slici 42 za vozilo pokretano na benzin, odnosno na slici 43 za vozilo pokretano na dizel. „Entropija energije“ za benzinski motor, ima složeniju (više „zupčastu“) strukturu, ali su šiljci (pikovi) češći i ujednačeniji u odnosu na slučaj kod dizel motora, gde se javlja manji broj ovih šiljaka sa većom razlikom u amplitudi.




Slika 42. Audio signal (slika gore) i obeležje „entropija energije“ (dole) zvuka vozila pokretanog na benzin dobijena za intervale kratke dužine



Slika 43. Audio signal (slika gore) i obeležje „entropija energije“ (dole) zvuka vozila pokretanog na dizel dobijena za intervale kratke dužine

Audio obeležje „broj prolaza kroz nulu“ (ZCR) predstavlja broj promena predznaka signala u određenom vremenskom intervalu, konkretno u ovom radu, u okviru svakog od segmenata analiziranih uzoraka. Rezultati izdvajanja ovog obeležja za dva različita tipa pogonskog goriva su prikazani na slici 44.



Slika 44. Audio obeležje „broj prolaza kroz nulu“ (ZCR) zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine


Upoređivanjem rezultata izdvojenog ZCR obeležja ne može se uočiti značajna razlika između motora sa unutrašnjim sagorevanjem pokretanih na benzin odnosno dizel zato što se radi o motorima sa istim brojem cilindara i istim brojem radnih taktova u jednom ciklusu, pri čemu rade na približno istom broju obrtaja radilice u minuti pa im je i osnovna frekvencija motora približno jednaka.

5.1.2 Obeležja u frekvencijskom domenu

U okviru analize u frekvencijskom domenu, prvo se računa diskretna Furijeova transformacija (*discrete Fourier transform-DFT*) pojedinačnih segmenata audio signala, nakon čega se izdvajaju sledeća obeležja: spektralni centroid (*spectral centroid*), spektralno širenje (*spectral spread*), spektralna entropija (*spectral entropy*) i MFCC koeficijenti.


Spektralni centroid i spektralno širenje predstavljaju meru položaja i oblika spektra [93]. Spektralni centroid predstavlja tačku (frekvenciju) ka kojoj gravitira najveći deo spektra (oko koje je energija spektra koncentrisana), dok je spektralno širenje mera disperzije ili širenja spektra oko spektralnog centroida. Rezultat izdvajanja obeležja „spektralni centroid“ za analizirane uzorke signala je prikazan na slici 45. Može se uočiti kako je frekvencija ka kojoj gravitira spektar vozila

pokretanog na dizel nešto niža u odnosu na vozilo pokretano na benzin što odgovara percepciji „dubljeg“ zvuka dizel motora. Vrednosti spektralnog centroida su bezdimenzione i normalizovane su deljenjem frekvencije spektralnog centroida Nikvistovom frekvencijom, što ih ograničava na opseg od 0 do 1. Ova normalizacija olakšava poređenje spektralnih centroida signala snimljenih sa različitim frekvencijama uzorkovanja.




Slika 45. Audio obeležje „spektralni centroid“ vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine

Kod audio obeležja „spektralno širenje“, veće vrednosti dobijenog parametra odgovaraju “svetlijem” zvuku [93]. Na slici 46 su prikazani dobijeni rezultati za ovo obeležje, gde je vidljivo da vozilo pokretano na benzin ima nešto veće vrednosti što takođe odgovara percepciji da vozila pokretana na benzin imaju manje prigušen, odnosno “svetliji” zvuk. Slično kao i za obeležje „spektralni centroid“ i vrednosti spektralnog širenja su predstavljene bezdimenziono tj. normalizovane su deljenjem Nikvistovom frekvencijom, što ih ograničava na opseg od 0 do 1.




Slika 46. Audio obeležje „spektralno širenje“ zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine

„Spektralna entropija“ se izračunava na sličan način kao i „entropija energije“, pri čemu se kod „spektralne entropije“ analizira raspodela energije u frekvencijskom spektru, tako što se spektar deli na manje podopsege za koje se računa entropija normalizovane spektralne energije. Spektralna entropija predstavlja meru ravnomernosti raspodele energije u frekvencijskom spektru, gde veće vrednosti ukazuju na ravnomerniju raspodelu, a manje vrednosti na koncentrisanu energiju na određenim frekvencijama. Na slici 47, koja prikazuje rezultat izdvajanja ovog obeležja, vozilo pokretano na benzin ima nešto veće vrednosti spektralne entropije u poređenju sa vozilom pokretanim na dizel. Ovo ukazuje na ravnomerniju raspodelu energije kroz spektar kod benzinskog motora, iako razlike nisu velike.




Slika 47. Audio obeležje „spektralna entropija“ zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine

Izdvajanje obeležja „*MFCC* koeficijenata“ podrazumeva određivanje kepralnih koeficijenata korišćenjem mel-ove skale, koja modeluje ljudsku (psihoakustičku) percepciju visine zvuka. Proces uključuje mapiranje spektra na mel skalu pomoću banke filtara, logaritmovanje energije i primenu diskretne kosinusne transformacije. Ovo audio obeležje je veoma zastupljeno u sistemima za automatsko prepoznavanje govora [93, 94]. Od ukupno 13 *MFCC* koeficijenata (obeležja), na slikama 48 i 49 su prikazana dva kod kojih je posebno jasna vidljiva razlika između vozila pokretanog na benzin i vozila pokretanog na dizel.



Slika 48. Audio obeležje „MFCC“ broj 8 zvuka vozila pokretanog na benzin (levo) i dizel (desno) za intervale srednje dužine



Slika 49. Audio obeležje MFCC broj 9 zvuka vozila pokretanog na benzin (levo) i dizel (desno)

Analizom slika 48 i 49 mogu se dobiti sledeći zaključci: vrednosti standardne devijacije podeljene sa srednjom vrednošću, srednje vrednosti i medijane obeležja su kod vozila na benzin pozitivne, dok su kod vozila na dizel negativne; maksimalna vrednost obeležja je kod vozila na benzin veća u odnosu na vozilo na dizel.

Među izdvojenim obeležjima, dobijeni rezultati su i za vremenski i za frekvencijski domen u skladu sa percepcijom slušaoca, pri čemu se grafičkim prikazom mogu uočiti razlike između tipa pogonskog goriva. Frekvencijska analiza, a posebno *MFCC* koeficijenti su dali najuočljiviju razliku između pogonskih goriva što pokazuje njihov potencijal za identifikaciju pogonskog goriva. Upravo na uočenim razlikama u grafičkom prikazu obeležja baziran je jedan od pristupa za izdvajanje obeležja tj. mapiranje (pretvaranje) zvučnih zapisa u slike.

5.2 Mapiranje audio signala motora sa unutrašnjim sagorevanjem u slike bazirane na spektrogramu

Vizuelne razlike između grafičkih prikaza izračunatih audio obeležja u frekvencijskom domenu za dva tipa pogonskog goriva koje su dobijene u prethodnoj fazi istraživanja, kao i radovi koji su, koristeći mapiranje zvučnih zapisa iz industrijskog okruženja u slike, dali visoku tačnost klasifikacije [95] motivisali su da nastavak istraživanja bude usmeren na adekvatno predstavljanje obeležja u vidu slika koje će u završnoj fazi predstavljati ulazne podatke za neki od algoritama mašinskog ili dubokog učenja.

Preslušavanjem snimljene baze uzoraka izdvojen je po jedan karakterističan signal rada benzinskog i jedan signal rada dizel motora u režimu praznog hoda. Kao predstavnici svojih klasa, ova dva signala su uporedno analizirana i mapirana u slike bazirane na spektrogramu, sa ciljem da se izdvoji prikaz ili nekoliko prikaza koji se vizuelno najviše razlikuju. Izabrani signali su mapirani u odgovarajuće slike koje imaju formu klasičnog spektrograma, mel-spektrograma, hromagrama, gamatonegrama i tempograma.

5.2.1 Spektrogram

Jedna od osnovnih tehnika za mapiranje akustičkih signala u sliku je ona koja kao rezultat daje spektrogram. Ovakva vrsta slike je veoma pogodna za korišćenje, zato što se pomoću nje signal predstavlja u tri dimenzije: na horizontalnoj osi prikazuje se vreme, na vertikalnoj osi prikazuje se frekvencija, dok se amplituda predstavlja skalom boja ili skalom nijansi boje. Spektrogram je grupa spektara signala poređanih jedan do drugog u vremenu, gde se vrednost spektralnih komponenti predstavlja intenzitetom boje. Spektrogram zapravo predstavlja „kratkovremensku“ (kratkoročnu) brzu Furijeovu transformaciju [96], i računa se kao brza Furijeova transformacija (*FFT*) na prozoru podataka (segmentu) koji se pomera duž vremenske ose.

Osnovna ideja kod spektrograma jeste da se ceo signal podeli na segmente (okvire, odnosno frejmove, eng. *frame*) koji se preklapaju u vremenu, i da se zatim primeni *FFT* na svaki segment. Korišćenje spektrograma je veoma važno kod signala koji su kvazi-stacionarni, odnosno kod

signala kod kojih postoji stacionarnost, ali samo u dovoljno kratkim intervalima (odsečcima) signala. Zbog toga, umesto standardne Furijeove transformacije koja transformiše vremenski diskretan signal beskonačnog trajanja u periodični spektar, kod obrade akustičkih i audio signala se uglavnom koristi vremenski kratkotrajna Furijeova transformacija. Njena glavna prednost jeste da se spektralna analiza sprovodi nad kratkim odsečcima signala kod kojih je zadovoljen uslov stacionarnosti.

Izdvajanje takvih odsečaka se sprovodi primenom odgovarajućih prozorskih funkcija u vremenu („vremenskih prozora“), koje su različite od nule samo za konačan skup indeksa. Množenjem ulaznog signala sa takvim vremenskim prozorom postavljenim na željeno mesto u signalu, dobija se novi signal takođe beskonačnog trajanja, ali čiji su uzorci jednaki nuli za sve indekse signala koji se nalaze izvan primenjenog vremenskog prozora.


Neka je audio signal dužine N odmeraka označen kao $s[n]$. Spektrogram signala predstavlja funkciju i vremena i frekvencije što se može zapisati kao:

$$STFT[f, t] = \sum_{n=0}^{N-1} s[n] \cdot w[n] e^{-j2\pi f n} \quad (7)$$


gde f predstavlja frekvenciju, n vremenski argument spektrograma, a $w[n]$ je prozorska funkcija.

U ovom istraživanju za računanje spektrograma signala korišćena je *stft* funkcija u okviru biblioteke *librosa* [97] u programskom jeziku *Python*. Podela signala na segmente (okvire) je već implementirana unutar funkcije. Potrebno je definisati širinu prozora W , zatim korak analize K (odnosno veličinu preklapanja prozora), kao i broj tačaka M u kojima se računa Furijeova transformacija. Drugim rečima, funkcija *stft* deli akustički signal na preklapajuće okvire (gde se definiše širina okvira i veličina preklapanja), zatim se za svaki od okvira računa *FFT* u onom broju tačaka koji se unapred definiše, a na spektrogramu se mogu pročitati informacije o vremenu, frekvenciji i amplitudi željenog signala. Izbor prethodno pomenutih parametara utiče na izgled spektrograma. Nakon izvršene analize gde su menjane vrednosti ovih parametara, izabran je sledeći skup parametara: širina prozora $W=2048$, preklapanje prozora $K=512$, i broj tačaka za računanje Furijeove transformacije $M=2048$. Izabrana prozorska funkcija je *Hann*-ova prozorska funkcija. Ovi parametri omogućavaju da se dobije takav spektrogram koji predstavlja kompromis između rezolucije u vremenskom i frekvencijskom domenu za spektre signala zvuka SUS motora.

Na slici 50. je prikazan spektrogram gde je snaga signala predstavljena u linearnoj razmeri, dok je na slici 51. takođe prikazan spektrogram istih signala pri čemu je snaga signala predstavljena u logaritamskoj razmeri.



Slika 50. Spektrogrami signala u linearnoj razmeri (linearni spektrogrami snage)



Slika 51. Spektrogrami signala u logaritamskoj razmeri (logaritamski spektrogrami snage)

Analizom signala spektrograma sa linearnom razmerom na slici 50 može se uočiti razlika signala između motora na benzin i dizel po više osnova. Spektrogram benzinskog motora ima gotovo desetostruko niži nivo signala, dok spektrogram dizel motora, pored višeg nivoa signala,


posедује izražene komponente i na frekvencijama iznad 64 Hz, što nije slučaj za benzinski motor. Pored toga, kod dizel motora je uočljiva neprekidnost spektrograma, posebno na osnovnoj učestanosti rada motora.

Prikazom ista dva signala u vidu spektrograma sa logaritamskom razmerom dobija se drugačiji prikaz frekvencijske raspodele signala, videti sliku 51. Na ovoj slici se takođe može uočiti viši nivo signala (veća koncentracija energije) zvučnog zapisa dizel motora na nižim frekvecnijama. Pored ove osobine signala dobijenog radom dizel motora, koji odgovara percepciji slušaoca, da ovaj tip motora generiše „dublji“ zvuk, može se uočiti ravnomernija „popunjenost“ spektra sve do visokih frekvencija, dok se kod benzinskog motora mogu uočiti frekvencijske oblasti sa nižom energijom, na primer na oko 500 Hz. Kod signala generisanog radom benzinskog motora je i u oblasti visokih frekvencija, preko 10 kHz, nivo signala nešto niži. Vredi istaći i činjenicu da su vozila sa dizel motorom često opremljena boljom zvučnom izolacijom, kako bi se smanjio uticaj buke koju proizvode dizel motori, čime se poboljšava komfor putnika u odnosu na iste modele vozila sa benzinskim motorima.

5.2.2 Mel-spektrogram

Mel-spektrogram predstavlja rezultat proračuna spektrograma upotrebom mel-skale. Ova skala koristi frekvencijske opsege različitih širina usklađene sa načinom na koji ljudi percipiraju tonove kao međusobno jednake po rastojanju. Mel skala odražava osobinu ljudskog sluha, koji nije jednako osetljiv na sve frekvencije.

Mapiranje audio signala u mel-spektrogram je realizovano upotrebom programskog jezika *Python* i biblioteke *librosa* [97]. Kako bi se dobio adekvatan prikaz signala korišćene su odgovarajuće funkcije sa sledećim parametrima: veličina prozora 1024 odmeraka, korak (pomeranje prozora) 256 odmeraka i broj generisanih mel frekvencijskih opsega 96. Prag izlaznog signala je definisan u odnosu na maksimalnu amplitudu 80 dB za određivanje amplitude signala u dB. Mel-spektrogrami reprezentativnih predstavnika klasa benzinskog i dizel motora su prikazani na slici 52.



Slika 52. Mel-spektrogram benzinskog (slika gore) i dizel motora (slika dole)


Prema dobijenim prikazima moguće je uočiti da se mel-spektrogrami za benzinski i dizel motor jasno razlikuju u odgovarajućim frekvencijskim opsezima, što je i očekivano uzimajući u obzir da postoje jasne perceptivne razlike zvukova ovih motora. Takođe je za dizel motor posebno istaknut viši nivo signala u opsegu od 4 kHz do 8 kHz, i u opsegu ispod 1 kHz. Za mel-spektrogram je karakteristična ravnomernija "popunjenost" grafičkog prikaza za dizel motor sa nekoliko značajnih komponenti koje se ističu duž čitavog audio signala. Dobijene razlike u mel-spektrogramima reprezentativnih signala za svaku od klasa su ukazale na potencijal da se mel-spektrogrami primene kao ulazni podaci za neki od klasifikatora baziranih na slikama. Pomenute činjenice su usmerile istraživanje ka detaljnijoj analizi mel-spektrograma na većem broju uzoraka, čiji su rezultati dati u poglavlju 5.4.

5.2.3 Hromagram

Hromagram (hroma spektar) predstavlja reprezentaciju audio signala u kojoj se ceo spektar projektuje na 12 binova koji predstavljaju 12 različitih polutonova (ili hroma) muzičke oktave [98]. Kako se u muzici note koje su udaljene za tačno jednu oktavu doživljavaju kao posebno slične, poznavanje raspodele hroma čak i bez poznavanja apsolutnih frekvencija (tj. originalne oktave) može pružiti korisne muzičke informacije o zvuku, odnosno može otkriti uočenu muzičku sličnost koja nije vidljiva u originalnim spektrima. Hromagram se dobija preslikavanjem diskretnih

vrednosti dobijenih kratkovremenskom brzom Furijeovom transformacijom (*STFT*) audio signala u 12 hroma, odnosno prelaskom iz domena diskretnih frekvencija u domen diskretnih veličina hroma.

Rezultat primene funkcija za određivanje hromograma za izabrane karakteristične signale rada benzinskog i dizel motora u praznom hodu je prikazan na slici 53 (*CQT – Constant Q-Transform* hromagram) . Na dobijenom prikazu se može uočiti da je kod dizel motora zastupljenost različitih visina tj. klasa tonova kroz čitav opseg od svih 12 klasa, gotovo uniforman, pri čemu su najistaknutije klase D, D#, F# i A#, dok su kod benzinskog motora izražene klase F, F#, G i A. Na osnovu ovakvog prikaza signala moguće je uočiti da su kod benzinskog motora zastupljenije osnovne klase tonova, dok su kod dizel motora zastupljenije povišene/snižene klase tonova.



Slika 53. Hromagrami benzinskog (slika gore) i dizel motora (slika dole)

5.2.4 Gamatonegram

Gama-spektrogram, odnosno gamatonegram, se za razliku od spektrograma zasniva na primeni *gamatone* filtara [99] kako bi se analiza zvuka približila percepciji čovekovog čula sluha. Spektrogram predstavlja vremensko-frekvencijsku vizualizaciju audio signala, ali zapravo ima nekih važnih razlika u odnosu na to kako ljudsko čulo sluha analizira zvuk. Najznačajnija razlika je to što frekvencijski podopsezi čula sluha postaju širi na višim frekvencijama, dok spektrogram

ima konstantan propusni opseg na svim frekvencijama, odnosno u svim frekvencijskim opsezima (kanalima). Kako bi se ovo ograničenje prevazišlo koriste se *gamatone* filtri.

Osnovna razlika između *gama* filtara (koji se koriste za generisanje gamatonegrama) i mel-skale je u tome što mel-skala suštinski predstavlja aproksimaciju ljudske percepcije visine tonova, dok su *gama* filtri zasnovani na fiziološkim modelima ljudskog slušnog sistema, odnosno na odgovoru slušnog sistema na spoljašnju pobudu zvukom.

Gamatone filtri su dizajnirani tako da modeluju frekvencijski selektivne aktivacione odzive ljudskog unutrašnjeg uva (kohlee) [100], pri čemu izlaz filtra simulira frekvencijski odziv bazilarne membrane. *Gamatone* filter je linearni filter opisan impulsnim odzivom koji je proizvod gama raspodele i sinusoidalnog tona. Impulsni odziv filtra dat je sledećom jednačinom:

$$g[k] = k^{P-1} T^{P-1} e^{-2bkT\pi} \cos(2fkT\pi + \theta) \quad (8)$$

gde je k vreme, P je red filtra, T je perioda odmeravanja, b je propusni opseg filtra, f je centralna frekvencija, a θ je faza nosioca. *Gamatone* filtri se sastoje od niza filtara propusnika opsega sa ciljem da modeluju ljudski slušni sistem. Banka *gamatone* filtara je formulisana prema „skali ekvivalentne pravougaone širine opsega“ (eng. *equivalent rectangular bandwidth – ERB*, odnosno *ERB* skala) [101], koja opisuje raspored frekvencijskih kanala u ljudskom unutrašnjem uvu na sledeći način:

$$ERB = 24,7(4,37 \cdot 10^{-3}f + 1) \quad (9)$$


Kako bi se generisao gamatonegram, korišćen je *toolbox* razvijen od strane Ellis at al. [99], primenjen u programskom jeziku *Python*. Prvo je audio signal transformisan u spektrogram (*STFT*), a zatim je primenjeno *gamatone* ponderisanje $COE[F_{gam}, F]$ na *STFT* kako bi se dobio gamatonegram:

$$GAM[f_{gam}, t] = COE[f_{gam}, f] \times STFT[f, t] \quad (10)$$

gde je f_{gam} rezolucija gamatonegrama (*GAM* spektrograma) i predstavlja broj *gamatone* filtara [102].

Primenom *gamatone* filtara prilikom proračuna spektrograma za signale koji su predstavnici klasa različitih pogonskih goriva dobijen je gamatonegram koji je prikazan na slici 54. Za dati prikaz su korišćena 64 *gamatone* filtra. Slično kao i kod mel-spektrograma, na

prikazanom gamatonegramu je moguće jasno uočiti razliku između dva pogonska goriva. Kod dizel motora, nivoi signala su viši na svim frekvencijama, a posebno je istaknut opseg 4-8 kHz, kao i opseg niskih frekvencija gde se nalazi osnovna frekvencija rada motora. Kod benzinskog motora je moguće uočiti veoma nizak nivo signala u opsegu ispod 1 kHz i iznad 10 kHz. Kako je gamatonegram posebno prilagođen ljudskom uvu, dobijeni prikazi odgovaraju percepciji „glasnijeg“ dizel motora u odnosu na benzinski motor.




Slika 54. Gamatonegram benzinskog (slika gore) i dizel motora (slika dole)

5.2.5 Tempogram

Tempogram se definiše kao vremenska-tempo reprezentacija, odnosno prikaz tempa u vremenu [103] i ima oblik sličan spektrogramu. Tempo predstavlja brzinu izvođenja muzičkog dela ili ritmičkog obrasca i izražava se u otkucajima u minuti (eng. *BPM* – *beats per minute*). Viši tempo znači brže izvođenje, dok niži tempo označava sporiji ritam. Tempogram signala je reprezentacija koja sadrži informaciju o lokalnom tempu za svaki frejm audio signala. Postoje dva tipa tempograma: Furijeov tempogram i autokorelacioni tempogram. Furijeov tempogram analizira frekvencijske komponente signala, konvertujući ih u tempo (*BPM*) i naglašavajući harmonike, dok autokorelacioni tempogram analizira vremensko kašnjenje (u sekundama) između periodičnih obrazaca, preslikavajući ga u tempo i ističući subharmonike. U ovom istraživanju je

korišćen ciklični tempogram dobijen upotrebom *librosa* biblioteke u *Python* programskom jeziku. Ciklični tempogram je izveden iz osnovnog Furijeovog tempograma [103] putem transformacije u ciklični domen. Ovakva vrsta tempograma se obično odnosi na reprezentaciju tempa u kojoj se ističu periodični obrasci tempa u odnosu na njihove harmonike.

U postupku analize izabranih audio signala posebna pažnja je posvećena percepciji slušaoca koja se odnosi na utisak veće ili manje ujednačenosti rada motora odnosno doživljaja tempa rada motora. Rezultat proračuna tempograma u vremenu prikazan je na slici 55, gde se mogu videti jasne razlike između benzinskog i dizel motora. Kod dizel motora, tempogram ima specifičan oblik gde se izdvajaju određene diskretne vrednosti tempa (horizontalne linije na tempogramu), dok kod benzinskog motora postoji uniformna raspodela vrednosti tempa u određenom opsegu bitova po minuti.



Slika 55. Tempogram benzinskog (slika gore) i dizel motora (slika dole)

5.3 Psihoakustička obeležja

Psihoakustika je nauka o ljudskoj percepciji zvuka. Za kvantifikaciju percepcije zvuka definisane su veličine (obeležja) koje povezuju percepciju (psihologija) i fizičku pobudu opisanu preko skupa varijabli (fizika) [104]. Neka od ovih obeležja, kao i načini na koje se ona izračunavaju su već standardizovani – glasnost (definisana u standardu DIN 45631/A1), tonalitet (definisana u standardu DIN 45681) i oštrina (definisana u standardu DIN 45692). Primena psihoakustičke analize se postepeno proširila u različitim oblastima industrije, kao što je projektovanje proizvoda i njihova proizvodnja, na primer razvoj centrifugalnih ventilatora za usisivače, detekcija kavitacije, dijagnoza kvarova zupčanika i opšte otkrivanje kvarova mašina [27] [83-85] [105-112]. Psihoakustičkim obeležjima se mogu efikasno izvući korisne informacije iz audio zapisa kojima mogu da se karakterišu varijacije u vremenskom i spektralnom domenu [84]. Ova obeležja mogu predstavljati alternativni skup vrednosti kojima se dopunjuju postojeći pristupi analize [85]. Shodno tome, ona imaju potencijal da se koriste u klasifikaciji različitih radnih uslova i mogu se primeniti kao ulazne veličine za algoritam samoorganizujućih mapa (SOM).

5.3.1 Glasnost

Glasnost je termin koji opisuje kako ljudi percipiraju nivoe zvuka [104]. Definisan je tako da 1 son odgovara tonu od 40 dB na 1 kHz. Skala glasnosti se koristi za kvantifikaciju koliko zvuk deluje glasno ljudskom uhu, i to je jedna od najvažnijih karakteristika za procenu kvaliteta zvuka. Za izračunavanje glasnosti, specifična glasnost se određuje prema:

$$N' = 0,08 \left(\frac{E}{E_0} \right)^{0,23} \left[\left(0,5 + 0,5 \frac{E}{E_{TQ}} \right)^{0,23} - 1 \right] \left[\frac{\text{sona}}{\text{bark}} \right] \quad (11)$$

gde je sa E_{TQ} označen nivo pobude na prag čujnosti, a sa E_0 nivo pobude koji se odnosi na referentni intenzitet od $I_0 = 10^{-12} \text{W/m}^2$. Kako se nivo pobude E približava nuli, specifična glasnost N' se takođe asimptotski približava nuli. Glasnost N se zatim izračunava integraljenjem specifične glasnosti preko kritičnog opsega z , koji se meri u jedinicama Bark. Ova integracija se može matematički izraziti kao:

$$N = \int_0^{24 \text{ bark}} N' dz \quad [\text{son}] \quad (12)$$

5.3.2 Hrapavost

Hrapavost predstavlja subjektivnu meru koja opisuje koliko deluje da je neki zvuk „grub“ ili „vibrirajući“ za čovekovo čulo sluha [104]. Ovaj slušni doživljaj nastaje kao rezultat brzih modulacija glasnosti ili frekvencije, pri čemu modulacije iznad 30 Hz stvaraju percepciju hrapavosti jer su previsoke da bi se mogle pojedinačno razlikovati. Hrapavost zvuka R u jedinici asper se može kvantifikovati korišćenjem sledećih jednačina:

$$R = 0,3 \frac{f_{\text{mod}}}{\text{kHz}} \int_0^{24 \text{ bark}} \frac{\Delta L_E(z)}{\text{dB bark}} dz \quad [\text{asper}] \quad (13)$$

$$\Delta L_E(z) = 20 \log \left(\frac{N_{\text{max}}}{N_{\text{min}}} \right) \quad [\text{dB}] \quad (14)$$

gde je $\Delta L_E(z)$ promena glasnosti u kritičnom opsegu, f_{mod} modulaciona frekvencija izražena u kHz, a N_{max} i N_{min} maksimalna i minimalna vrednost specifične glasnosti u trenutnom kritičnom opsegu, pri čemu se jedinica dB bark koristi za označavanje promena glasnosti zvuka unutar kritičnog opsega (Bark).

5.3.3 Oštrina

Oštrina kao psihoakustičko obeležje se odnosi na percepciju zvuka sa izraženim visokim tonovima. Ona je povezana sa udelom energije na visokim frekvencijama u odnosu na ukupnu energiju [104]. Da bi se kvantifikovala oštrina, raspodela glasnosti po frekvencijama se ponderiše i izračunava korišćenjem metode slične izračunavanju momenta površine, koja je predstavljena kao:

$$S = 0,11 \frac{\int_0^{24 \text{ bark}} N' g(z) z dz}{\int_0^{24 \text{ bark}} N' dz} \quad [\text{acum}] \quad (15)$$

gde je $g(z)$ funkcija ponderisanja koja ima konstantnu vrednost 1 ispod 3 kHz i nelinearni rast od 3 kHz do 20 kHz, gde ima vrednost četiri. Izražene spektralne komponentne na visokim frekvencijama su preduslov da oštrina ima visoke vrednosti.

5.3.4 Tonalitet

Tonalitet je karakteristika percepcije zvuka koja je povezana sa prisustvom tonalnih komponenti u spektru. Postoji nekoliko modela za izračunavanje tonaliteta, pri čemu je u ovom istraživanju korišćen Auresov model [113]:

$$T = c(\sum_{i=1}^n [q'_1(\Delta z_i) q'_2(f_i) q'_3(\Delta L_i)])^{\frac{0,29}{2}} \left(1 - \frac{N_{Gr}}{N}\right)^{0,79} [\text{t.u.}] \quad (16)$$

$$q_1(\Delta z_i) = \frac{0,13}{\Delta z + 0,13} \quad (17)$$

$$q_2(f_i) = \left(\sqrt{1 + 0,2 \left(\frac{f}{700} + \frac{700}{f} \right)^2} \right)^{-0,29} \quad (18)$$

$$q_3(\Delta L_i) = \left(1 - e^{\frac{-\Delta L_i}{15}} \right)^{0,29} \quad (19)$$

Funkcija ponderisanja za svaki od opsega komponenti tonaliteta, centralna frekvencija, i istaknutost (*prominence*) su predstavljeni sa $q'_1(\Delta z_i)$, $q'_2(f_i)$ i $q'_3(\Delta L_i)$, respektivno, gde je c konstanta izabrana tako da čist ton frekvencije 1 kHz nivoa 60 dB ima tonalitet vrednosti 1. N_{Gr} označava jačinu širokopojasne komponente šuma, Δz_i predstavlja razliku između frekvencije komponente tona i frekvencije maskirajuće buke, f_i je centralna frekvencija analiziranog tona, a ΔL_i predstavlja razliku u jačini zvuka između tonalne komponente i pozadinske buke. Dakle, tonalitet razlikuje zvukove koji prvenstveno sadrže tonalne komponente ili širokopojasni šum [104].

5.3.5 Rezultati izdvajanja psihoakustičkih obeležja SUS motora


Dužina audio snimaka rada motora u kreiranoj bazi uzoraka varira od dve do pet sekundi, nakon primene već opisanog algoritma koji eliminiše deo signala koji ne predstavlja rad u režimu praznog hoda. Važno je napomenuti da su ovde korišćeni samo stvarni podaci prikupljeni u relnim uslovima. Ovakav pristup osigurava autentičnost i pouzdanost dobijenih rezultata. Svaki snimljeni signal je podeljen na manje segmente dužine od 125 ms bez preklapanja, što je rezultiralo sa ukupno 17,606 segmenata (dalje korišćenih kao uzorci). Iz ovih uzoraka je izračunato 10 različitih obeležja, od kojih je pet izračunato direktno iz audio signala, a pet kao izvodi (derivati) prethodno dobijenih obeležja. Snimljeni audio signali koji sadrže zvuk rada motora nisu filtrirani, već je ceo

opseg frekvencija od 0 Hz do 20.000 Hz korišćen za ekstrakciju obeležja. Kako bi se povećala robusnost pristupa i krajnjeg rezultata klasifikacije, svaki signal je normalizovan pre ekstrakcije obeležja da bi se eliminisao uticaj nivoa zvučnog pritiska.

Sa ciljem boljeg razumevanja izdvojenih obeležja i njihove raspodele u zavisnosti od pogonskog goriva, grafički je uporedno predstavljena distribucija vrednosti obeležja za oba tipa pogonskog goriva. Na graficima izračunatih obeležja za celu bazu podataka su pored vrednosti već pomenutih psihoakustičkih obeležja date i vrednosti krest faktora, kao i broj prolaza kroz nulu, koji je na početku istraživanja analiziran samo za dva reprezentativna signala. Pri tome, krest faktor predstavlja odnos maksimalne (pik) vrednosti i efektivne vrednosti celokupnog signala, i izračunava se kao:


$$CF = \frac{|x_{\text{peak}}|}{x_{\text{rms}}} \quad (20)$$

Kao što što se može uočiti na slici 56, postoji veliko preklapanje raspodela vrednosti obeležja između dva tipa pogonskog goriva, i adekvatna klasifikacija u dve klase koristeći po jedno obeležje inicijalno izgleda malo verovatna. Uočljivo je da efekat korišćenja derivata za oštrinu, hrapavost i glasnost nije veliki, čak se može reći da je zanemarljiv. Derivat u ovom kontekstu pokazuje brzinu promene obeležja (npr. koliko brzo raste ili opada glasnost). Sa druge strane, primena derivata kod obeležja broj prolaza kroz nulu je uticala na distribuciju normalizovane vrednosti obeležja, dok je u slučaju krest faktora došlo do najveće promene koja se ogleda u pomeranju krive normalizovanih vrednosti obeležja ka nižim vrednostima.



Slika 56. Dobijene vrednosti definisanog skupa obeležja (gornji red grafika) i derivata ovih obeležja (donji red grafika)

Raspodele vrednosti psihoakustičkog obeležja tonaliteta za dve vrste pogonskog goriva se gotovo potpuno preklapaju, videti sliku 57, pa je ovo obeležje isključeno iz dalje analize.



Slika 57. Raspodela vrednosti tonaliteta i derivata tonaliteta za benzinska i dizel vozila

5.4. Sličnost zvukova motora sa unutrašnjim sagorevanjem bazirana na mel-spektrogramu

Sa ciljem što preciznije potencijalne binarne klasifikacije pogonskih goriva bazirane na slikama, ispitane su sličnosti mel-spektrograma na znatno većem broju uzoraka u odnosu na 5.2.2 za dve vrste pogonskog goriva. Za analizu je korišćena ranije pomenuta interno generisana baza zvukova motora sa unutrašnjim sagorevanjem koja se sastoji od 475 zvukova motora na dizel i benzin. Iz ove baze su identifikovane karakteristične podgrupe motora koje odgovaraju različitim pogonskim gorivima. Zvukovi iz ovih podgrupa su mapirani u mel-spektrogame čija je međusobna sličnost unutar podgrupa i između podgrupa analizirana primenom Euklidovog rastojanja.

Primena algoritma veštačke inteligencije baziranog na psihoakustičkim obeležjima, koji će detaljno biti opisan u narednom poglavlju, na generisanu bazu audio signala rezultirala je visokom tačnošću klasifikacije. Pri tome, određeni broj uzoraka, ispod 10%, je pogrešno klasifikovan. Broj benzinskih motora klasifikovanih kao dizel motor bio je za približno 25% veći nego broj dizel motora klasifikovanih kao benzin. Na osnovu dobijenih rezultata klasifikacije formirane su četiri podgrupe motora: benzinski motori klasifikovani tačno (“benzin klasifikovan kao benzin” – BkB), dizel motori klasifikovani tačno (DkD), benzinski motori klasifikovani kao dizel motori (BkD) i dizel motori klasifikovani kao benzinski motori (DkB). Dakle, pogrešno klasifikovani uzorci su smešteni u dve podrupe – podgrupa DkB (dizel motori klasifikovani kao benzinski motori) i podgrupa BkD (benzinski motori klasifikovani kao dizel motori), kako bi se dalje analizirali i doneli zaključci o uzrocima pogrešne klasifikacije.

Preslušavanjem je utvrđeno da u ovim podgrupama postoje motori veće međusobne sličnosti, pa su stoga formirane još četiri podgrupe: benzinski motori koji najviše zvuče kao benzinski motori (BpB – benzinski motor percipiran kao benzinski), dizel motori koji najviše zvuče kao dizel motori (DpD), benzinski motori koji se slušanjem mogu prepoznati kao dizel motori (BpD), i dizel motori čiji zvuk liči na zvuk benzinskih motora (DpB). Broj izabranih uzoraka u svakoj od ovih podgrupa je 16 najrepresantivnijih zvukova, kako bi se omogućio prikaz rezultata u vidu simetričnih grafika.

Audio signali iz podgrupa uzoraka su konvertovani u mel-spektrograme. Rezultat konverzije audio signala trajanja 5 sekundi, snimljenih sa frekvencijom odmeravanja 44100 Hz i rezolucijom 16 bita po odmerku, su mel-spektrogrami dimenzija 862×96 tačaka, gde je 96 broj mel podopsega.


Kako bi se kvantifikovala sličnost motora (mel-spektrograma zvuka motora) u okviru podgrupa, upotrebljena je često korišćena metoda u obradi slika – Euklidovo rastojanje [114, 115]. Ono može da se koristi za rastojanje između tačaka, ali i za određivanje sličnosti između slika korišćenjem više-dimenzionalne verzije izraza za Euklidovo rastojanje. Proračun Euklidovog rastojanja podrazumeva određivanje kvadratnog korena sume apsolutnih razlika pojedinačnih tačaka vektora p_k i q_k :

$$DE(p_k, q_k) = \sqrt{\sum_{k=1}^N (p_k - q_k)^2} \quad (21)$$

gde je N ukupan broj tačaka u svakom od vektora.


Euklidovo rastojanje je izračunato za sve podgrupe uzoraka na osnovu mel-spektrograma. Kako bi se formirao grafički prikaz u vidu kvadratne mape intenziteta (*heatmape*-e), Euklidovo rastojanje je izračunato za parove uzoraka po principu svaki uzorak sa svakim iz podgrupe. Prilikom formiranja grafičkog prikaza, x i y -osa su definisane nazivima uzoraka. Takođe su izračunata Euklidova rastojanja između reprezentativnih uzoraka i uzoraka unutar svake podgrupe. Ova analiza je urađena kako bi se utvrdilo koliko su uzorci iz podgrupe slični svojim reprezentativnim uzorcima (tj. koliko dobro podgrupa odražava karakteristike klase).

Dva reprezentativna mel-spektrograma (jedan za benzinski i jedan za dizel motor) su data na slici 58.




Slika 58. Mel-spektrogrami reprezentativnog benzinskog (B224) (slika gore) i dizel (D37) motora (slika dole)


Premet analize koja je za cilj imala pronalaženje uzroka pogrešne klasifikacije su predstavljali uzorci iz podgrupa BkD i DkB, kao i podgrupe zasnovane na percepciji slušaoca DpD, BpB, DpB i BpD. Proračunom Euklidovog rastojanja na osnovu mel-spektrograma za ovih šest podgrupa dobijene su vrednosti međusobnog rastojanja, odnosno sličnosti, koje su grafički prikazane na slikama 59-64. Statističke vrednosti Euklidovog rastojanja su date tabelarno za parove poređenih mel-spektrograma, i to maksimalne, medijalne i srednje (prosečne) vrednosti za svaku od podgrupa, videti tabelu 6.




Slika 59. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koji zvuče kao benzinski motori (BpB)




Slika 60. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koji zvuče kao dizel motori (DpD)




Slika 61. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koji zvuče kao dizel motori (BpD)



Slika 62. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koji zvuče kao benzinski motori (DpB)



Slika 63. Euklidovo rastojanje mel-spektrograma u okviru podgrupe benzinskih motora koje je algoritam klasifikovao kao dizel motori (BkD)



Slika 64. Euklidovo rastojanje mel-spektrograma u okviru podgrupe dizel motora koje je algoritam klasifikovao kao benzinski motori (DkB)

Opseg vrednosti Euklidovih rastojanja za svaki od grafika je od 0 do 60, jer je maksimalna vrednost dobijenih rastojanja, uzimajući u obzir rezultate za svih šest podgrupa, iznosila 55,8 i to u podgrupi BkD (slika 63).

Tabela 6. Statističke vrednosti Euklidovog rastojanja mel-spektrograma u okviru podgrupa


Podgrupa	Maksimalna vrednost	Vrednost medijane	Srednja vrednost
BpB	45,99	27,45	28,83
DpD	38,97	27,66	28,06
BpD	53,75	29,09	30,76
DpB	40,42	26,83	27,72
BkD	55,80	29,73	30,91
DkB	45,82	28,94	30,15

Posmatrajući dobijene grafičke prikaze Euklidovog rastojanja (slike 59-64) mogu se uočiti dijagonale svetle boje koje reprezentuju vrednost 0, što je rezultat za rastojanje između istih mel-spektrograma (uzorak uparen sa samim sobom), dok su veće vrednosti rastojanja prikazane tamnijim bojama. Uporednom analizom slika 59 i 60, odnosno podgrupa BpB i DpD, moguće je uočiti da su međusobne razlike između uzoraka u podgrupi dizel motora (DpD) manje. Uzorci koji se izdvajaju kao tamnije vertikalne ili horizontalne linije se mogu izdvojiti za dodatnu analizu jer oni predstavljaju uzorke koji se najviše razlikuju u okviru iste podgrupe. Posmatrajući tabelu 6 za ove dve podgrupe, uočljivo je da je maksimalna vrednost Euklidovog rastojanja u podgrupi benzinskih motora (BpB) znatno veća nego kod dizel motora. U podgrupi dizel motora (DpD) je i vrednost medijane bliža srednjoj vrednosti Euklidovog rastojanja, što odgovara ravnomernijoj raspodeli rastojanja, odnosno većoj homogenosti unutar podgrupe.


Poređenjem Euklidovih rastojanja u okviru podgrupe BpD i podgrupe DpB (slike 61 i 62), ponovo je moguće uočiti manje varijacije rastojanja, odnosno veću homogenost uzoraka u podgrupi dizel motora. Uzimajući u obzir vrednosti iz tabele 6, maksimalno rastojanje za podgrupu BpD je za oko 32% veće nego za podgrupu DpB. Medijana i srednja vrednost rastojanja u okviru ove podgrupe DpB su na manjem međusobnom rastojanju, što ponovo ukazuje na veću homogenost u okviru ove podgrupe.

Koristeći dva audio signala, jedan koji predstavlja tipičan zvuk benzinskog motora (referentni benzinski motor – B224) i drugi koji predstavlja karakterističan zvuk dizel motora (referentni dizel motor – D37), videti sliku 58, proračunata su Euklidova rastojanja za sve uzorke iz podgrupe gde se nalaze samo benzinski motori (BpB) i za sve uzorke iz podgrupe gde se nalaze dizel motori (DpD) u odnosu na referentni uzorak koji je izabran kao predstavnik date klase. Na osnovu dobijenih prikaza vrednosti Euklidovih rastojanja u okviru podgrupe BpB u odnosu na

referentni uzorak benzinskog i dizel motora (slike 65 i 66), moguće je uočiti nešto veću sličnost i manje varijacije rastojanja kada se vrši poređenje sa referentnim benzinskim motorom u odnosu na poređenje sa referentnim dizel motorom. Međutim, ovde postoje i benzinski motori koji su sličniji referentnom dizel motoru nego referentnom benzinskom motoru.




Slika 65. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe benzinskih motora BpB u odnosu na referentni benzinski motor




Slika 66. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe benzinskih motora BpB u odnosu na referentni dizel motor

Grafički prikazi vrednosti Euklidovih rastojanja mel-spektrograma za uzorke iz podgrupe BpD u odnosu na referentne uzorke benzinskog i dizel motora, videti slike 67 i 68, respektivno, načelno nemaju velikih razlika. Ovde je, takođe moguće uočiti benzinske motore koji su sličniji referentnom dizel motoru, nego referentnom benzinskom motoru (124 i 27), kao i benzinske

motore koji pokazuju jasno veće razlike u odnosu na referentni dizel motor nego na referentni benzinski motor (25 i 367).




Slika 67. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BpD u odnosu na referentni benzinski motor




Slika 68. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BpD u odnosu na referentni dizel motor

U okviru podgrupe DpB, uočljivija je veća sličnost sa referentnim uzorkom dizel motora (slike 69 i 70), što ukazuje na veću homogenost među uzorcima dizel motora, bez obzira kako oni zvučali slušaocu.



Slika 69. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DpB u odnosu na referentni benzinski motor




Slika 70. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DpB u odnosu na referentni dizel motor


Euklidova rastojanja mel-spektrograma za podgrupe uzoraka koje je algoritam pogrešno klasifikovao (BkD i DkB) u odnosu na referentne motore su data na slikama 71 do 74. Ovde je moguće uočiti identičnu pojavu kao i za podgrupe formirane slušanjem (percepcijom), a to je veća homogenost u podgrupi dizel motora. U odnosu na podgrupe dizel motora formirane slušanjem, Euklidova rastojanja su za pojedine uzorke u DkB podgrupi nešto veća, što i dalje ne narušava uniformnije rezultate, dok je u slučaju podgrupe benzinskih motora (BkD) prisutna veća heterogenost, što takođe odgovara podgrupama benzinskih motora formiranih slušanjem.

Na osnovu slika 71 i 72 koje prikazuju poređenje motora iz podgrupe BkD sa referentnim benzinskim i dizel motorom, moguće je zaključiti, slično kao i kod podgrupa formiranih slušanjem,

da postoji određena heterogenost u ovim podgrupama. Pored toga, uzorci sa maksimalnim rastojanjem u odnosu na jedan referentni motor, nemaju tako veliko rastojanje za drugi referentni motor. Može se, takođe, reći da su u proseku Euklidova rastojanja uzoraka u grupi BkD nešto veća u odnosu na referentni benzinski motor, nego na referentni dizel motor.




Slika 71. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BkD u odnosu na referentni benzinski motor




Slika 72. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe BkD u odnosu na referentni dizel motor

U podgrupi DkB, prilikom poređenja sa referentnim motorima (slike 73 i 74), moguće je uočiti veću sličnost sa referentnim dizel motorom. Ovakav odnos Euklidovih rastojanja postoji i u podgrupama dizel motora formiranih slušanjem.



Slika 73. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DkB u odnosu na referentni benzinski motor



Slika 74. Euklidovo rastojanje mel-spektrograma uzoraka iz podgrupe DkB u odnosu na referentni dizel motor

Dobijeni rezultati ukazuju da je kako slušanjem, tako i proračunom Euklidovog rastojanja veća sličnost među dizel motorima i da ih je lakše pravilno prepoznati i klasifikovati. Ova činjenica objašnjava i razlog manjeg broja pogrešno klasifikovanih dizel motora primenom algoritma veštačke inteligencije.

6. Klasifikacija SUS motora na osnovu zvuka

U ovom istraživanju su primenjena dva načina klasifikacije motora sa unutrašnjim sagorevanjem koristeći kreiranu bazu uzoraka zvuka motora. Jedan način klasifikacije je zasnovan na pristupu mapiranja zvučnih signala u slike, a drugi na pristupu koji kao ulazne podatke za klasifikaciju koristi psihoakustička obeležja. Oba pomenuta pristupa su dala visoku tačnost klasifikacije u primenama koje nisu vezane za motore sa unutrašnjim sagorevanjem, ali jesu za zvučne signale koji potiču od vozila ili iz industrijskog okruženja [105][116, 117]. Osnovni cilj ovog dela istraživanja je bio validacija celokupnog pristupa klasifikacije na osnovu zvuka rada motora formiranjem klasifikacionih modela visoke tačnosti, čime bi se ujedno izvršila i validacija novoformirane banke uzoraka. Još jedan od ciljeva je bio da se izvrši poređenje performansi dva pristupa klasifikacije – nadzirano (sa nadzorom ili nadgledano, *supervised*) i nenadzirano (bez nadzora ili nenadgledano, *unsupervised*) učenje, gde bi drugo pomenuti pristup potencijalno otkrio veze između obeležja koje nisu uočljive za slušaoca.

6.1 Evaluacija klasifikacionog modela

Prilikom procene mogućnosti (performansi) bilo kog algoritma mašinskog učenja, koristi se niz metričkih metoda. U prošlosti su modeli mašinskog i dubokog učenja prvenstveno upoređivani samo na osnovu njihove tačnosti (*accuracy*), ali danas je i F1 mera ili rezultat (*F1 score*) uobičajena metrika koja se koristi za merenje performansi klasifikacionih modela, koji mogu precizno meriti stvarne performanse i na balansiranim skupovima podataka i na onima koji to nisu. Razlog je taj što se uzima u obzir i preciznost i osetljivost modela, pružajući tako dobro zaokruženu procenu performansi modela [118, 119]. Tabela 7 prikazuje matricu konfuzije (*confusion matrix*) ili, u slučaju učenja bez nadzora, matricu sličnosti ili podudaranja (*matching matrix*).

Tabela 7: Matrica konfuzije stvarnih i predviđenih vrednosti

		Stvarne vrednosti	
		Pozitivne	Negativne
Predviđene vrednosti	Pozitivne	Stvarno pozitivne (<i>true positive</i> - TP)	Lažno pozitivne (<i>false positive</i> - FP)
	Negativne	Lažno negativne (<i>false negative</i> - FN)	Stvarno negativne (<i>true negative</i> - TN)

F1 mera se izračunava kao harmonijska sredina preciznosti i osetljivosti, obezbeđujući simetričnu reprezentaciju obe mere u jednoj metrici. U ovom istraživanju performanse klasifikacije su procenjene pomoću tačnosti, preciznosti (*precision*), osetljivosti (*sensitivity* ili *recall*), specifičnosti (*specificity*) koje su na kraju sumirane F1 rezultatom (*F1 score*). Pomenute mere se izračunavaju pomoću sledećih izraza:

$$Tačnost = \frac{\text{Broj tačno predviđenih uzoraka}}{\text{Ukupan broj uzoraka}} = \frac{TP+TN}{TP+FN+TN+FP} \quad (22)$$


$$Preciznost = \frac{\text{Broj ispravno predviđenih pozitivnih uzoraka}}{\text{Ukupan broj predviđenih pozitivnih uzoraka}} = \frac{TP}{TP+FP} \quad (23)$$

$$Osetljivost = \frac{\text{Broj ispravno identifikovanih pozitivnih uzoraka}}{\text{Ukupan broj stvarnih pozitivnih uzoraka}} = \frac{TP}{TP+FN} \quad (24)$$

$$Specifičnost = \frac{TN}{TN+FP} \quad (25)$$

$$F1 \text{ rezultat} = \frac{2 \cdot \text{Preciznost} \cdot \text{Osetljivost}}{\text{Preciznost} + \text{Osetljivost}} \quad (26)$$

Blok šema koja oslikava postupak evaluacije klasifikacionog modela po ovoj metodi je data na slici 75.



Slika 75. Blok šema evaluacije klasifikacionog modela primenom F1 rezultata

Tačnost daje procenat ispravno klasifikovanih uzoraka u odnosu na ukupan broj uzoraka. Međutim ova mera može dati lažnu predstavu o performansama modela kada su klase neuravnotežene (npr. kada jedna klasa dominira). U takvim slučajevima, model može imati visoku tačnost čak i ako ignoriše manje zastupljenu klasu.

Preciznost meri koliko je tačnih od svih pozitivnih predikcija koje je model napravio tj. od svih uzoraka koje je model predvideo kao pozitivne, koliko njih zaista jeste pozitivno.


Osetljivost meri koliko dobro model prepoznaje stvarne pozitivne slučajeve. Ova mera je važna kada je cilj da se identifikuje što više pozitivnih slučajeva, čak i po cenu dobijanja lažno pozitivnih rezultata.

F1 rezultat je metrička vrednost koja kombinuje preciznost i osetljivost u jedan broj, kako bi se dobila sveobuhvatnija ocena performansi modela. Ova mera se koristi kada je potrebno izbalansirati preciznosti i osetljivosti, posebno u situacijama kada su klase neuravnotežene po broju uzoraka.

6.2 Klasifikacija bazirana na mapiranju zvučnih signala u slike

Kao prvi metod klasifikacije vozila prema pogonskom gorivu na osnovu zvuka u ovom istraživanju izabrano je nadzirano učenje, odnosno algoritam koji formira model klasifikacije na osnovu podataka koji su već manuelno klasifikovani. U literaturi se mogu naći primeri algoritma koji koristi konvolucione neuronske mreže (*CNN*) sa velikom tačnošću klasifikacije za zvukove mapirane u slike koji se mogu smatrati da imaju sličan vremenski oblik kao i zvukovi motora sa unutrašnjim sagorevanjem [95][117][120].

Baza uzoraka je na osnovu manuelne evidencije sa mernog mesta podeljena u dve klase, zvukove koji pripadaju benzinskim i dizel motorima. Kako je u prethodnoj fazi istraživanja pokazano da postoje određene razlike između pogonskih goriva kada se zvukovi iz baze uzoraka mapiraju u slike slične spektrogramu, primenjena je klasifikacija upotrebom *CNN* strukture iz [117]. Dodatni razlog za direktnu primenu *CNN* strukture prikazane na slici 76 je identičan broj klasa na izlazu, tj. binarna klasifikacija.



Slika 76. Struktura konvolucione mreže korišćene u [117] za binarnu klasifikaciju industrijskih zvukova

Konvoluciona mreža sa slike 76 je realizovana u programskom jeziku *Python*. Ova konvoluciona mreža se sastoji od ulaznog sloja, pet konvolucionih slojeva, sloja za konverziju dvodimenzionalnog niza u jednodimenzioni vektor, četiri sloja za „puno“ povezivanje neurona (četiri „gusta“ (*dense*) sloja) i izlaznog sloja. Obrada podataka unutar ove strukture se obavlja na sledeći način:

- U ulaznom sloju se definiše ulazni oblik podataka (*input shape*), odnosno dimenzije matrice koja reprezentuje sliku, u ovom slučaju neki od ranije generisanih grafičkih prikaza audio signala sličnih spektrogramu;
- U prvom konvolucionom sloju se koristi:
 - o *Conv2D* funkcija sa 32 filtra, pri čemu se ulazna matrica (slika) deli na manje matrice (slike) dimenzija 3×3 vrednosti (tačaka ili piksela). Ova dimenzija se definiše kao veličina jezgra (*kernel-a*). U okviru ove funkcije se definiše *rectified linear unit (ReLU)* aktivacija za nenegativne vrednosti. Parametar *padding* se definiše kao „*same*“ što znači da će izlazna matrica (slika) imati iste dimenzije kao ulazna.
 - o *LeakyReLU* funkcija sa parametrom *alpha* omogućava da mali negativni ulazi prođu kroz aktivacionu funkciju, umesto da budu postavljeni na nulu.
 - o *MaxPooling2D* funkcija smanjuje dimenzije matrice (slike) tako što uzima maksimalnu vrednost iz svake oblasti čija dimenzija se definiše parametrom *pool size* koji u konkretnom slučaju ima veličinu 2×2 piksela. Parametar *padding* se takođe definiše kao „*same*“ kako bi izlazna matrica (slika) bila istih dimenzija kao ulazna.
 - o *Dropout* funkcija koristi *dropout* parametar kojim se definiše verovatnoća isključivanja određenih neurona tokom treninga, čime se sprečava prekomerno prilagođavanje („prenaučenosť“) modela (*overfitting*). Pomenuti *overfitting* se dešava kada klasifikacioni model „nauči“ previše specifičnih detalja iz skupa podataka za trening, što kasnije dovodi do nepravilne klasifikacije novih uzoraka koji prvobitno nisu bili deo trening skupa.
- U drugom, trećem, četvrtom i petom konvolucionom sloju se koriste identične funkcije kao i u prvom sloju, pri čemu se u četvrtom sloju broj filtara funkcije *conv2D* povećava na 64, a u petom sloju na 128;

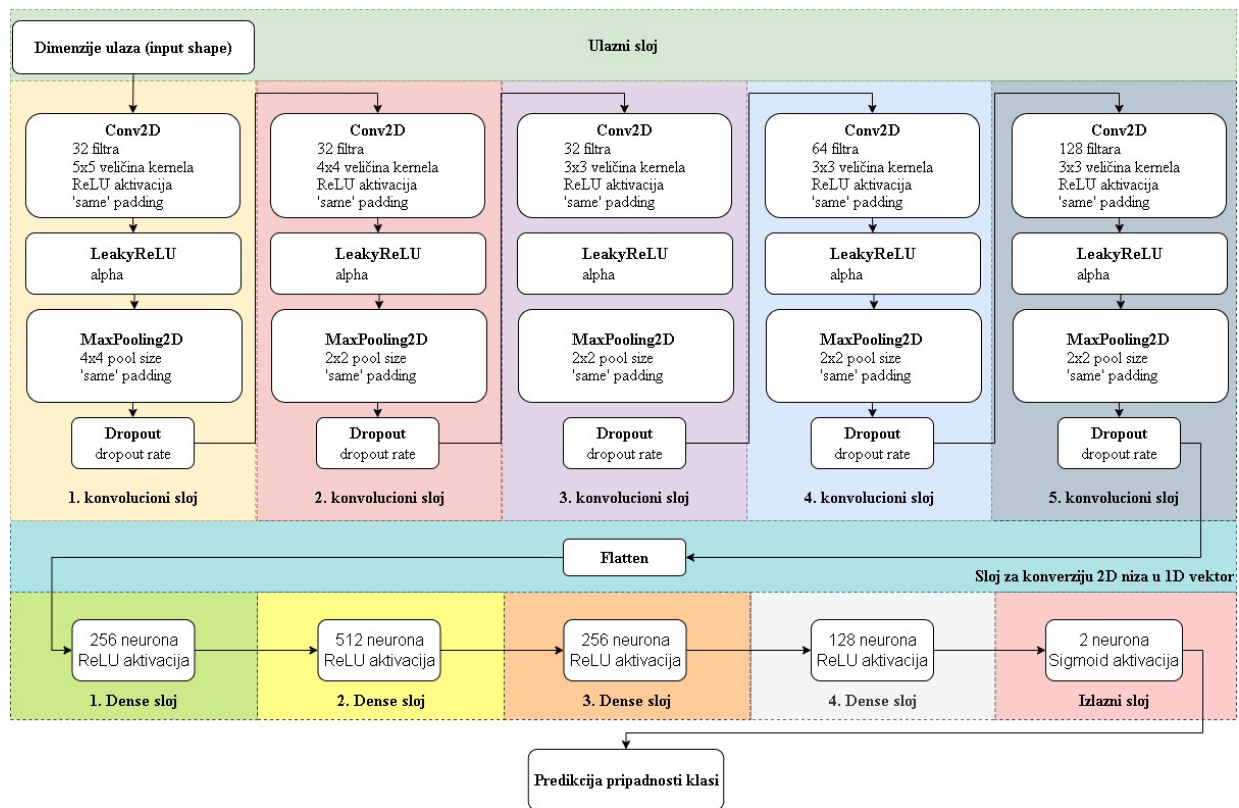
- Nakon konvolucionih slojeva, u narednom sloju, se koristi funkcija *flatten* kako bi se višedimenzioni niz konvertovao u jednodimenzioni niz, tj. vektor. U ovom slučaju se vrši konverzija dvodimenzionog niza u jednodimenzioni;
- Dobijeni jednodimenzioni niz podataka se procesira kroz četiri naredna sloja, gde se u svakom od slojeva vrši „gusto“ povezivanje neurona funkcijom *dense*, odnosno korišćenjem *dense* slojeva. U okviru ove funkcije se definiše broj neurona i tip aktivacije. Za sva četiri sloja se koristi *ReLU* tip aktivacije, a broj neurona je u prvom sloju 256, u drugom 512, u trećem 256 i u četvrtom 128;
- U poslednjem, izlaznom sloju, se korišćenjem *dense* funkcije definiše konačan broj klasa kao broj neurona. U ovom konkretnom primeru je broj klasa 2, a zatim se koristi *sigmoid* aktivacija koja je namenjena za binarnu klasifikaciju;
- Na osnovu celokupne prikazane obrade podataka kroz neuronsku mrežu u završnom koraku se vrši predikcija kojoj klasi pripadaju ulazni podaci.

Kao ulazni podaci u opisanu konvolucionu mrežu su korišćeni linearni spektrogram (spektrogram u linearnoj razmeri), logaritamski spektrogram, mel-spektrogram, gamatonegram i tempogram. Dimenzije ulaznih podataka kao i uspešnost klasifikacije za različite veličine ulaznih podatak su prikazani u tabeli 8.

Tabela 8. Rezultati primene konvolucione neuronske mreže sa slike 76 za klasifikaciju zvukova motora pokretanih na benzin i dizel mapiranih u spektrogram, mel-spektrogram, gamatonegram i tempogram

Vrsta ulaznih podataka	Ulazna matrica	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
Spektrogram (linearna razmera)	865x513	79%	80%	80%	80%	79%
Spektrogram (logaritamska razmera)	865x513	74%	74%	75%	74%	74%
Mel-spektrogram	865x96	54%	27%	50%	0%	54%
Gamatonegram	861x64	92%	93%	92%	92%	92%
Tempogram	865x384	54%	27%	50%	0%	54%

Na osnovu prikazanih rezultata moguće je uočiti da je klasifikacija bila najuspešnija za gamatonegram i spektrogram u linearnoj razmeri, dok je u potpunosti bila neuspešna za mel-spektrogram i tempogram. Kako su dobijeni rezultati pokazali uspešnost klasifikacije od preko 90% za gamatonegram i potencijal za određenu uspešnost kada se kao ulaz koristi spektrogram u linearnoj razmeri, postojeća konvoluciona mreža je izmenjena sa ciljem povećanja tačnosti. Iterativnim izmenama u konvolucionoj mreži postignut je maksimalni F1 rezultat od 97% za klasifikaciju kada se gamatonegram koristi kao ulaz. Izmene su bile bazirane na promeni broja slojeva, kao i na promeni veličina *kernel*-a konvolucionih slojeva. Konačan oblik *CNN*-a koji je dao visok stepen tačnosti klasifikacije je prikazan na slici 77. Nakon postignutog F1 rezultata od 97% svaka dalja izmena mreže je vodila ka lošijem rezultatu. Rezultati klasifikacije za izmenjenu arhitekturu konvolucione mreže su dati u tabeli 9.



Slika 77. Modifikovana struktura konvolucione mreže za klasifikaciju vozila prema pogonskom gorivu na osnovu zvuka mapiranog u slike spektrogram tipa

Tabela 9. Rezultati primene modifikovane konvolucione neuronske mreže za klasifikaciju zvukova motora pokretanih na benzin i dizel mapiranih u spektrogram i gamatonegram

Vrsta ulaznih podataka	Ulazna matrica	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
Spektrogram (linearna razmera)	865x513	95%	96%	94%	94%	95%
Gamatonegram	861x64	97%	98%	97%	97%	97%

6.3. Klasifikacija bazirana na psihoakustičkim obeležjima

6.3.1 Metodologija

Mašinsko, odnosno duboko učenje bez nadzora, za razliku od nadziranog učenja u većini slučajeva, nije podložno subjektivnoj ljudskoj percepciji, jer ne koristi podatke klasifikovane od strane ljudi za proces obuke neuronske mreže. Ulaz u algoritam kod ovakvog pristupa predstavljaju neoznačeni podaci koji se zatim koriste za grupisanje, povezivanje i smanjenje dimenzionalnosti. Ovakav algoritam omogućava nezavisnu i nepristrasnu klasifikaciju [121-124]. Rezultati klasifikacije bez nadzora se zatim upoređuju sa označenim podacima, koji su u slučaju audio signala klasifikovani na primer preslušavanjem snimaka od strane iskusnog slušaoca.

Umesto metoda nadziranog učenja, kao što su *k-NN* i „jednosmerne“ neuronske mreže (*feed forward neural networks*), za pristup klasifikacije bazirane ne nadziranom učenju ovde je izabrana Kohonenova mapa samoorganizovanja (*SOM*) [125]. Rezultat primene ovog algoritma je niskodimenzionalni, diskretizovani prikaz ulaznog prostora uz učenje bez nadzora. *SOM* je vrsta veštačke neuronske mreže koja primenjuje konkurentno učenje za razliku od učenja sa ispravljanjem grešaka, kao što je propagacija unazad sa gradijentnim opadanjem (*gradient descent*). Da bi se očuvala topološka svojstva ulaznog prostora, *SOM* koristi funkciju susedstva i obično se sastoji od 2-D mreže koja sadrži određeni broj neurona. *SOM* algoritam se pokazao kao važna komponenta prilikom dijagnostike mehaničkih kvarova [116][126-134], kao i koristan alat za klasifikaciju signala vibracija i buke [135-137].

Konvencionalni SOM algoritam se sastoji od sledećih koraka:

Korak 1: Kreiranje mreže od $a \times b$ neurona sa odgovarajućim težinskim vektorima c_i kojima se dodele proizvoljne vrednosti.

Korak 2: Nasumične selekcije ulaznog vektora x_n i “hranjenja” svih neurona u paraleli.

Korak 3: Pronalaženje pobedničkog neurona, tj. *Best matching unit (BMU)* korišćenjem proračuna Euklidovog rastojanja.

Korak 4: Težinski vektor neurona se ažurira na sledeći način:

$$c_{BMU}(n+1) = c_i(n) + h_{c,i}(n)[x_n - c_i(n)] \quad (27)$$

gde je $h_{c,i}(n)$ Gausova funkcija susedstva (Gausova funkcija koja se koristi za određivanje težine koja se dodeljuje susednim čvorovima) definisana kao:

$$h_{c,i}(n) = \alpha(n) \cdot \exp\left(\frac{\|r_{BMU} - r_i\|^2}{2\sigma^2(n)}\right) \quad (28)$$

gde je $\alpha(n)$ stepen učenja, $\sigma(n)$ širina prečnika suseda (određuje opseg oblasti u kojoj susedni neuroni značajno utiču na ažuriranje težina, odnosno određuje koliko daleko od "pobedničkog" neurona susedi u mreži imaju značajan uticaj na proces učenja), a r_i i r_{BMU} koordinate neurona na mapi. Obadva parametra $\alpha(n)$ i $\sigma(n)$ opadaju montono:


$$\alpha(n) = \alpha(0) \cdot \left(\frac{\alpha(N)}{\alpha(0)}\right)^{\frac{n}{N}} \quad (29)$$

$$\sigma(n) = \sigma(0) \cdot \left(\frac{\sigma(N)}{\sigma(0)}\right)^{\frac{n}{N}} \quad (30)$$

Koraci 1-4 se ponavljaju za sve ulazne podatke kojih ima N .

Kako bi se napravila razlika između dizel i benzinskih motora, odabrano je devet klasa koje su raspoređene u 1-D mrežu, videti sliku 78. Topološki sloj SOM-a (ulazni sloj) odgovara sekvenci (mreži) neurona koji su povezani sa ulaznim prostorom preko težinskih vektora. Funkcija susedstva uzrokuje da se neuroni na suprotnim stranama 1-D mreže mapiraju na suprotne strane deseto-dimenzionalnog (10-D) ulaznog prostora. Prednost je ovde data linearnom obliku (1-D mreži) jer je dao bolje rezultate u poređenju sa pravougaonim oblikom i omogućio veću fleksibilnost u manipulaciji oblikom. Kohonenova mapa samoorganizovanja je pokrenuta u

Mathworks Matlab skripti ugrađenoj u *LabView*. Uočeno je da performanse klasifikatora u velikoj meri zavise od kvaliteta obeležja koje se koriste kao ulaz u sloj za unos.




Slika 78. 1-D SOM izlazna mreža kreirana od 10-D ulaznog vektora obeležja

6.3.1.1 Formiranje ulaznih podataka u algoritam

Kao ulaz za izračunavanje obeležja, pored snimljenog zvuka (audio signala) dodatno je korišćen i numerički izvod (derivat) snimljenog signala. Derivat se dobija najjednostavnijom metodom Njutnovog količnika [138]. Za slučaj kada se izračunavanje izvoda relizuje odmerak (*sample*) po odmerak (sukcesivno duž signala), numerički izvod se definiše kao:

$$x' = x_{i+1} - x_i \quad (31)$$

gde je x jedan odmerak diskretizovanog signala. Obzirom da je ulazni signal podeljen na segmente trajanja 125 ms, u ovom istraživanju nije računato uobičajeno psihoakustičko obeležje jačina fluktuacije (*fluctuation strength*), jer izračunavanje takvog obeležja iziskuje trajanje zvučnog signala od najmanje 1000 ms. Kao što je ranije rečeno, jedan od ciljeva na početku istraživanja je bio da se razvije i ispita relativno brz sistem za prikupljanje i klasifikaciju zvukova motora sa minimalno potrebnim vremenom za snimanje uzoraka. Kako bi se eliminisao uticaj nivoa zvučnog pritiska, koji se razlikuje, ne samo prema pogonskom gorivu, već i prema starosti i ispravnosti vozila, svaki signal je normalizovan po amplitudi pre izračunavanja obeležja. Konačno dobijeni vektor obeležja, koji predstavlja ulaz u SOM algoritam, formiran je od 10 vrednosti, kao što je prikazano na slici 79.



Slika 79. Dobijanje ulaznog vektora obeležja za *SOM* algoritam

6.3.2 Rezultati klasifikacije primenom *SOM* algoritma

Provera uspešnosti predstavljene klasifikacije upotrebom *SOM* algoritma realizovana je tako što je od baze prikupljenih uzoraka formirana nova baza koja sadrži znatno veći broj uzoraka. Obzirom da su snimljeni signali u originalnoj bazi uzoraka približnog trajanja 5 sekundi, kao i da u vremenskom obliku signala nisu vidljive velike varijacije, dok sa druge strane signal nije u potpunosti redundantan, ovi uzorci su podeljeni na kraće uzorke. Konačan broj uzoraka korišćenih za razvoj i testiranje predstavljene metode je 17606. Uzorci u originalnoj bazi su preslušavanjem i na osnovu manuelne evidencije sa lokacije za akviziciju bili podeljeni u dve klase, zvukovi dizel i benzinskih motora. Nakon deljenja signala na kraće uzorke, ukupan broj uzoraka dizel vozila je iznosio 10014, a benzinskih vozila 7592.

Formiranje klasifikacionog modela je započeto sa dva neurona i postepeno je kroz dvadeset epoha povećavan broj neurona u svakoj od iteracija *SOM* algoritma. Inicijalna klasifikacija u samo dve klase nije dala zadovoljavajuće rezultate, što je prikazano u tabeli 10. Model se dobro pokazao


u pogledu specifičnosti, ali je potpuno podbacio u pogledu tačnosti, budući da se može uočiti da je potpuno nepouzdan za klasifikaciju dizel vozila.

Tabela 10. Matrica podudaranja i metrika evaluacije inicijalnog klasifikacionog modela sa dve klase

		Stvarne vrednosti						
		Dizel	Benzin					
Predviđene vrednosti	Dizel	5087	1834	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
		(50,8%)	(24,2%)	61,6%	73,5%	50,8%	75,8%	60,1%
	Benzin	4927	5758					
		(49,2%)	(75,8%)					

Prikazani početni rezultati su takođe pokazali složenost razlikovanja između dizel i benzinskih vozila samo na osnovu zvuka. Generalno posmatrano, kod učenja bez nadzora, SOM algoritam može da identifikuje skrivene obrasce i iskoristi sličnosti unutar skupa podataka koje slušalac često i ne percipira.

U nastavku istraživanja najbolje se pokazala SOM struktura 1×9 jer pruža najveću tačnost klasifikacije za najmanji broj neurona, što je prikazano na slici 80. Na slici 80 levo, vidljiva je zavisnost tačnosti klasifikacije za jednodimenzionalne ($1 \times N$) strukture, pri čemu se za strukturu 1×9 postiže maksimum, nakon čega tačnost ne raste. Na slici 80 desno prikazano je poređenje jednodimenzionih i višedimenzionih (matričnih) struktura, pri čemu su za isti broj neurona jednodimenzionalne strukture dale veću tačnost. Pet klasa (C1 i C6 - C9) predstavljalo je dizel vozila, a 4 klase (C2 - C5) vozila na benzin. Kumulativni rezultati ovakve klasifikacije su prikazani u tabeli 11.



Slika 80. Tačnost predikcije u zavisnosti od strukture SOM mreže

Tabela 11. Matrica podudaranja i metrika evaluacije modela sa devet klasa

		Stvarne vrednosti						
		Dizel	Benzin					
Predviđene vrednosti	Dizel	8171 (81,6%)	1954 (25,7%)	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
	Benzin	1843 (18,4%)	5638 (74,3%)	78,4%	80,7%	81,6%	74,3%	81,1 %

Ukupne performanse su znatno bolje u poređenju sa SOM klasifikacijom sa dva neurona, iako možemo videti da je detekcija benzinskih vozila (specifičnost) bila nešto lošija. Ovo ukazuje na kompleksnost 10-D ulaznog prostora i koliko su izdvojena obeležja isprepletana.

Raspored devet neurona je prikazan u tabeli 12, pri čemu prva klasa odgovara zvukovima dizel vozila, zatim četiri klase koje odgovaraju benzinskim vozilima i još četiri klase koje odgovaraju dizel vozilima. Iako je klasa 1 (C1) bila donekle odvojena od ostalih dizel klasa, pokazala se kao najuspešnija klasa u razlikovanju dva tipa pogonskog goriva (tabela 12). Tri klase (C3, C5 i C8) su pokazale manje od 70% tačne klasifikacije, međutim njihov mali procenat udela u bazi podataka (C5 sa 4,7% i C8 sa 8,8%) minimizira njihov uticaj na ukupnu tačnost modela.

Tabela 12. Rezultati klasifikacije unutar svake pojedinačne klase i njihov udeo u bazi podataka

		C1	C2	C3	C4	C5	C6	C7	C8	C9
Stvarna oznaka	Dizel	2013	296	833	469	252	1789	2181	1067	1225
	Benzin	230	1524	1522	2128	568	299	339	476	395
Tačna klasifikacija		89,7%	83,7%	64,6%	81,9%	69,3%	85,7%	86,5%	69,2%	75,6%
Udeo u bazi podataka		12,7%	10,3%	13,4%	14,8%	4,7%	11,9%	14,3%	8,8%	9,2%

6.3.2.1 Klasifikacija pojedinačnih vozila

Korišćenje vremenske konstante od 125 ms za segmentiranje zvučnih zapisa iz baze uzoraka, gde je usled primene funkcije za izdvajanje režima praznog hoda određeni broj zapisa bio kraći od 5 sekundi, rezultiralo je da su pojedinačni zapisi (uzorci) predstavljeni sa 16 do 40 vektora obeležja (gde postoji po jedan vektor za svaki od vremenskih segmenata trajanja 125 ms). Takođe je činjenica da je za pojedina vozila bilo više od jednog uzorka zvuka učinila klasifikaciju robusnijom, jer omogućava da se jave i neke pogrešne klasifikacije unutar pojedinačnog snimka. Klasifikacija sa devet klasa je postigla umeren F1 rezultat od 81,1%, ali treba napomenuti da se vektor ulaznih karakteristika sastojao od samo 10 vrednosti.

Izborom kratke vremenske konstante bilo je moguće vršiti usrednjavanje u okviru pojedinačnih snimaka svakog vozila. Prag za procenu ispravnosti klasifikacije bio je $> 50\%$, odnosno svi snimci u kojima je više od polovine uzoraka od 125 ms bilo tačno klasifikovano automatski su označeni kao tačna klasifikacija vozila prema vrsti goriva. Opisani pristup je validan za primenu jer je akvizicioni sistem u stanju da identifikuje da li se dogodila smena vozila iznad merne tačke, budući da poseduje dva ultrazvučna senzora koji pokreću snimanje zvukova i konstantno proveravaju okruženje. Rezultati ovakvog pristupa su prikazani u tabeli 13.

Tabela 13. Matrica podudaranja i metrika evaluacije metode pojedinačnih vozila

		Stvarne vrednosti						
		Dizel	Benzin					
Predviđene vrednosti	Dizel	251	28	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
		(92,3%)	(14,0%)	89,6%	90,0%	92,3%	86,0%	91,1%
	Benzin	21	172					
		(7,7%)	(86,0%)					

Na osnovu prikazanih rezultata može se uočiti da su performanse modela značajno poboljšane, dajući F1 rezultat od 91,1%. Uzimajući u obzir da nisu korišćeni nikakvi dodatni uzorci ili uzorci prikupljeni u laboratorijskim ili idealnim akustičkim uslovima, ovakav F1 rezultat se može smatrati veoma visokim. Ulazni podaci su se u potpunosti sastojali od stvarnih uzoraka prikupljenih direktno sa izabrane tačke akvizicije, često sa prisutnim pozadinskim zvukovima, odnosno ambijentalnom bukom. Ipak, klasifikacija vozila na benzin imala je veću stopu greške od one na dizel, kao što je prikazano u matrici podudaranja u tabeli 13.

Rezultati pojedinačne klasifikacije vozila detaljno su analizirani uz dodatna preslušavanja baze uzoraka. Preslušavanje 49 pogrešno klasifikovanih vozila dalo je sledeće rezultate: od 21 dizel vozila koja su klasifikovana kao benzinska, pet su moderna dizel vozila (tiša, bolja zvučna izolacija, harmonijski prigušivači), tri vozila su imala šestocilindrične dizel motore, dva vozila su imala start-stop sistem (deo snimka je samo sa pozadinskim šumom, odnosno ambijentalnom bukom), dva su imala neispravnost u vidu buke prenosnog remena u motoru, a jedan je imao nestabilan rad u režimu praznog hoda. Ovih 13 vozila nisu bili najreprezentativniji članovi dizel grupe i mogu se smatrati anomalijama. S druge strane, slična zapažanja su uočena u grupi vozila na benzin. Od 28 pogrešnih klasifikacija, 11 su bila stara vozila na benzin koja su pored osnovnog zvuka motora imala i dodatne zvuke koji potiču od neispravnosti prouzrokovanih habanjem. Drugi uzorci benzinskih motora koji su pogrešno klasifikovani kao dizel predstavljaju: tri vozila na benzin sa bukom ventilacije koja je bila aktivna tokom akvizicije, jedno vozilo sa neispravnim izduvnim sistemom i jedno vozilo sa praznim hodom na povećanom broju obrtaja. Imajući u vidu da se od 49 pogrešno klasifikovanih vozila, 29 (13 za dizel i 16 za benzin) može označiti kao posebna iz različitih razloga, kao što su kvarovi i nepravilan rad motora, može se reći da je samo

20 vozila pogrešno klasifikovano od ukupno 472 vozila. Rezultati i evaluacija klasifikacije za skup uzoraka koji ne uljučuje nabrojane slučajeve prikazan je u tabeli 14.

Tabela 14. Matrica podudaranja i metrika evaluacije metode pojedinačnih vozila bez specifičnih slučajeva

		Stvarne vrednosti						
		Dizel	Benzin					
Predviđene vrednosti	Dizel	264 (97,1%)	12 (6,0%)	Tačnost	Preciznost	Osetljivost	Specifičnost	F1 rezultat
				95,4%	96,4%	97,1%	94,0%	96,7%
	Benzin	8 (2,9%)	188 (94,0%)					

7. Zaključak

U ovom, završnom, poglavlju su sumirani najznačajniji rezultati i doprinosi disertacije. Disertacija istražuje novi pristup za prikupljanje i analizu zvukova vozila pokretanih SUS motorima u realnim uslovima, s ciljem klasifikacije vozila prema vrsti pogonskog goriva. Istraživanje obuhvata razvoj automatizovanog sistema koji omogućava akviziciju, obradu i klasifikaciju zvučnih zapisa bez narušavanja privatnosti uzorkovanih vozila. Pri čemu je posebna pažnja posvećena identifikaciji i izdvajanju relevantnih akustičkih obeležja koja omogućavaju precizno razlikovanje između vozila sa benzinskim i dizel motorima.

Razvoj ovog sistema realizovan je kroz tri ključne etape. Prva etapa se odnosi na prikupljanje zvučnih zapisa u realnim uslovima i njihovu obradu u cilju eliminacije spoljnih uticaja. Druga etapa posvećena je analizi i izdvajanju akustičkih obeležja koja su relevantna za klasifikaciju. Treća etapa obuhvata izbor i primenu algoritama mašinskog i dubokog učenja za klasifikaciju zvuka, uz prilagođavanje arhitektura modela u cilju postizanja optimalnih performansi.

Celokupnim istraživanjem pružen je metodološki okvir za automatizovano prepoznavanje tipa pogonskog goriva na osnovu zvučnih zapisa, što može imati široku primenu u oblasti kontrole emisija, zaštite životne sredine i optimizacije urbanih saobraćajnih sistema.

Rezultati naučnog istraživanja ove disertacije se mogu podeliti u tri celine:

1. Razvijen je originalni sistem za akviziciju zvuka SUS motora putničkih vozila u realnim uslovima. U postupku razvoja sistema za akviziciju detaljno je ispitano pozicioniranje mikrofona u odnosu na motor kao izvor zvuka, ispitan je uticaj režima rada motora na zvučni sadržaj snimljenog signala, osmišljen je postupak za automatsko izdvajanje najpogodnijeg režima rada iz ugla akustičke analize, a posebna pažnja je posvećena planiranju i realizaciji hardvera. Cilj je bio da akvizicioni sistem bude robustan, lak za instalaciju na mernom mestu, niske cene, sa mogućnošću dalje integracije kako bi prikupljeni uzorci bili dostupni odmah, bez odlaska na merno mesto.

Rezultat razvoja se ogleda u akvizicionom sistemu u kome pozicija mikrofona obezbeđuje nesmetan prolazak vozila prilikom uzorkovanja. Takođe, ova pozicija mikrofona omogućava snimanje uzoraka gde je izvor zvuka (motor) najbliži mikrofonu u odnosu na sve druge postavke, u kojima se vozilo ne stavlja van funkcije zbog merenja, videti radove [33, 34]. Predstavljeno pozicioniranje mikrofona na tlu, ispod vozila, obezbeđuje i „čiste“ snimke u realnim uslovima, sa zanemarljivim uticajem buke okoline. Sistem radi bez potrebe za intervencijom čoveka, samostalno detektuje prisustvo vozila, snima uzorak zvuka u predefinisanoj trajanju, analizira snimak i izdvaja režim praznog hoda, lako je prenosiv i jednostavan za postavku na mernom mestu. Primenom razvijenog sistema na ulazu u podzemnu garažu, uzorkovano je u četiri iteracije ukupno 350 automobila i formirana je baza sa 475 uzoraka zvuka.

2. Analizirane su i izdvojene dve grupe audio obeležja snimljenih audio signala koje omogućavaju razlikovanje vozila prema pogonskom gorivu. Analiza i izdvajanje audio obeležja započeto je u trenutku kada gotovo da nije bilo radova čija je tema klasifikacija automobila prema pogonskom gorivu, za razliku od izdvajanja audio obeležja iz signala govora ili muzike. Iz većeg broja analiziranih audio obeležja, selektovana su ona koja su pokazala najveće razlike između klasa, kako bi se kasnije koristila kao ulaz u neki od klasifikacionih metoda. Ovaj deo istraživanja je pokazao da obeležja koja su usko povezana sa percepcijom slušaoca, poput mel-spektrograma i gamatonegrama imaju najveći potencijal za razlikovanje klasa pogonskih goriva. Drugi pristup u izdvajanju obeležja, baziran na psihoakustičkim obeležjima, je bio iniciran dobrim rezultatima u detekciji mehaničkih anomalija vozila. Rezultat analize psihoakustičkih obeležja je pokazao da glasnost, hrapavost, oštrina i krest faktor oslikavaju razlike između klasa, dok se tonalitet pokazao sličnim za obe klase.

3. Primenjene su dve metode klasifikacije. Kako bi se verifikovao sadržaj i upotrebljivost baze uzoraka, kao i izbor izabranih audio obeležja, primenjene su dve različite metode klasifikacije u zavisnosti od skupa izdvojenih obeležja. Nadzirano učenje bazirano na algoritmu konvolucionih neuronskih mreža (*CNN*) je primenjeno na bazu podataka koju su činile slike dobijene mapiranjem iz zvuka (poput spektrograma, mel-spektrograma, gamatonegrama i tempograma). Rezultat primene ovakvog pristupa je pokazao da je uspešnost klasifikacije, izražena kao F1 rezultat, za slike u formatu spektrograma 95%, a za slike u formatu gamatonegrama čak 97%. Nenadzirano učenje zasnovano na algoritmu mape samoorganizovanja (*SOM*) i psihoakustičkim obeležjima

poput glasnosti, hrapavosti, oštine i krest faktora pokazalo je da je moguće postići F1 rezultat od 91,1%, a da se eliminacijom vozila koja imaju neku tehničku neispravnost ovaj rezultat uvećava na 96,7%.

Doprinosi disertacije su prikazani u nastavku:

1. Razvijeni sistem za akviziciju zvuka omogućio je prikupljanje visokokvalitetnih audio uzoraka u realnim uslovima, uz automatizovanu i samostalnu detekciju vozila i minimalan uticaj okoline na uzorke.

1.a. Doprinos razvoja ovakvog sistema se ogleda u uvođenju i detaljnom ispitivanju nove pozicije mikrofona, koja nije korišćena u istraživanjima realizovanim do trenutka pisanja ove disertacije, u načinu detekcije prisustva vozila upotrebom ultrazvučnih senzora i postupku izdvajanja režima praznog hoda motora u vremenskom domenu tj. bez konverzije u frekvencijski domen.

1.b. Konstrukcija sistema obezbeđuje jednostavnu instalaciju, bez remećenja okruženja i zakonskih propisa o privatnosti uzorkovanih vozila, prenosivost i kompatibilnost sa budućim *IoT* sistemima.

1.c. Zahvaljujući takvom dizajnu, sistem se može koristiti i za druge aplikacije u oblastima kao što su monitoring saobraćaja i buke, detekcija anomalija u radu SUS motora, kao i za naučna istraživanja u domenu akustike.

2. Formirana baza podataka sa 475 audio uzoraka predstavlja resurs za dalja istraživanja i validaciju novih metoda analize i klasifikacije. Ova baza je jedinstvena jer sadrži zvučne uzorke snimljene u realnim uslovima sa precizno dokumentovanim tehničkim parametrima vozila koja su od interesa, kao što su režim rada motora i vrsta pogonskog goriva.

2.a. Audio uzorci prikupljeni u oblasti ispod motora, gde zvučna izolacija proizvođača ne postoji ili je minimalna, mogu omogućiti identifikaciju nepravilnosti u radu SUS motora na osnovu čega se može razviti algoritam za ranu detekciju kvarova zasnovan na analizi zvuka.

2.b. Dodatno podaci iz baze mogu pomoći u razvoju *IoT* sistema za monitoring motora, gde se zvuk koristi za procenu performansi i stanja motora.

2.c. Kako je baza formirana od audio uzoraka rada SUS motora u režimu praznog hoda, gde se pojedinačni zvuci samog procesa sagorevanja i rada ostalih agregata motora perceptivno najlakše mogu razdvojiti, baza ima potencijal u istraživanjima u oblasti prepoznavanja akustičnih obrazaca, audio forenzike i razvoja modela koji objašnjavaju kako različiti delovi motora doprinose ukupnom zvuku.

2.d. Doprinos baze takođe može biti značajan u oblasti ispitivanja uticaja buke na životnu sredinu, zdravlje čoveka i životinja, razvoju tehnologija za smanjenje buke motora i razvoju standarda za procenu zvučnog kvaliteta SUS motora,

3. Identifikovana su audio obeležja sa najvećim potencijalom za razlikovanje vozila sa SUS motorima prema pogonskom gorivu, obuhvatajući akustičke i psihoakustičke karakteristike. Ova disertacija, između ostalog, ima za cilj razumevanje zvučnih fenomena vezanih za rad SUS motora i oblasti mašinskog i dubokog učenja primenjenog na akustiku. Dobijeni rezultati pružaju osnovu za razvoj još preciznijih i efikasnijih sistema klasifikacije, kao i unapređenje metodologija za obradu i analizu zvučnih signala.

4. Kombinacija izdvojenih akustičkih obeležja i savremenih metoda mašinskog i dubokog učenja pokazala je visok potencijal za praktičnu primenu u oblasti automatske klasifikacije vozila prema pogonskom gorivu.

4.a. Doprinos ovakvog pristupa se ogleda u izboru algoritama klasifikacije i analizi uspešnosti klasifikacije u zavisnosti od izabranog algoritma. Analizom u okviru ovog istraživanja je prikazano da je moguće postići visoku uspešnost klasifikacije upotrebom dva različita pristupa, algoritmom nadgledanog dubokog učenja koji analizira grafičke prikaze audio uzoraka i algoritmom nenadgledanog mašinskog učenja koji analizira psihoakustička obeležja.

4.b. Istraživanje je pokazalo da je moguće prilagoditi i implementirati već postojeće algoritme kako bi se rešili specifični problemi u realnom svetu, što doprinosi razvoju primenjenih rešenja u industriji i nauci. Takođe, ovakav pristup ostavlja mogućnost za unapređenje sistema klasifikacije kroz implementaciju novih tehnika.

Celokupno istraživanje je pokazalo da je moguće proširiti dosadašnje akvizicione metode novim pristupom, izdvojiti najznačajnija obeležja zvuka SUS motora i primeniti odgovarajuću metodu klasifikacije mašinskog, odnosno dubokog učenja, kako bi se postigla visoka tačnost klasifikacije. Na ovaj način je pokazano da je moguće razviti i realizovati samostalan sistem za automatsku klasifikaciju vozila prema pogonskom gorivu na osnovu zvuka.

Osim navedenih doprinosa, istraživanje pruža primer metodologije koja se može prilagoditi za analizu drugih tipova zvučnih signala, šireći primenu mašinskog i dubokog učenja u oblasti akustike i audia. Ovaj pristup omogućava istraživačima da primene slične tehnike u različitim aplikacijama, uključujući detekciju kvarova u industriji, procenu kvaliteta zvuka i razvoj akustičkih rešenja u urbanim sredinama. Primena akustičkih analiza u tehničkim sistemima može poboljšati efikasnost dijagnostike i optimizaciju rada različitih uređaja, čime se doprinosi razvoju inteligentnih sistema nadzora i održavanja.

Jedna od ključnih industrijskih primena ovog istraživanja odnosi se na dijagnostiku i nadzor stanja vozila. Metode bazirane na analizi akustičkih emisija mogu se koristiti za ranu detekciju mehaničkih kvarova, poput problema sa ubrizgavanjem goriva, nepravilnog rada cilindara ili kvara u izduvnom sistemu. Ovakvi sistemi omogućavaju neinvazivno praćenje performansi motora i prevenciju većih kvarova, čime se povećava bezbednost i smanjuju troškovi održavanja. Takođe, akustička analiza može igrati važnu ulogu u razvoju novih sistema za monitoring električnih vozila, gde bi prepoznala anomalije u radu elektromotora ili sistema prenosa.

Pored industrijske primene, sistem akustičke klasifikacije vozila može doprineti unapređenju upravljanja saobraćajem i kontroli zagađenja u urbanim sredinama. Klasifikacija vozila prema vrsti goriva u realnom vremenu može biti korisna za regulaciju saobraćaja u zonama niske emisije, optimizaciju naplate putarina i sprovođenje ekoloških propisa. Takođe, akustični senzorski sistemi mogu nadgledati nivo buke u saobraćaju, identifikovati izvore prekomerne buke i pomoći u implementaciji mera za smanjenje zvučnog zagađenja. Integracija ovih metoda u inteligentne transportne sisteme može omogućiti precizniji monitoring saobraćaja i poboljšati kvalitet života u urbanim sredinama.

Literatura

- [1] S. I. Builo, B. I. Builo, V. I. Kolesnikov, V. D. Vereskun, O. N. Popov, “Application of the acoustic emission method in problems of vehicle diagnostics,” *Journal of Physics: Conference Series*, vol. 1636, no. 1, p. 012006, Sep. 2020, IOP Publishing.
- [2] W. M. Adaileh, “Engine fault diagnosis using acoustic signals,” *Applied Mechanics and Materials*, vol. 295, pp. 2013–2020, 2013.
- [3] S. Singh, M. J. Kulshrestha, N. Rani, K. Kumar, C. Sharma, D. K. Aswal, “An overview of vehicular emission standards,” *Mapan*, vol. 38, no. 1, pp. 241–263, 2023.
- [4] M. Khare, S. M. S. Nagendra, Vehicular Pollution. *Springer*, 2007.
- [5] J. F. Peters, M. Burguillo, J. M. Arranz, “Low emission zones: Effects on alternative-fuel vehicle uptake and fleet CO₂ emissions,” *Transportation Research Part D: Transport and Environment*, vol. 95, p. 102882, 2021.
- [6] H. Cui, P. Gode, S. Wappelhorst, “A Global Overview of Zero-Emission Zones in Cities and Their Development Progress,” *International Council on Clean Transportation report*. 2021.
- [7] A. Ricci, S. Gaggi, R. Enei, M. Tomassini, M. Fioretto, et al., *Study on urban vehicle access regulations: Final report*. European Commission, 2017. Dostupno na: https://ec.europa.eu/transport/sites/transport/files/uvar_final_report_august_28.pdf, pristupljeno: februar 2025.
- [8] O. Klymenko, V. Gorytski, Y. Gutarevych, A. Shchelkunov, R. Kyrychenko, “Requirements for a unified system of road vehicles environmental labelling and low emission zones,” *Eastern-European Journal of Advanced Technologies*, vol. 6, no. 10, pp. 53–84, 2020.
- [9] R. Jardi-Cedo, M. Mut-Puigserver, M. M. Payeras-Capellà, J. Castella-Roca, A. Viejo, “Time-based low emission zones preserving drivers’ privacy,” *Future Generation Computer Systems*, vol. 80, pp. 558–571, 2018.

- [10] P. M. Diéguez, J. C. Urroz, D. Sáinz, J. Machin, M. Arana, L. M. Gandía, “Characterization of combustion anomalies in a hydrogen-fueled 1.4 L commercial spark-ignition engine by means of in-cylinder pressure, block-engine vibration, and acoustic measurements,” *Energy Conversion and Management*, vol. 172, pp. 67–80, Sep. 2018.
- [11] S. Ji, X. Lan, J. Lian, H. Wang, M. Li, Y. Cheng, W. Yin, “Combustion parameter estimation for ICE from surface vibration using frequency spectrum analysis,” *Measurement*, vol. 128, pp. 485–494, Nov. 2018.
- [12] N. Dayong, S. Changle, G. Yongjun, Z. Zengmeng, H. Jiaoyi, “Extraction of fault component from abnormal sound in diesel engines using acoustic signals,” *Mechanical Systems and Signal Processing*, vol. 75, pp. 544–555, Jun. 2016.
- [13] O. Bondarenko, T. Fukuda, “Potential of acoustic emission in unsupervised monitoring of gas-fuelled engines,” *IFAC-PapersOnLine*, vol. 49, no. 23, pp. 329–334, 2016.
- [14] S. Delvecchio, P. Bonfiglio, F. Pompoli, “Vibro-acoustic condition monitoring of internal combustion engines: A critical review of existing techniques,” *Mechanical Systems and Signal Processing*, vol. 99, pp. 661–683, Jan. 2018.
- [15] D. Siano, M. Viscardi, M. A. Panza, “Automotive materials: An experimental investigation of an engine bay acoustic performance,” *Energy Procedia*, vol. 101, pp. 598–605, Nov. 2016.
- [16] A. Rynell, G. Efraimsson, M. Chevalier, M. Abom, “Acoustic characteristics of a heavy-duty vehicle cooling module,” *Applied Acoustics*, vol. 111, pp. 67–76, Oct. 2016.
- [17] M. Turqueti, E. Oruklu, J. Saniie, “Smart acoustic sensor array (SASA) system for real-time sound processing applications,” *Smart Sensors and MEMS*, pp. 492–517, 2014.
- [18] N. Cavina, A. Businaro, N. Rojo, M. De Cesare, L. Paiano, A. Cerofolini, “Combustion and intake/exhaust systems diagnosis based on acoustic emissions of a GDI TC engine,” *Energy Procedia*, vol. 101, pp. 677–684, 2016.
- [19] M. A. Sobreira-Seoane, A. Rodriguez Molares, J. L. Alba, “Automatic classification of traffic noise,” *Proceedings of the Acoustics '08*, Paris, France, pp. 6221–6226, Jun. 29–Jul. 4, 2008.

- [20] K. Haddad, W. Song, X. Valero, “Environmental sound classification in realistic situations,” *Proceedings of the Forum Acusticum*, Krakow, Poland, Sep. 7–12, 2014.
- [21] K. J. Piczak, “Environmental sound classification with convolutional neural networks,” in *Proceedings of the IEEE 25th International Workshop on Machine Learning for Signal Processing (MLSP)*, Boston, MA, USA, pp. 1–6, 2015.
- [22] T. A. Nguyen, Y. Kai, M. Mikami, “Study on combustion noise from a running diesel engine based on transient combustion noise generation model,” *International Journal of Automotive Engineering*, vol. 3, pp. 131–140, 2012.
- [23] J. Yao, Y. Xiang, S. Qian, S. Wang, “Noise source separation of an internal combustion engine based on a single-channel algorithm,” *Shock and Vibration*, vol. 2019, 19 pages, 2019.
- [24] V. Singh, N. Meena, “Engine fault diagnosis using DTW, MFCC and FFT,” in *Proceedings of the First International Conference on Intelligent Human Computer Interaction (IHCI 2009)*, Allahabad, India, pp. 83–94, 20–23 January 2009.
- [25] A. Camacho, G. Piñero, M. de Diego, A. González, “Exploring roughness perception in car engine noises through complex cepstrum analysis,” *Acta Acustica United with Acustica*, vol. 94, pp. 130–140, January/February 2008.
- [26] M. Aliramezani, C. R. Koch, M. Shahbakhti, “Modeling, diagnostics, optimization, and control of internal combustion engines via modern machine learning techniques: A review and future directions,” *Progress in Energy and Combustion Science*, vol. 88, p. 100967, 2022.
- [27] M. Arana et al., “Acoustic and psychoacoustic levels from an internal combustion engine fueled by hydrogen vs. gasoline,” *Fuel*, vol. 317, p. 123505, 2022.
- [28] M. E. Altinsoy, “The evaluation of conventional, electric and hybrid electric passenger car pass-by noise annoyance using psychoacoustical properties,” *Applied Sciences*, vol. 12, no. 10, p. 5146, 2022.
- [29] S. Schneider, T. Luft, H. Rottengruber, “Psychoacoustic evaluation of internal combustion engine noises,” *Automotive and Engine Technology*, vol. 6, pp. 261–274, 2021.

- [30] L. Becker et al., "Audio feature extraction for vehicle engine noise classification," in *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP 2020)*, Barcelona, Spain, pp. 1–5, 2020.
- [31] A. M. Terwilliger, J. E. Siegel, "The AI Mechanic: Acoustic Vehicle Characterization Neural Networks," *arXiv preprint*, arXiv:2205.09667, 2022.
- [32] A. Wieczorkowska et al., "Spectral features for audio-based vehicle and engine classification," *Journal of Intelligent Information Systems*, vol. 50, pp. 265–290, 2018.
- [33] M. Milivojčević, E. Kisić, D. Ćirić, "Analysis of portable system for sound acquisition of vehicles powered by internal combustion engines," *Facta Universitatis Series: Electronics and Energetics*, Vol. 36, No 2, pp.299-314, 2023.
- [34] M. Milivojčević, F. Pantelić, D. Ćirić, "Pozicioniranje mikrofona prilikom snimanja audio karakteristika motora putničkih vozila," *Zbornik radova 63. konferencije ETRAN*, str.58-62, 2019.
- [35] M. Milivojčević, F. Pantelić, D. Ćirić, "Comparison of frequency characteristics of sound generated by internal combustion engines depending on fuel," *Proceedings of Papers, Noise and Vibration, 26th International Conference*, pp.115-119, 2018.
- [36] M. Milivojčević, E. Kisić, D. Ćirić, "Izdvajanje režima praznog hoda motora sa unutrašnjim sagorevanjem na osnovu audio zapisa," *Zbornik radova 65. konferencije ETRAN*, str.32-36, 2021.
- [37] M. Milivojčević, D. Ćirić, "Izdvajanje značajnih akustičkih karakteristika motora sa unutrašnjim sagorevanjem," *Zbornik radova 64. konferencije ETRAN*, str.49-53, 2020.
- [38] M. Milivojčević, E. Kisić, D. Ćirić, "Komparativna analiza akustičkih signala motora sa unutrašnjim sagorevanjem mapiranih u slike bazirane na spektrogramu," *Zbornik radova 66. konferencije ETRAN*, 2022.
- [39] M. Milivojčević, D. Ćirić, A. Zeković, "Sličnost zvukova motora sa unutrašnjim sagorevanjem bazirana na Mel-spektrogramu," *Zbornik radova 67. konferencije ETRAN*, 2023.
- [40] M. Milivojčević, F. Pantelić, D. Ćirić, S. Drašković, "Potencijal A-ponderisanja akustičkih signala u klasifikaciji baziranoj na slikama," *Zbornik radova 68. konferencije ETRAN*, str.48-53, 2024.

- [41] M. Milivojčević, D. Ćirić, J. Prezelj, J. Murovec „Analysis of unsupervised learning approach for classification of vehicle fuel type using psychoacoustic features“, *Measurement*, vol. 227, 2024.
- [42] M. Tomić, S. Petrović, *Motori sa unutrašnjim sagorevanjem*, Beograd: Mašinski fakultet, 2005.
- [43] “IC engine components and their functions, types and terminology,” [Online]. Dostupno na: <https://www.ingenieriaymecanicaautomotriz.com/ic-engine-components-and-their-functions-types-and-terminology/>, pristupljeno: februar 2025.
- [44] A. Aan, M. Heinloo, “Computer-based comparison analysis of single and double-connecting-rod slider-crank linkages,” *Agronomy Research*, vol. 10, pp. 3–10, 2012.
- [45] A. R. Mohanty, S. Fatima, “An overview of automobile noise and vibration control,” *Noise & Vibration Worldwide*, vol. 44, no. 6, pp. 10–19, 2013.
- [46] T. Priede, “In search of origins of engine noise—an historical review,” *SAE Transactions*, vol. 89, pp. 2039–2069, 1980.
- [47] P. W. Schaberg, T. Priede, R. K. Dutkiewicz, “Effects of rapid pressure rise on engine vibration and noise,” *SAE Technical Paper 900013*, 1990.
- [48] F. Gu, W. Li, A. D. Ball, A. Y. T. Leung, “Investigation into the condition monitoring of diesel engines from their acoustic characteristics,” *Manchester School of Engineering*, Technical Report MERG-0198, 1998.
- [49] W. Li, F. Gu, A. D. Ball, A. Y. T. Leung, “The representation of engine acoustic signals using continuous wavelet transform,” *Proceedings of the First International Conference on the Integration of Dynamics, Monitoring and Control*, Rotterdam, Netherlands, pp. 433–438, 1999.
- [50] Z. Li, S. Akishita, T. Kato, “Engine failure diagnosis with sound signal using wavelet transform,” in *SAE Technical Paper 970034*, 1997, pp. 79–86.
- [51] W. Li, F. Gu, A. D. Ball, A. Y. T. Leung, C. E. Phipps, “A study of the noise from diesel engines using the independent component analysis,” *Mechanical Systems and Signal Processing*, vol. 15, no. 6, pp. 1165–1184, 2001.

- [52] A. González, M. Ferrer, M. De Diego, G. Piñero, J. J. García-Bonito, “Sound quality of low-frequency and car engine noises after active noise control,” *Journal of Sound and Vibration*, vol. 265, no. 3, pp. 663–679, 2003.
- [53] G. Accardo, B. Cornelis, K. Janssens, B. Peeters, “Automatic microphone localization inside a car cabin for experimental acoustic modal analysis,” in *Proceedings of the 22nd International Congress on Sound and Vibration (ICSV 22)*, Florence, Italy, July 2015.
- [54] S. Mavuri, S. Watkins, X. Wang, S. St Hill, D. Weymouth, “An investigation of vehicle HVAC cabin noise,” in *SAE World Congress and Exhibition*, Detroit, MI, USA, 2008, pp. 1–4.
- [55] F. Akbalık, A. Yıldız, Ö. F. Ertuğrul, H. Zan, “Engine fault detection by sound analysis and machine learning,” *Applied Sciences*, vol. 14, no. 15, p. 6532, 2024.
- [56] S. K. Yadav, P. K. Kalra, “Automatic fault diagnosis of internal combustion engine based on spectrogram and artificial neural network,” in *Proceedings of the 10th WSEAS International Conference on Robotics, Control and Manufacturing Technology*, Hangzhou, China, April 2010.
- [57] M. Marmaroli, J.-M. Carmona, J.-M. Odobez, X. Falourd, H. Lissek, “Observation of vehicle axles through pass-by noise: A strategy of microphone array design,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 14, no. 4, pp. 1654–1664, Dec. 2013.
- [58] A. Y. Nooralahiyan, M. Dougherty, D. McKeown, H. R. Kirby, “A field trial of acoustic signature analysis for vehicle classification,” *Transportation Research Part C: Emerging Technologies*, vol. 5, no. 3–4, pp. 165–177, 1997.
- [59] Y. Schulz, A. K. Mattar, T. M. Hehn, J. F. P. Kooij, “Hearing what you cannot see: Acoustic vehicle detection around corners,” *IEEE Robotics and Automation Letters*, vol. 6, no. 2, pp. 2587–2594, Apr. 2021.
- [60] I. Salom et al., “An acoustic camera for use on UAVs,” *Sensors*, vol. 23, no. 2, p. 880, 2023.
- [61] L. A. Klein, “Roadside sensors for traffic management,” *IEEE Intelligent Transportation Systems Magazine*, vol. 16, no. 4, pp. 21–44, Jul.–Aug. 2024.
- [62] I. Rodriguez-Conde et al., “Horizontally distributed inference of deep neural networks for AI-enabled IoT,” *Sensors*, vol. 23, no. 1911, 2023.

- [63] L. Alzubaidi et al., “Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions,” *Journal of Big Data*, vol. 8, p. 53, 2023.
- [64] I. H. Sarker, “Deep learning: A comprehensive overview on techniques, taxonomy, applications and research directions,” *SN Computer Science*, vol. 2, p. 420, 2021.
- [65] L. Yin, Z. Zilong, “Decoding the application of deep learning in neuroscience: A bibliometric analysis,” *Frontiers in Computational Neuroscience*, vol. 18, 2024.
- [66] G. Hinton et al., “Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups,” *IEEE Signal Processing Magazine*, vol. 29, no. 6, pp. 82–97, Nov. 2012.
- [67] Y. Xu et al., “A regression approach to speech enhancement based on deep neural networks,” *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, vol. 23, no. 1, pp. 7–19, 2015.
- [68] G. Costantini et al., “New advances in audio signal processing,” *Applied Sciences*, vol. 14, no. 6, p. 2321, 2024.
- [69] M. Materlak, E. Majda-Zdancewicz, “Classification of engine type of vehicle based on audio signal as a source of identification,” *Electronics*, vol. 12, no. 9, p. 2012, 2023.
- [70] A. D. Mayvana et al., “Classification of vehicles based on audio signals using quadratic discriminant analysis and high energy feature vectors,” *International Journal of Soft Computing*, vol. 6, no. 1, pp. 53–64, 2015.
- [71] L. N. Thu et al., “Vehicle type classification based on acoustic signals using denoised MFCC,” in *Proceedings of the IEEE International Conference on Information, Communication, and Signal Processing (ICICSP)*, 2018, pp. 113–117.
- [72] K. Marciniuk, B. Kostek, “Machine learning applied to acoustic-based road traffic monitoring,” *Procedia Computer Science*, vol. 207, pp. 1087–1095, 2022.
- [73] M. A. Ghalela et al., “Vehicle classification system using the Haar wavelet transformation algorithm and machine learning,” in *AIP Conference Proceedings*, 2023.

- [74] M. Ashhad et al., “MVD: A novel methodology and dataset for acoustic vehicle type classification,” *arXiv e-prints*: arXiv-2309, 2023.
- [75] S. Kozhisseri, M. Bikdash, “Spectral features for the classification of civilian vehicles using acoustic sensors,” in *Proceedings of the IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems*, Nashville, TN, USA, 2009, pp. 93–100.
- [76] B. De Coensel et al., “Effects of traffic signal coordination on noise and air pollutant emissions,” *Environmental Modelling & Software*, vol. 35, pp. 74–83, 2012.
- [77] R. Evans et al., “Challenges of vehicle classification using acoustics,” in *Proceedings of the 35th International FLAIRS Conference*, 2022.
- [78] A. Y. Nooralahiyan et al., “Vehicle classification by acoustic signature,” *Mathematical and Computer Modelling*, vol. 27, no. 9–11, pp. 205–214, 1998.
- [79] Fraunhofer IDMT, “Traffic acoustic dataset,” [Online]. Dostupno na: <https://www.idmt.fraunhofer.de/en/publications/datasets/traffic.html>, pristupljeno: februar 2025.
- [80] A. I. Yassin et al., “Acoustic vehicle classification using mel-frequency features with long short-term memory neural networks,” *TEM Journal*, vol. 12, no. 3, 2023.
- [81] J. George et al., “Vehicle detection and classification from acoustic signal using ANN and KNN,” in *Proceedings of the International Conference on Control, Communication and Computing (ICCC)*, Thiruvananthapuram, India, 2013, pp. 436–439.
- [82] J. Wei et al., “Vehicle engine classification using normalized tone-pitch indexing and neural computing on short remote vibration sensing data,” *Expert Systems with Applications*, vol. 115, pp. 276–286, 2019.
- [83] P. V. Kane, A. B. Andhare, “Application of psychoacoustics for gear fault diagnosis using artificial neural network,” *Journal of Low Frequency Noise, Vibration & Active Control*, vol. 35, no. 3, pp. 207–220, 2016.
- [84] P. V. Kane, A. B. Andhare, “Critical evaluation and comparison of psychoacoustics, acoustics and vibration features for gear fault correlation and classification,” *Measurement*, vol. 154, p. 107495, 2020.

- [85] P. Poveda-Martínez, J. Ramis-Soriano, "A comparison between psychoacoustic parameters and condition indicators for machinery fault diagnosis using vibration signals," *Applied Acoustics*, vol. 166, p. 107364, 2020.
- [86] H. Chen, Z. Zhang, "Hybrid neural network based on novel audio feature for vehicle type identification," *Scientific Reports*, vol. 11, p. 7648, 2021.
- [87] S. Raynor, R. H. Haas, "Natural frequencies of multicylinder engines," *International Journal of Mechanical Sciences*, vol. 5, no. 1, pp. 69–75, Jan.–Feb. 1963.
- [88] Dbx, "RTA-M Reference Microphone," [Online]. Dostupno na: <https://dbxpro.com/en/products/rta-m>, pristupljeno: februar 2025.
- [89] Behringer, "Behringer UMC404HD USB Audio Interface," [Online]. Dostupno na: <https://www.behringer.com/product.html?modelCode=0805-AAT>, pristupljeno: februar 2025.
- [90] Studocu, "Ultrasonic distance module JSN-SR04T 2.0," [Online]. Dostupno na: <https://www.studocu.vn/vn/document/hanoi-university-of-science/english/hshopvn-jsn-sr04t-20-datasheet/60832827>, pristupljeno: februar 2025.
- [91] AKG, "C562 CM Boundary Layer Microphone," [Online]. Dostupno na: <https://www.ake.com/Microphones/Boundary%20Layer%20Microphones/C562CM.html>, pristupljeno: februar 2025.
- [92] IK Multimedia, "iRig Pre HD – Digital Microphone Interface for iOS, Mac, and PC," [Online]. Dostupno na: <https://www.ikmultimedia.com/products/irigprehd/>, pristupljeno: februar 2025.
- [93] T. Giannakopoulos, A. Pikrakis, *Introduction to Audio Analysis: A MATLAB Approach*, Academic Press, 2014.
- [94] B. J. Mohan, R. Babu N., "Speech recognition using MFCC and DTW," *International Conference on Advances in Electrical Engineering (ICAEE)*, Vellore, India, 9-11 January 2014.
- [95] D. Ćirić, Z. Perić, J. Nikolić, N. Vučić, "Audio Signal Mapping into Spectrogram-Based Images for Deep Learning Applications," *2021 20th International Symposium INFOTEH-JAHORINA (INFOTEH)*, 2021, pp. 1-6.

- [96] F. A. Andrade, I. Esat, M. N. M. Badi, "Gearbox fault detection using statistical methods, time–frequency methods (STFT and Wigner–Ville distribution) and harmonic wavelet—A comparative study," in *Proceedings of the COMADEM '99*, Chipping Norton, pp. 77–85, 1999.
- [97] B. McFee, C. Raffel, D. Liang, D. P. W. Ellis, M. McVicar, E. Battenberg, O. Nieto, "Librosa: Audio and music signal analysis in Python," *Proceedings of the 14th Python in Science Conference*, pp. 18-25, 2015.
- [98] M. A. Bartsch, G. H. Wakefield, "Audio thumbnailing of popular music using chroma-based representations," *IEEE Transactions on Multimedia*, vol. 7, no. 1, pp. 96–104, 2005.
- [99] D. P. W. Ellis, "Gammatone-like spectrograms," [Online]. Dostupno na: <http://www.ee.columbia.edu/dpwe/resources/matlab/gammatonegram>, pristupljeno: februar 2025.
- [100] R. D. Patterson, "Auditory filters and excitation patterns as representations of frequency resolution," *Frequency Selectivity in Hearing*, 1986.
- [101] B. R. Glasberg, B. C. J. Moore, "Derivation of auditory filter shapes from notched-noise data," *Hearing Research*, vol. 47, no. 1-2, pp. 103–138, 1990.
- [102] A. Nguyen, B. Phan, K. Tran, T. Nguyen, "Deep Learning Framework Applied for Predicting Anomaly of Respiratory Sounds," 2020.
- [103] P. Grosche, M. Müller, F. Kurth, "Cyclic tempogram—A mid-level tempo representation for music signals," *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2010.
- [104] E. Zwicker, H. Fastl, *Psychoacoustics: Facts and Models*, vol. 22, Springer Science & Business Media, 2013.
- [105] J. Murovec, et al., "Psychoacoustic approach for cavitation detection in centrifugal pumps," *Applied Acoustics*, vol. 165, p. 107323, 2020.
- [106] T. Mian, A. Choudhary, S. Fatima, "An efficient diagnosis approach for bearing faults using sound quality metrics," *Applied Acoustics*, vol. 195, p. 108839, 2022.
- [107] F. Duvinneau, et al., "Thermo-acoustic performance of full engine encapsulations—A numerical, experimental, and psychoacoustic study," *Applied Acoustics*, vol. 102, pp. 79-87, 2016.

- [108] S. Singh, S. Potala, A. R. Mohanty, "An improved method of detecting engine misfire by sound quality metrics of radiated sound," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, vol. 233, no. 12, pp. 3112–3124, 2019.
- [109] P. Potočnik, E. Govekar, I. Grabec, "Application of psychoacoustic filtering for machine fault detection," *Proceedings of the 8th International Conference of the Slovenian Society for Non-Destructive Testing: Application of Contemporary Non-Destructive Testing in Engineering*, Portorož, Slovenia, 2005.
- [110] J. Prezelj, T. Novaković, "Centrifugal fan with inclined blades for vacuum cleaner motor," *Applied Acoustics*, vol. 140, pp. 13–23, 2018.
- [111] T. Novaković, M. Ogris, J. Prezelj, "Validating impeller geometry optimization for sound quality based on psychoacoustics metrics," *Applied Acoustics*, vol. 157, p. 107013, 2020.
- [112] V. G. Cook, C. Caryer, A. Ali, "End-of-line inspection for annoying noises in automobiles: Trends and perspectives," *Applied Acoustics*, vol. 73, no. 3, pp. 265–275, 2012.
- [113] W. Aures, "Sensory pleasantness as a function of psychoacoustic sensations," *Acustica*, vol. 58, pp. 282–290, 1985.
- [114] K. Kavitha, B. Thirumala Rao, "Evaluation of distance measures for feature-based image registration using AlexNet," *International Journal of Advanced Computer Science and Applications*, vol. 9, no. 10, 2018.
- [115] L. Wang, Y. Zhang, J. Feng, "On the Euclidean distance of images," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 27, no. 8, pp. 1334–1339, Aug. 2005.
- [116] J. Prezelj, J. Murovec, S. Huemer-Kals, K. Häsler, P. Fischer, "Identification of different manifestations of nonlinear stick–slip phenomena during creep groan braking noise by using the unsupervised learning algorithms k-means and self-organizing map," *Mechanical Systems and Signal Processing*, vol. 166, p. 108349, 2022.
- [117] D. Cirić, M. Janković, M. Miletić, "Sound Based DC Motor Classification by a Convolution Neural Network," *Proceedings of the 57th ICEST*, 2022, pp. 93–96.
- [118] G. Salton, M. J. McGill, *Introduction to Modern Information Retrieval*, McGraw-Hill, 1983.

- [119] C. J. van Rijsbergen, *Information Retrieval*, Butterworth-Heinemann, 1979.
- [120] D. Ćirić, Z. Perić, N. Vučić, M. Miletić, "Analysis of Industrial Product Sound by Applying Image Similarity Measures," *Mathematics*, vol. 11, no. 3, p. 498, 2023.
- [121] O. A. Abbas, "Comparisons between data clustering algorithms," *International Arab Journal of Information Technology (IAJIT)*, vol. 5, no. 3, 2008.
- [122] R. Sathya, A. Abraham, "Comparison of supervised and unsupervised learning algorithms for pattern classification," *International Journal of Advanced Research in Artificial Intelligence*, vol. 2, no. 2, pp. 34–38, 2013.
- [123] G. Li et al., "Self-supervised learning for intelligent fault diagnosis of rotating machinery with limited labeled data," *Applied Acoustics*, vol. 191, p. 108663, 2022.
- [124] S. Yazdani, M. Montazeri-Gh, "A novel gas turbine fault detection and identification strategy based on hybrid dimensionality reduction and uncertain rule-based fuzzy logic," *Computers in Industry*, vol. 115, p. 103131, 2020.
- [125] T. Kohonen, *Self-organizing maps*, vol. 30, Springer Science & Business Media, 2012.
- [126] D. Xiao et al., "Unsupervised machine fault diagnosis for noisy domain adaptation using marginal denoising autoencoder based on acoustic signals," *Measurement*, vol. 176, p. 109186, 2021.
- [127] J. J. Saucedo-Dorantes et al., "Multiple-fault detection and identification scheme based on hierarchical self-organizing maps applied to an electric machine," *Applied Soft Computing*, vol. 81, p. 105497, 2019.
- [128] Y. Zhang et al., "Bearing performance degradation assessment based on time-frequency code features and SOM network," *Measurement Science and Technology*, vol. 28, no. 4, p. 045601, 2017.
- [129] A. Rai, S. H. Upadhyay, "Intelligent bearing performance degradation assessment and remaining useful life prediction based on self-organising map and support vector regression," *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, vol. 232, no. 6, pp. 1118–1132, 2018.

- [130] M. Skowron et al., "Application of self-organizing neural networks to electrical fault classification in induction motors," *Applied Sciences*, vol. 9, no. 4, p. 616, 2019.
- [131] J. Alvarez-Montoya, A. Carvajal-Castrillón, J. Sierra-Pérez, "In-flight and wireless damage detection in a UAV composite wing using fiber optic sensors and strain field pattern recognition," *Mechanical Systems and Signal Processing*, vol. 136, p. 106526, 2020.
- [132] Y. Shen, K. Khorasani, "Hybrid multi-mode machine learning-based fault diagnosis strategies with application to aircraft gas turbine engines," *Neural Networks*, vol. 130, pp. 135–142, 2020.
- [133] S. Schwartz et al., "A fault mode identification methodology based on self-organizing map," *Neural Computing & Applications*, vol. 32, no. 17, pp. 13405–13423, 2020.
- [134] W. Li et al., "Acoustic based condition monitoring of a diesel engine using self-organising map networks," *Applied Acoustics*, vol. 63, no. 7, pp. 699–711, 2002.
- [135] I. S. Andrades et al., "Low-cost road-surface classification system based on self-organizing maps," *Sensors*, vol. 20, no. 21, p. 6009, 2020.
- [136] H. Wu, Y. Zhonghua, Y. Wang, "Experimental study of the process failure diagnosis in additive manufacturing based on acoustic emission," *Measurement*, vol. 136, pp. 445–453, 2019.
- [137] N. M. Ghazaly et al., "Prediction of misfire location for SI engine by unsupervised vibration algorithm," *Applied Acoustics*, vol. 192, p. 108726, 2022.
- [138] B. H. Hahn, D. T. Valentine, *Essential MATLAB for Engineers and Scientists* (Sixth Edition), Elsevier, 2017.

Biografija autora

Marko Milivojčević je rođen 15. jula 1986. godine u Beogradu. Osnovnu školu „Milica Pavlović“ (sada „Kralj Petar Drugi Prestolonaslednik“) završio je kao đak generacije i dobitnik Vukove diplome. Nakon osnovne škole završio je Treću beogradsku gimnaziju prirodno-matematički smer takođe kao dobitnik Vukove diplome.

Diplomirao je na Elektrotehničkom fakultetu Univerziteta u Beogradu smer Telekomunikacije modul Radiokomunikacije 2014 godine. Na istom fakultetu 2015 godine, odbranom rada kod Dr Dejana Drajića pod nazivom "Upotreba bežičnih senzorskih mreža u nadgledanju i kontroli saobraćaja u urbanim sredinama", završio je master studije na smeru Telekomunikacije modul Sistemsko inženjerstvo i radiokomunikacije sa prosečnom ocenom 9,67.

2015. godine upisao je doktorske studije na Elektronskom fakultetu Univerziteta u Nišu na smeru Telekomunikacije.

2016. godine se zaposlio u srednjoj školi „Vazduhoplovna akademija“ kao nastavnik elektrotehničke grupe predmeta, a od jeseni 2016. je zaposlen u Visokoj školi elektrotehnike i računarstva strukovnih studija u Beogradu kao asistent na studijskom programu Elektronika i telekomunikacije. Od 2016. do 2025. je učestvovao u više međunarodnih ERASMUS+ projekata, kao i na domaćim projektima. U periodu od 2018. do 2025. je učestvovao kao autor i koautor u dvadesetjednom naučno-stručnom radu od čega je najviše radova iz oblasti akustike.

Oženjen, otac dvoje dece.

IZJAVA O AUTORSTVU

Izjavljujem da je doktorska disertacija, pod naslovom

KLASIFIKACIJA MOTORA AUTOMOBILA SA UNUTRAŠNjim SAGOREVANJEM PREMA POGONSKOM GORIVU NA OSNOVU GENERISANOG ZVUKA

koja je odbranjena na Elektronskom fakultetu Univerziteta u Nišu:

- rezultat sopstvenog istraživačkog rada;
- da ovu disertaciju, ni u celini, niti u delovima, nisam prijavljivao/la na drugim fakultetima, niti univerzitetima;
- da nisam povredio autorska prava, niti zloupotrebio intelektualnu svojinu drugih lica.

Dozvoljavam da se objave moji lični podaci, koji su u vezi sa autorstvom i dobijanjem akademskog zvanja doktora nauka, kao što su ime i prezime, godina i mesto rođenja i datum odbrane rada, i to u katalogu Biblioteke, Digitalnom repozitorijumu Univerziteta u Nišu, kao i u publikacijama Univerziteta u Nišu.

U Nišu, _____.

Potpis autora disertacije:



Marko M. Milivojčević

**IZJAVA O ISTOVETNOSTI ŠTAMPANOG I ELEKTRONSKOG OBLIKA
DOKTORSKE DISERTACIJE**

Naslov disertacije:

**KLASIFIKACIJA MOTORA AUTOMOBILA SA UNUTRAŠNjim SAGOREVANJEM
PREMA POGONSKOM GORIVU NA OSNOVU GENERISANOG ZVUKA**

Izjavljujem da je elektronski oblik moje doktorske disertacije, koju sam predao za unošenje u **Digitalni repozitorijum Univerziteta u Nišu**, istovetan štampanom obliku.

U Nišu,_____.

Potpis autora disertacije:



Marko M. Milivojčević

IZJAVA O KORIŠĆENJU

Ovlašćujem Univerzitetsku biblioteku „Nikola Tesla“ da u Digitalni repozitorijum Univerziteta u Nišu unese moju doktorsku disertaciju, pod naslovom:

KLASIFIKACIJA MOTORA AUTOMOBILA SA UNUTRAŠNjim SAGOREVANJEM PREMA POGONSKOM GORIVU NA OSNOVU GENERISANOG ZVUKA

Disertaciju sa svim prilogima predao sam u elektronskom obliku, pogodnom za trajno arhiviranje.

Moju doktorsku disertaciju, unetu u Digitalni repozitorijum Univerziteta u Nišu, mogu koristiti svi koji poštuju odredbe sadržane u odabranom tipu licence Kreativne zajednice (Creative Commons), za koju sam se odlučio.

1. Autorstvo (CC BY)

2. Autorstvo – nekomercijalno (CC BY-NC)

3. Autorstvo – nekomercijalno – bez prerade (CC BY-NC-ND)

4. Autorstvo – nekomercijalno – deliti pod istim uslovima (CC BY-NC-SA)

5. Autorstvo – bez prerade (CC BY-ND)

6. Autorstvo – deliti pod istim uslovima (CC BY-SA)

U Nišu,_____.

Potpis autora disertacije:



Marko M. Milivojčević