



УНИВЕРЗИТЕТ У НОВОМ САДУ
ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА
НОВИ САД



Мирослава Јордовић Павловић

**ПРОГРАМСКИ ОКВИР ЗАСНОВАН НА
МАШИНСКОМ УЧЕЊУ ЗА
АУТОМАТИЗАЦИЈУ ОБРАДЕ РЕЗУЛТАТА
ФОТОАКУСТИЧНИХ МЕРЕЊА
ДОКТОРСКА ДИСЕРТАЦИЈА**

Ментор:

Проф. др Александар Купусинац

Нови Сад, 2020.



УНИВЕРЗИТЕТ У НОВОМ САДУ • ФАКУЛТЕТ ТЕХНИЧКИХ НАУКА
21000 НОВИ САД, Трг Доситеја Обрадовића 6

КЉУЧНА ДОКУМЕНТАЦИЈСКА ИНФОРМАЦИЈА

Редни број, РБР:	
Идентификациони број, ИБР:	
Тип документације, ТД:	Монографска публикација
Тип записа, ТЗ:	Текстуални штампани материјал
Врста рада, ВР:	Докторска дисертација
Аутор, АУ:	Мирослава Јордовић Павловић
Ментор, МН:	Др Александар Купусинац
Наслов рада, НР:	ПРОГРАМСКИ ОКВИР ЗАСНОВАН НА МАШИНСКОМ УЧЕЊУ ЗА АУТОМАТИЗАЦИЈУ ОБРАДЕ РЕЗУЛТАТА ФОТОАКУСТИЧНИХ МЕРЕЊА
Језик публикације, ЈП:	српски
Језик извода, ЈИ:	српски/енглески
Земља публиковања, ЗП:	Република Србија
Уже географско подручје, УГП:	АП Војводина, Нови Сад
Година, ГО:	2020.
Издавач, ИЗ:	Ауторски репринт
Место и адреса, МА:	Факултет техничких наука, 21 000 Нови Сад, Трг Доситеја Обрадовића 6
Физички опис рада, ФО: <small>(поглавља/страна/ цитата/табела/слика/графика/прилога)</small>	8/108/87/23/50/0/0
Научна област, НО:	Електротехничко и рачунарско инжењерство
Научна дисциплина, НД:	Примењене рачунарске науке и информатика
Предметна одредница/Кључне речи, ПО:	Машинско учење; Вештачке неуронске мреже; Регресија; Класификација; Анализа главних компоненти; Фотоакустика; Микрофон
УДК	
Чува се, ЧУ:	Библиотека Факултета техничких наука у Новом Саду
Важна напомена, ВН:	

Извод, **ИЗ:**

Главни задатак истраживања приказаног у дисертацији је развој модела, заснованог на алгоритмима машинског учења, који описује сложени утицај мерног система на користан, експериментални сигнал са циљем његове елиминације. Студија случаја је широко распрострањена фотоакустична, трансмисиона мерна метода са хелијом минималне запремине. Мултидисциплинарност и комплексност проблема одредили су следеће кораке у методологији решења: 1) развој софтвера за генерисање симулираних експерименталних података, 2) развој регресионог модела заснованог на трослојној неуронској мрежи, за прецизну и поуздану карактеризацију детектора која се извршава у реалном времену, 3) развој класификационог модела заснованог на неуронској мрежи једноставне структуре за прецизну и поуздану предикцију типа коришћеног детектора која се извршава у реалном времену, 4) спрезање регресионог и класификационог модела уз развој додатног софтвера за прилагођење модела стварном експерименту. На овај начин заокружен је програмски оквир који извршава сложени задатак издвајања “правог” сигнала од изобличеног експерименталног сигнала без ангажовања истраживача, односно извршава аутокорекцију. Тестирање је извршено на више различитих детектора и више различитих материјала у фотоакустичном експерименту. Применом развијеног програмског оквира конкурентност експерименталне технике је знатно порасла: повећана је тачност и поузданост, проширен је мерни опсег и смањено време обраде резултата мерења.

Датум прихватања теме, **ДП:**

Датум одбране, **ДО:**

Чланови комисије, **КО:**

Председник:

др Драган Иветић

Члан:

др Марица Поповић

Члан:

др Душан Гајић

Члан:

др Дину Драган

Члан, ментор:

др Александар Купусинац

Потпис ментора



UNIVERSITY OF NOVI SAD ● FACULTY OF TECHNICAL SCIENCES
21000 NOVI SAD, Trg Dositeja Obradovića 6

KEY WORDS DOCUMENTATION

Accession number, ANO :	
Identification number, INO :	
Document type, DT :	Monographic publication
Type of record, TR :	Textual printed document
Contents code, CC :	Ph.D. thesis
Author, AU :	Miroslava Jordović Pavlović, M.Sc.
Mentor, MN :	Aleksandar Kupusinac, Ph.D.
Title, TI :	MACHINE LEARNING-BASED SOFTWARE FRAMEWORK FOR THE AUTOMATION OF PHOTOACOUSTIC MEASUREMENT DATA PROCESSING
Language of text, LT :	Serbian
Language of abstract, LA :	Serbian/English
Country of publication, CP :	Republic of Serbia
Locality of publication, LP :	AP Vojvodina, Novi Sad
Publication year, PY :	2020.
Publisher, PB :	Author's reprint
Publication place, PP :	Faculty of Technical Sciences, 21 000 Novi Sad, Trg Dositeja Obradovića 6
Physical description, PD : <small>(chapters/pages/ref./tables/pictures/graphs/appendixes)</small>	8/108/87/23/50/0/0
Scientific field, SF :	Electrical and Computer Engineering
Scientific discipline, SD :	Applied Computer Sciences and Informatics
Subject/Key words, S/KW :	Machine Learning; Artificial Neural Networks; Regression; Classification; Principal Component Analysis; Photoacoustics; Microphone
UC	
Holding data, HD :	Library of the Faculty of Technical Sciences in Novi Sad
Note, N :	

Abstract, **AB:**

The main task of the research presented in this dissertation is the development of the model based on machine learning algorithms, which describes the complex influence of the measuring system on a useful, experimental signal, with the aim of the elimination of this influence. The case study is a widespread photoacoustic, transmission measurement method with minimum volume cell configuration. Multidisciplinarity and complexity of the problem determined the following steps in the solution methodology: 1) development of the software for generating simulated experimental data, 2) development of the regression model based on a three-layer neural network, for precise and reliable characterization of detectors, performed in real time, 3) development of the classification model based on a neural network of simple structure for precise and reliable prediction of the type of detector in use, performed in real time, 4) coupling of the regression and the classification model with the development of additional software for adjustment of the model to a real experiment. In this way, the program framework is completed, which performs the complex task of extracting the "true" signal from the distorted experimental signal without the involvement of researchers, performing, thus, the autocorrection. Testing was performed on several different detectors and several different materials in a photoacoustic experiment. With the application of the developed software framework, the competitiveness of the experimental technique has significantly increased: the accuracy and the reliability have been increased, the measurement range has been expanded and the processing time of measurement results has been reduced.

Accepted by the Scientific Board on, **ASB:**

Defended on, **DE:**

Defended Board, **DB:**

President:

dr Dragan Ivetić

Member:

dr Marica Popović

Member:

dr Dušan Gajić

Member:

dr Dinu Dračan

Member, Mentor:

dr Aleksandar Kupusinac

Mentor's sign

Изјаве захвалности

Захваљујем се ментору др Александру Купусинцу, ванредном професору Факултета техничких наука у Новом Саду који ме је прихватио на прекретници мог научног узрастања и својим стручним и прагматичним саветима довео до одбране ове докторске дисертације.

Посебну захвалност дугујем др Марици Поповић, научном сараднику ИНН „Винча“, Универзитета у Београду од које сам научила како се несебично дели знање и стрпљиво истрајава на путу научних сазнања.

Изузетно сам захвална др Слободанки Боби Галовић, научном саветнику ИНН „Винча“, Универзитета у Београду, која ми је указала на важност енергичности у научној дискусији, идеје и сопственог научног става.

Изузетно сам захвална др Драгану Маркушеву, научном саветнику Института за физику Земун-Београд, Универзитета у Београду, који ми је показао како изгледа систематичан и посвећен научни рад.

Захваљујем се др Миољубу Нешићу, научном сараднику ИНН „Винча“, Универзитета у Београду и мр Катарини Ђорђевић, докторанту Физичког факултета, Универзитета у Београду на времену и истрајности у дугим научним расправама.

Мојој породици се захваљујем на разумевању и стрпљењу, а посебно супругу Горану који је несебично издвајао време да заједно савладамо просторну дистанцу до Ниша, Београда и на крају Новог Сада.

Сажетак

Главни задатак истраживања приказаног у дисертацији је развој модела, заснованог на алгоритмима машинског учења, који описује сложени утицај мерног система на користан, експериментални сигнал са циљем његове елиминације. Студија случаја је широко распрострањена фотоакустична, трансмисиона мерна метода са ћелијом минималне запремине. Мултидисциплинарност и комплексност проблема одредили су следеће кораке у методологији решења: 1) развој софтвера за генерисање симулираних експерименталних података, 2) развој регресионог модела заснованог на трослојној неуронској мрежи, за прецизну и поуздану карактеризацију детектора која се извршава у реалном времену, 3) развој класификационог модела заснованог на неуронској мрежи једноставне структуре за прецизну и поуздану предикцију типа коришћеног детектора која се извршава у реалном времену, 4) спрезање регресионог и класификационог модела уз развој додатног софтвера за прилагођење модела стварном експерименту. На овај начин заокружен је програмски оквир који извршава сложени задатак издвајања “правог” сигнала од изобличеног експерименталног сигнала без ангажовања истраживача, односно извршава аутокорекцију. Тестирање је извршено на више различитих детектора и више различитих материјала у фотоакустичном експерименту. Применом развијеног програмског оквира конкурентност експерименталне технике је знатно порасла: повећана је тачност и поузданост, проширен је мерни опсег и смањено време обраде резултата мерења.

Abstract

The main task of the research presented in this dissertation is the development of the model based on machine learning algorithms, which describes the complex influence of the measuring system on a useful, experimental signal, with the aim of the elimination of this influence. The case study is a widespread photoacoustic, transmission measurement method with minimum volume cell configuration. Multidisciplinarity and complexity of the problem determined the following steps in the solution methodology: 1) development of the software for generating simulated experimental data, 2) development of the regression model based on a three-layer neural network, for precise and reliable characterization of detectors, performed in real time, 3) development of the classification model based on a neural network of simple structure for precise and reliable prediction of the type of detector in use, performed in real time, 4) coupling of the regression and the classification model with the development of additional software for adjustment of the model to a real experiment. In this way, the program framework is completed, which performs the complex task of extracting the "true" signal from the distorted experimental signal without the involvement of researchers, performing, thus, the autocorrection. Testing was performed on several different detectors and several different materials in a photoacoustic experiment. With the application of the developed software framework, the competitiveness of the experimental technique has significantly increased: the accuracy and the reliability have been increased, the measurement range has been expanded and the processing time of measurement results has been reduced.

Слике

Слика 1: Електретски микрофон [29].....	11
Слика 2: Експериментална поставка [29][30] (Институт за физику у Земуну).....	12
Слика 3: Амплитудска карактеристика теоријско-математички симулираног ФА одзива у функцији модуларне фреквенције, 2 250 кривих [16].....	18
Слика 4: Фазна карактеристика теоријско-математички симулираног ФА одзива у функцији модуларне фреквенције, 2 250 кривих [16].....	18
Слика 5: Симулиране амплитуде а) A и фазе б) φ укупног ФА $\delta p_{total}f$ (црна линија) и изобличеног експерименталног Sf сигнала (црвена линија) у функцији фреквенције модуларне f . Електронски $H_{total}e(f) = H1e(f)H2e(f)$ и акустични $H_{total}a(f)$ одзив експеримента, [16].....	20
Слика 6: Визуализација података: парови вредности амплитуда и фаза за једну фреквенцију у једном запису базе података представљени једном тачком на дијаграму, различите боје одговарају различитим типовима микрофона.....	25
Слика 7: Нелинеарни неурон, где је w^T транспоновани вектор вектора w	26
Слика 8: Неуронска мрежа са L слојева.....	27
Слика 9: Површина функције цене у простору тежина, слика преузета са сајта cs224d.stanford.edu	30
Слика 10: Функција цене (а) издужена, код сирових података (б) симетрична, код нормализованих података, слика преузета са сајта medium.com	30
Слика 11: (а) Пут функције цене ка глобалном минимуму (пример) у случају ненормализованих улаза, (б) пут функције цене ка глобалном минимуму у случају нормализованих улаза, слике преузете са сајта medium.com	30
Слика 12: Нормализација методом зед-скор.....	31
Слика 13: Ациклични граф трослојне неуронске мреже.....	32
Слика 14: Поређење две технике оптимизације, градација опадања и градација опадања са моментумом, слика преузета са https://towardsdatascience.com	39
Слика 15: Поређење: бач (плава крива), стохастичког (љубичаста крива) и мини бач (енг. mini-batch) (зелена крива) градијента, преузето са datascience.stackexchange.com	41
Слика 16: Мини-бач техника, димензија 64.....	42
Слика 17: Прва и друга главна компонента, x_1 и x_2 су два обележја скупа података.....	43
Слика 18: Изглед базе података.....	46

Слика 19: Итеративни процес развоја модела машинског учења	48
Слика 20: Анализа броја неурона у првом и другом скривеном слоју	50
Слика 21: Поређење конвергенције функције цене у случају модела са 21+16 неурона и 30+17 неурона, функција цене тест скупа података је крива са израженим осцилацијама.....	51
Слика 22: Изабрано решење структуре неуронске мреже, [16].....	52
Слика 23: Дијаграм функције $\tanh()$, преузето са mathworld.wolfram.com/HyperbolicTangent.html	53
Слика 24: Конвергенција функције цене, Модел1, [16]	54
Слика 25: Функција цене одређена на тренинг скупу, валидационом и тест скупу података, Модел1	56
Слика 26: Усвојено решење структуре класификационог модела	66
Слика 27: Типична трансфер функција - крива одзива са обликом и равна крива одзива (а) амплитуда и (б) фаза у ФА мерењима [17].....	69
Слика 28: Блок шема методе за аутокорекцију изобличеног експерименталног сигнала, [17].....	71
Слика 29: Експериментални $S(f)$ ФА одзив (а) амплитуда, A , и (б) фаза, φ , у функцији модуларне фреквенције f , у случају истог узорка алуминијума мереног различитим типовима микрофона: ЕСМ60 (магента крива), ЕСМ30В (плава крива), WM66 (црвена крива) и ИМ (црна крива), [17]	72
Слика 30: Добијена $H(f)$ трансфер функција (а) амплитуда и (б) фаза као функција модуларне фреквенције f , за сваки тип микрофона као и на слици 29, [17]	72
Слика 31: “Прави” сигнал $\delta p_{total} f$ као функција модуларне фреквенције f , који потиче од истог узорка алуминијума, измерен различитим типовима микрофона: ЕСМ30В (плава крива), ЕСМ60 (магента крива), WM66 (зелена крива) и ИМ (црна крива), [17]	73
Слика 32: Блок шема методе калибрације [18]	75
Слика 33: (а) ФА експериментални одзив и (б) добијена фазна карактеристика микрофона у случају узорка од алуминијума мереног микрофоном ЕСМ30В, као функција модуларне фреквенције, [18].....	76
Слика 34: Експериментална (плава линија), калибрисана (црвена линија) и теоријски предвиђена (зелена линија) фазна карактеристика ласерски-синтерованог полиамида (РА12), [18]	78

Слика 35: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон ЕСМ30В, оригиналних димензија 400 x 67 500	81
Слика 36: Корелација на оригиналном скупу података, база микрофона ЕСМ30В...	82
Слика 37: Корелација амплитуда у оригиналном скупу података, база микрофона ЕСМ30В.....	83
Слика 38: Корелација фаза у оригиналном скупу података, база микрофона ЕСМ30В	83
Слика 39: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон ЕСМ60, оригиналних димензија 400 x 67 500	87
Слика 40: Корелација на оригиналном скупу података, база микрофона ЕСМ60	87
Слика 41: Корелација амплитуда у оригиналном скупу података, база микрофона ЕСМ60	88
Слика 42: Корелација фаза у оригиналном скупу података, база микрофона ЕСМ6088	
Слика 43: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон WM66, оригиналних димензија 400 x 67 500	92
Слика 44: Корелација на оригиналном скупу података, база микрофона WM66.....	92
Слика 45: Корелација амплитуда у оригиналном скупу података, база микрофона WM66.....	93
Слика 46: Корелација фаза у оригиналном скупу података, база микрофона WM66	93
Слика 47: Преостала варијанса у односу на број обележја у редукованом скупу података за базу коришћену за обуку класификационог модела, оригиналних димензија 400 x 270 000.....	96
Слика 48: Корелација на оригиналном скупу података, база 4 микрофона	98
Слика 49: Корелација амплитуда на оригиналном скупу података, база 4 микрофона	98
Слика 50: Корелација фаза на оригиналном скупу података, база 4 микрофона	99

Табеле

Табела 1: Теоријске вредности за узорак од алуминијума и ласерски синтерованог полиамида PA12	23
Табела 2: Резултати крос-валидације за различит број неурона у скривеним слојевима	50
Табела 3: Резултати крос-валидације за Модел1 и Модел2	52
Табела 4: Поређење одступања Модела1 за различите вредности корака обучавања	53
Табела 5: Поређење перформанси модела у случају различитих метода нормализације	54
Табела 6: Модел1, вредности хиперпараметара, [16]	55
Табела 7: Упоредни приказ перформанси Модела1, Модела2 и Модела3, [69]	56
Табела 8: Резултати независних тестова, регресиони модел, [16].....	57
Табела 9: Перформансе регресионог модела у условима експерименталне нестабилности, [16]	59
Табела 10: Перформансе регресионог модела за три комерцијална микрофона најчешће коришћена у ФА мерењима [17]	61
Табела 11: Анализа броја скривених слојева и броја неурона у скривеним слојевима, класификациони модел.....	64
Табела 12: Резултати независних тестова, класификациони модел.....	66
Табела 13: Перформансе регресионог модела за ФА одзив ласерски-синтерованог полиамида PA12, [18].....	77
Табела 14: Перформансе регресионог модела на редукованом скупу података за микрофон ЕСМ30В	84
Табела 15: Независни тестови регресионог модела тренираног на редукованом скупу података за микрофон ЕСМ30В.....	85
Табела 16: Перформансе регресионог модела за микрофон ЕСМ60 на редукованом скупу података.....	89
Табела 17: Провера поузданости регресионог модела са редукованим улазним вектором, микрофон ЕСМ60	90
Табела 18: Перформансе регресионог модела за микрофон WM66 на редукованом скупу података.....	94
Табела 19: Провера поузданости регресионог модела са редукованим улазним вектором, микрофон WM66	94

Табела 20: Перформансе класификационог модела за редуковани скуп улазних података на 5 мерних тачака	97
Табела 21: Провера поузданости класификационог модела са редукованом димензијом улазног вектора на 10 обележја	97
Табела 22: Перформансе класификационог модела за редуковани скуп улазних података на 1 мерну тачку са фреквенцијом 36.54 Hz.....	99
Табела 23: Провера поузданости класификационог модела са редукованом димензијом улазног вектора на два обележја, мерна тачка 36.54 Hz.....	100

Ознаке и скраћенице

ANN	Вештачка неуронска мрежа (енг. Artificial Neural Network)
Adam	Процена адаптивног момента (енг. Adaptive Moment Estimation)
CNN	Конволуцијске неуронске мреже (енг. Convolutional Neural Network)
CPU	Централна процесорска јединица (енг. Central Processing Unit)
GPU	Графичка процесорска јединица (енг. Graphic Processing Unit)
CSD	Кохерентна сметња (енг. Coherent Signal Deviation)
ECM	Кондензаторски електрет микрофон (енг. Electret Condenser Microphone)
FN	Фликер шум (енг. Flicker Noise)
ФА	Фотоакустика (енг. Photoacoustics)
ИМ	Идеални микрофон
MLP	Вишеслојни перцептрон (енг. Multilayer Perceptron)
ФАТ	Фотоакустичка томографија (енг. Photoacoustic Tomography)
РА12	Ласерски синтерован полиамид
РСА	Анализа главних компоненти (енг. Principal Component Analyses)
ФТ	Фототермални (енг. Photothermal)
РС	Отпорно кондензаторско коло (енг. Resistive Capacitor Circuit)
RGB	Колорни модел (енг. Red Green Blue)
RMS	Пропагација корена средњег квадрата (енг. Root Mean Squared Prop)
Std	Стандардна девијација (енг. Standard Deviation)
WM	Тип електрет микрофона

Садржај

1	Уводна разматрања.....	1
1.1	Предмет и мотивација	1
1.2	Циљеви	5
1.3	Научни доприноси	5
1.4	Полазне хипотезе	6
1.5	Методе истраживања	6
1.6	Организација докторске дисертације.....	7
2	Фотоакустика – пример модел зависне технике мерења	8
2.1	Математички модел фотоакустичног одзива	12
2.2	Процедура корекције сигнала.....	19
2.3	Неуронске мреже у фотоакустици.....	20
2.4	Подаци	22
3	Вишеслојне неуронске мреже	26
3.1	Врсте учења неуронских мрежа.....	27
3.2	Функција цене	28
3.3	Нормализација улаза	29
3.4	Математички модел вишеслојне неуронске мреже	32
3.5	Регуларизација.....	35
3.6	Иницијализација	37
3.7	Оптимизациони алгоритми	38
3.8	Мини бач у односу на бач.....	41
4	Анализа главних компоненти у проблемима машинског учења	43
5	Методологија-имплементација алгоритама	45
5.1	Захтеви	45

5.2	Нормализација података	46
5.3	Регресиони модел за предикцију параметара микрофона	47
5.3.1	Дискусија - архитектура и хиперпараметри модела	48
5.3.2	Тест модела на независном скупу података	57
5.3.3	Тест модела на подацима са шумом	59
5.3.4	Поређење перформанси модела за три различита микрофона	60
5.4	Класификациони модел.....	62
5.4.1	Дискусија - архитектура и хиперпараметри модела	63
5.4.2	Тест модела на независном скупу података	66
6	<i>Практична примена развијених модела</i>	68
6.1	Прилагођавање експерименталних података моделу.....	68
6.2	Метода за аутокорекцију сигнала	68
6.3	Калибрација микрофона.....	73
7	<i>Додатна истраживања.....</i>	79
7.1	Редукција димензија	80
7.1.1	Редукција димензија улазног вектора регресионог модела за микрофон ЕСМ30В	80
7.1.2	Редукција димензија улазног вектора регресионог модела за микрофон ЕСМ60	86
7.1.3	Редукција димензија улазног вектора регресионог модела за микрофон WM66	91
7.1.4	Редукција димензија улазног вектора класификационог модела	96
8	<i>Закључак и будућа истраживања</i>	101

1 Уводна разматрања

Последњих неколико година сведоци смо значајног унапређења могућности машинског учења, које у појединим областима и за специфичне задатке превазилазе људске могућности. Иницијални успеси машинског учења сада су део свакодневице великог броја људи: препознавање говора у виртуелним гласовним асистентима [1], препознавање слика на социјалним мрежама [2], системи препоруке приликом Интернет куповине [3] и др. Овакав напредак резултат је техничког развоја области, све веће доступности података и пораста снаге рачунара. Реална су очекивања да потенцијал машинског учења буде и даље у успону [3], с обзиром на разноликост примена: модеран бизнис, медицина, образовање, транспорт, итд.

Ова докторска дисертација изучава једну интересантну примену алгоритама машинског учења – решавање проблема несигурности мерења. Неуронске мреже као алгоритама машинског учења коришћене су као прецизан и поуздан алат за обраду резултата мерења у модел зависној експерименталној методи, где се не мери испитивана величина директно, већ индиректно мерећи другу величину која је са испитиваном повезана теоријско-математичким моделом. Истражена је и могућност коришћења симулираних података у недостатку реалних, а да се при томе одржи веродостојност са експериментом и омогући коришћење експерименталних резултата у софтверском моделу.

1.1 Предмет и мотивација

Проблем несигурности мерења је већ дуго актуелна истраживачка тема. Мерна несигурност карактерише и ближе описује грешке мерења. Развијене су различите технике за смањење грешака мерења било систематских или случајних, било утицаја мерног ланца на исход мерења. Утицај мерног ланца је посебна класа проблема зависна од примењених инструмената, јер за већину инструмената домен и начин утицаја је углавном непознат. Међутим, уколико се утицај мерног ланца може описати теоријско-математичким моделом то иницира нека нова решења у даљем

истраживању проблема несигурности мерења код овог типа мерних метода. Иако се ово истраживање може генерализовати на све модел зависне мерене методе, због великог броја примена, усмерено је на једну уско стручну област, фотоакустику.

Фотоакустика (ФА) је прва постављена и данас најшире коришћена фототермална (ФТ) метода [4]. ФТ методе су методе засноване на ФТ ефекту, односно појави периодичног загревања материјала који је апсорбовао електромагнетно зрачење или енергију побудног честичног снопа. ФА се веома успешно примењује за одређивање топлотних, еластичних, оптичких и других са њима повезаних физичких особина чврстих тела, танких филмова, сложених вишеслојних структура, електронских направа (на пример у процесу производње електронских кола), биолошких ткива, за дубинску профилометрију, снимање испод површинских структура и макроскопских дефеката различитих узорака, у микро и наноелектроници, али и као терапеутска и допунска дијагностичка метода у медицини, итд. [5][6][7][8][9]. Као и друге ФТ методе, и ФА је индиректна, модел зависна мерна метода. Са математичког становишта, карактеризација материјала овом методом представља инверзни проблем математичке физике. У највећем броју мерења, фотоакустични експериментални сигнал је изобличен на својим крајевима. Дисторзија сигнала настаје већим делом због утицаја електронских компоненти у мерном ланцу, а мањим због утицаја шума [10]. Анализом великог броја извршених мерења на различитим материјалима и упоређивањем са теоријским предвиђањима која детектор, уређај који има улогу да сними експериментални ФА сигнал, сматрају идеалним, долази се до закључка да микрофон као основни део детекторског система у експерименту извршеном на фотоакустичној поставци са хелијом минималне запремине, уноси највише сметњи [10][11]. У овом истраживању остали недоминантни утицаји су занемарени и посматран је само утицај микрофона, јер такав приступ повећава стабилност инверзног решавања ФА проблема.

Теоријско математички модели који описују ФА одзив су нелинеарне функције оптичких, топлотних и еластичних својстава узорка и његовог окружења, побуђеног ласерским зрачењем. Такође, процеси који се дешавају унутар микрофона су нелинеарни. На основу овога, може се закључити да електрични сигнал на излазу микрофона нелинеарно зависи не само од својстава узорка већ и од преносне функције микрофона. Према томе, физички параметри фотоакустичног одзива су нелинеарно зависни, са често недоступним и непознатим свим карактеристикама претварања

снимане величине у електрични сигнал. Овај сигнал се даље користи за карактеризацију узорка. Карактеризација, без претходне корекције сигнала или сужења искоришћеног опсега учестаности неће дати егзактне резултате, који су потребни како за фундаментална научна истраживања тако и за примену у индустрији. Корекција сигнала доприноси коришћењу целог мерног опсега фреквенција, што значајно доприноси једноставности и тачности извршене карактеризације.

Процедура корекције сигнала има неколико корака како би се из снимљеног сигнала издвојио користан сигнал који потиче само од испитиваног узорка. У првом кораку, током аквизиције података, евентуално присутни шум је измерен и његов утицај је отклоњен, што ће касније бити детаљније објашњено. Остаје проблем калибрације мерења. Преносна карактеристика микрофона, $H(f) = A(f)e^{j\varphi(f)}$, као презентација фреквентног одзива микрофона, где је $A(f)$ амплитудска карактеристика и $\varphi(f)$ фазна карактеристика микрофона, а коју дају произвођачи микрофона није потпуна. Амплитудска карактеристика микрофона $A(f)$, дата у спецификацијама произвођача није довољно прецизна, док фазна карактеристика, $\varphi(f)$, углавном не постоји. Такође, произвођачи не узимају у обзир геометријске карактеристике микрофонске шупљине, а које су веома важне за фреквентну, фотоакустичну ћелију минималне запремине која се користи као експериментална поставка и у којем улогу фотоакустичне ћелије игра микрофонска шупљина. Додатан проблем је што два идентична микрофона не постоје у пракси. Због свега наведеног официјелни приручници произвођача се не могу користити за прецизно дефинисање преносне карактеристике микрофона, а која је неопходна за елиминисање утицаја микрофона на снимљени ФА сигнал. Такође, у литератури [12][13] се могу пронаћи различите методе калибрације конвенционалних кондензаторских микрофона, али већина захтева геометријске и механичке карактеристике микрофона, под условом да су познате.

На основу свега до сада реченог, може се закључити да је утицај детектора сложен и измиче уобичајеним начинима диференцијалне калибрације и нормирања на референтни узорак. Домен и начин на који утиче детекторски систем је непознат.

На основу мерења извршених на различитим материјалима (са различитим физичким својствима) и са детекторима различитих параметара, у литератури се најчешће приказују резултати са одбаченим нискофреквентним и високофреквентним деловима кривих у којима је изражен утицај детектора [14][15], у сврху поузданог и

тачног одређивања карактеристика узорка. Тако, фотоакустична мерења не могу да обухвате цео чујни опсег. Мерни домени снимљеног одзива који се најчешће користе су, на пример, од 50 Hz до 2 kHz или од 100 Hz до 800 Hz, итд. На тај начин се смањује потенцијал извршених мерења за одређивање већег броја својстава материјала једним мерењем, јер се одбацује део мерног опсега у коме се меша утицај неких својстава материјала и детектора, а врло често се смањује и тачност добијања одређених својстава. Уколико је потребно проширити мерни опсег, потребно је извршити фотоакустична мерења са неколико микрофона. Коришћење тако добијених резултата захтева калибрацију сваког мерења и потом обједињавање резултата мерења са различитим микрофонима. Такве процедуре су временски захтевне, подложне грешкама и изискују знатну енергију.

Потребан је нови приступ у калибрацији мерне методе [16][17][18]. То значи да је за обраду експерименталних резултата мерења са циљем карактеризације разноврсних материјала, структура и направа, веома битно развити методу која ће препознати опсег утицаја разноврсних детектора, образац њихових утицаја и одлуку о начину раздвајања утицаја детектора од утицаја својстава материјала у мерном опсегу.

Обзиром да дубоко учење (енг. deep learning) може са високим степеном поузданости и тачности да апроксимира било које нелинеарно пресликавање и на тај начин препозна и створи образац утицаја појединачних параметара на користан сигнал реално је очекивати да развој и примена вишеслојних неуронских мрежа у фотоакустици и свим сличним модел-зависним методама код којих се користе детектори широке намене омогући калибрацију методе.

Докторска дисертација истражује нову методологију за калибрацију мерне методе уз очување основних захтева ФА експеримента дефинисаних од стране експерата у поузданости и прецизности мерења, уз анализу могућности повећања брзине обраде резултата мерења и поједностављења поступка мерења, одговарајући на следећа питања:

- Да ли се алгоритми машинског учења могу искористити за препознавање утицаја мерног система на експериментални сигнал уз постизање задовољавајуће тачности и прецизности мерења?
- Да ли се експертско знање може комбиновати са алгоритмима машинског учења?

- Да ли се оптимизацијом примењених алгоритама (подешавањем параметара и хиперпараметара модела и редукцијом димензија улазног вектора) може повећати брзина обраде резултата мерења и поједноставити сам поступак мерења?

Резултати истраживања представљеног у овој докторској дисертацији дати у поглављима 5, 6 и 7 представљају одговоре на постављена питања и доказ да су задовољени постављени захтеви ФА експеримента.

1.2 Циљеви

Циљеви овог истраживања усмерени су на примену машинског учења у оквирима елиминације изобличења експерименталног сигнала услед утицаја мерног система, а као студија случаја користи се уско стручну област, ФА.

Први циљ је креирање програмског оквира (енг. framework) заснованог на алгоритмима машинског учења за аутоматску обраду резултата ФА мерења: претпроцесирање (припрема експерименталног сигнала), класификација типа коришћеног детектора и предикција карактеристичних параметара детектора.

Други циљ произилази из првог и представља практичну примену креиране методологије, тј. развој модела за аутокорекцију ФА сигнала и модела за калибрацију мерења, чији је улаз изобличени ФА одзив, а излаз “прави” сигнал који потиче само од побуђеног, испитиваног узорка.

Обучавање је спроведено над симулираним резултатима ФА мерења, а тестирање и на симулираним и на реалним експерименталним резултатима добијеним у сарадњи са колегама из Института за нуклеарне науке “Винча” и Института за физику у Земуну.

1.3 Научни доприноси

Значај овог истраживања је развој методологије, засноване на алгоритмима машинског учења, за унапређење мерне методе за коју постоји теоријско-математички модел. Развијен је програмски оквир, заснован на неуронским мрежама, за добијање

“правог” експерименталног сигнала, који потиче само од испитиваног узорка, елиминисањем утицаја мерног ланца на користан сигнал, односно аутокорекцију сигнала код фотоакустичне трасмисионе мерне методе са ћелијом минималне запремине. Применом ове методологије проширује се корисни мерни опсег и повећава потенцијал експерименталне технике у одређивању већег броја својстава материјала једним мерењем, тачност и поузданост експерименталне технике расте, док време обраде резултата мерења се смањује. Конкурентност експерименталне технике, у односу на сличне методе, знатно се повећава.

Аутокорекција сигнала би могла бити први корак у моделовању интелигентног инструмента који би могао да решава комплексне проблеме ослањајући се на учење, резонување и самокорекцију. Интелигентни уређаји садрже софтвер који екстрахује знање из података и претходне употребе, са циљем да побољшају своје понашање. Програмски оквир описан у овој докторској дисертацији би могао бити део тог софтвера.

1.4 Полазне хипотезе

Централна хипотеза докторске дисертације је - алгоритми машинског учења, као што су вишеслојне неуронске мреже (енг. Artificial neural networks, ANN) и анализа главних компонената (енг. Principal Component Analysis - PCA), ће показати добра својства као потенцијалне методе за препознавање утицаја мерног ланца на користан сигнал, као и на проналажење оптималног модела.

1.5 Методе истраживања

Приликом иницијалне фазе истраживања примењене су квалитативне методе и теоријске методе. За анализу литературе се користе квалитативне и квантитативне методе. Практична реализација је извршена експерименталним и методама симулације. Алгоритми су развијени методама дизајна и композиције. Упоредивање резултата се спроводи статистичким, компаративним и квалитативним методама.

1.6 Организација докторске дисертације

Поглавље 2 представља кратак осврт на студију случаја у овом истраживању, ФА као модел зависну технику мерења. Дат је комплетан теоријско-математички модел ФА одзива, који представља основу за развој софтвера за генерисање података који се користе у овом истраживању. Описан је тренд примене неуронских мрежа у ФА. Комплетна процедура за генерисање података и приказ скупа података дати су на крају поглавља.

Поглавље 3 уводи читаоца ове докторске дисертације у теорију вишеслојних неуронских мрежа са прегледом алгоритама и поступака за оптимизацију и регуларизацију процеса учења неуронских мрежа.

Поглавље 4 даје кратак приказ алгорита за редукцију димензија скупа података, анализа главних компоненти.

Наредна поглавља: 5, 6 и 7 представљају резултате овог истраживања.

Поглавље 5 објашњава поступак развоја регресионог модела за предикцију карактеристичних параметара микрофона, као детектора у ФА експерименту и поступак развоја класификационог модела за предикцију типа микрофона као оптималних модела у односу на постављене захтеве ФА експеримента. Дат је приказ извршених тестова који доказују задовољавајуће добре перформансе модела.

Поглавље 6 представља две методе, методу за аутокорекцију изобличеног експерименталног сигнала у ”прави” сигнал који потиче само од испитиваног узорка и методе за калибрацију мерења, као практичне примене развијеног регресионог и класификационог модела. Дато је објашњење поступка и приказ резултата примене метода на реалним експерименталним сигнаlima.

У поглављу 7 је предложено поједностављење поступка мерења, смањењем броја мерења у експерименту на основу анализе редукције димензија улазног вектора регресионог и класификационог модела, тако да се очува прецизност и поузданост експеримента и рад у реалном времену. Дискусија избора мерних тачака поткрепљена је експертским знањем.

Поглавље 8 даје закључак истраживања и правце даљег рада.

2 Фотоакустика – пример модел зависне технике мерења

Неколико последњих деценија интензивно се усавршавају старе и развијају нове методе и инструменти за карактеризацију материјала и то из два разлога. Један је примена материјала у којој је неопходно познавати његова физичка својства, а други је инжењеринг особина материјала и формирање нових структура које се захтевају у различитим применама, од наноелектронике па до биомедицинских импланта [19]. Међу новијим методама, ФА и друге ФТ методе заузимају све значајније место због својих многобројних предности налазећи све ширу примену у различитим областима науке, технике, медицине, електронике, итд. [15][19][20][21][22][23]. Предности ФТ техника у односу на остале методе сличне намене су вишеструке, а пре свега то су:

- недеструктивна и неинвазивна природа ових метода,
- једноставност експерименталних поставки,
- могућност употребе под различитим експерименталним условима,
- лака припрема узорак – припреме су мале или никакве зависно од методе која се користи,
- дубине до којих ове методе могу да допру су променљиве,
- имају велики опсег димензија које могу да сниме,
- већина ФТ метода дозвољава безконтактна мерења,
- дозвољавају мерења у реалном времену,
- дозвољавају *in vivo* мерења.

ФА је прва ФТ метода коју је поставио Алан Розенцвајг (*Allan Rosenzweig*) 1973. године [4]. Као и све ФТ методе и ФА је заснована на ФТ ефекту. Енергија електромагнетског зрачења, или општије енергија снопова честица (фотона, електрона, протона итд.) апсорбује се практично у свим материјалима, било да су у гасовитом, течном или чврстом стању. Процес апсорпције је врло селективно побуђивање електронских стања атома или молекула, које је праћено нерадијативним деекситационим и релаксационим прелазима, који као резултат имају генерацију топлотних таласа. Такав процес побуђивања топлоте назива се ФТ ефектом. ФТ ефекат је, дакле, појава периодичног загревања материјала који је апсорбовао електромагнетно зрачење или енергију побудног честичног снопа. Топлота која је

генерисана на овај начин, доводи до поремећаја термодинамичког стања материјала. То значи да долази до промене температуре, притиска и запремине. Настали поремећај се даље шири унутар материјала и ближег окружења стварајући на тај начин низ ФТ феномена који се могу мерити. Услед простирања топлоте унутар узорка долази до:

- промене температуре на површини материјала,
- деформације и помераја површине узорка,
- појаве градијента оптичког индекса преламања у узорку и ефекта термалног сочива,
- појаве градијента оптичког индекса преламања у ближој, гасовитој околини узорка и ефекта фатаморгане (енг. mirage effect),
- промене температуре ваздуха тик уз површину загрејаног узорка,
- вибрације површине узорка,
- промене рефлексије и апсорпције,
- појаве секундарног инфрацрвеног зрачења.

Све ове секундарне појаве могу се користити за испитивање и мерење разних карактеристика материјала. Осмишљавањем различитих детекционих система и снимањем неког од набројаних феномена успоставља се конкретна ФТ метода. Разлике у методама се односе на одабир детекционих механизма. Детекциони механизми могу да буду разноврсни: термистори, микрофони, пиезоелектрици, пироелектрици, фотодиоде, ултразвук, инфрацрвени детектори, оптички детектори, који поред побудног електромагнетног снопа, користе и додатни детекторски (мерни) сноп са разноврсним оптичким детекторима [7][24][25].

ФА методе снимају промене притиска и појаве акустичних таласа који настају услед периодичног или импулсног загревања узорка. Могу да се детектују коришћењем микрофона или пиезоелектричног сензора за снимање акустичних таласа. Пренос топлоте генерисане путем апсорпције модулисаног снопа енергије, врши се кроз два механизма. Први механизам је директно спрезање топлотне енергије са вибрационим модовима самог материјала. Ово је термоеластични процес, који је у основи недисипативан и одвија се брзином простирања звука кроз испитивани узорак. Други механизам преноса топлоте је простирање топлотних таласа. Ово је дисипативан процес у коме су атоми, јони и молекули вибрационо побуђени. Део енергије, пренет на овај начин, одређен је динамичким топлотним својствима узорка

и његовог ближег окружења [7][15]. Из ова два механизма преноса топлоте непосредно произилазе и две различите групе ФА метода:

- ФА пиезоелектричне методе, које мере акустични сигнал узрокован оптички индукованим температурским варијацијама у узорку,
- ФА гас-микрофонске методе, засноване на мерењу промене притиска у околном флуиду топлотно спрегнутом са побуђеним узорком помоћу микрофона.

Гас-микрофонска мерна техника подразумева да се узорак налази у затвореној комори, која се назива ФА ћелијом. Поред ње, постоји и низ других делова, али се може узети да су основни: извор зрачења (енергетски сноп), модулатор, ФА ћелија, акустични детектор и систем за обраду сигнала [15][26].

Као извор оптичке побуде најчешће се користе ласери различитих снага реда величине десетак mW и ЛЕД диоде. Постоје два основна разлога зашто се ласерско зрачење највише користи. Први разлог је висока спектрална чистоћа и велика снага. За побуду узорка са датим коефицијентом апсорпције, температураске промене су пропорционалне оптичкој снази (у случају континуалне побуде), или енергији (у случају импулсне побуде). У општем случају, сигнал добијен ФТ методама, пропорционалан је температурским варијацијама, односно динамичкој промени температуре. Према томе, што је већа снага или енергија, добија се већи резултујући мерени сигнал, а ласери могу да обезбеде велике снаге или импулсне енергије. Други разлог је просторна кохеренција. Температурске варијације нису једино пропорционалне оптичкој снази или енергији, већ су и инверзно пропорционалне запремини која апсорбује светлост, пошто се топлотна капацитивност мења у односу на количину супстанце. Особина просторне кохеренције ласерског извора омогућава да светлост буде фокусирана на малу, дифракционо ограничену запремину. Мале запремине коришћене у ФТ методама повећавају амплитутски сигнал, што омогућава да се ФТ методе користе за анализу узорака са малом запремином и микроскопску анализу хетерогених материјала .


Извори зрачења могу да буду и у импулсном и у континуалном режиму. Извори који раде у континуалном режиму модулишу се по интензитету, било механичким чопером било струјно-напонском контролом напајања. На овај начин добија се побуа у облику неке периодичне функције, или поворке импулса и пауза приближно истог трајања, или простопериодичне функције. Модулисани ласерски зрак усмерава се на

ФА ћелију са узорком. Постоји велики број различитих типова ФА ћелија. Без обзира на разноликост конструкција, све ћелије се састоје из тела ћелије и акустичног детектора. Тело ћелије обезбеђује одговарајућу затворену акустичну запремину која може да буде резонантна или нерезонантна. Постоји више видова конфигурације ФА ћелије:

- рефлексиона конфигурација - конфигурација ћелије у којој су оптичка побуда и микрофон смештени са исте стране узорка,
- трансмисиона конфигурација – конфигурација ћелије у којој су оптичка побуда и микрофон смештени са различитих страна узорка, и
- конфигурација ћелије у облику Хелмхолцовог резонатора - користи се у случају две или више спојених комора.

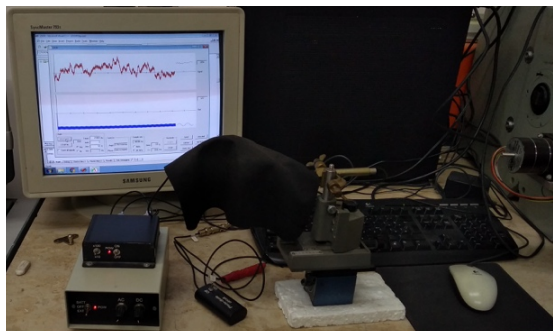
Детекција ФА одзива врши се разним врстама електрет микрофона, чија је скица са основним деловима приказана на слици 1. Основна разлика међу врстама електретских микрофона (а самим тим и цене) је у материјалу од кога је направљена електретска дијафрагма [15][26].

Измерени одзив који даје ћелија са трансмисионом конфигурацијом је слабији у односу на одзив који даје рефлексиона конфигурација. У потрази за повећањем мерног сигнала у случају трансмисионе ћелије настала је ћелија минималне запремине [27]. У литератури [28] може да се нађе и под називом конфигурација са отвореном ћелијом (енг. open cell configuration), слика 2. У случају овог типа ћелије, узорак се поставља директно на врх микрофона на место заштитног покривача, тако да сама микрофонска шупљина постаје тело ћелије.



Слика 1: Електретски микрофон [29]

Микрофон региструје ФА сигнал, односно амплитуду и фазу сигнала на свакој учестаности модулације захваљујући фазно-фреквентном детектору (енг. *lock-in amplifier*). То је аналогни електрични сигнал исте учестаности као што је учестаност модулације побудног електромагнетског зрака.



Слика 2: Експериментална поставка [29][30] (Институт за физику у Земуну)

ФА сигнал из ћелије води се у електронски мерно-контролни систем за обраду сигнала. Систем за обраду сигнала подразумева један сложени електронски део ФА мерног уређаја који врши издвајање, појачавање и даљу обраду добијеног електричног сигнала из ФА ћелије и састоји се од фазно-фреквентног детектора и рачунара [15].

2.1 Математички модел фотоакустичног одзива

Мерени ФТ сигнал носи информацију о геометријским, оптичким, термичким, еластичним, електронским, структурним и свим другим са њима повезаним физичким својствима испитиваних материјала са једне стране, и интензитету и модулационој фреквенцији упадног оптичког зрачења са друге стране. ФА спада у модел-зависне методе, што значи да се овом мерном техником, као и свим другим ФТ методама, не мере испитиване особине директно, већ индиректно решавањем инверзног проблема. Инверзни проблем у ФА представља процес израчунавања узрочних фактора као што су топлотна дифузивност, термоеластична и плазмаеластична својства на основу добијених резултата експеримента као последице. Инверзни проблем обухвата формирање математичко-симулационог модела и његово решавање. Одређивање физичких својстава испитиване структуре и решавање инверзног проблема одвија се, значи, у два корака:

1. развијање теоријско математичко симулационих модела који добро описују физичке процесе који повезују мерени ФТ одзив са оптичком побудом, што називамо директним решавањем инверзног проблема, и
2. инверзно решавање инверзног проблема, односно решавање математичко симулационог модела по непознатим параметрима.

Инверзно решавање проблема, према томе, представља одређивање физичких својстава узорка на основу измереног ФТ одзива, развијеног теоријско математичког модела и добро познатих и унапред подешених улазних параметара. У улазне параметре спадају интензитет и модулациона фреквенција упадног оптичког зрачења [26][31].

Математички модели који описују ФТ одзив су у својој суштини нелинеарне једначине са више непознатих параметара које немају једнозначно решење. Они представљају нестабилне системе, јер мале промене параметара модела доводе до великих промена симулираних одзива, а самим тим јачи је утицај експерименталног шума на поузданост мерења, односно одређивање физичких параметара из тих мерења (појава артифаката који немају физичку природу приликом реконструкције слике, на пример). Овакви проблеми математичке физике називају се лоше постављеним проблемима.

Код решавања инверзног проблема требало би узети у обзир још једно ограничење, а то је ограничење које поставља сам експеримент. Опсег мерења одзива никад није бесконачан, као што је у математичком решавању инверзних проблема, већ је ограничен техничким карактеристикама детекторског система. Значи да инверзно решавање проблема мора да се одвија у ограниченом домену фреквенција, у коме су одређени физички феномени доминантни. Ово повећава значај развоја симулационо математичких модела, зато што природа мерења поставља контрадикторне захтеве. Са једне стране, потребно је што боље описати све физичке процесе (или што је могуће већи број физичких процеса), а са друге стране потребно је избацити све недоминантне утицаје, јер ако се они узму у обзир смањује се тачност инверзног решавања, а самим тим и тачност и прецизност одређивања физичких својстава. Развој директних теоријских модела је веома битан сегмент како због доброг описивања физичких процеса, тако и због одређивања доминантних ефеката у доступном мерном опсегу анализом добијених модела. У првом кораку потребно је узети све утицаје у обзир, у другом је потребно одредити доминантне утицаје, а у трећем треба утврдити

да ли су уведене апроксимације добре, да ли треба увести још неке апроксимације или избећи неке од уведених, на основу поређења са експериментом.

Инверзно решавање инверзних проблема је доста проучавано и установљене су многе методе подешавања параметара и регуларизације. Неке инверзне ФА процедуре користе нормализацију података како би се са једне стране избегли електронски одзиви инструмента (само у случају ако су ти одзиви линеарни), а са друге избациле пропорционалне константе које су термофизички суштински небитне, све у циљу смањења броја непознатих променљивих величина, па самим тим и смањење утицаја експерименталног ланца.

Често коришћена метода приликом карактеризације материјала је метода фитовања на амплитудске и фазне карактеристике добијене мерењем, у којој се својства узорка процењују користећи криве снимљеног фототермалног одзива и теоријско-симулационог модела.

Најновија истраживања оптималних техника за инверзно решавање указују на то да би вештачка интелигенција (примена неуронских мрежа, генетских алгоритама или неких других метода) могла да омогући значајно краће време процене физичких својстава узорка (процена параметара у реалном времену), а такође и повећање тачности процене параметара модела.

Развој оптималних техника за решавање инверзног ФТ проблема је значајно како за карактеризацију разноврсних материјала са задовољавајућом тачношћу, тако и за унапређење метода ФТ осликавања (имицинга) разноврсних материјала: од макромолекулских наноструктура, преко наноелектронских и нанофотонских направа, све до биолошких ткива.

Фотоакустични одзив, у случају трансмисионе конфигурације је сума две доминантне компоненте термопроводне и термоеластичне компоненте. Термопроводна компонента настаје услед периодичног протока топлоте између узорка и танког слоја околног ваздуха (ефекат топлотног клипа) и термоеластичне компоненте која настаје услед термоеластичног савијања облоге (ефекат бубња) [25][32][33][34][35][36][37][38].

У експериментима описаним у овој докторској дисертацији користе се двослојне структуре. Први слој је црни премаз, а други слој је испитивани узорак. Теоријско-математички модел ФА одзива за двослојне системе дат је следећим једначинама [26][29]:

$$\widetilde{\delta p_{total}} = \tilde{p}_{th} + \tilde{p}_{te} \quad (1)$$

$$\tilde{p}_{te} = \frac{3\gamma P_0 R^4}{R_c^2 l_g (l_1 + l_2)^3} \quad (2)$$

$$\begin{aligned} & \times \left\{ \frac{\alpha_{1T}}{\tilde{\sigma}_1^2 \tilde{I}} \left[\left[\frac{\tilde{\sigma}_1(l_1 - l_2)}{2} \sinh \tilde{a} - \cosh \tilde{a} + 1 \right] \cdot \left[-\sinh \tilde{b} \cdot \tilde{U}_2 + \cosh \tilde{b} \cdot \tilde{z}_{c2} \tilde{U}_5 + \tilde{z}_{c2} \tilde{U}_6 \right] - \right. \\ & \quad \left. - \left[\sinh \tilde{b} \left[-\frac{\tilde{\sigma}_1(l_1 - l_2)}{2} + \frac{\tilde{\sigma}_1(l_1 + l_2)}{2} \cosh \tilde{a} - \sinh \tilde{a} \right] + \right. \right. \\ & \quad \left. \left. + r \cosh \tilde{b} \left[\frac{\tilde{\sigma}_1(l_1 + l_2)}{2} \sinh \tilde{a} - \cosh \tilde{a} + 1 \right] \right] \tilde{z}_{c1} \tilde{U}_4 \right] + \\ & + \frac{\alpha_{2T}}{\tilde{\sigma}_2^2 \tilde{I}} \left[\left[\frac{\tilde{\sigma}_2(l_1 - l_2)}{2} \sinh \tilde{b} + \cosh \tilde{b} - 1 \right] \cdot \left[\tilde{r} \sinh \tilde{a} \cdot \tilde{U}_2 + \tilde{z}_{c2} \tilde{U}_4 + \cosh \tilde{a} \cdot \tilde{z}_{c2} \tilde{U}_3 \right] + \right. \\ & \quad \left. + \left[\tilde{r} \sinh \tilde{a} \left[\frac{\tilde{\sigma}_2(l_1 + l_2)}{2} \cosh \tilde{b} - \frac{\tilde{\sigma}_2(l_1 - l_2)}{2} - \sinh \tilde{b} \right] - \right. \right. \\ & \quad \left. \left. - \cosh \tilde{a} \left[-\frac{\tilde{\sigma}_2(l_1 + l_2)}{2} \sinh \tilde{b} + \cosh \tilde{b} - 1 \right] \right] \cdot \tilde{z}_{c2} \tilde{U}_6 \right] + \\ & \quad + \frac{S_0 \alpha_{1T} \tilde{z}_{c1} \tilde{\sigma}_1}{\sigma_1^2 - \beta_1^2} \left[\frac{l_1 - l_2}{2} e^{-\beta_1 l_1} + \frac{l_1 + l_2}{2} + \frac{1}{\beta_1} e^{-\beta_1 l_1} - \frac{1}{\beta_1} \right] + \\ & \quad \left. + \frac{S_0 \alpha_{2T} \tilde{z}_{c2} \tilde{\sigma}_2}{\sigma_2^2 - \beta_2^2} e^{-\beta_1 l_1} \left[\frac{l_1 - l_2}{2} e^{-\beta_2 l_2} - \frac{l_1 + l_2}{2} + \frac{1}{\beta_2} e^{-\beta_2 l_2} - \frac{1}{\beta_2} \right] \right\} \end{aligned}$$

$$\begin{aligned} \tilde{p}_{th} = & \frac{\gamma P_0 S_0 \sqrt{D_{Tg} D_{T2}}}{l_g T_0 k_2} \cdot \frac{1}{j\omega} \cdot \frac{1 + j\omega\tau_2}{1 + j\omega\tau_g} \cdot \frac{e^{-\beta_1 l_1}}{\tilde{I}} \quad (3) \\ & \left[(\tilde{I} e^{-\beta_2 l_2} - \tilde{r} \sinh \tilde{a}) \tilde{\sigma}_2 + (\tilde{W}_2 e^{-\beta_2 l_2} - \cosh \tilde{a}) \beta_2 \right] \cdot B_2 + \\ & + (\sinh \tilde{a} \cdot \tilde{\sigma}_1 + \cosh \tilde{a} - e^{\beta_1 l_1} \beta_1) \cdot B_1 \end{aligned}$$

где је $\widetilde{\delta p_{total}}$ укупни притисак који се детектује, \tilde{p}_{th} је термопроводна компонента и \tilde{p}_{te} је термоеластична компонента. Параметри који фигуришу у претходним једначинама су:

$$\tilde{\sigma}_i = \sqrt{\frac{j\omega(1 + j\omega\tau_i)}{D_{Ti}}} \quad (4)$$

$$\tilde{z}_{ci} = \frac{\tilde{q}_i}{\tilde{q}_i} = \frac{\sqrt{D_{Ti}}}{k_i} \cdot \sqrt{\frac{1 + j\omega\tau_i}{j\omega}} \quad (5)$$

$$\tilde{B}_1 = \frac{\beta_1}{\tilde{\sigma}_1^2 - \beta_1^2}, \quad \tilde{B}_2 = \frac{\beta_2}{\tilde{\sigma}_2^2 - \beta_2^2} \quad (6)$$

$$\tilde{a} = \tilde{\sigma}_1 l_1, \quad \tilde{b} = \tilde{\sigma}_2 l_2, \quad \tilde{r} = \frac{\tilde{z}_{c2}}{\tilde{z}_{c1}} \quad (7)$$

$$\tilde{I} = \tilde{r} \sinh \tilde{a} \cosh \tilde{b} + \cosh \tilde{a} \sinh \tilde{b} \quad (8)$$

$$\tilde{W}_2 = \tilde{r} \sinh \tilde{a} \sinh \tilde{b} + \cosh \tilde{a} \cosh \tilde{b} \quad (9)$$

$$\tilde{U}_1 = \tilde{z}_{c1} \tilde{\sigma}_1 S_0 \tilde{B}_1 \quad (10)$$

$$\tilde{U}_2 = -\tilde{z}_{c1} \tilde{\sigma}_1 S_0 \tilde{B}_1 e^{-\beta_1 l_1} + \tilde{z}_{c2} \tilde{\sigma}_2 S_1 \tilde{B}_2 \quad (11)$$

$$\tilde{U}_3 = -\tilde{z}_{c2} \tilde{\sigma}_2 S_1 \tilde{B}_2 e^{-\beta_2 l_2} \quad (12)$$

$$\tilde{U}_4 = S_0 \beta_1 B_1 \quad (13)$$

$$\tilde{U}_5 = -S_0 \beta_1 B_1 e^{-\beta_1 l_1} + S_1 \beta_2 B_2 \quad (14)$$

$$\tilde{U}_6 = -S_1 \beta_2 B_2 e^{-\beta_2 l_2} \quad (15)$$

где је, I_0 побудни оптички флуks, k_i представља топлотну проводност [$\text{Wm}^{-1}\text{K}^{-1}$], C_{Pi} је запреминска топлотни капацитет [$\text{Jm}^{-3}\text{K}^{-1}$], D_{Ti} топлотна дифузивност узорка [m^2s^{-1}], β_i је коефицијент абсорпције [m^{-1}], док τ_i је топлотно време релаксације посматраних средина [s] ($i=a,1,2$) што одговара ваздуху, слоју 1 и слоју 2, респективно, и ω је кружна фреквенција ($\omega=2\pi f$), где је f модуациона фреквенција побудног зрачења [s^{-1}]. Даље P_0 је притисак у ћелији, V_0 је запремина ћелије (у случају ћелије минималне запремене V_0 представља запремину шупљине коморе), γ представља однос топлотног капацитета, α_{iT} је коефицијент топлотне експанзије првог и другог слоја респективно и R_c је пречник коморе испред дијафрагме микрофона.

Претходно презентовани модел описује укупни притисак и његове компоненте као ФА одзив у систему двослојног узорка окруженог ваздухом и заснован је на генерализованом моделу топлотне проводности који подразумева ограничену брзину ширења топлоте [39]. Систем описује запреминску абсорпцију побудног оптичког зрака у оба слоја [26][29].

У ФА експерименту са ћелијом минималне запремене, микрофон је фундаментални део детекторског система. Микрофон је акустично-електрични конвертер, али његова трансфер функција у фреквенцијском и временском домену се разликује у зависности од његове конструкције, примењене геометрије и типа мембране. У литератури [10] а то потврђују експерименти, понашање микрофона се описује као филтрирање. На ниским фреквенцијама ($< 1 \text{ kHz}$), електрет микрофони, као микрофони који се најчешће користе у ФА, се уобичајено понашају као електронски високо пропусни филтри, док на високим фреквенцијама ($> 1 \text{ kHz}$) ови микрофони се уобичајено понашају као акустични ниско пропусни филтри.

Утицај мерног ланца, укључујући и микрофон као компоненту која има највећи утицај на дисторзију сигнала, је дат следећим математичким изразима описујући укупну трансфер функцију [16][17][18]:

$$H_1^e(f) = \frac{1}{1 - j \frac{f_1}{f}} \quad (16)$$

$$H_2^e(f) = \frac{1}{1 - j \frac{f_2}{f}} \quad (17)$$

$$H_{total}^a(f) = \frac{f_3^2}{f_3^2 - f^2 + j f f_3 \xi_3} + \frac{f_4^2}{f_4^2 - f^2 + j f f_4 \xi_4} \quad (18)$$

$$H_{mic}(f) = H_2^e(f) H_{total}^a(f) \quad (19)$$

$$H_{total}(f) = H_1^e(f) H_{mic}(f) \quad (20)$$


У претходним једначинама, $H_1^e(f)$ представља електронске карактеристике осталих инструмената мерног ланца, у првом реду то је звучна карта прилагођена да ради као фазно-фреквентни појачавач, и f_1 је карактеристична фреквенција која описује овај систем. На основу експерименталног искуства узето је да је ова фреквенција константна. $H_2^e(f)$ и $H_{total}^a(f)$ представљају електронске и акустичне карактеристике микрофона. f_2 одговара карактеристичној фреквенцији електронског нискофреквентног филтра, а f_3 и f_4 карактеристичним фреквенцијама акустичног нископропусног филтра микрофона. ξ_3 и ξ_4 су реципрочне вредности фактора доброте или две вредности фактора пригушења, параметри који описују висину резонанце у микрофонској шупљини. Производ ове две компоненте, $H_2^e(f)$ и $H_{total}^a(f)$ представља одзив микрофона.

Последице су, одзив микрофона у фреквентном домену је изобличен и по амплитуди и по фази, нарочито на крајевима фреквентног опсега. Различити типови микрофона имају различите трансфер функције, међутим најчешће је случај да и трансфер функције два микрофона истог типа су различите јер два идентична микрофона не постоје у пракси.


Теоријско-математички модел за укупни ФА сигнал снимљен експерименталном поставком ФА ћелије минималне запремине представља производ укупног притиска и укупне трансфер функције:

$$S(f) = \sigma p_{total}(f) H_{total}(f) \quad (21)$$

На основу ове једначине добијене су нумеричке симулације експеримента а тиме и базе података. Амплитудска и фазна карактеристика симулираног ФА одзива дата је на сликама 3 и 4 респективно.



Слика 3: Амплитудска карактеристика теоријско-математички симулираног ФА одзива у функцији модулационе фреквенције, 2 250 кривих [16]



Слика 4: Фазна карактеристика теоријско-математички симулираног ФА одзива у функцији модулационе фреквенције, 2 250 кривих [16]

2.2 Процедура корекције сигнала

Добро је позната чињеница да сваки резултат мерења у фотоакустици $Y(f)$ може да се изрази као збир компоненти сигнала $S(f)$ и шума $N(f)$ [10][40]:

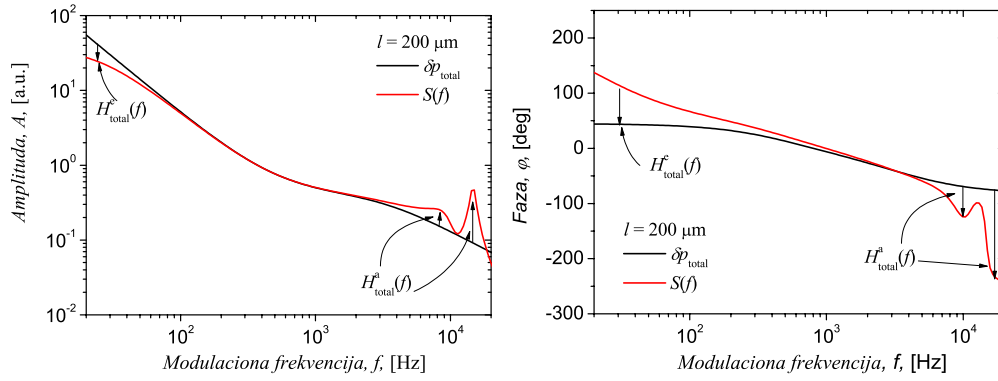
$$Y(f) = S(f) + N(f) \quad (22)$$

Овде је $N(f)$ дефинисано једначином [10] [40]:

$$N(f) = N_{FN}(f) + N_{CSD}(f) \quad (23)$$

где је $N_{FN}(f)$ прави шум, а $N_{CSD}(f)$ кохерентна сметња. Сигнал $S(f)$, тзв. изобличени сигнал, је дефинисан у претходном поглављу.

Главни циљ у сваком експерименту је да се добије $\delta p_{total}(f)$ и из њега извуку термички и механички параметри узорка. То се може постићи применом процедуре корекције сигнала дате у следећим корацима [10][40][41]: 1) пронаћи експерименталне услове који ће омогућити највећи однос сигнал-шум и тако занемарити утицај $N_{FN}(f)$; 2) измерити и ако треба одузети $N_{CSD}(f)$ од $Y(f)$ сигнала и добити $S(f)$ помоћу једначине (4); 3) одредити електро-акустичне карактеристике микрофона и фазно-фреквентног појачавача помоћу једначина (7) и (8); 4) кориговати $S(f)$ уклањањем свих откривених одступања у $H_{total}(f)$, тежећи добијању "правог" ФА сигнала. Могу се симулирати такви експериментални услови под којима сматрамо да су $N_{FN}(f)$ и $N_{CSD}(f)$ занемарљиво мали. Претпоставићемо да су непознате микрофонске карактеристике најодговорније за „кривљење“ сигнала, а да нам је утицај звучне картице познат, слика 5. Управо на овом кораку процедуре корекције је потребна вештачка интелигенција: неопходно је пронаћи методу која ће на основу препознавања $S(f)$ поуздано, прецизно и у реалном времену да одреди електронске и акустичке карактеристике микрофона како би успели да их уклонимо и дођемо до $\delta p_{total}(f)$, [16][17][18].



Слика 5: Симулиране амплитуде а) A и фазе б) φ укупног ФА $\delta p_{total}(f)$ (црна линија) и изобличеног експерименталног $S(f)$ сигнала (црвена линија) у функцији фреквенције модулације f . Електронски $H_{total}^e(f) = H_1^e(f)H_2^e(f)$ и акустични $H_{total}^a(f)$ одзив експеримента, [16]

2.3 Неуронске мреже у фотоакустици

Неуронске мреже су дуго присутне у ФА и другим модел зависним мерним техникама које се развијају за научна истраживања и биомедицинску дијагностику.

У раду [42] једноставна (енг. shallow) неуронска мрежа је коришћена за реконструкцију оптичког профила оптички градијентних материјала на основу фреквенције, амплитуде и фазе измереног фототермалног одзива.

Једноставна неуронска мрежа са пропацијом сигнала унапред у раду [6] дизајнирана је за симултано одређивање основних физичких параметара узорка: топлотне дифузивности, топлотног коефицијента експанзије и дебљине, користећи трансмисиони фреквенцијски модулисан ФА одзив као улазне податке.

Последњих година примери примене дубоког учења у ФА су све бројнији.

У раду [43] презентована је примена дубоких конволуцијских мрежа за отклањање шума у ФА препознавању слика. ФА имиџинг (енг. imaging) представља методу за визуализацију тачкастих мета, а тиме детекцију анатомских облика или металних импланта у људском телу, што даје значајну примену у откривању канцера, мониторингу протока крвних судова, вођеним операцијама и др. Трансмисија ласерског зрака у присуству високо ехогених структура има за последицу стварање рефлектованог ФА сигнала који се може третирати као шум. Дубоке конволуцијске мреже су се показале као добро решење које са високом тачношћу лоцира и класификује корисне изворе од других творевина.

Окружење засновано на дубоком учењу за реконструкцију слике у ФА томографији представљено је у раду [44]. Приказана је обрада ретких података у ФА томографији (ФАТ). Развијен је директан и високо ефикасан алгоритам за реконструкцију са дубоком конволуцијском неуронском мрежом (CNN), чије се тежине прилагођавају пре стварне реконструкције слике на основу тренинг скупа података. Нумерички резултати показују да предложени приступ дубоког учења реконструише слике са квалитетом који је упоредив са најсавременијим итеративним приступима за ФАТ.

У [45] раду аутори користе вишеслојну неуронску мрежу за симултано препознавање просторног профила ласерског зрака и одређивање времена релаксације молекула гаса у реалном времену код мониторинга гасова који су у траговима присутни у атмосфери. Просторни профил ласерског зрака је варијабилан па његово симултано препознавање значајно доприноси прецизности фотоакустичног експеримента, јер ће се кориговати настале варијације. Исти аутори у раду [46] иду корак даље, па MLP (енг. Multilayer Perceptron) са пропагацијом унапред осим што препознаје просторни профил ласерског зрачења одређује и густину енергије ласерског зрачења, што доприноси додатној прецизности у мерењу различитих концентрација полутаната у широком опсегу вредности у урбаним и руралним срединама.

У публикацији [47] као улазни параметри вишеслојне неуронске мреже узети су: топлотна проводност (k_s), топлотна дифузивност (D), линеарни коефицијент топлотног ширења (α_T), дебљина узорка (l_s) и фреквенција модулације упадног зрачења. Модел са великим успехом на обучавајућем скупу од 10 000 симулираних узорака опонаша вредност $\frac{\alpha_T}{k_s}$ уз грешку процене 0.71%.

Неуронске мреже још увек нису примењене у препознавању утицаја процеса у детектору на податке који се даље користе за карактеризацију. Овај утицај не може да се схвати као шум, већ као систематски утицај који зависи од детектора, а не постоје два иста детектора у пракси, тако да његово препознавање представља својеврсну калибрацију мерне поставке у којој се због потребе за већим појачањем или другачијим опсегом мерења код различитих материјала и структура, или због отказивања рада постојећег детектора у серији мерења истог узорка, понекад мењају детектори. Таква калибрација је неопходан корак за даље инверзно решавање

проблема, односно одређивање карактеристика испитиваног објекта са тачношћу коју захтевају фундаментална истраживања, а која је значајно већа од захтева за тачношћу коју изискује примена одређених материјала и структура или биомедицинска дијагностика. Очекивани исходи истраживања приказаног у овој докторској дисертацији су да ће методологија заснована на неуронским мрежама показати већу прецизност и поузданост, као и рад у реалном времену од претходно коришћених метода нормализације података и фитовања објашњених у поглављу 2.1.

2.4 Подаци

Симулирани подаци се последњих година често користе у проблемима машинског учења, у случајевима када је приступ реалним подацима из неког разлога лимитиран [48]. У представљеном истраживању разлози ограничења су - велику колекцију података је веома тешко сакупити и реални експериментални подаци крију веома озбиљан проблем утицаја мерног система на мерене вредности параметара. С обзиром да неуронске мреже захтевају велике скупове података из разлога боље ефикасности процеса учења, симулирани подаци су представљали решење [16][17][18].

На основу представљеног теоријско-математичког модела развијен је софтвер у програмском окружењу Matlab за креирање симулираних експерименталних вредности или нумеричких експеримената, тј. за дизајнирање базе података. У програмски код уносе се теоријски подаци микрофона и узорка материјала који се испитује. У овом истраживању анализирани су алуминијум и полиамид Табела 1. Коришћени су комерцијални микрофони веома чести у ФА експериментима: ЕСМ30В, ЕСМ60 и WM66. Међутим, за процедуру корекције врло је важан још један тип микрофона, тзв. идеални микрофон (ИМ). Микрофон идеалног понашања је онај микрофон који има скоро раван ФА одзив, што указује да је мерни ланац подједнако осетљив на целом фреквентном опсегу и да сигнал није изобличен. За такав микрофон није потребна процедура корекције, па он може послужити као референца за изобличене одзиве. Из тог разлога идеални микрофон је четврта класа микрофона у креираној бази података.

Коришћени су узорци од алуминијума и ласерски синтерованог полиамида, РА12 на које је нанесен танак слој црне боје. Дебљина узорка од алуминијума је 197 μm , дебљина узорка РА12 износи 320 μm , док је радијус оба узорка 10 mm. Слој црне

боје је дебљине 2 μm . Топлотни, оптички и параметри топлотне меморије дати су у Табели 1.

Табела 1: Теоријске вредности за узорак од алуминијума и ласерски синтерованог полиамида PA12

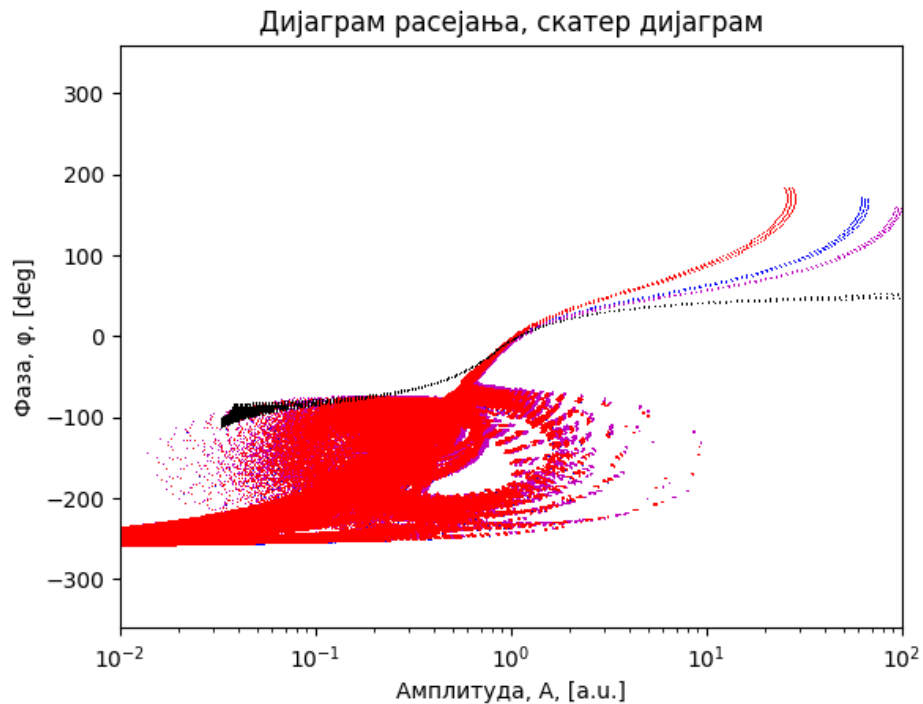
	Боја	Алуминијум	Полиамид PA12
Топлотна проводност [$\text{Wm}^{-1}\text{K}^{-1}$]	70	210	0.23
Топлотна дифузивност [m^2s^{-1}]	$2.5 \cdot 10^{-5}$	$8.6 \cdot 10^{-5}$	$1.85 \cdot 10^{-7}$
Топлотно време релаксације [s]	10^{-4}	10^{-12}	10^{-4}
Коефицијент апсорпције [m^{-1}]	10^8	$145 \cdot 10^6$	10^5

За веродостојност симулираних експерименталних вредности реалним експерименталним вредностима кључни фактор је експертско знање. На основу експерименталног искуства узета је у обзир различита стабилност карактеристичних параметара микрофона, где се под стабилности овде подразумева поновљивост у мерењима. У складу са тим различити опсеги вредности су узети за различите параметре. Фреквенција f_2 се понаша као најстабилнији параметар јер потиче од RC карактеристика микрофона, па су три вредности узете за тренирање мреже: централна вредност $f_{20} = 25 \text{ Hz}$ за микрофон ЕСМ30В и две вредности које су $\pm 5\%$ централне вредности (23.75 Hz и 26.25 Hz). Аналогно за ЕСМ60, узете су вредности: 14.25 Hz, 15 Hz and 15.75 Hz, за WM66 вредности су: 61.75 Hz, 65 Hz и 68.25 Hz, док за ИМ вредности су: 0.475 Hz, 0.5 Hz и 0.525 Hz. Фреквенције f_3 и f_4 више зависе од експерименталних услова него f_2 , па су тиме мање стабилне од f_2 . Претпостављено је да је 10 вредности еквидистантно распоређених у одговарајућем опсегу довољно за опис експерименталног понашања ових параметара. f_3 је узето у опсегу 8 930-9 866 Hz, а f_4 је узето у опсегу 13 965-15 432 Hz за микрофон ЕСМ30В. Микрофони ЕСМ60 и WM66, имају исте опсеге за фреквенције f_3 и f_4 , 7 980-8 817 Hz и 13 015-14 383 Hz респективно. За ИМ f_3 је у опсегу 190 000-209 998 Hz, док је f_4 у опсегу 285 000-314 997 Hz респективно.

Најнестабилнији параметри су фактори пригушења филтра пропусника ниских учестаности другог реда ξ_3 и ξ_4 , јер веома зависе од експерименталних услова. Опсези вредности за ξ_3 и ξ_4 су одређени на основу појављивања пика у амплитудској карактеристици филтра другог реда. Критична вредност фактора добротe за гранични случај екстремног пригушења сигнала, односно непригушења је $Q = 0.5$. Значајне промене се дешавају од $Q = 1$ до $Q = 100$, из тог разлога је узето $\xi \in [0.99, 0.015]$. За све четири класе микрофона узето је по 15 вредности неправилно распоређених у овом опсегу. Процењено је да је оваква расподела вредности параметара микрофона довољно добра да симулира све могуће експерименталне вредности. За сваки тип микрофона креирано је 65 000 упарених кривих, што представља 65 000 симулираних експерименталних резултата. Упарене криве представљају амплитудску и фазну карактеристику за дати скуп вредности параметара микрофона. Извршено је одабирање сваке криве на 200 фреквенција у опсегу од 10 Hz до 100 kHz. Вредности одбирака амплитудске и фазне карактеристике за један скуп вредности параметара микрофона чине један запис базе података. Према томе један запис базе података представљен је са 400 одбирака, 200 одбирака амплитуде и 200 одбирака фазе. То су улазни подаци за представљени проблем машинског учења. Другим речима свака фреквенција од посматраних 200 је представљена са два својства, одбирком амплитуде и одбирком фазе, према томе свака тачка криве представљена је са резолуцијом 2.

Визуализација података у бази дата је на слици 6, у форми дијаграма расејања или скатер дијаграма. Једна тачка на дијаграму је једна од 200 тачака које одговарају једној кривој од 270 000 кривих у бази података, када посматрамо све микрофоне заједно за случај узорка од алуминијума.

Као што се види на дијаграму тачке су потпуно класификоване у горњем десном делу дијаграма на четири класе или четири типа микрофона, што значи да за одређену расподелу вредности амплитуда и фаза очигледно је којој класи микрофона тачка припада. Таква расподела вредности амплитуда и фаза се дешава у нискофреквентном подручју. У осталим деловима дијаграма тачке су измешане, што значи да за ту расподелу вредности амплитуда и фаза не може се очигледно одредити којој класи тачка припада. Значи, у том делу фреквентног опсега се дешава преклапање кривих или преклапање класа.




Слика 6: Визуализација података: парови вредности амплитуда и фаза за једну фреквенцију у једном запису базе података представљени једном тачком на дијаграму, различите боје одговарају различитим типовима микрофона

Креирано је 5 база података:

- база симулираних експерименталних вредности за случај детектора ЕСМ30В и алуминијум, 67 500 записа,
- база симулираних експерименталних вредности за случај детектора ЕСМ30В и полиамид, 67 500 записа,
- база симулираних експерименталних вредности за случај детектора ЕСМ60 и алуминијум, 67 500 записа,
- база симулираних експерименталних вредности за случај детектора WM66 и алуминијум, 67 500 записа,
- база симулираних експерименталних вредности за случај детектора ИМ и алуминијум, 67 500 записа.

3 Вишеслојне неуронске мреже

Вишеслојне неуронске мреже са пропацијом унапред или вишеслојни перцептрони (енг. Multilayer Perceptron, MLP) су, суштински, модели са дубоким обучавањем [2][49]. Вишеслојна неуронска мрежа представља алгоритам надгледаног учења који открива функцију $f():R^n \rightarrow R^o$ обучавањем у офлајн бач (енг. offline batch) режиму на означеном скупу података, где су n димензија улаза и o димензија излаза. Скуп улазних параметара представљен је вектором $x=x_1, x_2, \dots, x_n$ док је циљна предикција представљена вектором $y_{pred} = y_{1pred}, y_{2pred}, \dots, y_{opred}$. Мрежа са пропацијом унапред дефинише пресликавање $y=f(x;w)$ и учи вредности параметара представљених вектором w што резултира у најбољој функцији апроксимације. Термин пропација унапред односи се на проток информације кроз функцију f полазећи од вектора x , кроз sukcesivна израчунавања у скривеним слојевима која су саставни део функције f , тако да се на излазу добија вектор y .

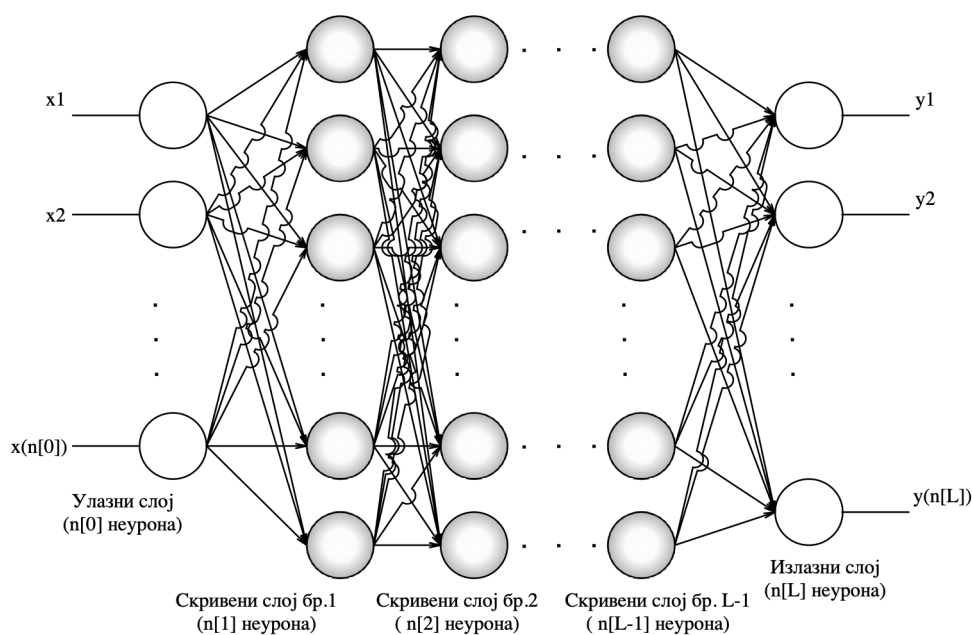


Слика 7: Нелинеарни неурон, где је w^T транспоновани вектор вектора w

Градивна јединица MLP-а названа је неурон због сличности и инспирације биолошким неуроном. Неурон је и градивна и јединица израчунавања и јединица конекције [50]. С обзиром на нелинеарност израчунавања то је нелинеарни неурон, слика 7. Према математичком моделу неуронске мреже, у неуронском чвору се израчунава линеарна комбинација отежаних улаза који побуђују његове “синапсе”, као и инкорпорација екстерног помераја или биаса (енг. bias), b [51]. Под отежаним улазима подразумева се да је сваки елемент улазног вектора помножен са вектором тежина w . То је први корак израчунавања у оквиру неурона, који као резултат даје променљиву z , док се у другом кораку израчунава активациона функција над z , што даје излазну променљиву a . Тако конципиран неурон представља нелинеарну, параметарску и ограничену функцију. Неурон је јединица конекције неуронске мреже,

јер до сваког неурона долазе и од њега полазе везе ка свим неуронима претходног и следећег слоја мреже.

Вишеслојна неуронска мрежа може имати већи број скривених слојева са специфичним бројем неурона у сваком слоју тако да укупна структура одговара проблему који ANN решава, слика 8. Укупан број слојева је број скривених слојева увећан за 1, што се односи на излазни слој. Модел се често представља директним ацикличним графом који описује како су функције међусобно повезане [2]. Снага израчунавања вишеслојне неуронске мреже зависи од дубине мреже (броја скривених слојева) и сложености међувеза. Што је архитектура дубља то је мрежа ефикаснија, јер заједно неурони могу постићи сложено нелинеарно мапирање, тако да излаз буде тражени одговор на дати улаз. Савремени тренд у теорији неуронских мрежа је доста скривених слојева, значи битна је дубина, а не величина мреже [52].



Слика 8: Неуронска мрежа са L слојева

3.1 Врсте учења неуронских мрежа

Машинско учење се генерално може окарактерисати као [2][53]:

- надгледано (енг. supervised),
- ненадгледано (енг. unsupervised),
- подржано учење (енг. reinforcement),

Термин надгледано учење потиче од чињенице да постоји знање о вредностима излаза y за дате улазе x . Свакој инстанци у скупу података додељена је мета или ознака (лабела), тако да имамо парове улаз - тачан излаз. На тај начин, постоји инструктор или учитељ који указују алгоритму машинског учења шта да ради у процесу предвиђања излаза y полазећи од одговарајућег улаза x . Учитељ надгледа процес учења. Тако током тренинга, алгоритам тражи обрасце који су у корелацији са познатим излазима. Циљ надгледаног учења је да за нове улазе предвиди што тачнију ознаку. Надгледано учење је најчешћи тип учења чија је ефикасност потврђена кроз велики број примена.

Супротно, код ненадгледаног учења не постоје означени излази, не постоји учитељ. Циљ је из структуре података научити експлицитно или имплицитно расподелу вероватноће $p(x)$ у скупу података или нека занимљива својства те расподеле.

Разлику између надгледаног и ненадгледаног учења најбоље је уочити на примеру, узмимо детекцију спам мејла у односу на детекцију аномалија у мејлу. У случају детекције спама тренинг скуп садржаће мејлове и спам/није спам ознаку. Након тренинга, открива се правило на основу кога се означава ново пристигла мејл порука као спам или није спам. То је надгледано учење. Код детекције аномалија, алгоритам добија скуп тела мејл порука без ознака и задатак је препознати неубичајене поруке.

Подржано учење није експлицитно учење, већ подразумева да након завршетка секвенце алгоритам на основу посебних критеријума за решавање добија логичку или стварну вредност, која дефинише да ли је резултат тачан или погрешан. Алгоритам на основу агента који интерагује са окружењем, учи из последица својих поступака, покушаја и схватања грешака. Своје будуће поступке алгоритам бира на основу својих прошлих искустава, али и новим изборима (истраживањима). Подржано учење је моћан алат за секвенцијално доношење одлука у неизвесном окружењу. Највећи број аутономних возила заснива свој рад на алгоритму подржаног учења.

3.2 Функција цене

Неуронске мреже уче да мапирају скуп улазних података на скуп излазних података користећи тренинг податке. Немогуће је израчунати идеалне тежине за неуронску

мрежу. Колико добро или довољно добро модел решава постављени задатак показује функција цене, која је на тај начин мера перформанси система. Постоји велики број функција које се могу користити у вишеслојним неуронским мрежама, а избор зависи од постављеног задатка, односно избора излаза [2]. Једна од најчешће коришћених, уз то врло ефикасна, али и једноставна функција цене је средње квадратно одступање од тачне вредности:

$$J = \frac{1}{m} \sum_{i=1}^m e_i^2 = \frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2 \quad (24)$$

где је m број примера или инстанци скупа података, e_i грешка предикције, \hat{y}_i i -ти излаз мреже (предикција), а y_i тачна вредност i -тог излазног параметра и J функција цене [54].

Уколико је проблем који се решава класификација скупа података на две класе (бинарна класификација) онда се најчешће користи крос-ентропи (енг. cross-entropy) функција:


$$J = -\frac{1}{m} \sum_{i=1}^m (y_i * \log(p(y_i)) + (1 - y_i) * \log(1 - p(y_i))) \quad (25)$$

где је $p(y_i)$ вероватноћа да излаз y_i има вредност 1.

У пракси је понекад тешко дефинисати меру за грешку или је израчунавање те мере неефикасно, па се мера одређује постављеним ограничењима система или захтевима пројекта.


3.3 Нормализација улаза

У зависности од проблема који описују улазни подаци неуронске мреже, врло често имају вредности у различитим опсезима који могу варирати и у неколико редова величина од обележја до обележја. У таквим случајевима површина функције цене у тродимензионалном простору тежина, помераја и функције цене или два изабрана параметра тежина и функције цене $w_1, w_2, \dots, w_n, b, J$, слика 9, може бити прилично издужена, слика 10 (а), што може довести до њеног значајног осциловања на путу ка глобалном минимуму слика 11 (а). Тада се не може користити велики корак обучавања, што даље доводи до успоравања тренинга.




Слика 9: Површина функције цене у простору тежина, слика преузета са сајта cs224d.stanford.edu

Међутим, ако се примени нормализација којом се улазни подаци скалирају изабраном методом изглед површине функције цене се значајно промени слика 10 (б). Сада је присутна симетрија у тродимензионалном простору w, b, J , што одговара бржој конвергенцији функције цене, слика 11 (б), а тиме и бржем учењу неуронске мреже [51][52].



Слика 10: Функција цене (а) издужена, код сирових података (б) симетрична, код нормализованих података, слика преузета са сајта medium.com



Слика 11: (а) Пут функције цене ка глобалном минимуму (пример) у случају ненормализованих улаза, (б) пут функције цене ка глобалном минимуму у случају нормализованих улаза, слике преузете са сајта medium.com

Избор методе нормализације зависи од постављеног задатка. Неке од метода су: зед-скор (енг. Z-score), мин-макс нормализација, нормализација максималном вредношћу, L1 норм, L2 норм итд. Овде је представљена нормализација по методи зед-скор.

По методи зед-скор, од вектора улаза одузима се средња вредност израчуната на свим примерима из скупа података, а потом се сваки елемент улазног вектора дели са стандардном девијацијом [51]:


$$\mu = \frac{1}{m} \sum_{i=1}^m x^{(i)} \quad (26)$$

$$x = x - \mu \quad (27)$$

$$\sigma^2 = \frac{1}{m} \sum_{i=1}^m (x^{(i)})^2 \quad (28)$$

$$x = x / \sigma \quad (29)$$

где је μ средња вредност, а σ стандардна девијација посматране расподеле. Графички приказ методе дат је на слици 12, у почетном тренутку улазни подаци x_1 и x_2 имају различите опсеге вредности, при чему је варијанса x_1 већа од варијансе x_2 . Након одузимања средње вредности од улазног вектора расподела података се мења и сада су сконцентрисани око 0, средња вредност у овој расподели износи 0, што је и био циљ. Након поделе са стандардном девијацијом мења се расподела по другој димензији, изједначава се варијанса за x_1 и x_2 и једнака је јединици. Новодобијена симетрија у простору улазних података довешће до жељене симетрије у тродимензионалном простору w, b, J .



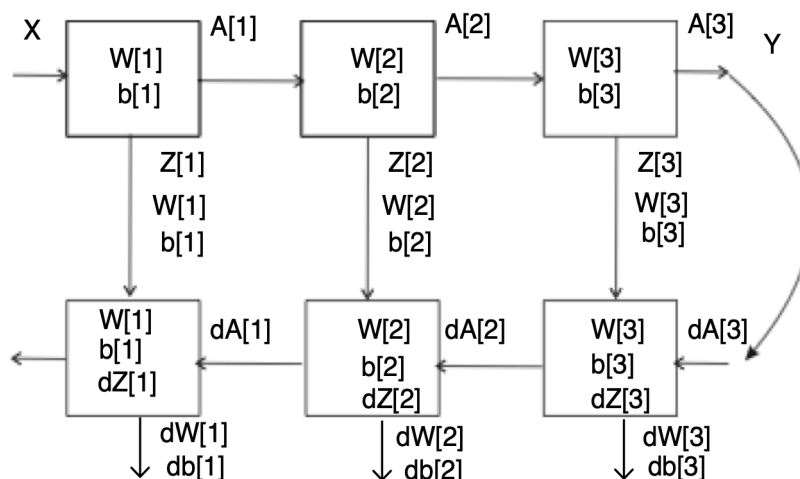
Слика 12: Нормализација методом зед-скор

3.4 Математички модел вишеслојне неуронске мреже

У овом поглављу представљен је математички модел трослојне неуронске мреже. Из разлога једноставности, коришћена је неуронска мрежа са два скривена слоја. Генерализација модела се лако може постићи додавањем произвољног броја слојева. Број слојева у ANN уобичајено се означава са L , број скривених слојева са $L - 1$, а број неурона у сваком слоју са $n[l]$, где је l ознака посматраног скривеног слоја.

У представљеном моделу користи се надгледано учење са пропацијом грешке уназад. На слици 13 представљена је пропација унапред и пропација уназад у форми ацикличног графа. У пропацији унапред информација тече у једном правцу од улаза до излаза. Пропација уназад је алгоритам заснован на функцији грешке, који користи шему локалног пролаза информација, односно повратно простирање грешке (енг. backpropagation). Учи се из података, користећи парове улаза и исправних излаза, са циљем минимизације функције цене. Резултат је усвојени вектор тежина за сваки појединачни неурон у ANN и за сваку итерацију. Крајњи резултат је нелинеарно мапирање излаза [2][3].

Као што је познато граф компоује функције. У представљеном моделу то су три функције, компоноване у ланац: $f(x) = f_3(f_2(f_1(x)))$, где је $f_1(x)$ функција првог скривеног слоја, $f_2(x)$ је функција другог скривеног слоја и $f_3(x)$ је функција излазног слоја [55][56][57].



Слика 13: Ациклични граф трослојне неуронске мреже

Генерално, једначине које описују слој l у пропацији унапред су:

$$Z^{[l]} = W^{[l]} \cdot A^{[l-1]} + b^{[l]} \quad (30)$$

$$A^{[l]} = g^{[l]} \cdot (Z^{[l]}) \quad (31)$$

где је, $g^{[l]}$ активациона функција слоја l , $Z^{[l]}$ је матрица димензије $(n^{[l]}, m)$, $n^{[l]}$ је број неурона у слоју l , m је број инстанци скупа података, $W^{[l]}$ је матрица тежина слоја l димензије $(n^{[l]}, n^{[l-1]})$, $n^{[l-1]}$ је број неурона у претходном слоју $l - 1$, $A^{[l-1]}$ је матрица активација слоја $l - 1$ димензије $(n^{[l-1]}, m)$, $b^{[l]}$ је вектор биаса слоја l са димензијом $(n^{[l]}, 1)$, $A^{[l]}$ је матрица активација слоја l димензије $(n^{[l]}, m)$.

Пратећи граф, слика 5, математички модел за случај пропагације унапред је:

$$Z^{[1]} = W^{[1]} \cdot X + b^{[1]} \quad (32)$$

$$A^{[1]} = g^{[1]} \cdot (Z^{[1]}) \quad (33)$$

$$Z^{[2]} = W^{[2]} \cdot A^{[1]} + b^{[2]} \quad (34)$$

$$A^{[2]} = g^{[2]} \cdot (Z^{[2]}) \quad (35)$$

$$Z^{[3]} = W^{[3]} \cdot A^{[2]} + b^{[3]} \quad (36)$$

$$A^{[3]} = g^{[3]} \cdot (Z^{[3]}) \quad (37)$$

$$\hat{Y} = A^{[3]} \quad (38)$$

Параметри пропагације унапред: $Z^{[1]}, W^{[1]}, b^{[1]}, Z^{[2]}, W^{[2]}, b^{[2]}, Z^{[3]}, W^{[3]}, b^{[3]}$ се меморишу (кеширају), како би се користили у пропагацији уназад.

Генерално пропагација уназад посматраног слоја l представљена је једначинама:

$$dZ^{[l]} = dA^{[l]} * g^{[l]'} \cdot (Z^{[l]}) \quad (39)$$

$$dW^{[l]} = \frac{1}{m} dZ^{[l]} \cdot A^{[l-1]T} \quad (40)$$

$$db^{[l]} = \frac{1}{m} \sum_{i=1}^m dZ^{[l](i)} \quad (41)$$

$$dA^{[l-1]} = W^{[l]T} \cdot dZ^{[l]} \quad (42)$$

$$dZ^{[l]} = W^{[l+1]T} \cdot dZ^{[l+1]} * g^{[l]'} \cdot (Z^{[l]}) \quad (43)$$

где је $dZ^{[l]}$ први извод функције цене $J(W, b)$ по варијабли $Z^{[l]}$, $dA^{[l]}$ први извод функције цене $J(W, b)$ по варијабли $A^{[l]}$, $g^{[l] \prime}$ је извод активационе функције $g^{[l] \prime} = \frac{d}{dZ} g^{[l]}$ по $Z^{[l]}$, $dW^{[l]}$ је извод функције цене по варијабли $W^{[l]}$, и $db^{[l]}$ је извод функције цене по биасу, * означава производ појединачних елемената вектора (енг. element-wise multiplication).

Пратећи граф, слика 5, једначине трећег слоја за случај пропагације уназад су:

$$dZ^{[3]} = A^{[3]} - Y^{(i)} \quad (44)$$

$$dW^{[3]} = \frac{1}{m} dZ^{[3]} \cdot A^{[2]T} \quad (45)$$

$$db^{[3]} = \frac{1}{m} \sum_{i=1}^m dZ^{[3](i)} \quad (46)$$

$$dA^{[2]} = W^{[3]T} \cdot dZ^{[3]} \quad (47)$$

где, $dZ^{[3]}$ је мера колико добро процена $\hat{Y} = A^{[3]}$ погађа тачну вредност Y , $dW^{[3]}$ је извод функције цене $J(W, b)$ по параметру $W^{[3]}$, $dW^{[3]} = \frac{dJ}{dW^{[3]}}$, $dA^{[2]}$ је извод функције цене $J(W, b)$ по параметру $A^{[2]}$, $dA^{[2]} = \frac{dJ}{dA^{[2]}}$, $db^{[3]}$ је извод функције цене $J(W, b)$ по параметру $b^{[3]}$, $db^{[3]} = \frac{dJ}{db^{[3]}}$.

Функција цене је $J(W, b) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$, где је $\mathcal{L}(\hat{y}^{(i)}, y^{(i)})$ функција грешке или губитка.

Једначине другог слоја су:

$$dZ^{[2]} = dA^{[2]} * g^{[2] \prime} \cdot (Z^{[2]}) \quad (48)$$

$$dW^{[2]} = \frac{1}{m} dZ^{[2]} \cdot A^{[1]T} \quad (49)$$

$$db^{[2]} = \frac{1}{m} \sum_{i=1}^m dZ^{[2](i)} \quad (50)$$

$$dA^{[1]} = W^{[2]T} \cdot dZ^{[2]} \quad (51)$$

$$dZ^{[2]} = W^{[3]T} \cdot dZ^{[3]} * g^{[2] \prime} \cdot (Z^{[2]}) \quad (52)$$

где је, $dZ^{[2]}$ први извод функције цене $J(W, b)$ по параметру $Z^{[2]}$, $dZ^{[2]} = \frac{dJ}{dZ^{[2]}}$, $dW^{[2]}$ је извод функције цене $J(W, b)$ по параметру $W^{[2]}$, $dW^{[2]} = \frac{dJ}{dW^{[2]}}$, $dA^{[1]}$ је извод

функције цене $J(W, b)$ по параметру $A^{[1]}$, $dA^{[1]} = \frac{dJ}{dA^{[1]}}$, $db^{[2]}$ је извод функције цене $J(W, b)$ по параметру $b^{[2]}$.

Једначине првог слоја су:

$$dZ^{[1]} = dA^{[1]} * g^{[1]'} \cdot (Z^{[1]}) \quad (53)$$

$$dW^{[1]} = \frac{1}{m} dZ^{[1]} \cdot X^T \quad (54)$$

$$db^{[1]} = \frac{1}{m} \sum_{i=1}^m dZ^{[1](i)} \quad (55)$$

$$dZ^{[1]} = W^{[2]T} \cdot dZ^{[2]} * g^{[1]'} \cdot (Z^{[1]}) \quad (56)$$

где, $dZ^{[1]}$ је извод функције цене $J(W, b)$ по параметру $Z^{[1]}$, $dZ^{[1]} = \frac{dJ}{dZ^{[1]}}$, $dW^{[1]}$ је извод функције цене $J(W, b)$ по параметру $W^{[1]}$, $dW^{[1]} = \frac{dJ}{dW^{[1]}}$, $db^{[1]}$ је извод функције цене $J(W, b)$ по параметру $b^{[1]}$.

Коначно, тежински параметри и биас сваког слоја су ажурирани:

$$W^{[l]} = W^{[l]} - \alpha dW^{[l]} \quad (57)$$

$$b^{[l]} = b^{[l]} - \alpha db^{[l]} \quad (58)$$

где је α корак обучавања. Корак обучавања је један од хиперпараметара модела.

У учењу је неопходно обезбедити услове, и то финим подешавањем параметра и хиперпараметара модела, да функција цене конвергира. Избор корака обучавања је посебно важан, ако се изабере превелика вредност може доћи до прескакања оптималне вредности функције цене, а ако је изабрана вредност премала, моделу ће требати више итерација да конвергира до оптималне вредности. Поступак простирања унапред и уназад се понавља све док функција цене не достигне свој минимум.

3.5 Регуларизација

Један од централних проблема у креирању модела заснованог на машинском учењу је направити такав модел чије ће перформансе бити добре не само на тренинг скупу (мало одступање, низак биас), већ и за нове улазе (мала варијанса). У анализи односа биаса и варијансе (енг. bias variance trade off), ако је висока варијанса на валидационом скупу једно од решења је повећати тренинг скуп података или применити

регуларизацију. Под регуларизацијом се подразумева много различитих стратегија, развијених како би се смањила грешка модела на тест подацима [2][52][58]. У овој дисертацији представићемо L_2 регуларизацију [59].

Функција цене код неуронске мреже са примењеном регуларизацијом:

$$J(W^{[1]}, b^{[1]}, W^{[2]}, b^{[2]}, \dots, W^{[L]}, b^{[L]}) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)}) + \frac{\lambda}{2m} \sum_{l=1}^L \|W^{(l)}\|_F^2 \quad (59)$$

где је: m број инстанци тренинг скупа података, $\mathcal{L}(\hat{y}^{(i)}, y^{(i)})$ функција грешке, λ параметар регуларизације, $W^{(l)}$ матрица тежинских параметра слоја l димензија $(n^{[l]}, n^{[l-1]})$, док је $\|W^{(l)}\|_F^2$ F норм (енг. Frobenius norm) матрице тежинских параметра:

$$\|W^{(l)}\|_F^2 = \sum_{i=1}^{n^{[l]}} \sum_{j=1}^{n^{[l-1]}} (W_{ij}^{[l]})^2 \quad (60)$$

Циљ је минимизирати $J(W^{[1]}, b^{[1]}, W^{[2]}, b^{[2]}, \dots, W^{[L]}, b^{[L]})$ по параметрима $W^{[1]}, b^{[1]}, W^{[2]}, b^{[2]}, \dots, W^{[L]}, b^{[L]}$. Значи, потребно је одредити $\frac{dJ}{dW^{[l]}} = dW^{[l]}$.

У претходном поглављу одређено је $dW^{[l]}$ када није примењена регуларизација, па је сада:

$$dW^{[l]} = (\text{iz propagacije unazad}) + \frac{\lambda}{m} \quad (61)$$

$$W^{[l]} = W^{[l]} - \alpha dW^{[l]} \quad (62)$$

Према томе:

$$W^{[l]} = W^{[l]} - \alpha \left[(\text{iz propagacije unazad}) + \frac{\lambda}{m} W^{[l]} \right] = W^{[l]} - \frac{\alpha\lambda}{m} W^{[l]} - \alpha (\text{iz propagacije unazad}) \quad (63)$$

$$W^{[l]} = \left(1 - \frac{\alpha\lambda}{m} \right) W^{[l]} - \alpha (\text{iz propagacije unazad}) \quad (64)$$

Из једначине (64) јасно је да правилним избором параметра регуларизације можемо доћи до стања “довољно добро” (енг. “just right”) у поступку подешавања биаса и варијансе. Ако је превише велико λ може се десити да је $W^{[l]} \approx 0$ што би одговарало ситуацији високог биаса, ако је λ превише мало, не би имали регуларизацију.

Оптимална, средња вредност одговара стању “довољно добро”, а то значи да ће функција цене монотонно да опада.

3.6 Иницијализација

Како би се обезбедило брже учење и боље перформансе модела, неопходно је изабрати ефикасан метод иницијализације вектора тежинских параметара. Иницијализација је врло важан корак пре уласка у процес тренинга. У литератури се могу наћи препоруке и сугестије за ефикасну иницијализацију [2][52][60][61].

Било која шема иницијализације са константним вредностима није добра јер би то значило да би се сваки неурон понашао слично, односно, не би био могућ сценарио да различити неурони уче различите чињенице из података, а то је управо потребно за делотворно учење. Ако су тежине иницијализоване на много мале или много велике вредности, може доћи до нестајања или експлодирања тежина (експоненцијални пад или експоненцијални раст), тиме је тренинг отежан, функција цене дивергира и мрежа се може заглавити у локалном минимуму [52].

Општа правила за ефикасну иницијализацију су:

1. средња вредност активација треба да буде 0, израз (65)
2. варијанса активација треба да остане иста у сваком слоју вишеслојне неуронске мреже, израз (66)

$$E(a^{[l-1]}) = E(a^{[l]}) \quad (65)$$

$$Var(a^{[l-1]}) = Var(a^{[l]}) \quad (66)$$

Добра пракса је иницијализовати тежине на случајне, мале вредности као код следећег метода иницијализације (датог кроз `python` наредбу):

$$W^{[l]} = np.random.randn(shape) * np.sqrt(\frac{1}{n^{[l-1]}}) \quad (67)$$

За овај случај варијанса износи:

$$Var(W^{[l]}) = \frac{1}{n^{[l-1]}} \quad (68)$$

где је n број неурона у претходном слоју.

Избор вредности варијансе зависи од избора активационе функције, тако за ReLu активациону функцију се често користи:

$$Var(W^{[l]}) = \frac{2}{n^{[l-1]}} \quad (69)$$

За tanh() активациону функцију важи:

$$Var(W^{[l]}) = \sqrt{\frac{1}{n^{[l-1]}}} \quad (70)$$

или

$$Var(W^{[l]}) = \sqrt{\frac{2}{n^{[l-1]} + n^{[l]}}} \quad (71)$$

што је познати Xavier метод иницијализације [62] .

Значи сви тежински параметри једног слоја узимају се као случајне вредности из нормалне расподеле тако да важи:

$$\mu(W^{[l]}) = 0 \quad (72)$$

$$\sigma^2(W^{[l]}) = \frac{1}{n^{[l-1]}} \quad (73)$$

Оваквом иницијализацијом се постиже рушење симетричности, што даље доводи до конвергенције функције грешке, а то значи брже учење.


3.7 Оптимизациони алгоритми

Оптимизација неуронских мрежа може се анализирати са више аспеката. На пример, оптимизација броја улазних параметра, оптимизација архитектуре модела, оптимизација тренинга итд. [52][60][61][63]. Овде ћемо размотрити оптимизацију тренинга и представити неколико техника оптимизације. За дефинисану архитектуру модела, вредности параметара одређују перформансе модела. Поставља се питање на који начин пронаћи оптималне вредности параметара модела. Одговор је у функцији грешке, јер функција грешке евалуира понашање модела, односно показује колико тачно модел решава задатак. Циљ тренинга је, према томе, пронаћи параметре тако да функција грешке буде минимална. С обзиром да је код неуронских мрежа функција цене не конвексна, тј. може имати неколико оптимума, од којих је само један

глобални, оптимизација тренинга неуронских мрежа је комплексан задатак [2][52][64].

Једна од техника оптимизације параметара у пропацији грешке уназад је градијентна опадација тежинских параметара која је представљена у поглављу Математички модел неуронске мреже, поглавље 3.4 [65]. Недостатак ове технике је што градијент осцилује и има велики број корака до минимума, слика 14. На овај начин је немогуће повећати корак обучавања што би могло довести до убрзања тренинга.

Унапређење ове технике оптимизације је градијентна опадација са моментумом, који је заснован на убацивању претходних промена тежина у тренутну промену тежине, како би се ухватио локални тренд промена тежина.



Слика 14: Поређење две технике оптимизације, градијентна опадација и градијентна опадација са моментумом, слика преузета са <https://towardsdatascience.com>

За итерацију t тренинга код градијента са моментумом важе следеће једначине:

$$V_{dW} = \beta_1 V_{dW} + (1 - \beta_1) dW, \quad (74)$$

$$V_{db} = \beta_1 V_{db} + (1 - \beta_1) db, \quad (75)$$

$$W = W - \alpha V_{dW}, \quad (76)$$

$$b = b - \alpha V_{db} \quad (77)$$

где је, V_{dW} први моментум тежина, dW извод функције цене по тежинским параметрима W , V_{db} први моментум биаса b , db извод функције цене по биасу. Почетна вредност варијабли V_{dW} и V_{db} је 0. β_1 је хиперпараметар који контролише експоненцијално отежане средње вредности, α корак обучавања. Најчешће је $\beta_1 = 0.9$, што значи да се врши експоненцијално усредњавање у задњих 10 вредности.

RMS prop (енг. Root Mean Squared prop) је техника оптимизације заснована на другом моментуму:

$$S_{dW} = \beta_2 S_{dW} + (1 - \beta_2) dW^2, \quad (78)$$

$$S_{db} = \beta_2 S_{db} + (1 - \beta_2) db^2, \quad (79)$$

$$W = W - \alpha \frac{dW}{\sqrt{S_{dW} + \epsilon}}, \quad (80)$$

$$b = b - \alpha \frac{db}{\sqrt{S_{db} + \epsilon}} \quad (81)$$

где је, S_{dW} други моментум тежина, S_{db} други моментум биаса b , β_2 хиперпараметар који контролише експоненцијално отежане средње вредности. Почетна вредност варијабли S_{dW} и S_{db} је 0. ϵ је помоћни параметар како би се избегло дељење са нулом, уобичајено су $\beta_2 = 0.999$ и $\epsilon = 10^{-8}$.

Коришћењем RMS проп-а убрзава се алгоритам обучавања јер је могуће повећати корак обучавања без дивергенције функције цене у хоризонталном правцу. Adam (енг. Addaptive moment estimation) оптимизациони алгоритам обједињује претходне две технике [66], па важи:

$$V_{dW} = \beta_1 V_{dW} + (1 - \beta_1) dW, \quad V_{dW}^{corrected} = \frac{V_{dW}}{(1 - \beta_1^t)} \quad (82)$$

$$V_{db} = \beta_1 V_{db} + (1 - \beta_1) db, \quad V_{db}^{corrected} = \frac{V_{db}}{(1 - \beta_1^t)} \quad (83)$$

$$S_{dW} = \beta_2 S_{dW} + (1 - \beta_2) dW^2, \quad S_{dW}^{corrected} = \frac{S_{dW}}{(1 - \beta_2^t)} \quad (84)$$

$$S_{db} = \beta_2 S_{db} + (1 - \beta_2) db^2, \quad S_{db}^{corrected} = \frac{S_{db}}{(1 - \beta_2^t)} \quad (85)$$

$$W = W - \alpha \frac{V_{dW}^{corrected}}{\sqrt{S_{dW}^{corrected} + \epsilon}}, \quad (86)$$

$$b = b - \alpha \frac{V_{db}^{corrected}}{\sqrt{S_{db}^{corrected} + \epsilon}}, \quad (87)$$


$V_{dW}^{corrected}$, $V_{db}^{corrected}$, $S_{dW}^{corrected}$, $S_{db}^{corrected}$ уведени су из разлога почетног биаса, тј. биаса у првих неколико вредности који одступају од тачних вредности. Овај биас се јавља из разлога што за почетне вредности V_{dW} , V_{db} , S_{dW} и S_{db} је узета 0, што није у потпуности исправно. Пошто су β_1 и β_2 мале вредности, после неколико итерација корекциони фактор ишчезава.

Adam оптимизациони алгоритам се показао успешним у великом броју различитих проблема и различитих архитектура вишеслојних неуронских мрежа. Из тих разлога врло је често коришћен.

3.8 Мини бач у односу на бач

Бач (енг. batch) опадање градијента је метод тренирања неуронске мреже код кога се сви тренинг подаци разматрају у једном кораку, за разлику од стохастичког (енг. stochastic) опадања градијента када се у једном кораку разматра само један пример тренинг скупа. На слици 15 је приказана оптимизација функције цене у обе ове технике. Концентричне елипсе представљају контуре функције цене. Минимум функције цене се налази у центру.

Код бач технике кораци ка минимуму су релативно велики и уобичајено нема шума, али с обзиром да је потребно проћи цео тренинг скуп време једне итерације је превелико. Код стохастичке технике може да се деси погрешан правац у кретању ка минимуму, па је путања прилично шумовита и углавном стохастички градијент осцилије око минимума. Додатни проблем је што се убрзање постигнуто векторизацијом губи јер се ажурирање ради за сваки пример.



Слика 15: Поређење: бач (плава крива), стохастичког (љубичаста крива) и мини бач (енг. mini-batch) (зелена крива) градијента, преузето са datascience.stackexchange.com


У пракси оптимална техника је негде између ове две. Показало се оптималним користити фиксни број примера из тренинг скупа, слика 16, који је мањи од укупног броја примера у тренинг скуп. Ова техника се зове мини-бач. Кораци су:

1. изабрати димензију мини-бача,
2. убацити у неуронску мрежу,
3. израчунати градијент мини-бача,
4. ажурирати тежинске параметре,
5. поновити кораке 2-4.

Функција цене код бач технике би требало, ако су сви остали хиперпараметри оптимизовани, да се смањује за сваку итерацију. Код мини-бач технике за сваки мини-

бач не мора да се смањује функција цене јер су у питању другачији подаци, генерални тренд је опадање, али се већ у првој епохи може видети опадање функције цене, напредак се постиже врло брзо.

Димензија мини-бача је један од хиперпараметара, и ако је правилно изабрана доведиће до бржег учења. Ако је мини-бач димензија једнака m онда је у питању бач техника, а ако је мини-бач димензија једнака 1 у питању је стохастичка техника. Типичне вредности величине mini-batch-а су 32, 64, 128, 512, односно 2^p и бира се на основу величине CPU или GPU меморије рачунара на коме се тренира мрежа.




Слика 16: Мини-бач техника, димензија 64

4 Анализа главних компоненти у проблемима машинског учења

Анализа главних компоненти (енг. Principal Component Analysis - PCA) је статистичка техника ненадгледаног учења која се у машинском учењу првенствено користи за редукцију димензија [51]. PCA је техника која тражи k -димензиони подпростор из n -димензионог простора који најбоље чува варијансу у подацима. Алгоритам предлаже површину нижих димензија, тако да је сума растојања тачака од њихових пројекција на дату површину минимална. PCA иде правцем којим варијанса постаје максимална, а средње квадратна грешка пројекције минимална [53][65][67].

Алгоритам бира правац у n -димензионом простору података у коме се највише простиру подаци, то је прва главна компонента. Друга и свака следећа главна компонента бира се тако да њен правац буде нормалан на претходни и да прати следећу највећу могућу дисперзију података. На овај начин добија се ортонормирана база која добро описује варијабилност у простору података. Главне компоненте су некорелисане, слика 17.



Слика 17: Прва и друга главна компонента, x_1 и x_2 су два обележја скупа података

Кораци у алгоритму PCA су [68]:

$PCA(D, \gamma)$, где је D скуп података, а γ задата-тражена вредност коваријансе

1. $\mu = \frac{1}{m} \sum_{i=1}^m x_i$, израчунавање средње вредности сваког обележја, где је m број примера из скупа података,
2. $Z = D - 1 * \mu^T$, центрирање података, тако да је средња вредности по сваком обележју једнака 0, резултат је нормирани скуп података Z ,

3. $std = \sqrt{\frac{\sum_{i=1}^m (x_i - \mu)^2}{m-1}}$, израчунавање стандардне девијације,
4. $Z = Z/std$, скалирање података како би имали упоредиве вредности,
5. $\Sigma = \frac{1}{m} (Z^T Z)$, израчунавање матрице коваријансе,
6. $(\lambda_1, \lambda_2, \dots, \lambda_d) = eigenvalues(\Sigma)$, израчунавање ајгенвредности (енг. eigenvalues), које дефинишу магнитуду варијансе података на осама,
7. $U = (u_1 u_2 \dots u_d) = eigenvectors(\Sigma)$, израчунавање ајгенвектора (енг. eigenvectors) који дефинише угао или правац оса кроз простор података,
8. $f(r) = \frac{\sum_{i=1}^r \lambda_i}{\sum_{i=1}^d \lambda_i}$, за све $r = 1, 2, \dots, d$, фракција укупне варијансе,
9. Бирамо најмање k тако да је $f(k) \geq \gamma$, бирамо димензију,
10. $U_k = (u_1 u_2 \dots u_k)$, редукована база,

$A = (a_i | a_i = U_k^T x_i \text{ за } i = 1, \dots, m)$, редукован скуп података [68].

Поставља се питање како изабрати k тако да редукција димензија буде задовољавајућа. Избор k еквивалентан је са одлуком колико главних компоненти вратити. Ако је k много велико, редукција димензија може бити недовољна, а ако је k много мало, апроксимација података може бити недовољно добра. Одлука о величини редукованог скупа података, k , треба да узме у обзир проценат преостале варијансе за различите вредности k , на тај начин се прави најбољи избор. У случају слика као посматраних података, уобичајена шема је изабрати k тако да преостала варијанса буде барем 99% првобитне варијансе. То значи, бира се најмање k које задовољава неједначину:

$$\frac{\sum_{j=1}^k \lambda_j}{\sum_{j=1}^n \lambda_j} \geq 0.99 \quad (89)$$

У зависности од примене, односно да ли су подаци осетљиви на грешке или не, користе се и вредности у опсегу 90-98%. Дефинисање преостале варијансе је бољи показатељ редукције димензија од броја обележја у редукованом скуп података.

5 Методологија-имплементација алгоритама

У овом поглављу доказаће се хипотеза да се алгоритми машинског учења могу искористити за препознавање утицаја мерног система на експериментални сигнал уз постизање задовољавајуће тачности и прецизности мерења.

5.1 Захтеви

Први проблем који је требало решити у оквиру дизајнирања програмског оквира за аутоматизацију обраде резултата ФА мерења је проблем машинског учења - предвидети карактеристичне параметре детектора коришћеног у ФА експерименту на основу снимљеног ФА одзива, тако да се остваре следећи захтеви експеримента:

1. задовољавајућа прецизност, тј. грешка предикције на тест скупу је мања или једнака 5% тачне вредности,
2. поузданост, тј. модел довољно добро интерполира излазне параметре,
3. рад у реалном времену, тј. модел предвиђа параметре за време мање од 100 ms,
4. модел се извршава на широко доступном хардверу.

ФА одзив као улаз алгоритма машинског учења може бити симулиран или експериментални.

Постављени проблем представља регресиони проблем машинског учења. Крајњи циљ, одређен датим захтевима ФА експеримента, дао је евалуациону метрику. Оптимизациона евалуациона метрика представљеног проблема машинског учења је - грешка предикције је мања или једнака 5% тачне вредности и модел је поуздан, а задовољавајућа метрика - време предикције је мање од 100 ms и модел се извршава на широко доступном хардверу. Када се у процесу развоја модела постигне дефинисана метрика, тада имамо оптимално решење за дефинисане захтеве [16][69].

Други проблем који је требало решити је такође проблем машинског учења - предвидети тип детектора у ФА експерименту на основу добијеног ФА одзива, тако да се остваре следећи захтеви:

1. задовољавајућа тачност на тест скупу података, тј. тачност већа или једнака од 95%,

2. поузданост, тј. модел довољно добро интерполира излазне параметре,
3. рад у реалном времену, тј. модел предвиђа параметре за мање од 100 ms,
4. модел се извршава на широко доступном хардверу.

ФА одзив као улаз алгоритма машинског учења може бити симулиран или експериментални.

Други проблем представља класификациони проблем машинског учења. Оптимизациона евалуациона метрика представљеног проблема машинског учења је тачност модела мора бити већа или једнака 95% и модел је поуздан, а задовољавајућа метрика је - време предикције је мање од 100 ms и модел се извршава на широко доступном хардверу. Када се у процесу развоја модела постигне дефинисана метрика, тада имамо оптимално решење класификационог модела за дефинисане захтеве.

5.2 Нормализација података

Анализом базе података утврђен је опсег вредности амплитуда одбирака и фаза одбирака, слика 18. Вредности амплитуда су од $x * 10^1$ до $x * 10^{-4}$, што је разлика у 5 редова величина, док је опсег вредности фаза одбирака од $-x * 10^2$ до $x * 10^2$. Закључак је да је неопходна нормализација улазне матрице података.

15.1671689	15.8856513	16.6381689	17.4263339	18.2518349	19.1164408	20.0220037	20.970464	21.0102.7678	62949.8899	65931.8827	69055.1352	72326.339	75752.5026	79340.9667	83099.4195
63.61599	62.70596	61.68763	60.56538	59.34464	58.03179	56.63406	55.15945	0.00191	0.00166	0.00145	0.00126	0.0011	9.56409E-4	8.33231E-4	7.25957E-4
63.61599	62.70596	61.68763	60.56538	59.34464	58.03179	56.63406	55.15945	0.00191	0.00166	0.00145	0.00126	0.0011	9.56227E-4	8.33641E-4	7.26282E-4
63.61599	62.70596	61.68763	60.56538	59.34464	58.03179	56.63406	55.15946	0.00191	0.00167	0.00145	0.00126	0.0011	9.5793E-4	8.34435E-4	7.2691E-4
63.61599	62.70597	61.68763	60.56539	59.34465	58.03179	56.63406	55.15946	0.00192	0.00167	0.00145	0.00127	0.0011	9.59349E-4	8.35557E-4	7.27798E-4
63.61599	62.70597	61.68764	60.56539	59.34465	58.03179	56.63407	55.15946	0.00192	0.00167	0.00146	0.00127	0.0011	9.61079E-4	8.36924E-4	7.28879E-4
63.616	62.70597	61.68764	60.56539	59.34465	58.0318	56.63407	55.15946	0.00193	0.00168	0.00146	0.00127	0.0011	9.62975E-4	8.38422E-4	7.30062E-4
63.616	62.70597	61.68764	60.56539	59.34465	58.0318	56.63407	55.15946	0.00194	0.00168	0.00146	0.00127	0.0011	9.64851E-4	8.39902E-4	7.3123E-4

12310.9931	54789.0118	57384.4165	60102.7678	62949.8899	65931.8827	69055.1352	72326.339	12.6038293	13.200884	13.8262217	14.4811823	15.1671689	15.8856513	16.6381689	17.4263339
-248.28456	-249.17146	-250.01473	-250.81715	-251.58125	-252.30937	-253.00364	-253.66604	156.45905	154.00666	151.51742	148.99514	146.44391	143.86801	141.27194	138.66031
-248.50083	-249.37814	-250.21221	-251.00581	-251.76146	-252.48149	-253.16803	-253.82304	156.45956	154.00721	151.51799	148.99573	146.44453	143.86867	141.27262	138.66103
-248.93591	-249.7937	-250.60908	-251.39478	-252.12332	-252.82698	-253.49788	-254.13795	156.4606	154.00829	151.51912	148.99692	146.44577	143.86997	141.27399	138.66246
-249.5947	-250.42237	-251.20898	-251.95722	-252.66954	-253.3462	-253.99524	-254.61255	156.46215	154.00991	151.52082	148.9987	146.44764	143.87193	141.27604	138.6646
-250.484	-251.27001	-252.01697	-252.72749	-253.40391	-254.04941	-254.66293	-255.24925	156.46422	154.01208	151.52309	149.00108	146.45013	143.87453	141.27877	138.66746
-251.6118	-252.34349	-253.03897	-253.70068	-254.33081	-254.93138	-255.50421	-256.05098	156.4668	154.01479	151.52593	149.00405	146.45324	143.87779	141.28218	138.67104
-252.98624	-253.64977	-254.28093	-254.8819	-255.45463	-256.0009	-256.52234	-257.02043	156.46991	154.01804	151.52933	149.00762	146.45697	143.8817	141.28628	138.67533

Слика 18: Изглед базе података

Постоји значајна сличност између проблема машинског учења представљеног у овој докторској дисертацији и проблема рачунарског вида. Као што је претходно описано, крива која представља ФА одзив је одмерена у 200 тачака фреквентне осе, и за сваки одбирок је одређена вредност амплитуде и фазе. Значи, свака тачка криве у

којој је извршено одмеравање, представљена је са два обележја: амплитудом и фазом. Код проблема рачунарског вида, свака тачка слике представљена је са три обележја: ниво црвене, ознака R (енг. red), ниво зелене, ознака G (енг. green) и ниво плаве, ознака B (енг. blue) [3]. Уобичајени метод нормализације код овог проблема је подела сваке вредности улазног вектора са константом 256, што је максимална вредност нивоа сваке од RGB компоненти. Код овде представљеног проблема, по аналогији то би била максимална вредност амплитуде и максимална вредност фазе свих одбирака узетих на i -тој фреквенцији.

Засновано на овој анализи, нормализација улазног вектора је постигнута поделом сваког елемента x_i максималном апсолутном вредношћу i -те врсте улазне матрице. Као резултат, све добијене вредности улазног вектора су мање или једнаке јединици, што је услов за ефикасно учење.

Тестирана су још два типа нормализације. Први је зед-скор (енг. Z- score), који подразумева најпре одузимање средње вредности i -те врсте улазне матрице од сваког елемента x_i , а затим поделу стандардном девијацијом i -те врсте улазне матрице. Други је N2 тип нормализације или F норм (енг. Frobenius norm), који рачуна Еуклидову норму или Еуклидово растојање улазне матрице, а затим поделу сваког елемента x_i са одговарајућим растојањем. Поређење перформанси модела за ова три различита типа нормализације дато је у поглављу 5.3.1 Дискусија – архитектура и хиперпараметри модела.

Нормализација максималном вредношћу усвојена је и за регресиони и за класификациони модел.


5.3 Регресиони модел за предикцију параметара микрофона

Регресија је предиктивна техника моделовања која проналази везе између зависне променљиве (циљ) која има континуалне вредности и независне променљиве или променљивих (предиктор). Регресија проналази циљну функцију, користећи расположиве податке, која може да укалупи улазне податке са минималном грешком, откривајући истовремено и снагу утицаја независних променљивих на зависну. У овом истраживању регресиона техника моделовања је коришћена за карактеризацију

микрофона, односно предикцију пет параметара микрофона који добро описују његово понашање [54].

5.3.1 Дискусија - архитектура и хиперпараметари модела

Развој модела машинског учења је емпиријски процес, заснован на препорукама у научној и стручној литератури [60][61][70][71][72][73][74][75][76][77][78][79], искуству и интуицији. У итеративном процесу идеја, програмски код и експеримент у одређеном броју итерација дефинишу се вредности хиперпараметара модела: број скривених слојева у вишеслојној неуронској мрежи, број неурона у сваком слоју, вредност корака обучавања, избор активационе функције, димензија мини бача, вредности моментум параметара, број епоха и димензија тренинг, валидационог, тест скупа података, слика 19.



Слика 19: Итеративни процес развоја модела машинског учења

У представљеном истраживању као метод провере избора оптималних вредности хиперпараметара коришћена је крос-валидација кроз евалуацију перформанси модела. С обзиром на постављене захтеве следеће перформансе су сматране значајним: тачност модела (процент примерака тест скупа података за које важи да је средње одступање од тачне вредности у процентима од тачне вредности $\geq 5\%$), средње одступање од тачне вредности у процентима од тачне вредности, конвергенција функције цене и потребна рачунарска снага.

Крос-валидација је статистички модел, у чијој основи је провера ван узорка (енг. out-of-sample), односно провера на улазне податке изван тренинг скупа података [51]. Јединствени скупа података је подељен на одређени број група, који представља параметар k процедуре. Најчешће примењена вредност овог параметра је 10, што је овде и усвојено. Извршава се у неколико корака:

1. измешати податке,
2. поделити скупа података на k група,

3. за сваку јединствену групу урадити:
 1. дату групу прогласити тест скупом података или тзв. задржаним (енг. hold out) скупом података,
 2. преостале групе сјединити у тренинг скуп,
 3. евалуацију модела урадити на тест скупу података,
4. средња вредност тачности модела из свих итерација се узима за тачност ван узорка.

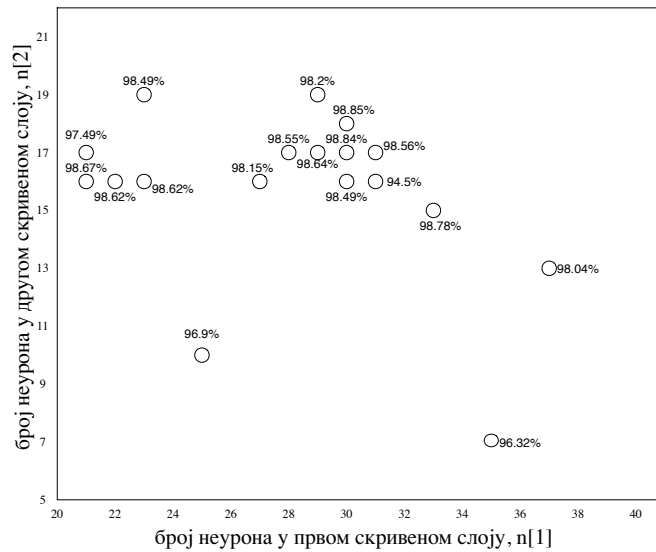
Полазна хипотеза овог истраживања је да ће за представљени регресиони проблем машинског учења добра својства показати вишеслојна неуронска мрежа.

Улазни вектор вишеслојне неуронске мреже према пропозицијама фотоакустичног експеримента има 400 елемената, при чему је узета у обзир и чињеница да модели са више слојева и великим бројем неурона у скривеним слојевима нису осетљиви на број улазних обележја. Првих 200 елемената су одбирци амплитудске карактеристике микрофона чија је фреквенција модулације узета на подједнаким растојањима логаритамске осе, у фреквентном опсегу 10-100 000 Hz. Других 200 елемената су одбирци фазне карактеристике дистрибуирани на исти начин.

Излазни вектор вишеслојне неуронске мреже има 5 елемената и то су циљни параметри микрофона: f_2 , карактеристична фреквенција микрофона повезана са његовим RC карактеристикама, f_3 и f_4 , карактеристичне акустичне резонанце микрофона и реципрочне вредности фактора добротe ξ_3 и ξ_4 . Вишеслојна неуронска мрежа са 5 излаза усвојена је као логично решење с обзиром на постављене захтеве за штедњом рачунарске снаге [16][69].

За развој модела коришћена је база података за микрофон ЕСМ30В и узорак од алуминијума. База се састоји од 67 500 записа. Извршена је подела на тренинг, валидациони и тест скуп у следећем односу димензија: тренинг скуп – 57 500 записа или 82.6% оригиналног скупа података, валидациони и тест скуп – 5 000 записа или 8.7% оригиналног скупа података, под претпоставком да су димензије валидационог и тест скупа података довољно велике и да ће функција цене одређена на ова два скупа података добро фитовати функцију цене тренинг скупа.

Узимајући у обзир број улаза и број излаза неуронске мреже, претпостављена је почетна структура неуронске мреже са два скривена слоја [61].



Слика 20: Анализа броја неурона у првом и другом скривеном слоју

Број неурона у првом и другом скривеном слоју одређен је на основу следеће анализе. Посматран је дводимензионални простор ова два хиперпараметра [61], слика 20, изабран је опсег од 20 до 40 за број неурона у првом скривеном слоју и опсег од 5 до 20 за број неурона у другом скривеном слоју. Примењено је случајно одабирање [63] и тестиране утврђене перформансе модела, а да остали хиперпараметри модела нису мењани. С обзиром на анализирани хиперпараметре, 18 различитих модела је тестирано. Примењен је следећи принцип: када је остварен добар резултат зумиран је регион око тог резултата и са већом густином су узимане вредности за број неурона у првом и број неурона у другом скривеном слоју мреже. Слика 20 показује да су се у овој анализи издвојила два региона добрих резултата. Из ових региона издвојена су три модела са највећом тачношћу посматрано у односу на осталих 15 модела и примењена је крос-валидација за сваки од њих. Средње вредности одступања представљене су у табели 2.

Табела 2: Резултати крос-валидације за различит број неурона у скривеним слојевима


Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Модел (30,17)	0.05568621	0.09077836	0.05424437	1.06229732	0.97844375

Модел (21,16)	0.0590526	0.08683182	0.07522292	0.88970101	1.11674051
Модел (30,18)	0.043280183	0.103096471	0.059770626	1.0462439	0.962344711

Додатно, анализом конвергенције функције цене [72] на тест скупа података, слика 21, закључујемо да модел са 21 неуроном у првом слоју и 16 неурона у другом слоју интензивно осцилује, што се може сматрати лошим понашањем. Модел са 30 неурона у првом слоју и 17 неурона у другом слоју видљиво мање осцилује. Модел са 30 неурона у првом слоју и 18 неурона у другом слоју очекивано је сличног понашања моделу са 30 неурона у првом слоју и 17 неурона у другом слоју. Додатно трошење рачунарске снаге сматрано је непотребним.

Узимајући у обзир све претходно наведене чињенице закључено је да је 30 неурона у првом скривеном слоју и 17 неурона у другом скривеном слоју оптималан број неурона по слојевима. Овај модел је означен са Модел1 ради даљег поређења.

Како би избор броја скривених слојева био додатно потврђен, извршено је поређење резултата крос-валидације Модела1 са два скривена слоја са по 30 и 17 неурона, секвенцијално са резултатима крос-валидације модела са једним скривеним слојем и 47 неурона, што је једнако збиру броја неурона у првом и броја неурона у другом слоју Модела1, означеном као Модел2. Резултати поређења, табела 3, показују да је почетна претпоставка тачна.




Слика 21: Поређење конвергенције функције цене у случају модела са 21+16 неурона и 30+17 неурона, функција цене тест скупа података је крива са израженим осцилацијама

Даље истраживање броја скривених слојева (на пример 3) није рађено јер је са Моделом1 постигнута довољна тачност дефинисана захтевима пројекта.

Табела 3: Резултати крос-валидације за Модел1 и Модел2


Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Модел1	0.05568621	0.09077836	0.05424437	1.06229732	0.97844375
Модел2	0.07304891	0.13197306	0.08531683	1.52501731	1.25724876

На овом кораку дискусије дефинисана је архитектура модела, слика 22.



Слика 22: Изабрано решење структуре неуронске мреже, [16]

С обзиром на позитивне и негативне вредности улазних података разматране су две могућности за активациону функцију $\tanh()$ и LeakyReLU [2]. Тачност модела за исте остале хиперпараметре и активациону функцију LeakyReLU износила је 95.76% на тест скупа података, што је у поређењу са тачношћу од 98.84% за активациону функцију $\tanh()$ сматрано доста лошијим резултатом, па крос валидација није рађена. Дијаграм функције $\tanh(x)$ приказан је на слици 23:



Слика 23: Дијаграм функције $\tanh()$, преузето са mathworld.wolfram.com/HyperbolicTangent.html

За корак обучавања [61] тестиране су четири вредности 10^{-3} , $3.3 * 10^{-4}$, 10^{-4} и 10^{-5} . Добијене су следеће вредности тачности модела 94.12%, 98.44%, 98.84% и 98.24% респективно. Табела 4 показује упоредне вредности средњег одступања од тачне вредности у процентима од тачне вредности за свих 5 излазних параметара за сваку од четири вредности корака обучавања. На овај начин је дефинисана вредност $\alpha = 10^{-4}$.

Табела 4: Поређење одступања Модела1 за различите вредности корака обучавања

Параметар	f_2	f_3	f_4	ξ_3	ξ_4
$\alpha = 10^{-3}$	0.01699083	0.23158267	0.1289954	2.321524	3.5612993
$\alpha = 3.3 * 10^{-4}$	0.0239851	0.21946612	0.05330153	1.1695489	1.1361622
$\alpha = 10^{-4}$	0.03588826	0.0637139	0.03934723	0.66793483	0.74441785
$\alpha = 10^{-5}$	0.06927925	0.11404843	0.09871689	1.0137877	1.1061128

Претпоставка о нормализацији података максималном вредношћу [3] доказана је поређењем перформанси модела у три случаја, табела 5. Тестирано је понашање модела са подацима нормализованим зед-скором и F нормом.


Табела 5: Поређење перформанси модела у случају различитих метода нормализације

Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Z-score	0.08930077	0.12761407	0.03709306	2.2586846	2.8044379
F норм	0.05823666	1.6414738	0.70049524	7.7628007	11.173368
Norm max	0.03588826	0.0637139	0.03934723	0.66793483	0.74441785

Вредности појединих хиперпараметара модела усвојене су као подразумеване на основу препорука које се могу наћи у литератури. То су димензија мини-бача (енг. mini-batch) =32 [61], Xavier алгоритам за иницијализацију тежинских параметара [62] и моментум параметри [66]:

$$\beta_1 = 0.9, \beta_2 = 0.999, \varepsilon = 10^{-8}$$

У тренингу од 3 000 епоха, над скупом од 57 500 записа, Модел1 достиже функцију цене од 10^{-6} . Конвергенција функције цене видљива је већ у првих неколико епоха, што је резултат примене мини-бач методе. Модел улази у сатурацију око 2 500 епоха, слика 24.



Слика 24: Конвергенција функције цене, Модел1, [16]

Тачност у смислу дефиниције постављене датим захтевима је 98.84%. Модел врши предикцију излаза за 14 ms. Коришћен је широко доступан хардвер нивоа канцеларијског (енг. office) рачунара. Закључујемо да Модел1 у потпуности испуњава

постављене захтеве за тачношћу, радом у реалном времену и коришћењем снаге рачунара. Задовољавајућа метрика је у потпуности постигнута, а за оптимизациону метрику недостаје доказ о поузданости модела, што ће бити представљено у наредним поглављима.

Димензија тест и валидационог скупа података одређена је тако да буде довољно велика да добро фитује функцију цене [80]. Димензија од 5 000 записа за тест и валидациони скупа података даје резултате за функцију цене одређене на валидационом и тест скупу врло блиске функцији цене одређене на тренинг скупу, слика 25. Закључујемо да мрежа добро генерализује. Није потребна регуларизација. Вредности хиперпараметара Модела1 систематизоване су у табели 6.


Табела 6: Модел1, вредности хиперпараметара, [16]

Број улаза	Број излаза	Метод нормализације	Број скривених слојева	Број неурона у скривеним слојевима	Активациона функција	Величина тренинг скупа	Величина валидационг скупа=величина тест скупа	Корак обучавања	Моментум параметри	Величина минибача	Број епоха
400	5	Norm max	2	$n[1] = 30,$ $n[2] = 17$	$\tanh()$	57 500	5000	10^{-4}	$\beta_1 = 0.9$ $\beta_2 = 0.999$ $\epsilon = 10^{-8}$	32	3 000

Како би ово истраживање било исцрпно, анализиран је још један модел, означен са Модел 3. Разлика Модела 3 и Модела 1 је у броју неуронских мрежа и броју излаза. Модел 3 има 5 неуронских мрежа са по једним излазом. Идеја је потекла од чињенице о различитом физичком пореклу сваког од параметара микрофона и различитој стабилности параметра у ФА мерењима, односно поновљивости вредности сваког од параметара. Неуронска мрежа Модела1 и неуронске мреже Модела3 имају исте хиперпараметре. Дискусија модела и избор оптималног решења публикован је у раду [69].

Табела 7 је упоредни приказ перформанси модела. Ради комплетности поређења приказане су и перформансе Модела2.

У табели 7 дате су вредности за тзв. рачунарско време и процесорско (енг. CPU) време. Рачунарско време укључује време потребно за учитавање параметара модела (тежинских параметара и биаса) са диска и време израчунавања излаза. CPU време се односи само на време израчунавања.



Слика 25: Функција цене одређена на тренинг скупу, валидационом и тест скупу података, Модел1

Табела 7: Упоредни приказ перформанси Модела1, Модела2 и Модела3, [69]

Средње одступање од тачне вредности у процентима тачне вредности на тренинг скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Модел1(98.86%)	0.03575609	0.06285055	0.03934497	0.6778274	0.7561904
Модел3(99.59%)	0.00367374	0.04975093	0.02321718	0.44225055	0.28317332
Модел2(96.98%)	0.09857772	0.0943098	0.098814	1.3681046	0.9577355
Средње одступање од тачне вредности у процентима тачне вредности на валидационом скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Модел1(98.97%)	0.03625588	0.06239692	0.0393014	0.674228	0.7194665
Модел3(99.34%)	0.00359443	0.05007159	0.02289878	0.4521597	0.31682032
Модел2(97.03%)	0.09865891	0.0927798	0.09756887	1.4194391	0.96946603
Средње одступање од тачне вредности у процентима тачне вредности на тест скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Модел1(98.84%)	0.03588826	0.0637139	0.03934723	0.66793483	0.74441785
Модел3(99.61%)	0.0037558	0.04898341	0.02315352	0.45252872	0.2967481
Модел2(96.98%)	0.09779967	0.09474918	0.09858618	1.3539855	0.92912674
Prediction time					
	CPU време		Рачунарско време		
Модел1	14 ms		31 ms		
Модел3	5x14 ms		5x30 ms		
Модел2	12 ms		29 ms		

Анализом табеле закључујемо да највећу тачност има Модел3, који даје и најмање средње одступање од тачне вредности, и код најнестабилнијих параметра

ξ_3 и ξ_4 . Модел3 међутим троши највише рачунарске снаге. Реализација модела би се могла извршити на једном рачунару када време предикције износи 5x14 ms (5x30 ms) или паралелно на 5 рачунара када је време предикције 14 ms (30 ms). Предност Модела2 је најмање време предикције, али за скоро 2% је мања тачност од Модела1. С обзиром на природу примене модела сматрано је да је 2% велико. Овом анализом доказано је да је Модел1 најпрактичније решење.

5.3.2 Тест модела на независном скупу података

Поузданост изабраног модела тестирана је на независном скупу података [16], одређеном од стране експерата, као симулација могућих исхода ФА експеримента. Испитано је 5 различитих амплитудско-фреквентних и фазно-фреквентних карактеристика микрофона, код којих су вредности параметара микрофона различите од оних на којима је мрежа обучавана, али су у датом опсегу. Вредности амплитуда и фаза узете су у истим корацима на фреквентној оси као за тренинг и евалуацију мреже. За Тест1 промењено је свих пет параметара у теоријском моделу f_2, f_3, f_4, ξ_3 и ξ_4 , добијене су амплитудско-фреквентна и фазно-фреквентна карактеристика одмерене у 200 тачака, укупно 400 улаза трослојне неуронске мреже. Тест2 је добијен променом f_2, f_3, f_4 , док је вредности за ξ_3 и ξ_4 мрежа већ “видела”. У Тесту3 ξ_3 и ξ_4 су промењени док су f_2, f_3, f_4 непромењени. У Тесту4 мењано је f_3 и ξ_3 , а у Тесту5 f_4 и ξ_4 . Резултати независних тестова приказани су у табели 8.

Табела 8: Резултати независних тестова, регресиони модел, [16]

НЕЗАВИСНИ ТЕСТОВИ					
ТЕСТ1					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.425E+01	9.505E+03	1.4536E+04	9.0E-01	1.50E-01
Предикција	2.42443E+01	9.49677E+03	1.45353E+04	9.00662E-01	1.49836E-01
Девиијација (abs)	5.7E-03	8.23E+00	7E-01	6.62E-04	1.64E-04
Девиијација (%)	2.35E-02	8.659E-02	4.816E-03	7.356E-02	1.093E-01
Време предикције	Рачунарско_време = 32 ms, CPU_време = 13.5 ms				
ТЕСТ2					

Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.425E+01	9.505E+03	1.4536E+04	7.50E-02	8.70E-01
Предикција	2.42195E+01	9.49823E+03	1.45338E+04	7.55838E-02	8.69804E-01
Девијација (abs)	3.05E-02	6.77E+00	2.2E+00	5.838E-04	1.96E-04
Девијација (%)	1.258E-01	7.122E-02	1.513E-02	7.784E-01	2.253E-02
Време предикције	Рачунарско_време = 32 ms, CPU_време = 14 ms				
ТЕСТ3					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.625E+01	9.658E+03	1.5432E+04	8.30E-01	7.20E-01
Предикција	2.62531E+01	9.65119E+03	1.54429E+04	8.30980E-01	7.19916E-01
Девијација (abs)	3.1E-03	6.81E+00	1.09E+01	9.8E-04	8.4E-05
Девијација (%)	1.181E-02	7.051E-02	7.063E-02	1.181E-01	1.167E-02
Време предикције	Рачунарско_време = 33 ms, CPU_време = 14 ms				
ТЕСТ4					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.500E+01	9.696E+03	1.5432E+04	8.30E-01	7.50E-02
Предикција	2.50089E+01	9.68688E+03	1.54350E+04	8.30888E-01	7.54828E-02
Девијација (abs)	8.9E-03	9.12E+00	3.0E+00	8.88E-04	4.828E-04
Девијација (%)	3.56E-02	9.406E-02	1.944E-02	1.070E-01	6.437E-01
Време предикције	Рачунарско_време = 32 ms, CPU_време = 14 ms				
ТЕСТ5					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.500E+01	9.658E+03	1.4536E+04	5.70E-01	9.00E-01
Предикција	2.50061E+01	9.65047E+03	1.45404E+04	5.71631E-01	8.98996E-01
Девијација (abs)	6.1E-03	7.53E+00	4.4E+00	1.631E-03	1.004E-03
Девијација (%)	2.44E-02	7.797E-02	3.027E-02	2.861E-01	1.116E-01
Време предикције	Рачунарско_време = 32 ms, CPU_време = 14 ms				

Максимално одступање од тачних вредности за параметар f_2 је реда величине 0.1 % тачне вредности. Максимално одступање од тачних вредности за параметар f_3 је реда величине 0.09 % тачне вредности, за параметар f_4 је реда величине 0.07 % тачне

вредности, за параметар ξ_3 је реда величине 0.8 % тачне вредности, док је максимално одступање од тачних вредности за параметар ξ_4 реда величине 0.6 % тачне вредности. Највеће одступање од тачних вредности је код параметара ξ_3 и ξ_4 што није изненађујуће јер су ова два параметра теоријски веома нестабилна и зависе од великог броја других параметара. Може се закључити да мрежа добро интерполира излазе, јер постиже мало одступање од тачних вредности за случај непознатих вредности параметара у опсегу тренинг вредности. Поузданост модела је добра, а како је претходно показано да тачност модела задовољава постављене захтеве, тиме је постигнута оптимизациона метрика. Пошто је већ констатовано да је усвојени модел постигао задовољавајућу метрику, може се извести закључак да усвојени модел задовољава у потпуности евалуациону метрику.

5.3.3 Тест модела на подацима са шумом

Како би се узели у обзир стварни услови експеримента, односно експериментална несигурност, проверене су перформансе мреже код података са унетим случајним шумом у опсегу $\pm 5\%$ од теоријско предвиђених вредности, на неке примере из базе података [16]. Тестови 6, 7 и 8 су подаци са шумом. Резултати су приказани у табели 9. Закључујемо да мрежа на одступање експеримента одговара већим одступањем од тачних вредности, односно уграђује несигурност у свој излаз. То ће само у екстремним случајевима велике експерименталне несигурности направити веће одступање од тачних вредности, као што се десило у Тесту7, али с обзиром да су такви случајеви ретки може се закључити да шум неће генерално реметити рад регресионог модела.

Табела 9: Перформансе регресионог модела у условима експерименталне нестабилности, [16]

ЕКСПЕРИМЕНТАЛНА НЕСТАБИЛНОСТ					
ТЕСТ6					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.375E+01	9.40E+03	1.470E+04	2.70E-01	5.70E-01
Предикција	2.35979E+01	9.45269E+03	1.47199E+04	2.62567E-01	5.64571E-01
Девијација (abs)	1.521E-01	5.269E+01	1.99E+01	7.433E-03	5.429E-03

Девиијација (%)	6.404E-01	5.605E-01	1.354E-01	2.753E+00	9.524E-01
Време предикције	Computation_time = 31 ms, CPU_time = 14 ms				
ТЕСТ7					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.50E+01	9.40E+03	1.470E+04	2.70E-01	5.70E-01
Предикција	2.49779E+01	9.41556E+03	1.48160E+04	2.45943E-01	5.95208E-01
Девиијација (abs)	2.21E-02	1.556E+01	1.16E+02	2.406E-02	2.521E-02
Девиијација (%)	8.84E-02	1.655E-01	7.891E-01	8.91E+00	4.423E+00
Време предикције	Computation_time = 32 ms, CPU_time = 14 ms				
ТЕСТ8					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.625E+01	9.40E+03	1.470E+04	5.70E-01	2.70E-01
Предикција	2.630E+01	9.39938E+03	1.46657E+04	5.83379E-01	2.79566E-01
Девиијација (abs)	5.0E-02	6.2E-01	3.43E+01	1.338E-02	9.566E-03
Девиијација (%)	1.905E-01	6.596E-03	2.333E-01	2.347E+00	3.543E+00
Време предикције	Computation_time = 32 ms, CPU_време = 14 ms				

5.3.4 Поређење перформанси модела за три различита микрофона

Током развоја модела коришћени су симулирани подаци добијени на основу техничких података за микрофон ЕСМ30В и узорак материјала од алуминијума. Перформансе модела су проверене над подацима за још два често коришћена типа микрофона у ФА експерименту: ЕСМ60 и WM66, док је узорак остао исти [17]. У овом тестирању модела смањен је опсег улазних података на домен фреквенција врло често коришћен у ФА мерењима, од 20 Hz до 20 kHz. На овај начин проверава се и толеранција модела на смањење броја обележја. Резултати за сва три типа микрофона приказани су у табели 10.

Табела 10: Перформансе регресионог модела за три комерцијална микрофона најчешће коришћена у ФА мерењима [17]

Средње одступање од тачне вредности изражено у процентима тачне вредности на тренинг скупу податка за микрофон ЕСМ30В (фреквенцијски опсег 20-20 000 Hz), тачност = 98.68%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07132456	0.14649154	0.05109024	0.74361974	0.967724
Средње одступање од тачне вредности изражено у процентима тачне вредности на валидационом скупу податка за микрофон ЕСМ30В (фреквенцијски опсег 20-20 000 Hz), тачност = 98.73%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07109252	0.14936025	0.05018261	0.73954904	0.95961267
Средње одступање од тачне вредности изражено у процентима тачне вредности на тест скупу податка за микрофон ЕСМ30В (фреквенцијски опсег 20-20000 Hz), тачност = 98.46%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07197632	0.14702412	0.05081375	0.78105694	1.0586549
Време предикције за микрофон ЕСМ30В (фреквенцијски опсег 20-20000 Hz)					
CPU време			Рачунарско време		
14 ms			40ms		
Средње одступање од тачне вредности изражено у процентима тачне вредности на тренинг скупу података за микрофон ЕСМ60(фреквентни опсег 20-20 000 Hz), тачност = 98.5%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.08030392	0.06785115	0.06096664	0.7990959	1.0014774
Средње одступање од тачне вредности изражено у процентима тачне вредности на валидационом скупу података за микрофон ЕСМ60 (фреквентни опсег 20-20000 Hz), тачност = 98.5%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07929239	0.0674798	0.06169094	0.76554894	1.0300709
Средње одступање од тачне вредности изражено у процентима тачне вредности на тест скупу података за микрофон ЕСМ60 (фреквентни опсег 20-20 000 Hz), тачност = 98.44%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.08065586	0.06766558	0.06113705	0.8405477	1.0059946
Време предикције за микрофон ЕСМ60 (фреквентни опсег 20-20 000 Hz)					
CPU време			Рачунарско време		
13 ms			35ms		
Средње одступање од тачне вредности изражено у процентима тачне вредности на тренинг скупу података за микрофон WM66 (фреквентни опсег 20-20 000 Hz), тачност = 98.87%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07622549	0.07398161	0.06836206	0.6666061	0.7081819
Средње одступање од тачне вредности изражено у процентима тачне вредности на валидационом скупу података за микрофон WM66 (фреквентни опсег 20-20 000 Hz), тачност = 98.93%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07429651	0.07452826	0.06824242	0.6592338	0.6810206
Средње одступање од тачне вредности изражено у процентима тачне вредности на тест скупу података за микрофон WM66 (фреквентни опсег 20-20 000 Hz), тачност = 98.68%					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
	0.07601995	0.07425365	0.06885304	0.7398573	0.7364045
Време предикције за микрофон WM66 (фреквентни опсег 20-20000 Hz)					
CPU време			Рачунарско време		
14 ms			41 ms		

На основу табеле 10 може се извести закључак да су перформансе модела за сва три микрофона за смањени опсег улазних података задовољавајуће по свим задатим критеријумима: тачност, средње одступање од тачне вредности и брзина обраде. Тачност модела за сва три типа микрофона креће се у опсегу 98.46% до 98.93%, односно тачност за различите типове микрофона је приближних вредности. Такође средње одступање од тачне вредности за свих пет параметара посматрано за сва три типа микрофона нема већих одступања. Време предикције је приближно исто.

С обзиром на могућност примене усвојеног модела на више различитих типова микрофона са скоро истим перформансама модела за сваки тип микрофона и могућности избора опсега улазних података у зависности од потреба експеримента, усвојени модел би се могао сматрати генералним регресионим моделом за ФА инверзни проблем. Очекује се ће модел показати слично понашање и за друге типове микрофона који нису обухваћени овим истраживањем.

5.4 Класификациони модел

Класификација је проблем машинског учења који предвиђа класу инстанцама из скупа података. То је предиктивна техника моделовања којом се апроксимира функција мапирања улазне променљиве у дискретну излазну променљиву [54]. Постоји више типова класификације у машинском учењу:

- бинарна класификација, која се односи на проблеме који имају две класе,
- мултикласна класификација, која се односи на проблеме који имају више од две класе,
- класификација са више лабела, која се односи на проблеме где се једна или више класних лабела може доделити свакој инстанци података,
- небалансирана класификација, која се односи на проблеме где број инстанци у свакој класи није једнако дистрибуиран.

У овом истраживању класификациона техника моделовања коришћена је за предикцију типа микрофона од могућа четири, значи у питању је мултикласна класификација. Број класа у класификационом проблему је могуће повећати, ако такви захтеви ФА експеримента постоје.

5.4.1 Дискусија - архитектура и хиперпараметри модела

Полазна хипотеза овог истраживања је да ће за представљени класификациони проблем машинског учења добра својства показати вишеслојна неуронска мрежа.

Итеративни процес развоја класификационог модела и подешавања хиперпараметара олакшан је искуством у развоју претходно описаног регресионог модела, с обзиром да се ради о истим подацима.

База података за класификациони проблем добијена је спајањем база података за сваки од претходно поменутих микрофона: ЕСМ30В, ЕСМ60 и WM66, са додатком базе података за идеални микрофон, укупно 270 000 записа. На крај сваког записа додата је информација о типу микрофона од посматраних 4, коме тај запис припада. Тако, класификациони проблем има 4 класе, симболично презентоване са 0, 1, 2 и 3. Подела базе података на тренинг, валидациони и тест скупа извршена је у следећем односу димензија: 243 000 записа или 90% укупног броја записа садржи тренинг скуп, по 13 500 записа или 5% укупног броја записа садрже валидациони и тест скуп.

Усвојени су следећи хиперпараметри: корак обучавања 10^{-4} , моментум параметри $\beta_1 = 0.9, \beta_2 = 0.999, \epsilon = 10^{-8}$ [66], Xavier алгоритам за иницијализацију тежинских параметара [62], нормализација максималном вредношћу, активациона функција $\tanh()$ осим у излазном слоју где је због постојања више класа изабрана функција софтмакс:

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad (90)$$

Број елемената улазног вектора неуронске мреже је 400, 200 су одбирци амплитудске карактеристике микрофона чија је фреквенција модулације узета на једнаким растојањима у фреквентном опсегу 10-100 000 Hz, других 200 елемената су одбирци фазне карактеристике дистрибуирани на исти начин.

Излазни вектор неуронске мреже има 4 елемента, то су четири класе које представљају четири типа микрофона ЕСМ30В, ЕСМ60, WM66 и идеални микрофон. Ако је вредност једног излаза 1, остали излази морају имати вредност 0, а то значи да посматрани микрофон припада селектованој класи (излаз=1).

За функцију цене у посматраном моделу изабрана је софтмакс крос ентропија (енг.softmax_cross_entropy_with_logits) која је у кореспонденцији са активационом функцијом излазног слоја неуронске мреже.

Почетна разматрања су архитектура модела са два и са једним скривеним слојем. Анализа броја неурона у скривеним слојевима дата је табелом 11. Пошло се од претпоставке да је укупан број неурона једнак 10, што је дало добре резултате тачности модела 99.99% и ефикасности тренинга од 100 епоха, сем у случају структуре са два скривена слоја конфигурације 9+1.

Табела 11: Анализа броја скривених слојева и броја неурона у скривеним слојевима, класификациони модел

Бр. скр. слојева	1	2	2	2	1	2	2	1	2	2	1	2	1
Бр. неу. 1.скр сл.	10	8	7	9	5	3	4	4	2	3	3	2	2
Бр. неу. 2.скр. сл.	/	2	3	1	/	2	1	/	2	1	0	1	0
Тач. на тр. ск(%)	99.99	99.99	99.99	75.02	99.99	99.99	50.03	99.99	99.99	81.15	99.99	75.01	99.99
Тач. на ва.ск.(%)	99.99	99.99	99.99	74.15	99.99	99.99	49.19	99.99	99.99	82.09	99.99	75.03	99.99
Тач. на тес.ск(%)	99.99	99.99	99.99	75.45	99.99	99.99	50.15	99.99	99.99	81.11	99.99	74.7	99.99
Бр. епоха	100	100	100	100	100	100	100	100	100	100	100	100	100
Вр. пред. (ms)	14.34	17.89	17.44	/	14.06	16.75	/	13.89	16.89	/	13.73	/	13.93

Један неурон у другом скривеном слоју у конфигурацији са два скривена слоја се очекивано показао потпуно неодговарајући према броју излаза, што су потврдили тестови и других конфигурација са једним неуроном у другом скривеном слоју, табела 11. Ове конфигурације су одбачене. Укупан број неурона је затим преполовљен, и испитане су све могуће такве конфигурације са једним или два скривена слоја. Тестирање се наставило са сукцесивним смањењем укупног броја неурона.

Анализом табеле могу се извући следећи закључци. Не постоји разлика у тачности модела за случај конфигурације са једним скривеним слојем и

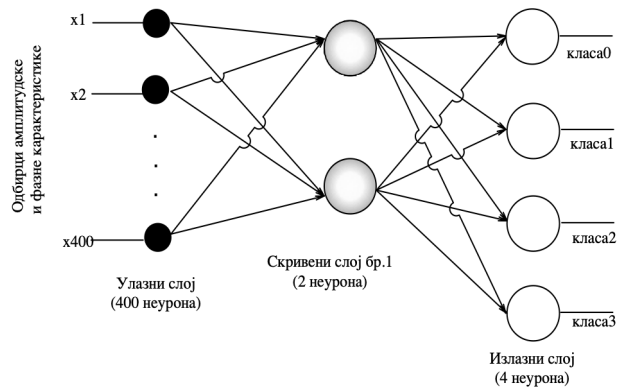
конфигурације са два скривена слоја за исти укупан број неурона. На основу експерименталног искуства може се рећи да за друге проблеме машинског учења то није случај. Ово је специфичност овог конкретног проблема. Очекивано, време предикције је мање за конфигурацију са једним слојем и исти број неурона у односу на конфигурацију са два слоја. Топологија, као и избор параметара и хиперпараметара модела је специфичност конкретног проблема машинског учења, као и квалитета и количине доступних података [81]. Минимална конфигурација која задовољава захтевану тачност је један скривени слој са 2 неурона, слика 26. Значи, једноставна мрежа са малим бројем неурона. Оваква структура неуронске мреже се објашњава великим тренинг скупом података, добрим избором хиперпараметара и једноставношћу проблема (4 класе). Велики скупови података уносе у модел велико знање о проблему [53], а у случају класификационог проблема представљеног у овом истраживању знање о ФА експерименталном окружењу. Генерално, за исти проблем машинског учења, повећање скупа података смањује број јединица израчунавања (неурона) [52], чиме мрежа постаје рачунарски једноставнија. Користећи знање из података моделу је потребно мање рачунарске снаге и мањи број епоха за учење.

Модел омогућава лако повећање броја класа, ако такви захтеви ФА експеримента постоје. То ће, вероватно, довести до усложњавања постојеће архитектуре.

Поређењем времена предикције за различите топологије класификационог модела, закључујемо да највећи утицај на брзину обраде има број скривених слојева, док број неурона у скривеним слојевима има мањи утицај чак и када је разлика у броју неурона знатна.

Јасно је да се усвојени класификациони модел са приказаном једноставном конфигурацијом неуронске мреже може извршити на широко доступном хардверу.

Усвојени модел задовољава постављене захтеве за тачношћу, радом у реалном времену и коришћењем снаге рачунара, постигнута је задовољавајућа метрика, док за оптимизациону метрику недостаје доказ о поузданости модела, који следи у наредном поглављу.



Слика 26: Усвојено решење структуре класификационог модела

5.4.2 Тест модела на независном скупу података

Поузданост изабраног модела тестирана је на независном скупу података, одређеном од стране експерата: Тест1, настао променом свих пет параметара f_2 , f_3 , f_4 , ξ_3 и ξ_4 у теоријском моделу, где су добијене амплитудско-фреквентна и фазно-фреквентна карактеристика одмерене у 200 тачака са кораком истим као за тренинг мреже; Тест2 добијен променом f_2 , f_3 , f_4 док су вредности за ξ_3 и ξ_4 непромењене. Тест3, где су ξ_3 и ξ_4 промењени, док су f_2 , f_3 , f_4 непромењени; Тест4 где је мењано f_3 и ξ_3 , Тест5 где је мењано f_4 и ξ_4 . За све тестове вредности параметара микрофона различите су од оних на којима је мрежа обучавана, али су у датом опсегу вредности параметара. За сваки микрофон направљено је ових 5 тестова, укупно 20. Резултати независних тестова приказани су у табели 12.

Табела 12: Резултати независних тестова, класификациони модел

Тест	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Класификација неуронском мрежом	1	3	0	2	1	2	3	0	2	0	1	2	1	0	3	0	3	3	1	2
Тачност	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Тачност класификације: 100%, просечно време предикције: 13 ms																				

На основу табеле 12 закључујемо да је усвојени класификациони модел поуздан, прецизно препознаје тип микрофона и за вредности параметара које мрежа “није видела“. Модел даје одговор о типу микрофона у реалном времену. Овим је

доказана поузданост модела, а тиме је постигнута оптимизациона евалуациона метрика.

6 Практична примена развијених модела

Други постављени циљ овог истраживања је развој две методе, методе за аутокорекцију сигнала и методе за калибрацију мерења користећи развијени регресиони и класификациони модел, тако да се истовремено минимизују два објективна показатеља перформанси модела: грешка предикције и време предикције. Успешност метода проверена је тестирањем на ФА реалним експерименталним сигнаlima.

6.1 Прилагођавање експерименталних података моделу

Евалуацијом развијених модела за предикцију типа и карактеристичних параметара микрофона издвојена су њихова ограничења. Неопходан услов за поуздан рад неуронске мреже је - расподела фреквенција улазног вектора мора бити иста као у тренирању мреже. Овај услов јесте ограничење, које важи за оба модела. То значи да се одабирање амплитудске и фазне карактеристике сигнала мора извршити на истим фреквенцијама као и код тренинг, валидационог и тест скуп података. У реалним експерименталним условима проблем не преклапања фреквенција између експеримента и симулација је очекиван, и у овом истраживању решен је интерполацијом. Коришћен је CubicSpline метод који извршава процену вредности користећи полиноме трећег реда који пролазе кроз контролне тачке [82]. Минимизира се укупна кривина површина, а резултат је глатка површина која пролази кроз улазне тачке. У случају интерполације ФА експерименталних вредности одступање од тачних вредности је реда величине 10^{-3} , што је сматрано добрим резултатом, па је овај метод усвојен као процедура предпроцесирања експерименталног сигнала за примену модела [17][18].


6.2 Метода за аутокорекцију сигнала

За развој методе за аутокорекцију ФА сигнала дефинисани су следећи захтеви - систем извршава корекцију улазног сигнала (изобличени ФА одзив) тако да је излаз

“прави” сигнал који потиче само од испитиваног узорка. Обрада се извршава у реалном времену.

Развој методе је заснован на претходно развијеном регресионом и класификационом моделу, који препознају трансфер функцију микрофона у фреквентном домену, као прецизну репрезентацију одзива микрофона у фреквентном домену. Поступак подразумева одређивање типа микрофона и његових карактеристичних параметара уско повезаних са филтерским својствима микрофона. Добијени подаци су од пресудног значаја за процедуру корекције сигнала, чији је резултат “прави”, неизобличен сигнал. Такав сигнал се даље користи у процесу карактеризације материјала, за тачно, прецизно и поуздано одређивање параметара испитиваног узорка [17].

Потпуни опис фреквентног одзива микрофона изискује специфичне детаље који се могу сврстати у неколико различитих класа, а односе се на облик трансфер функције и различите нивое појачања и слабљења сигнала. Разликујемо раван одзив микрофона и одзив са обликом, слика 27. Равна крива одзива је скоро равна линија, указујући на то да је мерни ланац скоро подједнако осетљив дуж целог фреквентног опсега, тако да је сигнал $\sigma p_{total}(f)$ пренесен без изобличења ($S(f) = \sigma p_{total}(f)$). Крива одзива са обликом има структуру са пиковима и долинама указујући да је микрофон више осетљив на одређеним фреквентним опсезима у поређењу са другим, тако да је сигнал $\sigma p_{total}(f)$ пренесен са одређеним степеном изобличења.



Слика 27: Типична трансфер функција - крива одзива са обликом и равна крива одзива (а) амплитуда и (б) фаза у ФА мерењима [17]

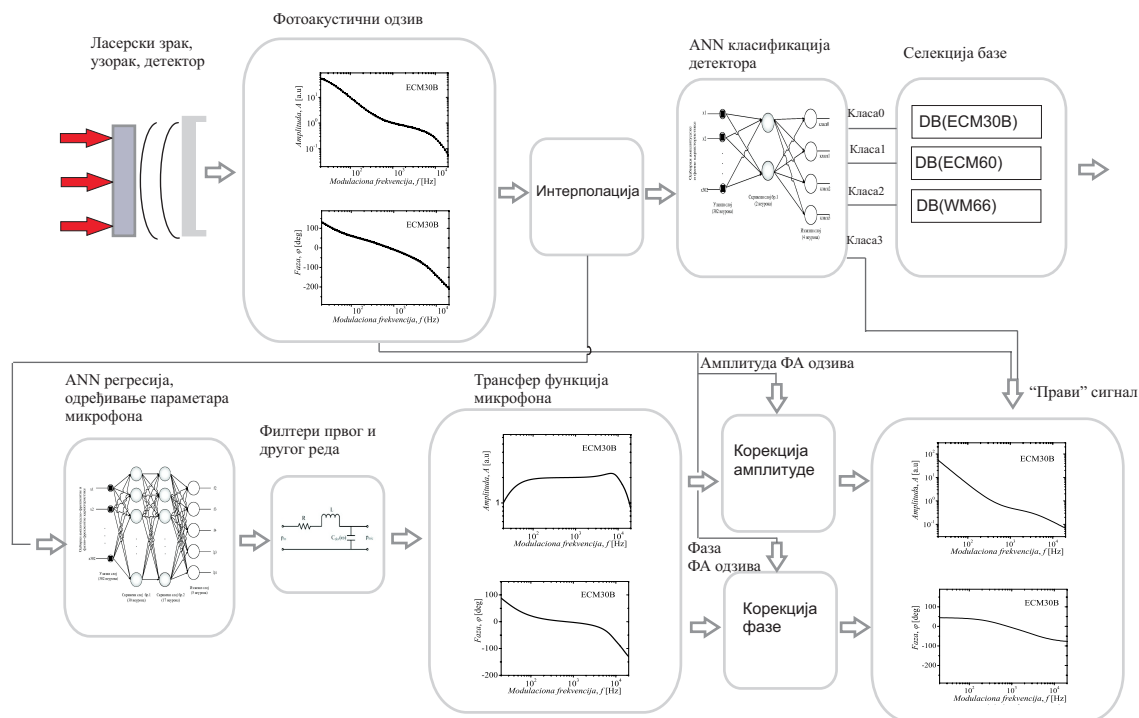
Све класе се могу поистоветити са различитим типовима микрофона. Управо у овоме је значај и корист развијеног класификационог модела. Овом методом

регресиони и класификациони модел су спрегнути на такав начин да класификациони модел најпре препознаје облик трансфер функције који одговара специфичном типу микрофона, а потом регресиони модел предвиђа нумеричке вредности параметара који одговарају том облику трансфер функције у фреквентном домену.

У оваквој поставци класификациони модел убрзава процес обраде резултата ФА мерења, препознавањем типа криве фреквентног одзива: ако је препознат раван облик криве, сигнал $S(f)$ није изобличен и аутоматски је прослеђен на излаз, ако препозната крива одзива има облик, што је типични одзив у ФА мерењима, тиме је сигнал $S(f)$ изобличен и класификациони модел има задатак да препозна који тип микрофона има такав одзив. На основу информације добијене од класификационог модела врши се избор регресионог модела тренираног над базом која одговара препознатом типу микрофона. Сигнал се затим прослеђује регресионом моделу који предвиђа карактеристичне параметре f_2, f_3, f_4, ξ_3 и ξ_4 . Тако, уместо да се користи једна база за све типове микрофона и један регресиони модел, што би био комплекснији задатак, користи се само база за дати микрофон који је препознат од стране класификационог модела. На овај начин време обраде је знатно смањено.

Одређена трансфер функција микрофона, који се користи у експерименту, даље се прослеђује у процедуру корекције ФА сигнала. Резултат је “прави”, неизобличени сигнал који се даље користи за одређивање термичких, механичких и оптичких карактеристика испитиваног узорка.

На слици 28 је приказана блок шема методе. ФА одзив експерименталне поставке измерен у одређеном броју тачака представља улазни сигнал. Примењује се алгоритам интерполације над улазним сигналом. Интерполирани ФА одзив је потом улаз класификационог модела. Излаз је тип микрофона, који се користи као детектор у експерименталној поставци. Даље, класа микрофона одређује одговарајућу базу података. Регресиони модел, трениран на селектованој бази података, предвиђа циљне параметре микрофона. Тип микрофона и карактеристични параметри одређују трансфер функцију микрофона у фреквентном домену, која улази у процедуру корекције сигнала. Резултати корекција су амплитудна и фазна карактеристика “правог” ФА сигнала. У случају класе 3 (ИМ) регресија се не извршава, експериментални сигнал је управо “прави” ФА сигнал.




Слика 28: Блок шема методе за аутокорекцију изобличеног експерименталног сигнала, [17]

Тестирање методе обављено је на три експериментална сигнала. За сва три експеримента коришћен је узорак алуминијума, док су као детектори коришћени различити типови микрофона: ECM30B, ECM60 и WM66.


На слици 29 је представљен ФА експериментални $S(f)$ (а) амплитудски и (б) фазни одзив у случају истог алуминијумског узорка мереног са ECM60, ECM30B и WM66 заједно са симулираним ИМ одзивом. Ови сигнали се класификују на следећи начин: ако је ECM60, ECM30B или WM66 препознат, примењен је одговарајући регресиони модел да пронађе карактеристичне параметре сваке обликоване $H(f)$ трансфер функције. Ако је ИМ препознат, регресија није потребна, трансфер функција је равна, $H(f) = 1$ и сматра се да нема дисторзије сигнала.

На слици 30 је представљена добијена трансфер функција $H(f)$ (а) амплитудска и (б) фазна сваког типа микрофона. Раван ИМ одзив приказан на овој слици је добра апроксимација пошто овај микрофон такође има својих 5 карактеристичних параметара али са фреквенцијама f_2, f_3, f_4 лоцираним ван ФА опсега модулационе фреквенције. Ова ситуација, у реалности, може се једноставно постићи променом материјала мембране (на пр. никл или графен уместо Mylar).

Пратећи процедуру корекције сигнала [40][10] описану у поглављу 2.3, $\delta p_{total}(f)$ је одређена на основу а) експерименталног сигнала $S(f)$, слика 29 и б) трансфер функције $H(f)$ са слике 30. У свим случајевима $\delta p_{total}(f)$ је исти, као што се види на слици 31. То је управо и жељени резултат, јер се исти узорак алуминијума користио у сва три експеримента и потврда тачности и поузданости развијене методе. $\delta p_{total}(f)$ представља “прави” сигнал који потиче само од узорка и не зависи од примењеног детектора-микрофона. Утицај мерног ланца у потпуности је елиминисан и на основу њега може се извести комплетна карактеризација испитиваног узорка.

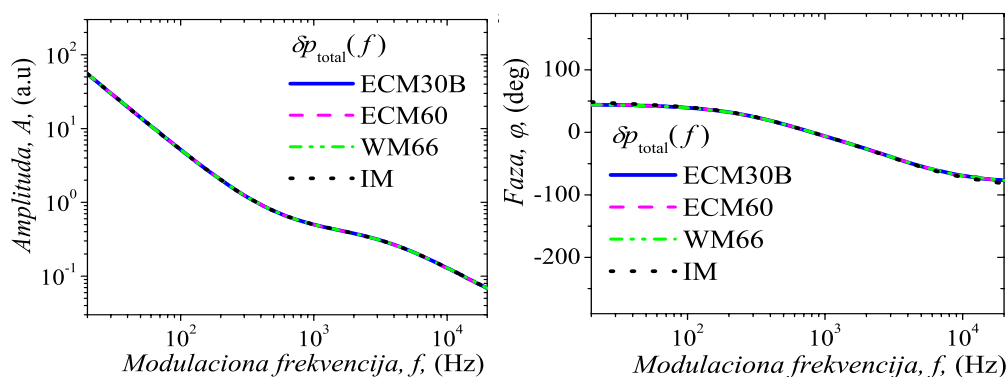


Слика 29: Експериментални $S(f)$ ФА одзив (а) амплитуда, A , и (б) фаза, φ , у функцији модулатионе фреквенције f , у случају истог узорка алуминијума мереног различитим типовима микрофона: ЕСМ60 (магента крива), ЕСМ30В (плава крива), WM66 (црвена крива) и ИМ (црна крива), [17]



Слика 30: Добијена $H(f)$ трансфер функција (а) амплитуда и (б) фаза као функција модулатионе фреквенције f , за сваки тип микрофона као и на слици 29, [17]

Слика 31 представља ФА одзив који потиче од алуминијумске плоче са основним физичким параметрима: термална дифузивност (D_T), $8.64 * 10^{-5} m^2 s^{-1}$, термална проводност (k), $210 W m^{-1} K^{-1}$, коефицијент термалне експанзије (α_T), $23.1 * 10^{-6} K^{-1}$ и дебљина (l) $197 \mu m$.



Слика 31: “Прави” сигнал $\delta p_{total}(f)$ као функција модулационе фреквенције f , који потиче од истог узорка алуминијума, измерен различитим типовима микрофона: ECM30B (плава крива), ECM60 (магента крива), WM66 (зелена крива) и ИМ (црна крива), [17]

На основу резултата тестирања може се закључити да је модел идентификовао различите типове микрофона и поуздано и прецизно одредио карактеристичне параметре њихове трансфер функције, који су даље дефинисали “прави” сигнал. Укупно време обраде је мање од 100 ms, према томе извршена је корекција сигнала у реалном времену. Презентована метода побољшава тачност и прецизност ФА мерног процеса и може бити примењена на испитиване узорке направљене од различитог материјала (метали, полупроводници, полиетилен, итд.).

6.3 Калибрација микрофона

Добро је позната чињеница да се калибрација користи када желимо да будемо сигурни да су мерења коректна или да докажемо да су мерне методе и опрема исправни. Различите методе се користе за калибрацију конвенционалних кондензаторских микрофона, али већина њих захтева да се урачунају геометријски и механички

параметри. У овом истраживању примењена је нова метода, калибрација на основу поклапања фаза [83], заснована на развијеном регресионом моделу.

Фазни одзив је веома осетљив на промене у условима ФА експеримента, поготово када се промени материјал озраченог узорка. Међутим, утицај микрофона на ФА одзив на ниским фреквенцијама ($f < 10^3$ Hz) би требало да је независан од материјала узорка, односно изражен утицај материјала не би требало да постоји. У нискофреквентном домену фазна функција микрофона зависи од RC карактеристика микрофона, које су скоро константне током целог експеримента. Генерално, то значи да трансфер функција микрофона на ниским фреквенцијама мора бити иста без обзира на експерименталне услове (материјал узорка, интензитет зрачења узорка, позиција узорка у односу на мембрану микрофона, итд.). Главна идеја представљене методе је да се калибрише микрофон одређен снимљеним подацима ФА одзива за случај различитих материјала користећи референтну фазну трансфер карактеристику и то њен део на ниским фреквенцијама ($f < 10^3$ Hz), где је доминантан параметар микрофона фреквенција f_2 као карактеристика филтра пропусника високих учестаности [30][10][11]. Као најстабилнији параметар, скоро независан од експерименталних услова, f_2 се може користити као референтни параметар, који дефинише референтну фазну трансфер карактеристику. Степен поузданости у тачност методе може се добити на основу тога колико добро се произвољан ФА одзив коригован са референтном фазном трансфер функцијом слаже са теоријски предвиђеним ФА одзивом.

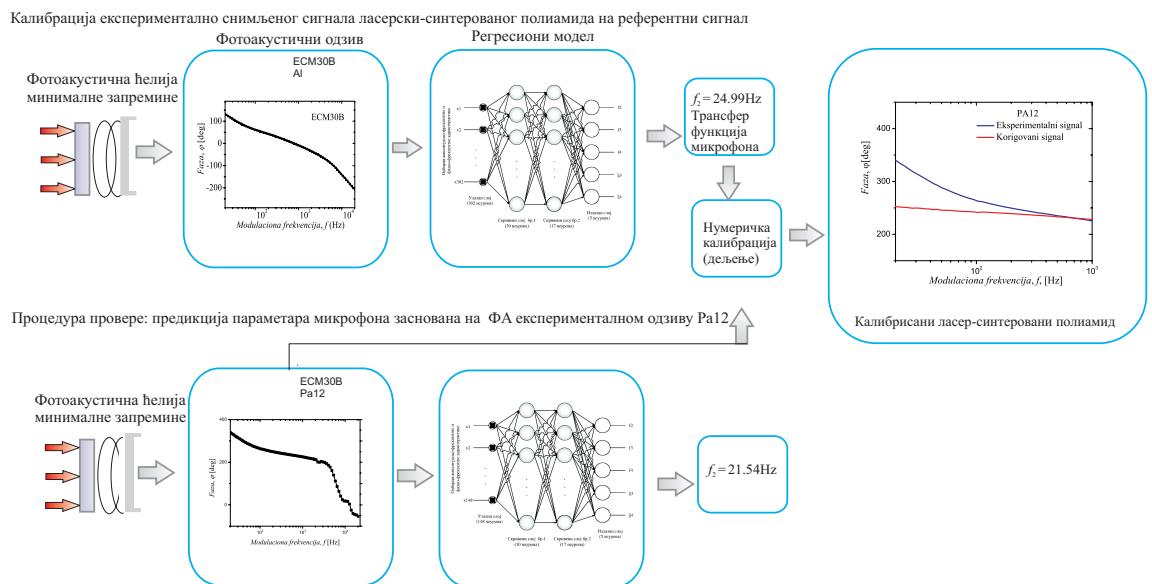
Метода користи регресиони модел за један тип микрофона у два мерења са узорцима два различита материјала. ФА мерења испитиваног материјала су калибрисана на ФА одзив референтног материјала. Врши се поређење трансфер функције микрофона, одређене регресионим моделом тренираним на нумеричким експериментима за испитивани материјал, са трансфер функцијом микрофона за референтни материјал [18].

Регресиони модел предвиђа пет параметара микрофона. На основу теоријског модела користећи пет добијених параметара одређена је трансфер функција микрофона [10][11].

Идеја о калибрацији микрофона састоји се од следећих корака:

1. одредити трансфер функцију микрофона на референтном материјалу у ниско фреквентном домену, како би се добиле његове електричне карактеристике,
2. извршити калибрацију експерименталног сигнала узорка другог материјала делећи га са референтном трансфер карактеристиком микрофона.

На слици 32 је приказана блок шема методе. Интерполирани ФА одзив за случај узорка од референтног материјала представља улаз регресионог модела тренираног над базом симулираних експерименталних вредности за тај тип микрофона и тај материјал.



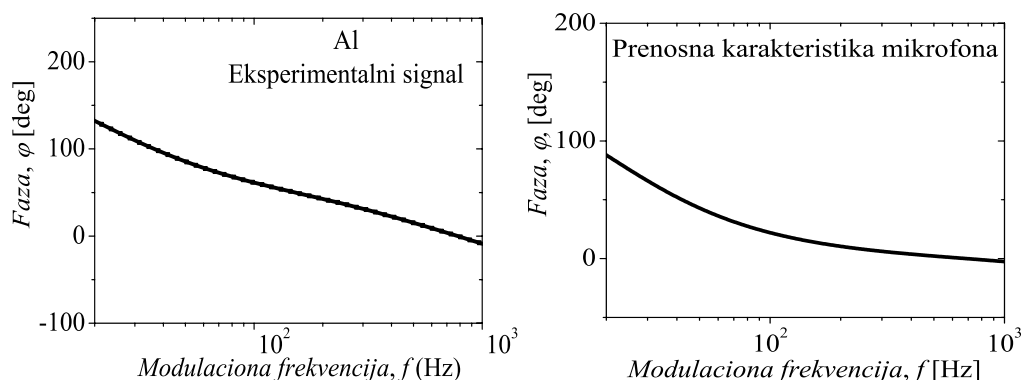
Слика 32: Блок шема методе калибрације [18]

Регресиони модел предвиђа пет карактеристичних параметара микрофона који је коришћен у експерименту. На основу теоријског модела користећи пет добијених параметара одређена је трансфер функција микрофона [10][11] за референтни материјал. Интерполирани РА одзив за случај узорка од испитиваног материјала представља улаз регресионог модела тренираног над базом симулираних експерименталних вредности за тај тип микрофона и тај материјал. Одређује се трансфер функција микрофона за испитивани материјал. Кораци који се односе на испитивани материјал служе као процедура за проверу методе.

Метода је тестирана на реалним експерименталним подацима, материјали су референтни - алуминијум, испитивани - ласерски синтерован полиамид PA12, микрофон је ESM30B, а мерења су обављена у истим осталим експерименталним условима. Пошто је у питању калибрација заснована на поклапању фаза, посматрамо

само фазну карактеристику ФА одзива. На слици 33(а) представљена је фазна карактеристика ФА одзива за случај алуминијума. Перформансе регресионог модела за алуминијум и микрофон ЕСМ30В представљене су поглављу 5.3.4., табела 10. Регресиони модел је предвидео пет параметара микрофона и то: $f_2 = 24.99 \text{ Hz}$, $f_3 = 9415.27 \text{ Hz}$, $f_4 = 14696.09 \text{ Hz}$, $\xi_3 = 0.9508$, $\xi_4 = 0.9801$. Добијена фазна трансфер карактеристика микрофона ЕСМ30В за фреквентни опсег 20 Hz – 20 kHz приказана је на слици 33 (б). Као што је претходно речено овде се користи само њен део на ниским фреквенцијама, где је f_2 доминантно.

За тренинг, у случају ласерски-синтерованог полиамида PA12, се користе подаци добијени одабирањем фазне карактеристике ФА одзива. База је димензија 67 500 записа са 148 обележја. Како би нумеричке експерименте што више приближили реалним експериментима $\pm 5\%$ Гаусовог шума је додато на сваки запис у бази података.



Слика 33: (а) ФА експериментални одзив и (б) добијена фазна карактеристика микрофона у случају узорка од алуминијума мереног микрофоном ЕСМ30В, као функција модулационе фреквенције, [18]

Перформансе регресионог модела за случај ласерски-синтерованог полиамида PA12 приказане су у табели 13. Анализом табеле може се закључити да је тачност модела задовољавајуће висока, а средње одступање од тачне вредности задовољавајуће ниско. Пошто је у питању калибрација заснована на поклапању фаза у нискофреквентном опсегу, пореди се вредност параметра микрофона f_2 добијена предвиђањем регресионог модела на референтном материјалу са вредношћу добијеном предикцијом регресионим моделом на испитиваном материјалу.


Табела 13: Перформансе регресионог модела за ФА одзив ласерски-синтерованог полиамида PA12, [18]

Средње одступање од тачне вредности изражено у процентима тачне вредности на тренинг скупу					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Одступање	0.12029643	0.07038221	0.08084355	0.5788087	0.4029342
Тачност на тренинг скупу: 99.5%					
Средње одступање од тачне вредности изражено у процентима тачне вредности на валидационом скупу					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Одступање	0.11927654	0.0708506	0.08202486	0.5853438	0.41552734
Тачност на валидационом скупу: 99.47%					
Средње одступање од тачне вредности изражено у процентима тачне вредности на тест скупу					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Одступање	0.11965714	0.06870354	0.08087056	0.5796086	0.39402157
Тачност на тест скупу: 99.5%					
Време предикције					
CPU време			Рачунарско време		
14 ms			35 ms		

Предикција регресионог модела у случају полиамида је $f_2 = 21.54$ Hz, слика 32, тиме је одступање од референтне AI вредности (25 Hz) приближно 7.5%. Ово се може сматрати добрим резултатом знајући да се референтна трансфер карактеристика и фазна трансфер карактеристика полиамида добро слажу на ниским фреквенцијама.

Поделом експерименталног одзива PA12 са референтном (AI) фазном трансфер карактеристиком, слика 33(б) добија се кориговани PA12 сигнал, слика 34 (црвена линија). Поређењем овог резултата са “правим” теоретским, ФА сигналом за полиамид, слика 34 (зелена линија) може се закључити да је слагање између ове две линије доста добро, што значи да су испуњени критеријуми за калибрацију засновану на поклапању фаза, поузданост и прецизност методе је задовољавајуће висока.

Представљена метода калибрације може се применити на било који тип кондензаторског микрофона, као и на било који тип ФА одзива, без обзира на материјал узорка. Применом описане методе калибрације могуће је проширити опсег за инверзно решавање ФА проблема, и на тај начин повећати тачност и прецизност методе [31].



Слика 34: Експериментална (плава линија), калибрисана (црвена линија) и теоријски предвиђена (зелена линија) фазна карактеристика ласерски-синтерованог полиамида (PA12), [18]

7 Додатна истраживања

Ток истраживања представљен у овој докторској дисертацији одредили су правци практичне примене. Постављена хипотеза да ће вишеслојне неуронске мреже показати довољно добре перформансе у карактеризацији и класификацији микрофона као детектора у ФА експерименту показала се потпуно оправданом. Евалуациона метрика је у потпуности задовољена. Међутим, током тестирања модела у различитим условима: на нумеричким експериментима из ширег (независни тестови) или ужег опсега учестаности, са или без шума, на експерименталним сигнаlima из ширег или ужег опсега учестаности, са или без шума, на различитим материјалима и мерено на различитим микрофонима уочено је неколико проблема везаних за процедуру мерења. Наиме, како би се прецизно дефинисала амплитудска карактеристика микрофона у фреквентном домену у ФА експерименту, неопходан је велики број мерних тачака, што је један од проблема ФА мерења. Принцип - мерење у великом броју тачака, задржан је у креирању симулираних експерименталних вредности, односно база података. Опис криве са 400 обележја (један запис у бази), за фреквентни опсег од 10 Hz до 100 kHz, значи 200 мерења у реалном експерименту. Када се у експерименту користи ужи опсег учестаности, нпр. од 20 Hz до 20 kHz (велики број истраживача често користи овај опсег), као што је учињено у методи за опис микрофона, користи се мањи број улазних обележја, 302. Следећа ситуација је када се у експерименту користе само амплитуде или само фазе за одређени опсег учестаности, као што је учињено у методи за калибрацију мерења на основу фазног поклапања, користи се 148 обележја. У оба случаја редукованог скупа података, и регресиони и класификациони модел су задржали добре перформансе. То је очекивано понашање јер вишеслојне неуронске мреже, а поготово дубоко учење, нису осетљиве на број улазних параметара и не захтевају претходни инжењеринг података [3]. Пошто је хипотеза била да ће вишеслојне неуронске мреже показати добре особине за препознавање утицаја мерног ланца на користан сигнал, као и на проналажење оптималног модела, предпроцесирање није рађено. У тестирању регресионог и класификационог модела за смањену димензију улазног вектора (302 и 148), утврђено је да смањење времена процесирања није значајно. На основу свега реченог до сада, закључак је да би редукција димензија била важнија за решење проблема великог броја мерења у

експерименту него за повећање брзине обраде резултата мерења. Такође, уочен је и проблем различитог броја мерења од експеримента до експеримента. Број мерних тачака зависи од експерименталних услова и онога ко врши експеримент. Ови проблеми чине мерења веома спорим и исцрпљујућим, а додатно, отежавају научну сарадњу. Потребна је метода која би задржала тачност и поузданост, повећала брзину мерења и генерализовала избор мерних тачака.

Очекује се да ће алгоритам за редукцију димензија, PCA, показати да је потребан мањи број мерних тачака, односно мањи број обележја за сваку од база података коришћених у овом истраживању [84][85][86]. То ће значити мањи број улаза неуронске мреже, за задовољавајуће добру карактеризацију и класификацију микрофона. На тај начин експериментална процедура ће бити поједностављена и убрзана. У исто време проблем различитог броја мерних тачака од експеримента до експеримента биће генерализован новим редукованим скупом обележја.

PCA и филтрирање обележја скупа података у комбинацији са експертским знањем треба да дају одговор - који је то број тачака и које су то тачке на фреквентној оси у којима ће се мерити. Тестирање перформанси регресионог и класификационог модела за нови, редуковани улазни вектор треба да да потврду ове хипотезе.

7.1 Редукција димензија


Проблем смањења броја мерних тачака у експерименту може се разложити на проблем редукције димензија улазног вектора код регресионог модела за сва три типа микрофона обухваћених овим истраживањем и проблем редукције димензија улазног вектора код класификационог модела.

7.1.1 Редукција димензија улазног вектора регресионог модела за микрофон ЕСМ30В

Применом алгоритма PCA на базу података микрофона ЕСМ30В добија се расподела преостале варијансе приказана на слици 35. Вредност преостале варијансе за 20 обележја (10 амплитуда и 10 фаза), што представља редукцију броја мерних тачака на 10, износи 99.999%. Преостала варијанса за 10 обележја (5 амплитуда и 5 фаза), што представља редукцију броја мерних тачака на 5, износи 99.989%. За 3 мерне тачке,

преостала варијанса износи 99.964%. Све представљене вредности варијансе су довољно велике, па на основу дискусије у поглављу 4, може се претпоставити да се број елемената улазног вектора регресионог модела може редуковати и на 10 и на 5 и на 3 тачке, а да се не наруше перформансе модела.

Анализа редукције димензија РСА алгоритмом допуњена је дискусијом корелација између обележја скупа података. Посматрана је корелација: између свих 400 обележја, корелација првих 200 обележја, односно корелација амплитуда одбирака и корелација других 200 обележја, односно корелација фаза. У истраживању редукције димензија задржан је принцип упаривања амплитуда и фаза, као обележја једне мерне тачке.

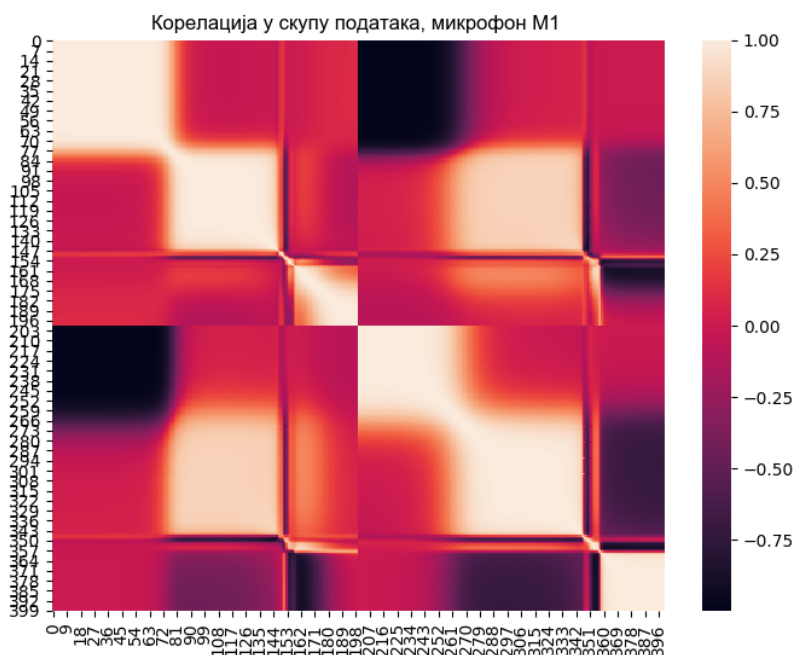


Слика 35: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон ЕСМ30В, оригиналних димензија 400 x 67 500

Анализом дијаграма корелација на целом скупу података, слика 36, закључујемо да постоје области са високом корелацијом обухваћених обележја или улазних варијабли (светла поља). Уочљива је подела дијаграма на четири сегмента, то су односи амплитуда-амплитуда, амплитуда-фаза, фаза-амплитуда и фаза-фаза. Сегменти амплитуда-фаза и фаза-амплитуда су идентични. Интензивна тамна поља у ова два сегмента показују да не постоји корелација између амплитуде и фазе истог одбирка за ниже фреквенције, светла поља у ова два сегмента доказују постојање корелације између амплитуда и фаза истог одбирка за више фреквенције. С обзиром да је наш циљ редукција димензија у смислу смањења броја тачака а не избор између амплитуде и фазе, ова два сегмента нису од значаја за даљу анализу. У сегментима

амплитуда-амплитуда и фаза-фаза изражена су поља светле боје која се простиру дуж дијагонале сегмента. Прецизнију анализу даће дијаграми корелација амплитуда-амплитуда и фаза-фаза, слика 37 и 38.

Анализом и поређењем ова два дијаграма уочавају се 5 правоугаоника светле боје, врло слична на оба дијаграма. На дијаграму фаза уочавају се јасније границе између ових 5 области.




Слика 36: Корелација на оригиналном скупу података, база микрофона ЕСМ30В

Чињенице да је коефицијент корелације између обележја који припадају једној области велики и равномеран, као и да је РСА алгоритам показао високу преосталу варијансу за 5 мерних тачака, наводе на идеју да ако се изабере по једно било које обележје из ових 5 области, исто и за амплитуду и за фазу, то ће бити 5 тражених мерних тачака.

Анализа перформанси регресионог модела за редуковану димензију улазног вектора на 10 обележја би требало да потврди постављену претпоставку. С обзиром да је степен корелације између обележја равномеран, избор тачке као представника области корелације може бити произвољан. Не нарушавајући општост, узета су обележја из центара претходно поменутих 5 области корелација, како за амплитуду тако и за фазу. Фреквенције на којима су узети одбирци су: 36.54 Hz, 1 289.89 Hz, 9 437.88 Hz, 11 357.33 Hz и 37 123.43 Hz.



Слика 37: Корелација амплитуда у оригиналном скупу података, база микрофона ЕСМ30В



Слика 38: Корелација фаза у оригиналном скупу података, база микрофона ЕСМ30В

Експертско знање потврђује постављену хипотезу [87]. На основу доказа теорија физике, за дефинисање криве потребно је 5 тачака. Значи број тачака се слаже

са претходном анализом. Што се тиче избора тачака: прва тачка припада нискофреквентној области (до 800 Hz), где су изражене електронске карактеристике микрофона које су стабилне и карактеристичне за сваки микрофон, па је оправдан избор једне мерне тачке у тој области. Следећа тачка припада тзв. заравњеној области (од 800 Hz до 2 000 Hz), где су амплитуде и фазе приближних вредности за сва три микрофона, односно присутно је преклапање кривих једног микрофона, и делимично са кривама осталих микрофона, флукуација вредности амплитуда и фаза је мала, па је и овде оправдан избор једне тачке. Преостале три тачке припадају високофреквентној области у којој су изражене акустичне карактеристике микрофона, које су нестабилне и уносе велику флукуацију вредности амплитуда и фаза, па је оправдан избор три тачке у овој области, јер је потребно више информација за дефинисање параметара микрофона изражених у овој области.

У табели 14 су представљене перформансе модела за редуковани скуп података на 10 обележја, за микрофон ЕСМ30В.

Табела 14: Перформансе регресионог модела на редукованом скупу података за микрофон ЕСМ30В

Средње одступање од тачне вредности у процентима тачне вредности на тренинг скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 97.81 %	0.05634921	0.1387076	0.07057983	1.3173068	1.2944126
Средње одступање од тачне вредности у процентима тачне вредности на валидационом скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 97.86 %	0.0566444	0.13916919	0.07028325	1.2990386	1.2882006
Средње одступање од тачне вредности у процентима тачне вредности на тест скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 97.8 %	0.05664359	0.13738047	0.0719733	1.290471	1.2778711

На основу табеле 14 може се закључити да су перформансе регресионог модела за улазни вектор редукованих димензија на 10 елемената и исте остале хиперпараметре модела, задовољавајуће добре. Средње одступање карактеристичних параметара микрофона је у границама захтева фотоакустичног експеримента и износи

највише 1.29% за параметар ξ_3 на тест скупу података. Тачност модела смањена је за приближно 1% у односу на тачност модела тренираног на оригиналном скупу података, док је тренирање модела знатно дуже 7 000 епоха, али и даље прихватљиво за примену у ФА.

Поузданост модела са редукованом димензијом улаза проверена је на независним тестовима, табела 15.

Табела 15: Независни тестови регресионог модела тренираног на редукованом скупу података за микрофон ЕСМ30В.

НЕЗАВИСНИ ТЕСТОВИ					
ТЕСТ1					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.425E+01	9.505E+03	1.4536E+04	9.0E-01	1.50E-01
Предикција	2.4232E+01	9.5128E+03	1.45359E+04	9.011E-01	1.501E-01
Девијација (abs)	1.8E-02	7.8E+00	1.0E-01	1.1E-03	1.0E-04
Девијација (%)	7.423E-02	8.206E-02	6.88E-04	1.22E-01	6.67E-02
Време предикције	Рачунарско_време = 32 ms, CPU_време = 15 ms				
ТЕСТ2					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.425E+01	9.505E+03	1.4536E+04	7.50E-02	8.70E-01
Предикција	2.4235E+01	9.50128E+03	1.45381E+04	7.5648E-02	8.7108E-01
Девијација (abs)	1.5E-02	3.72E+00	2.1E+00	6.48E-04	1.08E-03
Девијација (%)	6.186E-02	3.914E-02	1.44E-02	8.64E-01	1.241E-01
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13 ms				
ТЕСТ3					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.625E+01	9.658E+03	1.5432E+04	8.30E-01	7.20E-01
Предикција	2.6231E+01	9.676E+03	1.5443E+04	8.3354E-01	7.19996E-01
Девијација (abs)	1.9E-02	1.8E+01	1.1E+01	3.54E-03	4.0E-06
Девијација (%)	7.238E-02	1.864E-01	7.128E-02	4.265E-01	5.56E-04
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13.5 ms				

ТЕСТ4					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.500E+01	9.696E+03	1.5432E+04	8.30E-01	7.50E-02
Предикција	2.4979E+01	9.7801E+03	1.5425E+04	8.3192E-01	7.3244E-02
Девијација (abs)	2.1E-02	8.41E+01	7.0E+01	1.92E-03	1.756E-03
Девијација (%)	8.4E-02	8.673E-01	4.536E-02	2.313E-01	2.341E+00
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13.5 ms				
ТЕСТ5					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	2.500E+01	9.658E+03	1.4536E+04	5.70E-01	9.00E-01
Предикција	2.5008E+01	9.676E+03	1.45297E+04	5.73551E-01	8.9952E-01
Девијација (abs)	8.0E-03	1.8E+01	6.3E+00	3.551E-03	4.8E-04
Девијација (%)	3.2E-02	1.86E-01	4.334E-02	6.23E-01	5.33E-02
Време предикције	Рачунарско_време = 28 ms, CPU_време = 13 ms				


Одступање од тачних вредности код независних тестова је испод захтева дефинисаних ФА експериментом. Највеће одступање је 2.34% за параметар ξ_4 у тесту 4, али је у оквирима захтева ФА експеримента. Остали резултати су врло блиски резултатима тестирања регресионог модела тренираног на оригиналном скупу података. Поузданост модела са редукованом димензијом улазног вектора је овим доказана.

Приказаном редукацијом димензија улазног вектора одређен је број и избор мерних тачака у ФА експерименту где се као детектор користи микрофон ЕСМ30В. За потпуну карактеризацију микрофона ЕСМ30В потребно је извршити мерење у 5 тачака и то: 36.54 Hz, 1 289.89 Hz, 9 437.88 Hz, 11 357.33 Hz и 37 123.43 Hz, при чему модел ради прецизно, поуздано и у реалном времену.


7.1.2 Редукација димензија улазног вектора регресионог модела за микрофон ЕСМ60

Поједностављење експеримента би било комплетно када би један избор тачака важио за све типове микрофона који се користе у фотоакустичном експерименту.

Анализа успешности редукције димензија код микрофона ЕСМ60 подразумева исте кораке као и за микрофон ЕСМ30В. Провера резултата РСА алгоритма за базу података за овај микрофон представљена је на слици 39. Закључујемо да за 5 мерних тачака, односно 10 обележја вредност преостале варијансе износи 99.987%, што значи да се може извршити редукција димензија на 10 обележја.

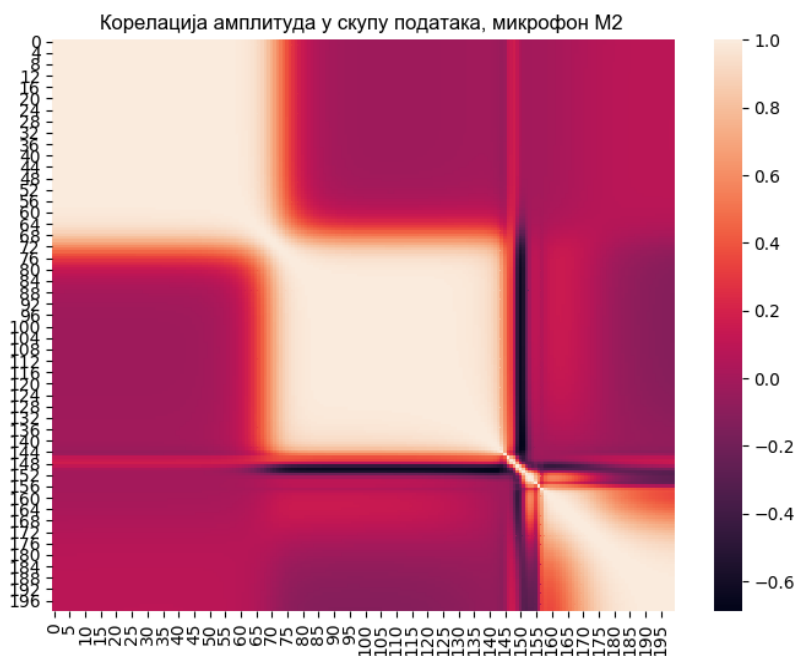


Слика 39: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон ЕСМ60, оригиналних димензија 400 x 67 500




Слика 40: Корелација на оригиналном скупу података, база микрофона ЕСМ60

Корелација између обележја за базу података за микрофон ЕСМ60 приказана је на сликама 40, 41 и 42 посматрано за сва обележја, само амплитуде и само фазе, респективно.



Слика 41: Корелација амплитуда у оригиналном скупу података, база микрофона ЕСМ60



Слика 42: Корелација фаза у оригиналном скупу података, база микрофона ЕСМ60

Изводи се закључак да су центри прве, друге и пете корелационе области исти као за микрофон ЕСМ30В, док се центри треће и четврте области разликују за пар обележја. Претходно изабране тачке 9 437.88 Hz и 11 357.33 Hz су високо корелисане са осталим тачкама треће и четврте корелационе области, па тако могу бити избор. Може се узети исти избор тачака за посматрана два од укупно три микрофона.

Перформансе регресионог модела за микрофон ЕСМ60 доказаће ову тврдњу, табела 16.

Табела 16: Перформансе регресионог модела за микрофон ЕСМ60 на редукованом скупу података

Средње одступање од тачне вредности у процентима тачне вредности на тренинг скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 98.51%	0.06754803	0.08464493	0.0522848	0.79440355	1.0548072
Средње одступање од тачне вредности у процентима тачне вредности на валидационом скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 98.44%	0.06784417	0.08575927	0.05350335	0.82717246	1.033815
Средње одступање од тачне вредности у процентима тачне вредности на тест скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 98.32%	0.06761368	0.08670316	0.05289495	0.85380656	1.0646605

На основу табеле 16 закључује се да су перформансе регресионог модела за редуковани улазни вектор на 10 обележја за микрофон ЕСМ60 задовољавајуће добре. Разлика тачности модела за редуковани улазни вектор у односу на оригинални је незнатно мања, док тренинг мреже траје 7 000 епоха што је солидно повећање времена потребног за обуку мреже, али још увек у границама толеранције ФА експеримента.

Поузданост модела са редкованом димензијом улазног вектора проверена је на независним тестовима, табела 17.

Табела 17: Провера поузданости регресионог модела са редукованим улазним вектором, микрофон ЕСМ60

НЕЗАВИСНИ ТЕСТОВИ					
ТЕСТ1					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	1.475E+01	8.206E+03	1.5243E+04	9.0E-01	1.50E-01
Предикција	1.4738E+01	8.1558E+03	1.52709E+04	9.0095E-01	1.424E-01
Девиијација (abs)	1.2E-02	5.02E+01	2.79E+01	9.5E-04	7.6E-03
Девиијација (%)	8.136E-02	6.12E-01	1.83E-01	1.06E-01	5.067E+00
Време предикције	Рачунарско_време = 30 ms, CPU_време = 13 ms				
ТЕСТ2					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	1.475E+01	8.206E+03	1.5243E+04	7.5E-02	8.7E-01
Предикција	1.4735E+01	8.1575E+03	1.52308E+04	7.714E-02	8.6386E-01
Девиијација (abs)	1.5E-02	4.85E+01	1.22E+01	2.14E-03	6.14E-03
Девиијација (%)	1.017E-01	5.91E-01	8.004E-02	2.85E+00	7.057E-01
Време предикције	Рачунарско_време = 32 ms, CPU_време = 15 ms				
ТЕСТ3					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	1.5E+01	8.352E+03	1.3319E+04	8.3E-01	7.2E-01
Предикција	1.5011E+01	8.348E+03	1.3309E+04	8.274E-01	7.1991E-01
Девиијација (abs)	1.1E-02	4.0E+00	1.0E+01	2.6E-03	9.0E-05
Девиијација (%)	7.33E-02	4.79E-02	7.51E-02	3.13E-01	1.25E-02
Време предикције	Рачунарско_време = 28 ms, CPU_време = 12 ms				
ТЕСТ4					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	1.500E+01	8.206E+03	1.3319E+04	8.30E-01	7.50E-02
Предикција	1.501E+01	8.2002E+03	1.33148E+04	8.2959E-01	7.4479E-02
Девиијација (abs)	1.0E-02	5.8E+00	4.2E+00	4.1E-04	5.21E-04
Девиијација (%)	6.67E-02	7.07E-02	3.153E-02	4.94E-02	6.946E-01
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13.5 ms				

ТЕСТ5					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	1.500E+01	8.352E+03	1.5243E+04	5.7E-01	9.00E-01
Предикција	1.5031E+01	8.31198E+03	1.52269E+04	5.617E-01	8.979E-01
Девијација (abs)	3.1E-02	4.002E+01	1.61E+01	8.3E-03	2.1E-03
Девијација (%)	2.067E-01	4.792E-01	1.056E-01	1.456E+00	2.33E-01
Време предикције	Рачунарско_време = 30 ms, CPU_време = 14 ms				

Анализом табеле 17, јасно је да за један од пет карактеристичних параметара у оквиру једног теста од пет примењених, независних тестова, одступање је приближно са задатих 5%. У питању је најнестабилнији параметар микрофона. Остале вредности су испод границе дефинисане ФА експериментом.


Закључујемо да регресиони модел за редуковани улазни вектор на 5 мерних тачака, и то 36.54 Hz, 1 289.89 Hz, 9 437.88 Hz, 11 357.33 Hz и 37 123.43 Hz, за микрофон ЕСМ60 има задовољавајућу прецизност и поузданост за рад у реалном времену.

7.1.3 Редукција димензија улазног вектора регресионог модела за микрофон WM66


Сличном анализом као за микрофоне ЕСМ30В и ЕСМ60, провериће се успешност редукције димензија улазног вектора на 5 тачака за микрофон WM66 као и могућност генерализације избора тачака на фреквентној оси за сва три микрофона.

Вредност преостале варијансе за редукцију димензија улазног вектора регресионог модела за микрофон WM66 приказана је на слици 43. Вредност преостале варијансе за редукцију димензија улазног вектора на 5 мерних тачака, односно 10 обележја износи 99.988%, што потврђује оправданост редукције димензија.

Корелационе материце за свих 400 обележја, као и за амплитуде и за фазе приказане су на сликама 44, 45 и 46 респективно. Анализом дијаграма закључујемо да је распоред обележја на корелационе области за микрофон WM66 идентичан са распоредом за микрофон ЕСМ30В.

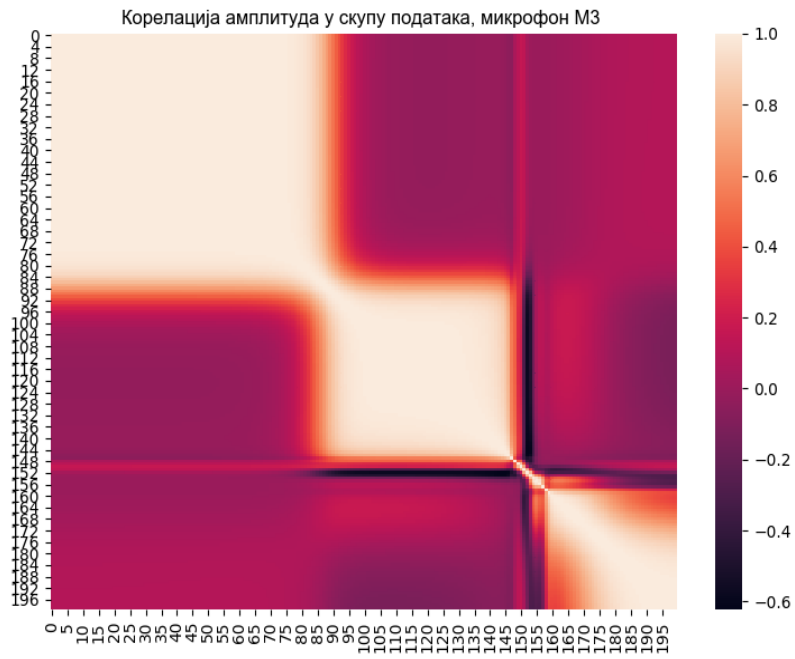


Слика 43: Преостала варијанса у односу на број обележја у редукованом скупу података за микрофон WM66, оригиналних димензија 400 x 67 500




Слика 44: Корелација на оригиналном скупу података, база микрофона WM66

Потребно је проверити перформансе регресионог модела за редуковани улазни вектор табела 18, као и поузданост модела провереном на независним тестовима табела 19.



Слика 45: Корелација амплитуда у оригиналном скупу података, база микрофона WM66



Слика 46: Корелација фаза у оригиналном скупу података, база микрофона WM66

Табела 18: Перформансе регресионог модела за микрофон WM66 на редукованом скупу података

Средње одступање од тачне вредности у процентима тачне вредности на тренинг скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 97.92%	0.07427786	0.13739842	0.08694855	1.156819	1.3114735
Средње одступање од тачне вредности у процентима тачне вредности на валидационом скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 98.02%	0.07487136	0.13933049	0.08738445	1.1038309	1.2729754
Средње одступање од тачне вредности у процентима тачне вредности на тест скупу података					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачност 98.02%	0.0737425	0.13992077	0.08633012	1.1550651	1.2725114

Табела 19: Провера поузданости регресионог модела са редукованим улазним вектором, микрофон WM66

НЕЗАВИСНИ ТЕСТОВИ					
ТЕСТ1					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	6.7E+01	9.505E+03	1.4536E+04	9.0E-01	1.50E-01
Предикција	6.6962E+01	9.49598E+03	1.45454E+04	8.987E-01	1.488E-01
Девиијација (abs)	3.8E-02	9.02E+00	9.4E+00	1.3E-03	1.2E-03
Девиијација (%)	5.67E-02	9.49E-02	6.467E-02	1.44E-01	8.0E-01
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13 ms				
ТЕСТ2					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	6.7E+01	9.505E+03	1.4536E+04	7.5E-02	8.7E-01
Предикција	6.6967E+01	9.5059E+03	1.45285E+04	7.425E-02	8.691E-01
Девиијација (abs)	3.3E-02	9.0E-01	7.5E+00	7.5E-04	9.0E-04
Девиијација (%)	4.925E-02	9.47E-03	5.16E-02	1.0E+00	1.03E-01
Време предикције	Рачунарско_време = 31 ms, CPU_време = 14 ms				
ТЕСТ3					

Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	6.5E+01	9.658E+03	1.5432E+04	8.3E-01	7.2E-01
Предикција	6.493E+01	9.6588E+03	1.54225E+04	8.301E-01	7.1897E-01
Девиијација (abs)	7.0E-02	8.0E-01	9.5E+00	1.0E-04	1.03E-03
Девиијација (%)	1.077E-01	8.28E-03	6.156E-02	1.205E-02	1.43E-01
Време предикције	Рачунарско_време = 29 ms, CPU_време = 12.5 ms				
ТЕСТ4					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	6.500E+01	9.696E+03	1.5432E+04	8.30E-01	7.50E-02
Предикција	6.4931E+01	9.692E+03	1.54296E+04	8.303E-01	7.372E-02
Девиијација (abs)	6.9E-02	4.00E+00	2.4E+00	3.0E-04	1.28E-03
Девиијација (%)	1.062E-01	4.125E-02	1.555E-02	3.615E-02	1.706E+00
Време предикције	Рачунарско_време = 29 ms, CPU_време = 13 ms				
ТЕСТ5					
Параметар	f_2	f_3	f_4	ξ_3	ξ_4
Тачна вредност	6.500E+01	9.658E+03	1.4536E+04	5.7E-01	9.00E-01
Предикција	6.4973E+01	9.6628E+03	1.4525E+04	5.7205E-01	8.967E-01
Девиијација (abs)	2.7E-02	4.8E+00	1.1E+01	2.05E-03	3.3E-03
Девиијација (%)	4.154E-02	4.97E-02	7.567E-02	3.596E-01	3.67E-01
Време предикције	Рачунарско_време = 30 ms, CPU_време = 13 ms				


Табела 18 доказује да су перформансе модела задовољавајуће добре за редуковани скуп података. Највеће одступање је за параметар ξ_4 и износи 1.7%. Тачност модела је незнатно лошија у односу на тачност модела на оригиналном скупу података, док обука траје дуже, 7 000 епоха. Успешност модела у тестирању на независним тестовима доказује његову поузданост, табела 19.

Може се закључити - регресиони модел са редукованим скупом података на 5 мерних тачака и то 36.54 Hz, 1 289.89 Hz, 9 437.88 Hz, 11 357.33 Hz и 37 123.43 Hz има задовољавајућу прецизност и поузданост и ради у реалном времену за сва три микрофона обухваћена овим истраживањем. Број и избор мерних тачака је тако генерализован на сва три микрофона, обухваћена овим истраживањем. Уместо мерења

у 200 тачака процедура мерења се своди на 5 мерних тачака. Редукција димензија омогућила је знатно поједностављење процедуре мерења, лако и брзо мерењем у 5 тачака извршава се карактеризација коришћеног микрофона у ФА експерименту.

7.1.4 Редукција димензија улазног вектора класификационог модела

РСА алгоритам примењен на базу података коришћену за обуку класификационог модела, даје расподелу преостале варијансе у односу на број обележја као на слици 47. Преостала варијанса за 5 мерних тачака, односно 10 обележја износи 99.978 %, за 4 обележја, односно 2 мерне тачке износи 99.772%, док за 2 обележја односно 1 мерну тачку износи 98.849%. Високе вредности преостале варијансе указују на могућност значајног поједностављења процедуре мерења са циљем класификације детектора.



Слика 47: Преостала варијанса у односу на број обележја у редукованом скупу података за базу коришћену за обуку класификационог модела, оригиналних димензија 400 x 270 000

Анализа редукције димензија улазног вектора класификационог модела биће усмерена у правцу практичне примене класификационог модела. У складу са дискусијом у поглављу 6.2, улога класификационог модела је да препозна тип коришћеног микрофона ради прецизнијег дефинисања трансфер функције микрофона, али и уштеде у времену обраде података, јер ће регресионом моделу бити додељена само потребна база података. У методи за потпуни опис микрофона, исти вектор прослеђен је на улаз и класификационог и регресионог модела, слика 28. На

основу дискусије из претходних поглавља, за регресиони модел за сва три микрофона генерализован је избор 5 мерних тачака. Из разлога једноставности, усвојићемо редукцију димензија за улазни вектор класификационог модела на 5 тачака ради примене у методи за аутокорекцију сигнала.

Перформансе класификационог модела са редукованом димензијом улазног вектора приказане су у табели 20. Нема разлике између перформанси класификационог модела за оригинални скуп података и редуковани скуп података на 10 изабраних обележја. Поузданост модела проверена је на независном скупу података.

Табела 20: Перформансе класификационог модела за редуковани скуп улазних података на 5 мерних тачака

Димензија улазног вектора	Број слојева	Број неурона	Тачност модела	Време обуке
10	1	2	99.99%	100 епоха


Табела 21: Провера поузданости класификационог модела са редукованом димензијом улазног вектора на 10 обележја

Тест	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Предикција класификационог модела са ред. ул. вектором	0	3	1	0	2	2	3	1	3	0	1	2	3	1	3	0	2	0	1	2
Тачност	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Тачност класификације: 100%, просечно време предикције: 13 ms																				


Може се извести закључак да класификациони модел са редукованом димензијом улазног вектора на 10 обележја извршава предикцију једног од четири типа микрофона прецизно, поуздано и у реалном времену и тиме задовољава услове за примену у методи за аутокорекцију сигнала.

У овој докторској дисертацији дат је и предлог класификационог модела са редукованом димензијом улазног вектора на једну мерну тачку, односно два обележја за остале, будуће примене класификационог модела. Основ за претпоставку да ће перформансе, поузданост и време предикције модела бити задовољавајуће добри су

чињенице да је вредност преостале варијансе за два обележја висока, као и дискусија дијаграма расејања или скатер дијаграма приказаног на слици 6. У нискофрекветном опсегу (за фреквенције ≤ 800 Hz) јасно је уочљива класификација тачака на четири класе, односно четири типа микрофона.




Слика 48: Корелација на оригиналном скупу података, база 4 микрофона



Слика 49: Корелација амплитуда на оригиналном скупу података, база 4 микрофона

Одговор на питање да ли ће класификационом моделу обученом на бази података димензија 2 x 270 000 бити довољно информација које носи једна мерна тачка да одреди тип микрофона, односно припадност одређеној класи од могуће 4, даће анализа перформанси и поузданости модела, табеле 22 и 23, респективно. Одабир тачке, као и претходно извршиће се на основу корелационе матрице, слике 48-50. У избору од 5 тачака за регресиони модел, ако се водимо идејом о спрезању ова два модела, једна тачка са фреквенцијом 36.54 Hz припада нискофреквентном опсегу. Анализом корелационе матрице закључује се да је ова тачка високо корелисана са осталим тачкама из прве корелационе области, тиме испуњава услове за избор.



Слика 50: Корелација фаза на оригиналном скупу података, база 4 микрофона

Табела 22: Перформансе класификационог модела за редуковани скуп улазних података на 1 мерну тачку са фреквенцијом 36.54 Hz

Димензија улазног вектора	Број слојева	Број неурона	Тачност модела	Време обуке
2	1	2	99.99%	100 епоха

Табела 23: Провера поузданости класификационог модела са редукованом димензијом улазног вектора на два обележја, мерна тачка 36.54 Hz

Тест	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Предикција класификационог модела са ред. ул. вектором	2	1	3	0	2	3	3	2	1	0	1	2	3	1	3	0	2	0	0	1
Тачност	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Тачност класификације: 100%, просечно време предикције: 13 ms																				

Може се извести следећи закључак – неуронска мрежа једноставне структуре обучена за кратко време (100 епоха) на великом скупу података са само два обележја, одређена статистичким методама, прецизно, поуздано и у реалном времену препознаје тип микрофона као детектора у ФА експерименту. Једноставним мерењем у једној тачки у нискофреквентном опсегу извршава се класификација коришћеног детектора у ФА експерименту. Ови резултати додатно потврђују закључке изведене у поглављу 5.4.1.

8 Закључак и будућа истраживања

У овој дисертацији представљена је методологија примене неуронских мрежа, обучених на великом скупу симулираних података, за потпуни опис ФА детектора – микрофона, који се даље користи за исправљање и чишћење експерименталног сигнала од утицаја мерног ланца са циљем добијања „правог“ сигнала који потиче само од побуђеног узорка. Неуронске мреже, оптимизоване за представљени проблем, показале су се као поуздан и прецизан алат који ради у реалном времену.

Недостатак довољно велике и поуздане колекције реалних експерименталних података надомешћен је генерисањем симулираних података. Софтвер за генерисање симулираних експерименталних вредности развијен је на основу теоријског модела, који препознаје електронске и акустичне карактеристике микрофона које се јављају приликом трансмисионих ФА мерења са тзв. конфигурацијом минималне запремине.

Окосница програмског оквира за аутоматизацију обраде резултата фотоакустичних мерења су развијени регресиони и класификациони модел.

Регресиони модел са задовољавајуће високом тачношћу и прецизношћу (функција цене реда величине 10^{-6}) одређује 5 карактеристичних параметара микрофона за просечно време од 14 ms, како у реалним тако и у симулираним експерименталним условима. Средња одступања од тачних вредности, добијених крос-валидацијом, на тест скупу података су: за параметар f_2 је 0.05568621, за параметар f_3 је 0.09077836, за параметар f_4 је 0.05424437, за параметар ξ_3 је 1.06229732 и параметар ξ_4 је 0.97844375. Перформансе модела су приближних вредности за три различита комерцијална, електрет микрофона, често коришћена у ФА експерименту, и за два материјала испитиваног узорка, А1 и РА12, па је реално очекивати да ће бити сличног понашања и за друге типове микрофона и већи број различитих материјала. Модел се понаша стабилно у условима уобичајене експерименталне нестабилности. Модел омогућава интерполацију излаза. Перформансе модела се незнатно мењају са променом опсега учестаности у експерименту, односно променом броја обележја скупа података коришћеног за обуку, што омогућава његово вишеструко коришћење у различитим ФА експериментима. Редукција димензија улазног вектора је могућа све до екстремно ниског броја мерних тачака (5). Стабилно понашање модела и за мали број мерних

тачака омогућава значајно поједностављење мерне процедуре. Тиме је регресиони модел у потпуности задовољио све захтеве примене у ФА експерименту, и додатно, понудио ново решење поједностављења мерне процедуре мерењем у 5 тачака на фреквенцијама: 36.54 Hz, 1 289.89 Hz, 9 437.88 Hz, 11 357.33 Hz и 37 123.43 Hz.

Класификациони модел са високом тачношћу, 99.99% врши предикцију типа детектора коришћеног у ФА експерименту од могућа 4, за просечно време од 13 ms. Једноставна структура и кратко време обуке омогућиће лаку надоградњу модела у случају захтева ФА експеримента за већим бројем класа, односно типова микрофона. Модел омогућава интерполацију излаза. Промена опсега учестаности не утиче на перформансе класификационог модела. Редукција димензија улазног вектора је могућа до екстремног случаја од једне мерне тачке изабране у нискофреквентном опсегу учестаности. Овим је класификациони модел у потпуности задовољио захтеве ФА експеримента и додатно, понудио решење класификације типа микрофона мерењем у једној тачки.

Програмски оквир за аутоматизацију обраде резултата ФА мерења поред софтвера за генерисање података, регресионог и класификационог модела, садржи и развијени софтвер, заснован на интерполационом алгоритму CubicSpline, за прилагођење експерименталних података регресионом и класификационом моделу, чиме је омогућено генерализовано коришћење експерименталних резултата.

Спрезањем развијених модела, регресионог и класификационог, уз коришћење интерполационог алгоритма настала је метода за аутокорекцију изобличеног експерименталног сигнала у “прави” сигнал који потиче само од испитиваног узорка. Исправљање и чишћење изобличеног експерименталног сигнала обавља се прецизно, поуздано, у реалном времену и без учешћа истраживача.

Коришћењем развијеног регресионог модела креирана је метода за калибрацију мерења на основу поклапања фаза, која прецизно, поуздано, у реалном времену и без учешћа истраживача извршава калибрацију ФА одзива за испитивани узорак на референтни материјал.

Коришћењем развијеног програмског оквира за аутоматизацију обраде резултата мерења у ФА (студија случаја) унапређења су значајна: елиминисан је утицај мерног ланца на експериментални сигнал, а тиме је омогућена прецизнија и поузданија карактеризација материјала. Користан мерни опсег је проширен,

омогућујући одређивање више различитих својстава материјала једним мерењем. Време обраде резултата мерења је значајно смањено, до реда $x \cdot 10 \text{ ms}$.

Реално је очекивати да методологија примењена у овом истраживању може да се примени у великом броју модел зависних мерних метода за које постоји теоријско-математички модел. Такође, постоји реална индикација примене и на друге трансмисионе системе за које постоји теоријски модел.

Прилагођавањем специфичним условима и избором одговарајућег, референтног узорка произвођачи микрофона би могли да врше контролу квалитета микрофона и дају тачне преносне карактеристике коришћењем развијене методе калибрације. То би могла бити још једна практична примена овог истраживања.

Програмски оквир представљен у овој докторској дисертацији може бити основа за развој интелигентног уређаја који ће поред аутокорекције изобличеног експерименталног сигнала моћи да извршава комплексне задатке диктиране природом експеримента ослањајући се на учење, резонување и адаптацију. То су правци даљих истраживања.

Овим истраживањем машинско учење, а поготово неуронске мреже добиле су још једну интересантну примену, што је један од низа доказа тенденције да вештачка интелигенција постаје неизоставни део великог броја научних дисциплина, технике, технологије и живота уопште.

ЛИТЕРАТУРА

- [1] S. Sigtia, P. Clark, R. Haynes, H. Richards, and J. Bridle, "Multi-Task Learning for Voice Trigger Detection," in *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2020, pp. 7449–7453.
- [2] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [3] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [4] A. Rosencwaig, "Photoacoustic Spectroscopy of Solids," *Opt Commun*, 7(4), pp. 305–308, 1973.
- [5] A. Mandelis, "Progress in Photoacoustic and Photothermal Science and Technology." Elsevier New York, 1991.
- [6] K. L. Djordjevic, D. D. Markushev, Ž. M. Čojbašić, and et al., "Photoacoustic Measurements of the Thermal and Elastic Properties of n-Type Silicon Using Neural Networks," *Silicon*, vol. 12, no. 6, pp. 1289–1300, 2020.
- [7] S. E. Bialkowski, *Photothermal Spectroscopy Methods for Chemical Analysis*. New York: John Wiley&Sons, Inc., 1996.
- [8] R. G. M. Kolkman, W. Steenbergen, and T. G. van Leeuwen, "In vivo photoacoustic imaging of blood vessels with a pulsed laser Diode," *Lasers Med. Sci.*, vol. 21, pp. 134–139, 2006.
- [9] K. G. et Al., "Thermoacoustic and photoacoustic tomography of thick biological tissues toward breast imaging," *Technol. Cancer Res. Treat.*, vol. 4, no. 5, pp. 559–566, 2005.
- [10] S. Aleksic, D. Markushev, D. Pantic, M. Rabasovic, D. Markushev, and D. Todorovic, "Electro-acoustic influence of the measuring system on the photoacoustic signal amplitude and phase in frequency domain," *Facta Univ. - Ser. Physics, Chem. Technol.*, vol. 14, no. 1, pp. 9–20, 2016.
- [11] M. N. Popovic *et al.*, "Helmholtz Resonances in Photoacoustic Experiment with Laser-Sintered Polyamide Including Thermal Memory of Samples," *Int. J. Thermophys.*, vol. 37, no. 12, pp. 1–9, 2016.
- [12] S. Ollivier, E. Salze, M. Averiyarov, P. V Yuldashev, and V. Khokhlova, "Calibration method for high frequency microphones," *French Soc. Acoust.*, no. April, pp. 3503–3507, 2012.
- [13] C. Walber, C. Salzano, M. Nowak, and N. Larratta, "Acoustic Methods of Microphone Calibration," in *Proceedings of 22nd International Congress on Sound and Vibration (ICSV 22)*, 2015, pp. 12–16.
- [14] E. Marin *et al.*, "On the thermal characterization of two-layer systems by means of the photoacoustic effect," *J. Phys. D. Appl. Phys.*, vol. 29, no. 4, pp. 981–986, 1996.
- [15] P. M. Nikolic and D. M. Todorović, "An investigation of semiconducting materials using a photoacoustic method. u: Technical sciences book 40, Monographs, Belgrade: Serbian Academy of Sciences and Arts Department, vol. DCXLVIII." Serbian Academy of Sciences and Arts, 2001.
- [16] M. I. Jordović-Pavlović, M. M. Stanković, M. N. Popović, Ž. M. Čojbašić, S. P. Galović, and D. D. Markushev, "The application of artificial neural networks in solid-state photoacoustics for the recognition of microphone response effects in the frequency domain," *J. Comput. Electron.*, vol. 19, no. 3, pp. 1268–1280, 2020.
- [17] M. I. Jordovic-Pavlovic *et al.*, "Computationally intelligent description of a photoacoustic detector," *Opt. Quantum Electron.*, vol. 52, no. 5, pp. 1–14, 2020.
- [18] M. I. Jordovic-Pavlovic *et al.*, "Deep Neural Network Application in the Phase-Match

- Calibration of Gas– Microphone Photoacoustics,” *Int J Thermophys*, vol. 41, no. 6, pp. 1–10, 2020.
- [19] S. P. Galovic, Z. N. Soskic, M. N. Popovic, Z. Stojanovic, D. Cevizovic, and Z. Stojanovic, “Theory of photoacoustic effect in media with thermal memory,” *J. Appl. Phys.*, vol. 116, no. 2, pp. 0–12, 2014.
- [20] P. C. Beard, “Photoacoustic Imaging of Blood Vessel Equivalent Phantoms,” in *Proc. SPIE*, 2002, pp. 54–62.
- [21] M. Terzić, M. W. Sigirist, J. Možina, and D. Markushev, “Primena fotoakustične spektroskopije u medicine i fizici,” in *Zbornik radova, XLVIII, Konf za ETRAN, Čačak, tom III*, 2004.
- [22] A. C. Bento, D. T. Dias, L. Olenka, A. N. Medina, and M. L. Baesso, “On the Application of the Photoacoustic Methods for the Determination of Thermo-Optical Properties of Polymers,” *Brazilian J. Phys.*, vol. 32, no. 2B, pp. 483–494, 2002.
- [23] K. S. Valluru, K. E. Wilson, and J. K. Willmann, “Photoacoustic Imaging in Oncology: Translational Preclinical and Early Clinical Experience,” *Radiology*, vol. 280, no. 2, pp. 332–349, 2016.
- [24] S. Galović, “Modelovanje i analiza fototermalnih signala za sredine sa toplotnom memorijom,” Univerzitet u Beogradu, 2003.
- [25] D. M. Todorović and P. M. Nikolic, “Carrier transport Contribution on Thermoelastic and Electronic Deformation in Semiconductors,” in *Progress in Photothermal and Photoacoustic Science and Technology*, vol. 4, A. Mandelis and P. Hess, Eds. Washington, USA: SPIE Press, Bellingham, 2000, p. 272.
- [26] M. Popovic, *Generalizovani fotoakustični odziv dvoslojnih struktura*. Beograd: Zadužbina Andrejević, 2018.
- [27] L. C. M. Perondi, L. F. Miranda, “Minimal-Volume Photoacoustic Cell Measurement of Thermal Diffusivity: Effect of the Thermoelastic Sample Bending,” *J. Appl. Phys.*, vol. 62, pp. 2955–2959, 1987.
- [28] H. Vargas and L. C. M. Miranda, “Photoacoustic and related photothermal techniques,” *Phys. Rep.*, vol. 161, pp. 43–101, 1988.
- [29] M. N. Popovic, “Fotoakustički odziv transmisione fotoakustičke konfiguracije i analiza rezonantnih fenomena za dvoslojne uzorke sa toplotnom memorijom,” Univerzitet u Novom Sadu, 2016.
- [30] M. D. Rabasovic, M. G. Nikolic, M. D. Dramicanin, M. Franko, and D. D. Markushev, “Low-cost, portable photoacoustic setup for solid samples,” *Meas. Sci. Technol.*, vol. 20, no. 9, p. 95902, 2009.
- [31] M. Nestic, M. Popovic, and S. Galovic, “Developing the techniques for solving the inverse problem in photoacoustics,” *Atoms*, vol. 7, no. 1, 2019.
- [32] A. Rosencwaig and A. Gerscho, “Theory of the photoacoustic effect with solids,” *J. Appl. Phys.*, vol. 47, no. 1, pp. 64–69, 1976.
- [33] F. A. McDonald and G. C. Wetsel, “Generalized theory of the photoacoustic effect,” *J. Appl. Phys.*, vol. 49, no. 4, pp. 2313–2322, Apr. 1978.
- [34] L. Rousset, F. Lepoutre, and L. Bertrand, “Influence of thermoelastic bending on photoacoustic experiments related to measurements of thermal diffusivity of metals,” *J. Appl. Phys.*, vol. 54, no. 5, pp. 2383–2391, 1983.
- [35] D. D. Markushev, M. D. Rabasović, M. V Nestic, M. N. Popovic, and S. P. Galovic, “Influence of thermal memory on thermal piston model of photoacoustic response,” *Int. J. Thermophys.*, vol. 33, no. 10–11, pp. 2210–2216, 2012.
- [36] M. V Nestic, S. P. Galovic, Z. N. Soskic, M. N. Popovic, and D. M. Todorović, “Photothermal thermoelastic bending for media with thermal memory,” *Int. J.*

- Thermophys.*, vol. 33, no. 10–11, pp. 2203–2209, 2012.
- [37] D. M. Todorović, M. D. Rabasovic, and D. D. Markushev, “Photoacoustic elastic bending in thin film—Substrate system,” *J. Appl. Phys.*, vol. 114, no. 21, p. 213510, 2013.
- [38] D. M. Todorović, M. D. Rabasovic, D. D. Markushev, and M. Sarajlić, “Photoacoustic elastic bending in thin film-substrate system: Experimental determination of the thin film parameters,” *J. Appl. Phys.*, vol. 116, no. 5, 2014.
- [39] S. P. Galovic and D. Kostoski, “Photothermal wave propagation in media with thermal memory,” *J. Appl. Phys.*, vol. 93, no. 5, p. 3063:3070, 2003.
- [40] D. D. Markushev, M. D. Rabasović, D. M. Todorović, S. Galović, and S. E. Bialkowski, “Photoacoustic signal and noise analysis for Si thin plate: Signal correction in frequency domain,” *Rev. Sci. Instrum.*, vol. 86, no. 3, 2015.
- [41] D. D. Markushev *et al.*, “Thermal and elastic characterization of glassy carbon thin films by photoacoustic measurements,” *Eur. Phys. J. Plus*, vol. 132, no. 33, pp. 1–9, 2017.
- [42] M. N. Popovic, D. Furundzic, and S. P. Galovic, “Photothermal Depth Profiling Of Optical Gradient Materials By Neural Network,” *Publ. Astron. Obs. Belgrade*, vol. 89, no. May 2015, 2010.
- [43] D. Allman, A. Reiter, and M. A. L. Bell, “Photoacoustic Source Detection and Reflection Artifact Removal Enabled by Deep Learning,” *IEEE Trans. Med. Imaging*, vol. 37, no. 6, pp. 1464–1477, 2018.
- [44] S. Antholzer, M. Haltmeier, and J. Schwab, “Deep learning for photoacoustic tomography from sparse data,” *Inverse Probl. Sci. Eng.*, pp. 1–22, 2018.
- [45] M. Lukić, Ž. Čojbašić, M. D. Rabasović, and D. D. Markushev, “Computationally intelligent pulsed photoacoustics,” *Meas. Sci. Technol.*, vol. 25, no. 12, p. 125203, 2014.
- [46] M. Lukić, Čojbašić, M. D. Rabasović, D. D. Markushev, and D. M. Todorović, “Laser Fluence Recognition Using Computationally Intelligent Pulsed Photoacoustics Within the Trace Gases Analysis,” *Int. J. Thermophys.*, vol. 38, no. 11, 2017.
- [47] M. Nestic, “Razvoj tehnika za rešavanje inverznog fotoakustičkog problema,” Univerzitet u Beogradu, 2017.
- [48] G. Cosne *et al.*, “Using Simulated Data to Generate Images of Climate Change,” in *ML-IRL workshop at ICLR, 2020*, pp. 1–9.
- [49] S. Ding, H. Li, C. Su, J. Yu, and F. Jin, “Evolutionary artificial neural networks: a review,” *J. Artif. Intell. Rev.*, no. 10.1007/s10462-011-9270–6, pp. 1–10, 2011.
- [50] Russell, S. J., Norvig, P., *Artificial intelligence: A modern approach. Englewood Cliffs, N.J: Prentice Hall.e.* Englewood Cliffs, N.J: Prentice Hall, 1995.
- [51] S. Haykin, *Neural Networks and Learning Machines*. Pearson, 2008.
- [52] Q. V Le, J. Ngiam, A. Coates, A. Lahiri, B. Prochnow, and A. Y. Ng, “On Optimization Methods for Deep Learning,” in *Proceedings of the 28th International Conference on Machine Learning*, 2011, pp. 265–272.
- [53] S. Shalev-Shwartz and S. Ben-David, *Understanding machine learning: From theory to algorithms*. New York, USA: Cambridge University Press., 2014.
- [54] C. M. Bishop, *Pattern Recognition and Machine Learning*. Springer, 2006.
- [55] G. Montavon, W. Samek, and K.-R. Müller, “Methods for interpreting and understanding deep neural networks,” *Digit. Signal Process.*, vol. 73, pp. 1–15, 2018.
- [56] A. N. Vasilyev and D. A. Tarkhov†, “Mathematical Models of Complex Systems on the Basis of Artificial Neural Networks,” *Nonlinear Phenom. Complex Syst.*, vol. 17, no. 3, 2014.

- [57] A. Bielecki, “Mathemtical model of architecture and learning processes of artificial neural networks,” *TASK Q.*, vol. 7, no. 1, pp. 93–114, 2003.
- [58] J. Schmidhuber, “Deep Learning in neural networks: An overview,” *Neural Networks*, vol. 61, pp. 85–117, 2015.
- [59] A. Y. Ng, “Feature Selection, L1 vs. L2 Regularization, and Rotational Invariance,” in *Proceedings of the Twenty-First International Conference on Machine Learning*, 2004, p. 78.
- [60] G. E. Hinton, S. Osindero, and Y. W. Teh, “A Fast Learning Algorithm for Deep Belief Nets,” *Neural Comput.*, vol. 18, no. 7, pp. 1527–54, 2006.
- [61] Y. Bengio, “Practical recommendations for gradient-based training of deep architectures,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7700 LECTU, pp. 437–478, 2012.
- [62] X. Glorot and Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks,” in *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, 2010, vol. 9, pp. 249–256.
- [63] J. Bergstra and Y. Bengio, “Random Search for Hyper-Parameter Optimization,” vol. 13, pp. 281–305, 2012.
- [64] T. Domhan, J. T. Springenberg, and F. Hutter, “Speeding Up Automatic Hyperparameter Optimization of Deep Neural Networks by Extrapolation of Learning Curves,” in *IJCAI*, 2015.
- [65] M. P. Deisenroth, A. A. Faisal, and C. Soong Ong, *Mathematics for Machine Learning*. Cambridge University Press, 2020.
- [66] D. P. Kingma and J. Ba, “Adam: {A} Method for Stochastic Optimization,” *CoRR*, vol. abs/1412.6, 2014.
- [67] A. Rajaraman, J. D. Ullman, and J. Leskovec, “Mining of Massive Datasets (Google eBook),” p. 315, 2012.
- [68] M. J. Zaki and W. J. Meira, *Data Mining and Analysis: fundamental concepts and algorithms*. Cambridge University Press, 2014.
- [69] M. J. Pavlović, D. Markushev, M. Popovi, and S. Galović, “Deep Learning in Development of Model- Dependent Diagnostic: Recognition of Detector Characteristics in Measured Responses,” in *Proceedings of 6th International conference on electrical, electronic, and computing engineering (IcETRAN)*, 2019.
- [70] J. Bergstra, R. Bardenet, Y. Bengio, and K. Balazs, “Algorithms for Hyper-Parameter Optimization,” in *In Advances in Neural Information Processing Systems 24: 25th Annual Conference on Neural Information Processing Systems 2011, NIPS 2011*, 2011, pp. 1–9.
- [71] B. J. Snoek, H. Larochelle, and R. P. Adams, “Practical Bayesian optimization of machine learning algorithms,” in *NIPS’12: Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 2*, 2012, pp. 1–12.
- [72] A. Avati, K. Jung, S. Harman, L. Downing, A. Ng, and N. H. Shah, “Improving palliative care with deep learning,” *BMC Med. Inform. Decis. Mak.*, vol. 18, pp. 311–316, 2018.
- [73] A. Kupusinac, E. Stokić, and R. Doroslovački, “Predicting body fat percentage based on gender, age and BMI by using artificial neural networks,” *Comput. Methods Programs Biomed.*, vol. Vol. 113, no. No 2, pp. 610–619, 2014.
- [74] A. Kupusinac, E. Stokić, D. Lečić, D. Tomić-Naglić, and B. Srdić Galić, “Gender-, Age-, and BMI-Specific Threshold Values of Sagittal Abdominal Diameter Obtained by Artificial Neural Networks,” *J. Med. Biol. Eng.*, vol. Vol. 35, no. No 6, pp. 783–788, 2015.

- [75] D. Ivanović, A. Kupusinac, E. Stokić, R. Doroslovački, and D. Ivetić, “ANN Prediction of Metabolic Syndrome: a Complex Puzzle that will be Completed,” *J. Med. Syst.*, vol. 40, no. 12, pp. 1–7, 2016.
- [76] A. Kupusinac, R. Doroslovački, D. Malbaški, B. Srdić Galić, and E. Stokić, “A primary estimation of the cardiometabolic risk by using artificial neural networks, Vol. 43, No 6, pp. 751-757, ISSN 0010-4825,” *Comput. Biol. Med.*, vol. Vol. 43, no. No 6, pp. 751–757, 2013.
- [77] I. Ilievski, T. Akhtar, J. Feng, and C. A. Shoemaker, “Efficient Hyperparameter Optimization of Deep Learning Algorithms Using Deterministic RBF Surrogates,” pp. 822–829, 2012.
- [78] J. Ahmad, H. Farman, and Z. Jan, “Deep Learning Methods and Applications,” *SpringerBriefs Comput. Sci.*, pp. 31–42, 2019.
- [79] K. Djordjevic *et al.*, “Photoacoustic optical semiconductor characterization based on machine learning and reverse-back procedure,” *Opt. Quantum Electron.*, vol. 52, no. 5, 2020.
- [80] K. Kawaguchi, L. P. Kaelbling, and Y. Bengio, “Generalization in Deep Learning,” 2017.
- [81] Y. S. Abu-Mostafa, M. Magdon-Ismail, and H.-T. Lin, *Learning From Data*. AML Book, 2012.
- [82] S. A. Dyer and J. S. Dyer, “Cubic-spline interpolation. 1,” *IEEE Instrum. Meas. Mag.*, vol. 4, no. 1, pp. 44–46, Mar. 2001.
- [83] A. M. Mansanares, H. Vargas, F. Galembeck, J. Buijs, and D. Bicanic, “Photoacoustic characterization of a two-layer system,” *J. Appl. Phys.*, vol. 70, no. 11, pp. 7046–7050, 1991.
- [84] E. Martel *et al.*, “Implementation of the Principal Component Analysis onto high-performance computer facilities for hyperspectral dimensionality reduction: Results and comparisons,” *Remote Sens.*, vol. 10, no. 6, 2018.
- [85] S. Samadi, U. Tantipongpipat, J. Morgenstern, M. Singh, and S. Vempala, “The Price of Fair PCA: One Extra Dimension,” *NeurIPS*, 2018.
- [86] T. I. Jolliffe and J. Cadima, “Principal component analysis: a review and recent developments,” *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.*, vol. 374, no. 2065, Apr. 2016.
- [87] C. A. Uribe, “Expert knowledge-guided feature selection for data-based industrial process monitoring,” *Rev.fac.ing.univ. Antioquia*, vol. 65, no. December 2012, pp. 112–125, 2012.

Овај Образац чини саставни део докторске дисертације, односно докторског уметничког пројекта који се брани на Универзитету у Новом Саду. Попуњен Образац укоричити иза текста докторске дисертације, односно докторског уметничког пројекта.

План третмана података

Назив пројекта/истраживања
Програмски оквир заснован на машинском учењу за аутоматизацију обраде резултата фотоакустичних мерења
Назив институције/институција у оквиру којих се спроводи истраживање
а) Универзитет у Новом Саду, Факултет техничких наука, Департман за рачунарство и аутоматику; б) Универзитет у Београду, Институт за нуклеарне науке “Винча”, институт од националног значаја; в) Универзитет у Београду, Институт за физику у Земуну, институт од националног значаја; г) Академија струковних студија Западна Србија.
Назив програма у оквиру ког се реализује истраживање
1. Опис података
1.1 Врста студије <i>Укратко описати тип студије у оквиру које се подаци прикупљају</i> Докторска дисертација
1.2 Врсте података а) квантитативни б) квалитативни
1.3. Начин прикупљања података

- а) анкете, упитници, тестови
- б) клиничке процене, медицински записи, електронски здравствени записи
- в) генотипови: навести врсту _____
- г) административни подаци: навести врсту _____
- д) узорци ткива: навести врсту _____
- ђ) снимци, фотографије: навести врсту _____
- е) текст, навести врсту **Литературни извори**
- ж) мапа, навести врсту _____
- з) остало: описати **Нумерички експерименти и реални експерименти**

1.3 Формат података, употребљене скале, количина података

1.3.1 Употребљени софтвер и формат датотеке:

- а) Excel фајл, датотека _____
- б) SPSS фајл, датотека _____
- в) PDF фајл, датотека _____
- д) Текст фајл, датотека **.txt**
- е) JPG фајл, датотека _____
- ф) Остало, датотека **.opj, .mat**

1.3.2. Број записа (код квантитативних података)

- а) број варијабли **400**
- б) број мерења (испитаника, процена, снимака и сл.) **337 500**

1.3.3. Поновљена мерења

- а) да
- б) **не**

Уколико је одговор да, одговорити на следећа питања:

- а) временски размак између поновљених мера је _____ је

- б) варијабле које се више пута мере односе се на _____
- в) нове верзије фајлова који садрже поновљена мерења су именоване као _____

Напомене: _____

Да ли формати и софтвер омогућавају дељење и дугорочну валидност података?

а) *Да*

б) *Не*

Ако је одговор не, образложити _____

2. Прикупљање података

2.1 Методологија за прикупљање/генерисање података

2.1.1. У оквиру ког истраживачког нацрта су подаци прикупљени?

- а) експеримент, навести тип **нумерички и реални експеримент**
- б) корелационо истраживање, навести тип _____
- ц) анализа текста, навести тип _____
- д) остало, навести шта _____

2.1.2 Навести врсте мерних инструмената или стандарде података специфичних за одређену научну дисциплину (ако постоје).

Гас микрофонска фреквентна фотоакустична поставка са хелијом минималне запремине

2.2 Квалитет података и стандарди

2.2.1. Третман недостајућих података

- а) Да ли матрица садржи недостајуће податке? Да **Не**

Ако је одговор да, одговорити на следећа питања:

- а) Колики је број недостајућих података? _____
- б) Да ли се кориснику матрице препоручује замена недостајућих података? Да Не
- в) Ако је одговор да, навести сугестије за третман замене недостајућих података
-

2.2.2. На који начин је контролисан квалитет података? Описати

Квалитет података је контролисан поређењем добијених података са реалним експериментом.

2.2.3. На који начин је извршена контрола уноса података у матрицу?

Контрола уноса података у матрицу је изведена теоријским моделом и експертским знањем.

3. Третман података и пратећа документација

3.1. Третман и чување података

3.1.1. Подаци ће бити депоновани у Репозиторијум докторских дисертација на Универзитету у Новом Саду

3.1.2. URL адреса <https://www.cris.uns.ac.rs/searchDissertations.jsf>

3.1.3. DOI _____

3.1.4. Да ли ће подаци бити у отвореном приступу?

- а) Да
- б) Да, али после ембарга који ће трајати до _____
- в) Не

Ако је одговор не, навести разлог _____

3.1.5. Подаци неће бити депоновани у репозиторијум, али ће бити чувани.

Образложење

3.2 Метаподаци и документација података

3.2.1. Који стандард за метаподатке ће бити примењен? _____

3.2.1. Навести метаподатке на основу којих су подаци депоновани у репозиторијум.

Ако је потребно, навести методе које се користе за преузимање података, аналитичке и процедуралне информације, њихово кодирање, детаљне описе варијабли, записа итд.

3.3 Стратегија и стандарди за чување података

3.3.1. До ког периода ће подаци бити чувани у репозиторијуму? _____

3.3.2. Да ли ће подаци бити депоновани под шифром? **Да** **Не**

3.3.3. Да ли ће шифра бити доступна одређеном кругу истраживача? **Да** **Не**

3.3.4. Да ли се подаци морају уклонити из отвореног приступа после извесног времена?

Да **Не**

Образложити

4. Безбедност података и заштита поверљивих информација

Овај одељак МОРА бити попуњен ако ваши подаци укључују личне податке који се односе на учеснике у истраживању. За друга истраживања треба такође размотрити заштиту и сигурност података.

4.1 Формални стандарди за сигурност информација/података

Истраживачи који спроводе испитивања с људима морају да се придржавају Закона о заштити података о личности (https://www.paragraf.rs/propisi/zakon_o_zastiti_podataka_o_licnosti.html) и одговарајућег институционалног кодекса о академском интегритету.

4.1.2. Да ли је истраживање одобрено од стране етичке комисије? **Да** **Не**

Ако је одговор **Да**, навести датум и назив етичке комисије која је одобрила истраживање

4.1.2. Да ли подаци укључују личне податке учесника у истраживању? Да **Не**

Ако је одговор да, наведите на који начин сте осигурали поверљивост и сигурност информација везаних за испитанике:

- а) Подаци нису у отвореном приступу
 - б) Подаци су анонимизирани
 - ц) Остало, навести шта
-
-

5. Доступност података

5.1. Подаци ће бити

- а) **јавно доступни**
- б) доступни само уском кругу истраживача у одређеној научној области
- ц) затворени

Ако су подаци доступни само уском кругу истраживача, навести под којим условима могу да их користе:

Ако су подаци доступни само уском кругу истраживача, навести на који начин могу приступити подацима:

5.4. Навести лиценцу под којом ће прикупљени подаци бити архивирани.

Ауторство-некомерцијално-без прераде

6. Улоге и одговорност

6.1. Навести име и презиме и мејл адресу власника (аутора) података

Мирослава Јордовић Павловић, miroslava.jp@gmail.com, miroslava.jordovic-pavlovic@vpts.edu.rs

6.2. Навести име и презиме и мејл адресу особе која одржава матрицу с подацима

Мирослава Јордовић Павловић, miroslavajp@gmail.com, miroslava.jordovic-pavlovic@vpts.edu.rs

6.3. Навести име и презиме и мејл адресу особе која омогућује приступ подацима другим истраживачима

Мирослава Јордовић Павловић, miroslavajp@gmail.com, miroslava.jordovic-pavlovic@vpts.edu.rs
