

УНИВЕРЗИТЕТ У БЕОГРАДУ
ЕЛЕКТРОТЕХНИЧКИ ФАКУЛТЕТ

Владимир С. Полужански

**Примена вештачке интелигенције у
изражавању мерне несигурности
неитеративног алгоритма за акустичко
лоцирање парцијалног пражњења у
минералном уљу**

Докторска дисертација

Београд, 2023.

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Vladimir S. Poluzanski

**Application of artificial intelligence to express
the measurement uncertainty of non-iterative
algorithm for the acoustic location of partial
discharge in mineral oil**

Doctoral Dissertation

Belgrade, 2023.

Ова страна је намерно остављена празна

**ПОДАЦИ О МЕНТОРУ И ЧЛАНОВИМА КОМИСИЈЕ ЗА ОДБРАНУ
ДОКТОРСКЕ ДИСЕРТАЦИЈЕ**

Ментори

Др Бошко Николић, редовни професор
Универзитет у Београду, Електротехнички факултет

Др Ковиљка Станковић, ванредни професор
Универзитет у Београду, Електротехнички факултет

Чланови комисије

Датум одбране: _____

Ова страна је намерно остављена празна

ЗАХВАЛНИЦА

Ову дисертацију посвећујем мојој породици, оцу Срећку, мајци Новки, сестри Гордани, сестрићу Филипу и баби Кати уз захвалност на свесрдној подршци на овом путу.

Менторима др Бошку Николићу, редовном професору и др Ковиљки Станковић, ванредном професору, се захваљујем на стручној подршци и усмеравању.

Захвалан сам за подршку и разумевање од стране моје матичне куће Електротехничког института Никола Тесла АД Београд, а посебно директору Института Драгану Ковачевићу и интерном ментору Срђану Милосављевићу.

За свесрдну подршку и сарадњу захвалност дугујем колегама: Ненаду Карталовићу, Николи Миладиновићу, Александру Жигићу, Јелени Лукић, Валентини Васовић, Мирославу Радојчићу, Урошу Ковачевићу и Марјану Стојковићу.

Посебну захвалност дугујем породици Стевановић и мојој тетки Вуки, васпитачици Светлани Ерић, учитељу Раду Нићифоровићу, разредној Цани Вукашиновић, професору математике Ивану Павловићу и професору физике Мирољубу Станојевићу.

Примена вештачке интелигенције у изражавању мерне несигурности неитеративног алгоритма за акустичко лоцирање парцијалног пражњења у минералном уљу

Сажетак: Стандардне методе за акустичко лоцирање парцијалног пражњења у минералном уљу користе претпоставку о константној вредности температуре минералног уља при изражавању резултата. Истраживањем у оквиру докторске дисертације се таргетира оправданост коришћења дате претпоставке у неитеративном алгоритму на нови начин, са аспекта мерне несигурности. Резултат предметног истраживања је квантификација утицаја промене температуре минералног уља на буџет комбиноване мерне несигурности неитеративног алгоритма применом метода вештачке интелигенције, као и утврђивање значајности односно доприноса других улазних параметара (релативна конфигурација сензора и извора, коришћени модел машинског обучавања) у буџету мерне несигурности. У сврху формирања и имплементације поступка квантификације доприноса промене температуре минералног уља комбинованој мерној несигурности неитеративног алгоритма, развијен је наменски софтверски агент са обучавањем (машинским учењем). На основу вредности коефицијента детерминације R^2 , употреба метода машинског обучавања је унапредила процену доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма за више од два пута. Међутим, дата примена метода машинског обучавања (вештачке интелигенције) је проузроковала нови извор мерне несигурности који потиче од самог модела машинског обучавања. За изражавање мерне несигурности модела машинског обучавања предложен је нови поступак на основу изражавања мерне несигурности типа Б и аналогije између модела машинског обучавања и мерног уређаја. Валидација резултата софтверског агента је спроведена на моделу у лабораторијским условима. Истраживања су у складу са трендом коришћења софтверских алата и метода вештачке интелигенције у оптимизацији решавања нелинеарних проблема код којих се до решења не може доћи аналитичким методама на једноставан (познат) начин. Циљ истраживања је унапређење неитеративне све-акустичке методе преко подизања нивоа статистичке сигурности и поузданости резултата мерења применом наменског софтверског агента. Унапређени алгоритам могу користити стручњаци који се баве стандардизацијом метода, који врше испитивања опреме у лабораторијама, погонима и на терену, код које се користи минерално уље као изолациони материјал. Нови предложени поступак за одређивање мерне несигурности регресионог модела машинског обучавања није ограничен на скуп података из предметног истраживања већ се може користити у свим сличним регресионим моделима укључујући и оне који користе концепт великих података (енгл. *big data*) за обучавање.

Кључне речи: вештачка интелигенција, машинско учење, Монте Карло метода, мерна несигурност, неитеративни алгоритам, парцијално пражњење, акустичка мерења, изолационо минерално уље, температура минералног уља, софтверски агент

Научна област: Техничке науке – електротехника

Уже научне области: Вештачка интелигенција, Метрологија

УДК:

Application of artificial intelligence to express the measurement uncertainty of non-iterative algorithm for the acoustic location of partial discharge in mineral oil

Abstract: Standard acoustic methods for locating partial discharge in mineral oil use the assumption of a constant oil temperature when expressing the results. The research within the doctoral dissertation targets the justification of using the given assumption in the non-iterative algorithm in a novel way from the aspect of measurement uncertainty. The result of the subject research is the quantification of the influence of the change in mineral oil temperature on a budget of the combined measurement uncertainty of the non-iterative algorithm using artificial intelligence, as well as the determination of the significance of the contribution of other input parameters (relative configuration of sensors and partial discharge, the used machine learning model) in the budget of measurement uncertainty. A dedicated software agent with machine learning was developed to create and implement a procedure for quantifying the contribution of mineral oil temperature changes to the combined measurement uncertainty of the non-iterative algorithm. Based on the value of the coefficient of determination R^2 , machine learning methods improved the estimation of the contribution of mineral oil temperature to the measurement uncertainty budget of the non-iterative algorithm by more than two times. However, the application of machine learning (artificial intelligence) has caused a new source of measurement uncertainty that originates from the machine learning model. A novel procedure to express the measurement uncertainty of the machine learning model was proposed based on the type B measurement uncertainty and the analogy between a machine learning model and a measuring device. The validation of the results of the software agent was carried out on the actual model in laboratory conditions. Research is in line with the trend of using software tools and artificial intelligence methods to optimize non-linear problems where the solution cannot be reached by analytical techniques in a straightforward (known) way. The research aims to improve the non-iterative all-acoustic method by increasing the statistical certainty and reliability of measurement results using a dedicated software agent. The improved algorithm can be used by experts who standardize methods and perform equipment tests in laboratories, plants, and the field, where mineral oil is used as an insulating material. The novel proposed procedure for determining the measurement uncertainty of the machine learning regression model is not limited to the data set from the subject research but can be used in all similar regression models, including those that use big data for training.

Keywords: artificial intelligence, machine learning, Monte Carlo method, measurement uncertainty, non-iterative algorithm, partial discharge, acoustic measurements, insulating mineral oil, mineral oil temperature, software agent

Scientific field: Technical science – Electrical engineering

Scientific subfields: Artificial intelligence, Metrology

UDK:

Садржај

1. Увод	- 1 -
1.1. Сврха истраживања	- 1 -
1.1.1. Опис изазова	- 1 -
1.1.2. Квантификација утицаја промене температуре минералног уља	- 1 -
1.1.3. Квантификација утицаја модела машинског обучавања	- 3 -
1.1.4. Појашњење предметног истраживања и предложеног решења	- 3 -
1.2. Преглед дисертације по поглављима	- 4 -
2. Изражавање мерне несигурности	- 6 -
2.1. Увод	- 6 -
2.2. Обрада мерних резултата	- 6 -
2.3. Функције расподеле вероватноће резултата мерења	- 7 -
2.4. Одређивање мерне несигурности	- 8 -
2.5. Мерна несигурност типа А	- 8 -
2.6. Мерна несигурност типа Б	- 9 -
2.7. Комбинована мерна несигурност	- 9 -
2.8. Буџет мерне несигурности	- 10 -
2.9. Процена вредности коефицијента осетљивости	- 11 -
2.10. Нумеричко диференцирање помоћу Тејлоровог реда	- 11 -
3. Акустичко лоцирање парцијалног пражњења у минералном уљу	- 13 -
3.1. Парцијално пражњење	- 13 -
3.2. Детекција парцијалног пражњења у минералном уљу	- 13 -
3.3. Све-акустичка метода за лоцирање парцијалног пражњења у минералном уљу	- 14 -
3.4. Нелинеарност	- 15 -
3.5. Неитеративно све-акустичко лоцирање парцијалног пражњења у минералном уљу	- 16 -
3.6. Неитеративни алгоритам	- 16 -
3.7. Проблем проузрокован конструкцијом (енгл. <i>Structure-born problem</i>)	- 19 -
3.8. Проблем тоталне рефлексије	- 21 -
3.9. Изолационо минерално уље	- 22 -
3.10. Температура минералног уља	- 23 -
3.11. Типичне врсте парцијалног пражњења у минералном уљу	- 25 -
4. Вештачка интелигенција	- 27 -
4.1. Увод	- 27 -
4.2. Машинско обучавање (учење)	- 28 -
4.2.1. Увод	- 28 -
4.2.2. Обучавање на основу примера	- 29 -
4.2.3. Надгледано обучавање	- 30 -
4.2.4. Процењивање и бирање најбоље хипотезе	- 32 -
4.2.5. Функција губитка	- 33 -
4.2.6. Регуларизација	- 34 -
4.2.7. Коефицијент детерминације- R^2	- 35 -
4.2.8. Обучавање стабала одлучивања	- 35 -
4.2.8.1. Увод	- 35 -
4.2.8.2. Индукција стабла одлучивања из примера	- 36 -
4.2.8.3. Бирање тестова атрибута	- 39 -
4.2.8.4. Преприлагођавање	- 42 -
4.2.9. Линеарна регресија	- 42 -
4.2.10. Скупно обучавање	- 44 -
4.2.10.1. Подстицање опадањем градијента	- 45 -
4.2.10.2. Случајне шуме	- 46 -
4.2.10.3. Онлајн обучавање	- 47 -
4.2.10.4. ДАРТ алгоритам	- 48 -
4.3. Технологија ML.NET за имплементацију машинског обучавања	- 49 -
5. Интелигентни агенти	- 51 -

5.1.	Увод.....	- 51 -
5.2.	Окружење задатка.....	- 52 -
5.3.	Структура агента.....	- 55 -
5.4.	Једноставни рефлексни агенти	- 56 -
5.5.	Рефлексни агенти засновани на моделу.....	- 57 -
5.6.	Агенти засновани на циљу.....	- 58 -
5.7.	Агенти засновани на корисности	- 58 -
5.8.	Агенти са обучавањем.....	- 59 -
6.	Асистент за прорачун мерне несигурности	- 61 -
6.1.	Формирање алгорита за процену доприноса температуре уља стандардној комбинованој мерној несигурности неитеративног алгорита.....	- 61 -
6.1.1.	Анализа осетљивости неитеративног модела.....	- 61 -
6.1.1.1.	Увод.....	- 61 -
6.1.1.2.	Улазне и излазне информације модела	- 62 -
6.1.1.3.	Коефицијент осетљивости температуре минералног уља.....	- 63 -
6.1.2.	Алгоритам један по један	- 64 -
6.1.3.	Алгоритам за истовремене варијације улазних променљивих	- 67 -
6.2.	Имплементација алгорита у софтверског агента	- 70 -
6.2.1.	Прва фаза: једноставни рефлексни агент.....	- 71 -
6.2.2.	Друга фаза: рефлексни агент заснован на моделу	- 73 -
6.2.3.	Мерна несигурност модела машинског обучавања	- 76 -
6.2.4.	Трећа фаза: рефлексни агент заснован са моделу, са обучавањем.....	- 78 -
7.	Резултати истраживања	- 80 -
7.1.	Резултати софтверских симулација.....	- 80 -
7.1.1.	Почетна симулација.....	- 80 -
7.1.2.	Прва симулација.....	- 86 -
7.1.3.	Друга симулација.....	- 93 -
7.1.4.	Додатне симулације.....	- 95 -
7.2.	Експериментална поставка	- 98 -
7.3.	Експериментални резултати	- 101 -
7.3.1.	Верификација резултата прве симулације.....	- 101 -
7.3.2.	Верификација резултата друге симулације	- 102 -
7.4.	Резултати тренирања, валидације и тестирања модела машинског обучавања	- 104 -
8.	Анализа и дискусија добијених резултата	- 110 -
9.	Закључак и смернице будућег истраживања	- 115 -
9.1.	Закључак.....	- 115 -
9.2.	Смернице будућег истраживања	- 116 -
	ЛИТЕРАТУРА.....	- 117 -
	ПРИЛОГ 1.....	- 126 -
	БИОГРАФСКИ ПОДАЦИ О АУТОРУ ДИСЕРТАЦИЈЕ.....	- 136 -
	Изјава о ауторству.....	- 137 -
	Изјава о истоветности штампане и електронске верзије докторског рада.....	- 138 -
	Изјава о коришћењу.....	- 139 -

АКРОНИМИ

ПП	парцијално пражњење
ВИ	вештачка интелигенција
МО	машинско обучавање
ДАРТ	<i>Dropout Additive Regression Trees</i>
ЦПУ	централна процесорска јединица
ИоТ	<i>Internet of Things</i>
АЕ	акустички
АПИ	<i>Application Programming Interface</i>

1. Увод

У уводном поглављу објашњена је сврха, описани изазови и постављени циљеви предметног истраживања примене вештачке интелигенције у изражавању мерне несигурности неитеративног алгоритма за акустичко лоцирање парцијалног пражњења у минералном уљу. Први од циљева је квантификација утицаја промене температуре минералног уља на буџет комбиноване мерне несигурности неитеративног алгоритма. Други циљ је квантификација утицаја модела машинског обучавања на дати буџет. Постизање постављених циљева је довело до значајних резултата у смислу доприноса истраживањима, према актуелној релевантној литератури. На крају, дат је преглед дисертације по поглављима.

1.1. Сврха истраживања

Сврха предметног истраживања је квантификација утицаја промене температуре минералног уља на буџет комбиноване мерне несигурности неитеративног алгоритма за све-акустичко лоцирање ПП у минералном уљу применом метода вештачке интелигенције (машинског обучавања), као и утврђивање значајности односно доприноса других улазних параметара (релативна конфигурација сензора и извора, коришћеног модела машинског обучавања) датом буџету мерне несигурности.

1.1.1. Опис изазова

Неитеративни математички алгоритам даје решење за систем нелинеарних једначина које одређују локацију ПП. Истраживања нелинеарне динамике откривају да нелинеарне појаве могу дати нове и корисне ефекте у многим практичним инжењерским проблемима [1]. Постојећи алгоритми из доступне научне литературе се доминантно баве карактеризацијом акустичких сигнала као и прецизношћу и тачношћу мерења. Међутим, доступна литература се не бави поузданошћу резултата мерења акустичких метода као ни утврђивањем значајности односно доприноса улазних параметара буџету мерне несигурности. Само у неким радовима, из шире области методологије лоцирања ПП, је примећен утицај конфигурације сензора на прецизност и тачност резултата, али није подробније истраживан [2]–[7]. Доступна литература у којој се анализира утицај температуре минералног уља на поузданост акустичких метода је скромна [2], [8]. Такође, важећи стандарди који се односе на методу не дају препоруке за температурну корекцију резултата мерења [9], [10].

Неитеративни алгоритам има укупно 19 параметара (16 улазних и 3 излазна), односно релативно велики деветнаесто-димензионални простор стања. Квантификација утицаја промене температуре минералног уља на буџет комбиноване мерне несигурности неитеративног алгоритма се не може извршити аналитичким методама на директан (познат) начин. За дати проблем, генерисање, истраживање простора стања, уочавање одређених особина и односа међу параметрима, формирање и унапређење поступка квантификације (процене) се може ефикасно постићи применом статистичких метода, нумеричких метода, Монте Карло методе и методе машинског обучавања (учења), из области вештачке интелигенције.

1.1.2. Квантификација утицаја промене температуре минералног уља

Ниједан изолациони материјал није „савршен“. Изолационо минерално уље као природни диелектрик користи се у великом броју уређаја који учествују у процесима производње, преноса, дистрибуције електричне енергије као и у индустријским постројењима. Правилан рад и одржавање датих уређаја (опреме) су кључни да би се избегли

непланирани застоји, финансијски губици и очувала животна средина. Парцијална пражњења су међу најчешћим узроцима деградације диелектричних карактеристика изолационог минералног уља. Правовремено и прецизно откривање, лоцирање, праћење и дијагностика ПП значајно унапређују поузданост рада опреме у којој се минерално уље користи као изолациони материјал. Последњих година, са унапређењем технологије израде сензора, сензорских мрежа и рачунарских система (нпр. индустријски интернет предмета), примена модела праћења стања опреме заснованих на подацима (енгл. *data-driven decision-making*) је у експанзији [8], [11].

У доступној литератури, као најзначајнији параметар који утиче на тачност акустичких метода за лоцирање ПП у минералном уљу наводи се прецизност одређивања временског кашњења акустичких сигнала ПП на сензоре. Међутим, неитеративне акустичке методе (све-акустичка или комбинована електрично акустичка) имају додатни параметар који може значајно да утиче на тачност одређивања локације ПП који потиче од специфичности математичког модела методе.

Математички модел све-акустичке неитеративне методе заснива се на апроксимацији (претпоставци) да је брзина акустичког сигнала константна по волумену материјала. Брзина акустичког сигнала доминантно зависи од температуре минералног уља [12], односно температура уља се такође сматра константном. Посматрано са становишта физике, термодинамичких својстава флуида и конструкције опреме, дата апроксимација је „груба“ и може бити извор велике мерне несигурности при одређивању локације ПП датом методом. Температура минералног уља је хетерогена, нестационарна и може значајно варирати током рада опреме (у зависности од оптерећења опреме, температуре околине и конструкције опреме) [13].

У доступној литератури се за вредност брзине простирања акустичког сигнала у неитеративном алгоритму користи усвојена константна вредност. Ова вредност се може усвојити на основу препоруке за све акустичке методе да занемаре утицај промене брзине акустичког сигнала и користе константну вредност од 1413 m/s, што одговара температури минералног уља од 20 °C [9]. Ова препорука потиче из стандарда *IEEE C57.127-2007*, али је уклоњена током припреме *IEEE C57.127-2018* [14]. Поједини истраживачи препоручују усвајање константне вредности која одговара средњој температури минералног уља у тренутку мерења [10]. Обе ове препоруке третирају изолационо минерално уље као хомоген, стационаран медијум [8]. У литератури је предложена и идеја прецизног одређивања путања акустичког сигнала ПП кроз електроенергетску опрему и одређивање варијација брзине акустичког сигнала кроз минерално уље [15]. Дата идеја подразумева прецизно познавање конструкције опреме, места појаве ПП и путање акустичког сигнала ПП до сензора, што у пракси најчешће није могуће. У доступној литератури није пронађена посебна препорука за све-акустичку неитеративну методу која узима у обзир специфичност математичког модела методе, нелинеарност неитеративног алгоритма и утицај промене температуре минералног уља (брзине акустичког сигнала).

У оквиру предметног истраживања таргетира се оправданост коришћења претпоставке о коришћењу константне вредности температуре минералног уља у неитеративном алгоритму на нови начин, са аспекта мерне несигурности. У сврху формирања и имплементације поступка квантификације доприноса промене температуре минералног уља комбинованој мерној несигурности неитеративног алгоритма развијен је наменски софтверски агент са обучавањем (машинским учењем). За потребе софтверског агента осмишљен је алгоритам који има могућност симулирања (Монте Карло методом [16], [17]) скупа параметара са великим бројем тачака у вишедимензионалном простору стања неитеративног алгоритма. Валидација резултата софтверског агента је спроведена на моделу у лабораторијским условима. Користећи добијене и експериментално потврђене закључке и податке за тренинг, валидацију и тестирање модела, унапређене су перформансе софтверског агента функционалношћу обучавања.

Примена метода машинског обучавања за квантификацију утицаја промене температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма проузроковала је нови (додатни) извор мерне несигурности који потиче од самог модела машинског обучавања, који такође треба независно квантификовати.

1.1.3. Квантификација утицаја модела машинског обучавања

Најновији развој информационо-комуникационих технологија у свакодневном животу омогућава све већу примену различитих уређаја и алата, њихову повезаност и аутоматизацију рада. Неке од битних карактеристика ових система су генерисање велике количине података, праћење и предвиђање различитих параметара, као и могућност смањења (оптимизације) употребе ресурса. Да би се постигли најбољи резултати, приликом развоја оваквих платформи користи се вештачка интелигенција, али је потребна и процена мерне несигурности примењених модела [18], [19].

Уопштено речено, технике вештачке интелигенције и машинског обучавања користе се за анализу сложених података и предузимање одговарајућих радњи. У савременом друштву, различити сектори који играју виталну улогу, као што су паметне мреже, интелигентни транспорт, сајбер-безбедност и комуникационе технологије, подржани су анализом великих података и ефикасном употребом ВИ и МО техника [19]–[23]. Подаци прикупљени са ИоТ (сензори, системи за праћење, финансијски подаци, здравствени подаци, друштвене мреже и сл.) могу бити недоследни, некомплетни и редундантни, што доводи до смањеног поверења у анализу података [24]. Контролисање и квантификовање несигурности МО модела побољшава поузданост анализе података. Такође, повећава поверење у одлуке модела.

Модел МО се састоји од знања о структури модела и скупу података за обуку. У контексту МО, природа неизвесности се може класификовати као епистемичка (неизвесност параметара) и алеаторична (неизвесност података) [24]–[27]. У доступној литератури, концепти квантификације несигурности релевантни за МО су груписани као фреквентистичко закључивање и Бајесово закључивање. Фреквентистичко закључивање се бави грешкама у проценама параметара. Бајесово закључивање се користи у традиционалном МО (Гаусова регресија процеса (ГРП), ГРП и неуронске мреже засноване на физици) и дубоком учењу (Бајесова неуронска мрежа и Бајесова неуронска мрежа заснована на физици) [24], [28]. Ови концепти се првенствено баве прецизношћу модела [29]–[31] (инверзни проблем пропагације) а не мерном несигурношћу [32]. Недавно су истраживачи повећали интересовање за квантификацију несигурности у вези са моделима машинског обучавања [33]–[35]. У систематским прегледима литературе везаним за МО и апликације дубоког учења у паметним градовима [36] и епидемији КОВИД-19 [37], параметар прецизности је добио највећу пажњу међу прегледаним чланцима (28,1% и 48,8%, респективно). Број истраживачких публикација у вези са овом темом порастао је са око 7000 у 2011. на око 24 000 у 2020. години [19], [24].

У оквиру предметног истраживања предложен је нови приступ „на основу процене“ (енгл. „*judgmental*“) [19], [28] у процени (изражавању) мерне несигурности регресионог модела машинског обучавања. Метода се заснива на аналогiji МО модела и стварног мерног уређаја. Дати приступ користи процедуру за изражавање мерне несигурности типа Б [38] и максималне вредности емпиријске апсолутне функције губитка МО модела. Пошто је изражавање мерне несигурности типа Б засновано на искуству и просуђивању мерача (оператора), приступ је назван „на основу процене“.

1.1.4. Појашњење предметног истраживања и предложеног решења

Истраживање је у складу са трендом коришћења софтверских алата и метода вештачке интелигенције у оптимизацији решавања нелинеарних проблема код којих се до решења не

може доћи аналитичким методама на једноставан (познат) начин. Циљ истраживања је унапређење неитеративне све-акустичке методе преко подизања нивоа статистичке сигурности и поузданости резултата мерења применом наменског софтверског агента.

Унапређени алгоритам могу користити стручњаци који се баве стандардизацијом метода, који врше испитивања опреме у лабораторијама, погонима и на терену, код које се користи минерално уље као изолациони материјал.

Нови предложени поступак за одређивање мерне несигурности регресионог модела машинског обучавања није ограничен на скуп података из предметног истраживања већ се може користити у свим сличним регресионим моделима укључујући и оне који користе концепт великих података (енгл. *big data*) за обучавање.

Предметно истраживање се не односи на специфичну врсту опреме која користи минерално уље као изолациони материјал већ се разматра област испуњена минералним уљем независно од врсте опреме у којој се налази. Такође, истраживањем се не улази у разматрање термодинамичких својстава минералног уља током његове експлоатације. Предложено решење заснива се на новом приступу датом проблему са аспекта изражавања мерне несигурности (поузданости резултата мерења) помоћу метода вештачке интелигенције (машинског обучавања), за одговарајући опсег несигурности температуре минералног уља и средње растојање акустичких сензора од извора ПП.

1.2. Преглед дисертације по поглављима

Истраживање у оквиру дисертације је представљено кроз 9 поглавља и један прилог. Структура садржаја докторске дисертације одговара спроведеним фазама истраживања.

У уводном поглављу детаљно је описана сврха предметног истраживања и дато је појашњење на које научне дисциплине се предметно истраживање односи.

Друго поглавље описује најважније концепте из области мерне несигурности. Акценат је стављен на изражавање комбиноване мерне несигурности, мерну несигурност типа Б, буџет мерне несигурности и одређивање (процену) одговарајућих коефицијената осетљивости утицајних величина.

Треће поглавље описује лоцирање ПП у минералном уљу акустичким методама. Акценат је стављен на истраживану све-акустичку неитеративну методу за лоцирање ПП у минералном уљу. Описани су трендови из области испитивања нелинеарних феномена у одговарајућим инжењерским областима. Приказан је неитеративни алгоритам и дискутовани изазови који се могу јавити при детекцији акустичког сигнала у експерименталним (реалним) условима. Затим је укратко објашњена природа минералним уља, приказана зависност брзине акустичког сигнала од температуре минералног уља и типичне врсте ПП које се јављају у минералном уљу током експлоатације.

У четвртом поглављу представљени су актуелни трендови и разматрања из доступне литературе из области ВИ и МО. Затим, описани су најзначајнији концепти из области машинског обучавања на основу примера. Дато поглавље укључује и дефиниције одговарајућих функција губитка као и коефицијента детерминације R^2 који се користе за евалуацију резултата предметног истраживања. Такође, дат је преглед обучавања стабала одлучивања, описани концепти регресије и скупног обучавања у контексту МО, са акцентом на алгоритме случајне шуме и ДАРТ алгоритам. У овом поглављу описан је и програмски оквир *ML.NET* за имплементацију машинског обучавања у *.NET* програмском окружењу.

У петом поглављу описани су основни појмови везани за теорију интелигентних агената. Акценат је стављен на описивање окружења задатка, одговарајуће особине датог окружења и представљање концепта једноставног рефлексног агента, агента заснованог на моделу и агента са функционалношћу обучавања.

У шестом поглављу описан је развој софтверског агента названог „Асистент за прорачун мерне несигурности“ по одговарајућим фазама еволутивног животног циклуса. Приказан је алгоритам за процену доприноса температуре минералног уља стандардној комбинованој мерној несигурности неитеративног алгоритма који је конструисан (осмишљен) за потребе предметног истраживања и налази се у основи датог софтверског агента. Додатно, описана је новопредложена метода „на основу процене“ за изражавање мерне несигурности модела машинског обучавања заснована на изражавању мерне несигурности типа Б и аналогiji између модела МО и реалног мерног инструмента.

Седмо поглавље приказује резултате предметног истраживања у складу са током истраживања. Прво су представљени резултати софтверских симулација затим експериментална провера (верификација) добијених резултата и напослетку резултати тренирања, валидације и тестирања одговарајућих модела машинског обучавања користећи експериментално верификоване резултате софтверских симулација.

У осмом поглављу дискутовани су и анализирани резултати из претходног поглавља. Акценат је стављен на предлог новог поступка за прорачун доприноса температуре минералног уља комбинованој мерној несигурности неитеративног алгоритма применом модела машинског обучавања који представља свеобухватну синергију резултата предметног истраживања. Такође, у датом поглављу анализирана је и оправданост препоруке из доступне литературе о коришћењу константне вредности температуре минералног уља при локализацији ПП са аспекта добијених резултата предметног истраживања.

У последњем поглављу приказани су закључци предметног истраживања и дате одговарајуће смернице будућег истраживања.

2. Изражавање мерне несигурности

Мерна несигурност је фундаментални концепт у области мерења и анализе података. Дато поглавље о изражавању мерне несигурности има за циљ да пружи свеобухватно разумевање концепта мерне несигурности, њених извора и метода које се користе за њену квантификацију (процену). Акценат је стављен на изражавање комбиноване мерне несигурности, мерну несигурност типа Б, Равномерну функцију расподеле, буџет мерне несигурности и одређивање (процену) одговарајућих коефицијената осетљивости утицајних величина.

2.1. Увод

Тачну вредност мерне величине није могуће одредити јер резултати реалних мерења у себи садрже одређен степен несигурности. Грешка мерења се дефинише као разлика измерене вредности и „тачне вредности“. „Тачна вредност“ представља вредност која је измерена еталонским мерилом, односно доступним мерилом највишег нивоа тачности. Недостатак датог приступа (теорије грешака) при обради и изражавању резултата мерења је одсуство уједначености обраде резултата и немогућност поређења истих врста мерења из различитих установа [39], [40], [41].

У циљу увођења стандардизације у област обраде и изражавања мерних резултата, водеће институције међународног метролошког система су 1993. године објавиле прву верзију Упутства за изражавање мерне несигурности [42]. Појам (концепт) мерне несигурности није у супротности са теоријом грешака већ представља нов приступ, заснован на истом математичком апарату, који је више прилагођен реалним (експерименталним) мерењима. Изражавање резултата мерења са придруженом мерном несигурношћу је заменило потребу за изражавањем грешке мерења јер се она већ налази унутар интервала мерне несигурности [39], [40], [43].

На основу [40], [41], [43] при обради и изражавању мерних резултата потребно је одредити три мерне величине: резултат мерења, мерну несигурност и њену статистичку сигурност. Резултат мерења се одређује као средња вредност поновљених мерења. Мерна несигурност (дисперзија или расипање резултата мерења) изражава се интервалом око средње вредности у коме се очекује да се налази стварна вредност мерне величине. Датом податку се придружује степен статистичке сигурности (вероватноће) [40], [41].

Сви фактори који утичу на резултат мерења могу бити извори мерне несигурности. Идентификацијом (откривањем) датих фактора и проценом њихових вредности могуће је утицати на мерну несигурност [39], [40], [41], [43], [44].

2.2. Обрада мерних резултата

За посматрану физичку величину, добијени скуп резултата поновљеним мерењем: $x_1, x_2, x_3, \dots, x_n$, назива се узорак мерења.

Средња вредност узорка је:

$$x_s = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n}. \quad (2.1)$$

Стандардно одступање узорка:

$$s = \sqrt{\sum_{i=1}^n \frac{(x_i - x_s)^2}{n-1}}. \quad (2.2)$$

Стандардно одступање средње вредности:

$$s_{x_s} = \sqrt{\sum_{i=1}^n \frac{(x_i - x_s)^2}{n(n-1)}}. \quad (2.3)$$

У случају да се мерна величина у одређује индиректно, на основу мерних утицајних величина x_i :

$$y = f(x_1, x_2, x_3, \dots, x_k), \quad (2.4)$$

стандардно одступање величине у износи:

$$s_y = \sqrt{\sum_{i=1}^k \left[\left(\frac{\partial y}{\partial x_i} \right)^2 s_{x_i}^2 \right]}, \quad (2.5)$$

при чему s_{x_i} представља стандардно одступање утицајне величине x_i .

Коефицијент корелације представља везу између утицајних величина x_p и x_q :


$$r_{x_p x_q} = \frac{\sum_{i=1}^n (x_{p,i} - x_{p,s})(x_{q,i} - x_{q,s})}{(n-1)s_{x_p} s_{x_q}}, \quad (2.6)$$

при чему s_{x_p} , s_{x_q} представљају стандардна одступања утицајних величина x_p и x_q [40], [41].

2.3. Функције расподеле вероватноће резултата мерења

Функције расподеле вероватноће које се најчешће придружују резултатима мерења су: Равномерна (Униформна), Троугаона и Гаусова (Нормална).

Код Равномерне расподеле вредности мерних резултата припадају ограниченом интервалу $(x_s - a, x_s + a)$. Све вредности унутар интервала су једнако вероватне тј. $p(x) = 1/(2a)$, где је a полуширина расподеле. Стандардно одступање је $s = a/\sqrt{3}$ при чему у интервалу $(x_s - s, x_s + s)$ се налази приближно 57,7% резултата мерења (слика 2-1). Дата расподела се примењује када се располаже са недовољно информација о мерном инструменту.



Слика 2-1 Функција расподеле вероватноће Равномерне расподеле.

Код Троугаоне расподеле постоји одређено груписање око средње вредности. Вредности мерне величине припадају ограниченom интервалу $(x_s - a, x_s + a)$. Стандардно одступање је $s = a/\sqrt{6}$ при чему у интервалу $(x_s - s, x_s + s)$ се налази приближно 65% резултата мерења. Дата расподела се примењује у случајевима када постоји груписање резултата око средње вредности, али расподела не одговара Гаусовој.

Гаусова (Нормална) расподела је дефинисана на неограниченом опсегу. У интервалу ширине једног стандардног одступања $(x_s - s, x_s + s)$ се налази приближно 68% резултата мерења [40], [41].

2.4. Одређивање мерне несигурности

Стандардна мерна несигурност u (енгл. *uncertainty*) једнака је стандардном одступању s . У зависности од придружене расподеле, статистичка сигурност која одговара интервалу $x_s \pm u$ износи приближно 57,7% за Равномерну расподелу, 65% за Троугаону расподелу и 68% за Нормалну расподелу.

Ако на мерну несигурност утиче више компоненти израчунава се стандардна комбинована мерна несигурност u_c .

Проширена мерна несигурност U је производ стандардне мерне несигурности и коефицијента проширења k . Коефицијент проширења може имати вредности у интервалу од $\sqrt{3}$ до 3. Коефицијент проширења зависи од придружене функције расподеле и циљане статистичке сигурности. На пример, за Нормалну расподелу коефицијенту проширења који је једнак тачно 2 одговара статистичка сигурност од приближно 95%, коефицијенту проширења 2,56 одговара статистичка сигурност од приближно 99% и коефицијенту проширења 3 одговара статистичка сигурност од приближно 99,7%.

На основу метода којима се одређују, постоје два основна типа мерне несигурности: мерна несигурност типа А и типа Б. Нормална расподела се најчешће придружује мерној несигурности типа А, док се мерној несигурности типа Б придружују различите расподеле [40], [41].

2.5. Мерна несигурност типа А

Мерна несигурност типа А се искључиво одређује методом статистичке обраде резултата. Да би се одредила дата мерна несигурност потребно је да мерење буде поновљено више пута (n). Мерна несигурност типа А, u_A једнака је стандардном одступању средње вредности:

$$u_A = s_{x_s} = \sqrt{\sum_{i=1}^n \frac{(x_i - x_s)^2}{n(n-1)}}. \quad (2.7)$$

Статистичка сигурност која одговара стандардној мерној несигурности типа А зависи од придружене расподеле. Код довољно великих узорака средња вредност мерења испуњава услове Централне граничне теореме па се средњој вредности може придружити Гаусова расподела. У случају мањих узорака средњој вредности се може придружити Студентова расподела. У пракси, величина узорка која се сматра довољно великом да јој се може придружити Гаусова (Студентова) расподела је $n \geq 10$ [40], [41].

У случају да практичне околности не дозвољавају понављање мерења већи број пута (нпр. само једно или два, три мерења) за мерну несигурност типа А може се користити податак о обједињеној мерној несигурности. Обједињена мерна несигурност се одређује при испитивању инструмента израчунавањем експерименталног стандардног одступања тј. стандардне мерне несигурности типа А. Дати податак се налази у уверењу о прегледу мерила под називом обједињена мерна несигурност типа А (u_{A0}) [40], [41].

2.6. Мерна несигурност типа Б

Према [40], [41] мерна несигурност типа Б одређује се свим осталим методама осим статистичком анализом поновљених резултата мерења. Дата мерна несигурност се може одредити и у случају када је мерење извршено само једанпут. Узимајући у обзир да скуп метода за одређивање дате мерне несигурности није одређен, избор метода зависи од захтева, знања и искуства мерача.

Извори података о мерној несигурности типа Б могу бити: подаци о оперативном поступку мерења, подаци о мерној опреми (упутства произвођача, уверења о еталонирању), сазнања о утицају околине на процес мерења (температура, влажност), сазнања о утицају сметњи (електромагнетне, механичке-вибрације), резултати претходних мерења, променљивост особља које врши исту врсту мерења и сл. [40], [45], [46].

Стандардна мерна несигурност типа Б, u_B , једнака је стандардном одступању услед утицаја величине од које потиче. У највећем броју случајева, услед недостатка података, мерној несигурности типа Б се придружује равномерна (униформна) расподела [40], [41].

2.7. Комбинована мерна несигурност

У случају када несигурност потиче од више различитих компоненти, одређује се комбинована мерна несигурност која представља резултантну вредност датих компоненти. Случајеви у којима се израчунава комбинована мерна несигурност су:

1. постоји мерна несигурност типа А и типа Б (мерење је понављано),
2. постоје барем две или више компоненти мерне несигурности Б које потичу од утицајних величина, а не постоји мерна несигурност типа А (мерење није понављано).

Стандардна комбинована мерна несигурност u_c израчунава се на основу поступка одређивања стандардног одступања за индиректно мерену величину у када се идентификују свих $k \geq 2$ параметара који утичу на резултат мерења:

$$u_c = \sqrt{\sum_{i=1}^k \left[\left(\frac{\partial y}{\partial x_i} \right)^2 u_{x_i}^2 \right]}, \quad (2.8)$$

где u_{x_i} представља стандардну мерну несигурност утицајне величине x_i .

Претходни израз се односи на случај када су утицајне величине x_i некорелисане (статистички независне) тј. када промена једне од величина не изазива предвидљиву промену друге величине.

У општем случају стандардна комбинована мерна несигурност је дата изразом:

$$u_c = \sqrt{\sum_{i=1}^k \left[\left(\frac{\partial y}{\partial x_i} \right)^2 u_{x_i}^2 \right] + \sum_{i=1}^k \sum_{j \neq i, j=1}^k r_{x_i x_j} u_{x_i} u_{x_j}}, \quad (2.9)$$

где је $r_{x_i x_j}$ коефицијент корелације величина x_i и x_j .

Коефицијент корелације има бројну вредност за коју важи $0 \leq |r_{x_i x_j}| \leq 1$. У случају да је дати коефицијент једнак 0, у питању су потпуно некорелисане величине. У случају да је апсолутна вредност датог коефицијента једнака 1 имамо случај потпуно корелисаних величина. У случају осталих вредности коефицијента корелације кажемо да су величине делимично корелисане. Комбинована мерна несигурност за случај потпуно корелисаних

величина је већа у односу на случај делимично корелисаних величина, док је она већа у односу на случај некорелисаних величина [40], [41].

Одређивање функције расподеле комбиноване мерне несигурности се врши конволуцијом функција расподела компонената мерне несигурности. Резултантна расподела се може одредити аналитичким или у сложенијим случајевима нумеричким (нпр. Монте Карло) поступцима. За брзо, апроксимативно, придруживање функција расподеле комбинованој мерној несигурности могу се користити одређене препоруке. На пример, уколико је мерна несигурност једне утицајне величине доминантна њена функција расподеле се може придружити комбинованој мерној несигурности и сл. [40], [41].

У пракси је чест случај да параметри (утицајне величине) од индиректно мерене величине у имају нормалну расподелу са различитим бројем степени слободe. Тада се, у смислу апроксимације, у може придружити Студентова расподела и одредити ефективни број степени слободe помоћу *Welsh-Satterthwaite* формуле [40], [41]:

$$n_{s,eff} = \frac{u_c(y)^4}{\sum_{i=1}^k \frac{(\frac{\partial y}{\partial x_i})^4 u_{x_i}^4}{n_{s_i}}}, \quad (2.10)$$

где u_{x_i} представља стандардну мерну несигурност утицајне величине x_i , и n_{s_i} број степени слободe утицајне величине x_i . За мерну несигурност типа А $n_s=n-1$ где је n број поновљених мерења. За мерну несигурност типа Б, којој се најчешће придружује равномерна расподела, $n_s \rightarrow \infty$. На основу ефективног броја степени слободe и статистичке сигурности из Студентове расподеле одређује се коефицијент проширења $k = t_{n_{s,eff}, P}$ [40], [41].

2.8. Буџет мерне несигурности

На основу [40], [42], [45], [46] резултат прорачуна мерне несигурности треба да буде представљен транспарентно тј. тако да приказује све релевантне чињенице везане за поступак одређивања мерне несигурности. Таблични приказ датих података назива се буџет мерне несигурности. Подаци које садржи буџет мерне несигурности су: идентификоване утицајне мерне величине, функције расподела утицајних величина са стандардним мерним несигурностима, усвојене функције расподеле комбиноване мерне несигурности са одговарајућим образложењем, одговарајуће факторе проширења итд. [44], [47].

У буџету мерне несигурности, меру утицаја одговарајуће компоненте на комбиновану мерну несигурност можемо изразити коефицијентима осетљивости. Ако се израз за комбиновану мерну несигурност (2.8) напише у облику:

$$u_c = \sqrt{\left(\frac{\partial y}{\partial x_1}\right)^2 u_{x_1}^2 + \left(\frac{\partial y}{\partial x_2}\right)^2 u_{x_2}^2 + \dots + \left(\frac{\partial y}{\partial x_k}\right)^2 u_{x_k}^2}. \quad (2.11)$$

За одговарајуће парцијалне изводе може да се уведе $c_i = \frac{\partial y}{\partial x_i}, i=1 \dots k$:

$$u_c = \sqrt{c_1^2 u_{x_1}^2 + c_2^2 u_{x_2}^2 + \dots + c_k^2 u_{x_k}^2}. \quad (2.12)$$

Вредност c_i називамо коефицијент осетљивости утицајне величине x_i . Дати коефицијент изражава меру утицаја одговарајуће компоненте на комбиновану мерну несигурност.

Ако су коефицијенти осетљивости свих утицајних величина једнаки 1, значи да све компоненте несигурности подједнако утичу на комбиновану мерну несигурност (адитивно одређивање мерне несигурности које се најчешће сусреће у пракси) [40], [41].

2.9. Процена вредности коефицијента осетљивости

При процени мерне несигурности типа Б, ако су познате једино доња и горња граница опсега несигурности утицајне величине $x_i \pm u_i$, оправдано је придружити Равномерну расподелу датој величини. Одговарајући коефицијент осетљивости c_i се може проценити нумеричком методом као количник промене вредности индиректно мерене величине y у тачкама горње и доње границе опсега несигурности x_i и ширине датог опсега [45]:

$$c_i = \frac{y(x_{i_s} + u_i) - y(x_{i_s} - u_i)}{2u_i}. \quad (2.13)$$

2.10. Нумеричко диференцирање помоћу Тејлоровог реда

Нека је функција f континуална функција дискретизована у еквидистантним тачкама, са кораком дискретизације h . Формула за нумеричко диференцирање функције f у тачки x_0 која узима у обзир вредности функције f у две тачке, x_0 и x_0+h , се може извести ако се дата функција представи Тејлоровим полиномом у тачки x_0 [48]:

$$f(x_0 + h) = f(x_0) + f'(x_0)h + \frac{f''(\xi)}{2}h^2, \quad \xi \in [x_0, x_0 + h]. \quad (2.14)$$

Одавде произилази:

$$f'(x_0) = \frac{f(x_0 + h) - f(x_0)}{h} - \frac{f''(\xi)}{2}h. \quad (2.15)$$

Формула за диференцирање унапред је (двотачкаста формула):

$$f'(x_0) \approx \frac{f(x_0 + h) - f(x_0)}{h}. \quad (2.16)$$

Дата апроксимација има укупну грешку диференцирања $R(h)$:

$$R(h) = r(h) + E(h). \quad (2.17)$$

Дата грешка је збир грешке методе (дискретизације) $r(h)$:

$$r(h) \approx \frac{|f''(\xi)|}{2}h, \quad r = O(h), \quad (2.18)$$

и грешке заокруживања $E(h)$:

$$E(h) = \frac{2\varepsilon}{h}, \quad |e(x)| \leq \varepsilon, \quad (2.19)$$

где је $e(x)$ грешка заокруживања вредности функције f у тачки x .

Аналогно претходном, формула за диференцирање уназад (двотачкаста формула) [48]:


$$f'(x_0) \approx \frac{f(x_0) - f(x_0 - h)}{h}. \quad (2.20)$$

Формула за централно диференцирање функције f у тачки x_0 , која узима у обзир вредности функције f у тачкама x_0+h и x_0-h (тротачкаста формула) [48]:

$$f'(x_0) \approx \frac{f(x_0 + h) - f(x_0 - h)}{2h}. \quad (2.21)$$

Грешка методе код формуле за централно диференцирање $r=O(h^2)$ тј. тачност формуле је другог реда за разлику од грешака методе код диференцирања унапред и уназад где је

тачност формуле првог реда. За малу вредност h , формула за централно диференцирање је квалитетнија од формула за диференцирање унапред и уназад [48].



Слика 2-2 Илустрација нумеричког диференцирања помоћу Тејлоровог реда.

Додатно, једначина 2.22 приказује основну теорему интегралног рачуна (Њутн-Лајбницова формулу):

$$\int_a^b g(x)dx = G(b) - G(a), \quad (2.22)$$

где је $G(x)$ примитивна функција (антидериwација) функције $g(x)$.

Средња вредност непрекидне функције $g(x)$ на интервалу $[a, b]$ дефинише се као:

$$\bar{g} = \frac{1}{b-a} \int_a^b g(x)dx, \quad (2.23)$$

тако да Њутн-Лајбницова формула се може изразити и на следећи начин:

$$\bar{g} = \frac{G(b) - G(a)}{b-a}. \quad (2.24)$$

3. Акустичко лоцирање парцијалног пражњења у минералном уљу

У овом поглављу приказани су основни принципи детекције и локализације ПП у минералном уљу неитеративном све-акустичком методом. Описани су феномени који се могу јавити при детекцији акустичких сигнала ПП у експерименталним (реалним) условима. Показан је значај температурне зависности брзине акустичког сигнала ПП и типичне ситуације у којима долази до појаве ПП у минералном уљу.

3.1. Парцијално пражњење

Ниједан изолациони материјал није „савршен“. Изолациони материјали садрже мање или веће насавршености чији узроци могу бити бројни [49].

Сам изолациони материјал може поседовати природне нехомогености које се не могу елиминисати. Поједине аномалије у изолационом материјалу могу бити последица неадекватног технолошког процеса производње. Такође, неизбежан процес старења материјала и значајна диелектрична напрезања доводе до оштећења изолационог материјала [49].

У случају да се изолациони материјал у местима „несавршености“ нађе у међуелектродном простору са успостављеним напоном, односно електромагнетним пољем, постоји вероватноћа да се у датим местима јави локално јачање електромагнетног поља. „Несавршена“ места у изолационом материјалу можемо назвати и „критична“ јер имају мању диелектричну чврстоћу од остатка изолатора. Када вредност појачаног електричног поља на датим местима постане већа од пробојне вредности изолатора појавиће се електрични пробој локалног типа. Дати пробој кратко спаја један мали део изолационог материјала и то на тај начин да остатак изолације може да издржи напонско напрезање и не долази до потпуног пробоја. Управо тај локализован, ограничен пробој се назива парцијално пражњење [49], [50].

3.2. Детекција парцијалног пражњења у минералном уљу

Кварови електроенергетске опреме могу бити узроковани грешкама у пројектовању, замором материјала, грешкама у технологији производње, неправилним одржавањем или радним условима који се разликују од пројектних претпоставки [51]. Код дуготрајног рада и одржавања електроенергетске опреме посебну пажњу треба посветити методама праћења стања, стратегији одржавања и процени ризика квара како би се одредиле приоритетне радње које треба предузети у циљу смањења глобалног утицаја на организацију или систем у целини.

Комплементарном применом различитих дијагностичких метода може се утврдити тренд деградације минералног уља и динамика примене превентивних мера у електроенергетској опреми у којој се минерално уље користи као изолациони материјал [52]. Парцијално пражњење се сматра једним од главних узрока деградације изолационог минералног уља. Парцијално пражњење настаје када јачина електричног поља премашује диелектричну чврстоћу изолационог минералног уља у локализованом подручју [53]–[55]. Парцијално пражњење изазива бројне ефекте у изолационом минералном уљу: диелектричне губитке, промене притиска у гасовима, хемијске промене у саставу материјала, акустичке ефекте, оптичке ефекте, топлотне ефекте, електромагнетно зрачење, појаву струје и напона [14], [56]–[60]. Локализација ПП у минералном уљу је од суштинског значаја за поуздан и дуготрајан рад електроенергетске опреме у којој се минерално уље користи као изолациони материјал. Због велике капиталне вредности електроенергетске опреме и њене критичне

улоге у електроенергетској мрежи, постоји све већа потреба за развојем неинтрузивних дијагностичких метода за детекцију ПП у минералном уљу. Ове методе су дизајниране да открију пропратне нежељене ефекте ПП и одреде његову локацију користећи различите математичке алгоритме. Поједини примери датих метода су:

- метода која открива хемијске ефекте ПП коришћењем анализе растворених гасова у минералном уљу (гасна хроматографија, енгл. *DGA*, није у могућности да пружи информацију о локацији ПП) [59],
- метода који детектује појаву електричне енергије узроковане ПП [61], [62],
- метода која детектује електромагнетно зрачење ПП користећи сензоре ултра-високе фреквенције (УХФ) [63], [64], [65] или сензоре радио фреквенције (РФ) [20],
- метода која детектује акустичне ефекте ПП користећи пиезоелектричне сензоре [10], [66]–[70],
- метода која детектује оптичке ефекте ПП коришћењем оптичких сензора [71],
- комбиноване методе, попут УХФ-акустичне методе, електрично-акустичке, електромагнетно-акустичке користећи пиезокерамичке сензоре, акустичко-симулациона метода која може да користи само један акустички сензор и рачунарску симулацију за одређивање локације ПП [72]–[79].

Све ове методе дају различите резултате у смислу прецизности локализације ПП, једноставности употребе, исплативости, могућности примене за континуални надзор (мониторинг), смањења шума и сл. Сходно томе, постоји стална потреба за унапређењем постојећих метода за детекцију и локализацију ПП или развијање нових.

3.3. Све-акустичка метода за лоцирање парцијалног пражњења у минералном уљу

Све-акустичка метода за лоцирање парцијалног пражњења у минералном уљу искључиво користи акустичке сигнале за одређивање локације ПП. Ова метода има предности у односу на друге методе за детекцију ПП: имуна је на електромагнетне сметње, може да пружи информацију о локацији ПП, није инвазивна, једноставна је за инсталацију (нпр. на опрему под напонским оптерећењем) и погодна је за испитивање и надгледање опреме у реалном времену (мониторинг). Недостаци ове методе су њена умерена осетљивост (>300 pC), осетљивост на временске услове (нпр. грмљавину, кишу и ветар), изворе вибрација који не потичу од ПП (нпр. лабави делови и вентилатори за хлађење опреме) који ометају акустички сигнал, и слабљење акустичког сигнала током пропагације кроз различите материјале (нпр. бакар, челик, минерално уље и воду) [70], [80].

У доступној литератури, истраживачи су демонстрирали различите приступе за локализацију ПП помоћу све-акустичке методе. Приступ заснован на препознавању образаца (енгл. *pattern recognition*) приказан је у [81], различити приступи који користе методу триангулације у [82], [83] и коришћење неитеративног алгоритма у [69]. Новији приступи засновани су на интелигентним алгоритмима: генетички алгоритми (ГА) [84], [85], [86], алгоритми за оптимизацију роја честица (енгл. *particle swarm optimization*, PSO) [87], неуралним мрежама (енгл. *artificial neural networks*, АНН) [88], PSO у комбинацији са АНН [89] или са фази логиком [90], и алгоритмима слепих мишева (енгл. *bat algorithms*) [91]. Најефикаснији резултати у пракси се постижу истовременом применом акустичке и електричне методе, а све-акустичка метода се користи за локализацију ПП који се јављају у изолационом минералном уљу [9].

Предметно истраживање анализира све-акустичку неитеративну методу за лоцирање ПП у минералном уљу која користи нелинеарни неитеративни алгоритам за локализацију ПП.

3.4. Нелинеарност

Нелинеарне појаве су свеприсутне у различитим инжењерским областима и често се сматрају нежељеним и проблематичним елементима динамичких система. Стога постоји распрострањена тенденција заобилажења, контроле или игнорисања датих појава. Овакав приступ је резултирао развојем различитих метода за линеаризацију, компензацију или стабилизацију нелинеарности [1].

Међутим, истраживања нелинеарне динамике данас континуирано откривају да нелинеарне појаве могу донети нове изненађујуће и корисне ефекте у многим практичним инжењерским проблемима као што су контрола вибрација, прикупљање енергије (енгл. *energy harvesting*), праћење здравља структура, микро/нано-електро-механички системи и сл. Многи од ових нових ефеката и феномена су искључиво нелинеарни и немају пандана у класичној линеарној теорији [92]–[94].

Стога, истраживање нелинеарности система постепено доживљава дубоку промену методологије ка новом активном приступу истраживања и предиктивног коришћења корисних ефеката нелинеарних феномена у широким и разноврсним областима инжењерства [1].

Неке од предности нелинеарности у инжењерским проблемима су:

- Боља репрезентација стварности (многи системи у стварном свету су инхерентно нелинеарни, а њихово моделирање са нелинеарним једначинама може пружити веродостојнију репрезентацију понашања система),
- Боља репрезентација сложености (могу указати на сложене односе између променљивих, омогућавајући диференцираније разумевање система који се моделира),
- Боље предвиђање (могу пружити боља предвиђања у случајевима када су линеарни модели неадекватни, јер могу да обухвате нелинеарне односе и интеракције између променљивих).


Са друге стране, недостаци могу бити:

- Повећана рачунска сложеност (нелинеарни модели су често рачунарски сложенији од линеарних, што их чини тежим за решавање и захтевају више рачунарских ресурса),
- Нестабилност модела (могу бити склони нестабилности, што отежава предвиђање њиховог понашања у одређеним условима),
- Потешкоће у тумачењу (могу бити тешки за тумачење и разумевање, што отежава разумевање односа између променљивих и узрока одређених понашања),
- Потешкоће у оптимизацији: (нелинеарне моделе може бити тешко оптимизовати, што отежава проналажење најбољег решења за проблем који се моделује).

У будућности, напредак у рачунарским методама и техникама машинског обучавања ће вероватно побољшати тачност и стабилност нелинеарних модела, чинећи их приступачнијим и кориснијим за решавање још ширег спектра инжењерских проблема. Поред тога, растућа потражња за решењима заснованим на подацима и све већа доступност великих количина података ће вероватно покренути даљи развој у области нелинеарног моделирања [1], [92]–[94].

3.5. Неитеративно све-акустичко лоцирање парцијалног пражњења у минералном уљу

Неитеративну све-акустичку методу први су предложили *Kundu et. al.* 2009. године [69]. Главне предности дате методе су њене могућности примене, једноставност употребе и економичност [95]. Представљени експериментални резултати дате методе у доступној литератури се сматрају прихватљивим за практичну примену [69]. На терену, уз одговарајућу припрему и планирање, дата метода се може применити на опреми која је у погону, коришћењем само четири акустичка сензора постављена на кућиште опреме (слика 3-1).



Слика 3-1 Илустрација индиректног одређивања локације ПП све-акустичком неитеративном методом у замишљеној области облика коцке испуњеној минералним уљем [8]¹.

3.6. Неитеративни алгоритам

Улазне променљиве неитеративног алгоритма су:

- брзина акустичног сигнала v_s ,
- координате акустичких сензора: x_{si}, y_{si}, z_{si} ($i = 1, \dots, 4$),
- временске разлике доласка акустичког сигнала ПП на сензоре: $\tau_{12}, \tau_{13}, \tau_{14}$,

док су излазне променљиве:

- координате извора ПП: x, y, z .

Нелинеарна све-акустичка метода за одређивање локације ПП је заснована на принципу временске разлике који је описан следећим нелинеарним једначинама:

¹ <https://creativecommons.org/licenses/by/4.0/>
одговарајући термини преведени на српски

$$(x - x_{s_1})^2 + (y - y_{s_1})^2 + (z - z_{s_1})^2 = (v_s T_1)^2. \quad (3.1)$$

$$(x - x_{s_2})^2 + (y - y_{s_2})^2 + (z - z_{s_2})^2 = (v_s (T_1 + \tau_{12}))^2. \quad (3.2)$$

$$(x - x_{s_3})^2 + (y - y_{s_3})^2 + (z - z_{s_3})^2 = (v_s (T_1 + \tau_{13}))^2. \quad (3.3)$$

$$(x - x_{s_4})^2 + (y - y_{s_4})^2 + (z - z_{s_4})^2 = (v_s (T_1 + \tau_{14}))^2. \quad (3.4)$$

Да би се одредиле тачне координате ПП x , y и z потребно је решити дати систем нелинеарних једначина. У овом конкретном случају то се постиже неитеративним математичким алгоритмом. Банкрофт (енгл. *Bancroft*) је 1985. [96] први поставио математичку основу за решавање система нелинеарних једначина (3.1)-(3.4). У наставку је представљено решење из [69].

Једначине (3.1)-(3.4) представљају сфере, са центрима у одговарајућим позицијама сензора, које пролазе кроз извор ПП.

Било које две сфере (3.1)-(3.4) се секу, а извор ПП се налази у пресечној равни. Једначина пресечне равни за сфере (3.1) и (3.2) се може добити узимањем разлике (3.1) и (3.2). Ова једначина пресечне равни дата је у (3.5). У наредним једначинама, k_i су константе.

$$2x(x_{s_2} - x_{s_1}) + 2y(y_{s_2} - y_{s_1}) + 2z(z_{s_2} - z_{s_1}) + 2v_s^2 \tau_{12} T_1 = k_1. \quad (3.5)$$

$$k_1 = (x_{s_2}^2 - x_{s_1}^2) + (y_{s_2}^2 - y_{s_1}^2) + (z_{s_2}^2 - z_{s_1}^2) - v_s^2 \tau_{12}^2. \quad (3.5a)$$

Слично претходном, једначине за равни које се секу за сфере (3.1) и (3.3) и за сфере (3.1) и (3.4) се добијају узимањем разлике (3.1), (3.3) и (3.1), (3.4), респективно. Ове једначине су дате у (3.6) и (3.7).

$$2x(x_{s_3} - x_{s_1}) + 2y(y_{s_3} - y_{s_1}) + 2z(z_{s_3} - z_{s_1}) + 2v_s^2 \tau_{13} T_1 = k_2. \quad (3.6)$$

$$k_2 = (x_{s_3}^2 - x_{s_1}^2) + (y_{s_3}^2 - y_{s_1}^2) + (z_{s_3}^2 - z_{s_1}^2) - v_s^2 \tau_{13}^2. \quad (3.6a)$$

$$2x(x_{s_4} - x_{s_1}) + 2y(y_{s_4} - y_{s_1}) + 2z(z_{s_4} - z_{s_1}) + 2v_s^2 \tau_{14} T_1 = k_3. \quad (3.7)$$

$$k_3 = (x_{s_4}^2 - x_{s_1}^2) + (y_{s_4}^2 - y_{s_1}^2) + (z_{s_4}^2 - z_{s_1}^2) - v_s^2 \tau_{14}^2. \quad (3.7a)$$

Једначине (3.5)-(3.7) имају непознату променљиву T_1 . Елиминацијом T_1 из три једначине добијају се две једначине равни које су дате у (3.8) и (3.9).

$$2xk_4 + 2yk_5 + 2zk_6 = k_7. \quad (3.8)$$

$$k_4 = \frac{(x_{s_2} - x_{s_1})}{2v_s^2 \tau_{12}} - \frac{(x_{s_3} - x_{s_1})}{2v_s^2 \tau_{13}}. \quad (3.8a)$$

$$k_5 = \frac{(y_{s_2} - y_{s_1})}{2v_s^2 \tau_{12}} - \frac{(y_{s_3} - y_{s_1})}{2v_s^2 \tau_{13}}. \quad (3.8b)$$

$$k_6 = \frac{(z_{s_2} - z_{s_1})}{2v_s^2 \tau_{12}} - \frac{(z_{s_3} - z_{s_1})}{2v_s^2 \tau_{13}}. \quad (3.8c)$$

$$k_7 = \frac{k_1}{2v_s^2 \tau_{12}} - \frac{k_2}{2v_s^2 \tau_{13}}. \quad (3.8d)$$

$$2xk_8 + 2yk_9 + 2zk_{10} = k_{11}. \quad (3.9)$$

$$k_8 = \frac{(x_{s_2} - x_{s_1})}{2v_s^2 \tau_{12}} - \frac{(x_{s_4} - x_{s_1})}{2v_s^2 \tau_{14}}. \quad (3.9a)$$

$$k_9 = \frac{(y_{s_2} - y_{s_1})}{2v_s^2 \tau_{12}} - \frac{(y_{s_4} - y_{s_1})}{2v_s^2 \tau_{14}}. \quad (3.9б)$$

$$k_{10} = \frac{(z_{s_2} - z_{s_1})}{2v_s^2 \tau_{12}} - \frac{(z_{s_4} - z_{s_1})}{2v_s^2 \tau_{14}}. \quad (3.9ц)$$

$$k_{11} = \frac{k_1}{2v_s^2 \tau_{12}} - \frac{k_3}{2v_s^2 \tau_{14}}. \quad (3.9д)$$

Ове две равни (3.8) и (3.9) секу се у правој која пролази кроз извор ПП. Заменом и елиминацијом добијају се једначине праве у тродимензионалном простору (3.10).

$$z = \frac{x + k_{12}}{k_{13}} = \frac{k_{14} - y}{k_{15}} = A. \quad (3.10)$$

$$k_{12} = \frac{k_7 k_9 - k_5 k_{11}}{2(k_5 k_8 - k_4 k_9)}. \quad (23.10a)$$

$$k_{13} = \frac{k_6 k_9 - k_5 k_{10}}{(k_5 k_8 - k_4 k_9)}. \quad (3.10б)$$

$$k_{14} = \frac{k_7 k_8 - k_4 k_{11}}{2(k_5 k_8 - k_4 k_9)}. \quad (3.10ц)$$

$$k_{15} = \frac{k_6 k_8 - k_4 k_{10}}{(k_5 k_8 - k_4 k_9)}. \quad (3.10д)$$

Где је A претпостављена реална променљива. Координате било које тачке на правој могу се добити из (3.10) и дате су у (3.11).

$$z = A; x = k_{13}A - k_{12}; y = k_{14} - k_{15}A. \quad (3.11)$$

Стављањем (3.11) у (3.5) добија се вредност T_l у зависности од A и константи (3.12):

$$T_l = k_{16} - Ak_{17}. \quad (3.12)$$

$$k_{16} = \frac{k_1 + 2k_{12}(x_{s_2} - x_{s_1}) - 2k_{14}(y_{s_2} - y_{s_1})}{2v_s^2 \tau_{12}}. \quad (3.12a)$$

$$k_{17} = \frac{k_{13}(x_{s_2} - x_{s_1}) - k_{15}(y_{s_2} - y_{s_1}) + (z_{s_2} - z_{s_1})}{v_s^2 \tau_{12}}. \quad (3.12б)$$

Сада се подразумева да се извор ПП налази на сферама као и на линији. Дакле, тачка пресека између линије и сфере даје локацију извора ПП. Права сече сфере у две тачке. Једна од ове две тачке представља тражено решење.

Заменом x, y, z у (3.11) и T_l из (3.12) у (3.1), добија се квадратна једначина по A (3.13).

$$A^2 k_{18} + Ak_{19} + k_{20} = 0. \quad (3.13)$$

$$k_{18} = k_{13}^2 + k_{15}^2 + 1 - v_s^2 k_{17}^2. \quad (3.13a)$$

$$k_{19} = 2v_s^2 k_{16} k_{17} - 2k_{13}(k_{12} + x_{s_1}) - 2k_{15}(k_{14} - y_1) - 2z_{s_1}. \quad (3.13б)$$

$$k_{20} = (k_{12} + x_1)^2 + (k_{14} - y_1)^2 + z_{12} - v_s^2 k_{16}^2. \quad (3.13ц)$$

Решавањем квадратне једначине (3.13) добијају се две вредности за A . Накнадно, заменом A , у (3.11) и (3.12), одређују се два скупа $[x, y, z]$ и T_I . Од ова два скупа, једно се решење прихвата, док се друго одбацује из практичних разлога. То може бити зато што је добијена вредност T_I негативна или су добијене вредности за x, y, z негативне или су изван граница разматране области.


3.7. Проблем проузрокован конструкцијом (енгл. *Structure-born problem*)

Конструкција опреме, као и материјали коришћени за израду делова унутар опреме, могу значајно утицати на начин и брзину простирања акустичког таласа унутар опреме у којој се као изолатор користи изолационо минерално уље.


У доступној литератури, већина аутора претпоставља да је правац простирања акустичког таласа директан (праволинијски) од извора ПП до акустичког сензора. Међутим, у већини случајева у пракси, долази до комплексног простирања акустичког поља због појаве рефлексација и преламања у различитим материјалима унутар опреме. У случају да постоји препрека на правцу простирања таласа ка сензору, може се десити да се звучни талас простира заобилазном путањом, око препреке. Ово изазива повећање времена простирања таласа до сензора и уноси несигурност у прорачун локације извора ПП. Такође, може доћи и до простирања акустичког таласа кроз препреку (дата појава се може детектовати ако су решења за локацију ПП одговарајућег алгоритма у комплексном домену [97], [98]). У датом случају брзина звучног таласа се повећава или смањује у односу на брзину простирања кроз минерално уље, што такође утиче на несигурност прорачуна. У циљу превазилажења датог проблема, једна од стратегија је да се добијени резултати локације извора ПП потврде понављањем поступка при више различитих позиција акустичких сензора.

При удару акустичког таласа у кућиште опреме долази до кретања таласа кроз зид кућишта услед чега се брзина таласа најчешће значајно повећава у односу на брзину у минералном уљу. У флуиду као што је минерално уље постоје само лонгитудинални таласи, док у металу постоје и трансверзални и лонгитудинални таласи. Дати феномен у техничкој литератури се назива енгл. *Structure-born* проблем.

Лонгитудинални талас који емитује ПП креће се кроз уље брзином од 1100 m/s до 1600 m/s, међутим при додиру са кућиштем долази до кретања звучног таласа дуж кућишта. С обзиром да је брзина простирања звучног таласа кроз метал (~ 5900 m/s лонгитудинални и ~ 3200 m/s трансверзални) значајно већа од брзине простирања кроз уље може доћи до одступања при мерењу времена доласка таласа. Разлог томе је да талас који се креће кућиштем може доћи до сензора пре онога који се креће кроз уље и на тај начин довести до преране активације акустичког сензора. *Structure-born* проблем се може сматрати сметњом при мерењу доласка акустичког сигнала ПП на сензор. На слици 3-2 приказан је удаљени сензор од извора ПП и три могућности простирања таласа од извора ПП до акустичког сензора: директним (најкраћим) путем, кроз зид кућишта (*Structure-born*) и кретање таласа кроз минерално уље са рефлексацијом од зида кућишта опреме.



Слика 3-2 Илустрација три могуће путање акустичког сигнала од извора ПП до акустичког сензора: директна (1), кроз зид кућишта, *Structure-born* (2), рефлексијом од зид кућишта (3).



Слика 3-3 Илустрација изгледа амплитуде типичног акустичког сигнала у времену детектованог од стране акустичког сензора са слике 3-2. Назначене су сметње услед *Structure-born* феномена и тренутак стижања директног сигнала.

На слици 3-3 приказан је типичан изглед акустичког сигнала ПП детектованог акустичким сензором са слике 3-2. Слабљење сигнала дуж путање која пролази кроз кућиште (метал) је израженије него директним путем (минерално уље). Директни сигнал има већу енергију и већу амплитуду у поређењу са амплитудом индиректног сигнала. Приметан је долазак јачег, директног ПП сигнала [10].

3.8. Проблем тоталне рефлексije

Због могућности тоталне рефлексije директног сигнала, поједини истраживачи препоручују коришћење индиректног сигнала за одређивање времена стижања акустичког сигнала ПП на сензор [99].

Као што је приказано на слици 3-4, акустички сензор не може да детектује акустички сигнал директног таласа (зелена линија на слици 3-4) када је упадни угао већи од укупног угла рефлексije од 26° . Под овим околностима, акустички сензор може да детектује само индиректни таласни сигнал попут путања 2 или 3 означених на слици 3-4. Имајући у виду дати феномен, при одређивању времена доласка акустичког сигнала на сензор, сигнал индиректног таласа не треба увек занемарити [100].




Слика 3-4 Илустрација тоталне рефлексije директног сигнала.

3.9. Изолационо минерално уље

Изолационо минерално уље је угљениково једињење које поседује добра диелектрична својства и спада у групу природних изолатора. Минерална уља се производе од сирове нафте и представљају вакуум сирове дестилате одговарајуће вискозности [101].

Хемијски састав минералног уља чини смеша нафтенских, C_N , парафинских, C_P и ароматских, C_A угљоводоника. Проценат одговарајућих угљоводоника зависи од врсте нафте од које је минерално уље произведено. Тако, нафтенска нафта даје уље са већим процентом C_N док парафинска нафта са већим процентом C_P . Проценат C_A који је најважнији за квалитет минералног уља је приближан и код нафтенског и код парафинског уља и креће се од 4% до 18%. Минерална уља садрже у малом проценту и хетероциклична једињења која у својој структури имају елементе као што су азот, сумпор и кисеоник. Молекули у минералном уљу су повезани у различите врсте молекуларних структура. На слици 3-5 је приказан изглед класичног молекула минералног уља [101].



Слика 3-5 Илустрација класичног молекула минералног уља.

Диелектричне карактеристике изолационих минералних уља су добре, што се објашњава одсуством дипола у њиховој молекуларној структури. Особине минералних уља значајно зависе од њиховог састава и чистоте. Тако, и мали садржај воде и/или присуство чврстих честица значајно смањује диелектричну чврстоћу. Процес функционалног старења такође неповољно утиче на диелектрична својства минералних уља. Температурно напрезање, постојање нечистоћа, а нарочито појава парцијалних пражњења и дејство електричног лука доводе до слабљења диелектричних карактеристика минералних изолационих уља током експлоатације. У циљу превентивног откривања погоршања диелектричних карактеристика врше се анализе узорака минералног изолационог уља, нпр. мерењем фактора диелектричних губитака и садржаја гасне фазе у њему (гасна хроматографија). Гасна хроматографија, поред података о тренутном стању изолације, даје податке о нивоу парцијалних пражњења у посматраном изолационом систему. Дата метода има могућност откривања постојања ПП али не може да пружи информацију о његовој локацији [49], [101].

Поред гасне хроматографије, врше се и друга конвенционална хемијска испитивања минералног уља: мерење садржаја воде у изолационом уљу (метода титрације по Карл-Фишеру), процена садржаја воде у чврстој (папирној) изолацији на основу мерења садржаја воде у изолационом уљу и радне температуре уља коришћењем равнотежних дијаграма, мерење садржаја деривата фурана у изолационом уљу, мерење физичких, хемијских и електричних карактеристика уља у складу са стандардом *IEC 60422*. Будући да се анализом уља на једноставан и брз начин може добити велики број корисних информација, у свету постоји константни рад на развијању нових дијагностичких метода и унапређењу постојећих. Неке од датих метода су: одређивање корозивности уља према бакру и сребру (*ASTM* тестови корозије), квантификација корозивних сумпорних једињења (елементарног сумпора, укупног реактивног сумпора), садржај метанола и етанола у уљу [102], [103].

Минерална изолациона уља се у електротехници примењују у функцији изолације и хлађења. Минерална изолациона уља се најчешће користе у трансформаторима, исправљачима, напонским уводницима, кабловима, кондензаторима, машинама и прекидачима. Код већине рафинерија, на производњу минералних уља одлази само 1% укупне производње нафтних деривата [49].

Имајући у виду неминовно исцрпљивање нафтних резерви у блиској будућности, очување животне средине и захтеве за смањење карбонског отиска у доступној литератури за потенцијалне наследнике минералних уља се најчешће помињу природни естри [104].

3.10. Температура минералног уља

За израчунавање положаја ПП у минералном уљу све-акустичком неитеративном методом, неопходна је вредност брзине простирања акустичког сигнала у минералном уљу. На брзину простирања акустичких таласа кроз еластичну средину значајан утицај имају одговарајуће карактеристике средине, а понајвише температура. Иако је брзина простирања акустичког сигнала важна особина материјала-минералног уља, у пракси се најчешће мери, прати и/или процењује температура минералног уља.

У флуиду према Њутн-Лапласовој формули, брзина звука c зависи од адијабатског модула стишљивости K_s и густине ρ [8], [105], [106].

$$c = \sqrt{\frac{K_s}{\rho}} \quad (3.14)$$

При амбијенталном притиску, изотермички модул стишљивости K_T ($K_s = (c_p/c_v) K_T$) се може представити као [8], [106]:

$$K_0 = K_{00} e^{-\beta_k T} \quad (3.15)$$

где је K_{00} вредност K_0 екстраполована на нулту температуру, β_k је температурни коефицијент модула стишљивости, c_p је топлотни капацитет при константном притиску, c_v је топлотни капацитет при константној запремини. При амбијенталном притиску за температурну зависност густине, може се користити линеарна апроксимација [8], [106]:

$$\frac{\rho_0}{\rho_R} = 1 - \alpha_\rho (T - T_R), \quad (3.16)$$

где је α_ρ термичка дилатација флуида, док индекс R означава референтно стање (атмосферски притисак од 0,1 МПа и температуру $T = T_R = 273,15$ К).

На основу једначина (3.14)–(3.16), температурна зависност брзине звука може се представити линеарном апроксимацијом [8]:

$$c \propto \sqrt{\frac{1 + \alpha_\rho (T - T_R)}{1 + \beta_k (T - T_R)}} \propto 1 - \frac{\beta_k - \alpha_\rho}{2} (T - T_R) \quad (3.17)$$

За минерална уља ($\beta_k - \alpha_\rho > 0$ [106], чинећи c опадајућом функцијом температуре.


У доступној литератури, смањење брзине акустичког сигнала са порастом температуре минералног уља се објашњава као последица смањења густине. Смањење густине минералног уља услед пораста температуре подразумева термичко ширење и на тај начин доводи до повећања међумолекулске удаљености. Повећане међумолекулске удаљености смањује брзину акустичког сигнала, зато што звук путује брже у збијеном распореду молекула [107].

Брзина звука као физичка величина има сложене физичке основе теоретски проучаване и моделоване на молекуларном нивоу. Минерална уља су сложеног састава, K_s , ρ и c је захтевно одредити теоретски, те се стога ове величине уобичајено одређују лабораторијским тестовима [8], [106], [107].

У доступној литератури, за температурну зависност брзине звука у минералном уљу референцирају се експериментални резултати истраживања за минерално уље типа *Texaso 55* приказани у [12]. За дато минерално уље, у опсегу температуре од $-30\text{ }^{\circ}\text{C}$ до $130\text{ }^{\circ}\text{C}$, брзина акустичког сигнала се брзо мења са приближно 1600 m/s на 1150 m/s . Брзина такође зависи од фреквенције акустичког сигнала и од садржаја гасова и воде у минералном уљу. За постизање високог нивоа прецизности, потребно је узети у обзир све горе наведене параметре. Међутим, за многе практичне примене, укључујући детекцију и локализацију ПП, довољна је апроксимација која узима у обзир само температуру минералног уља (табела 1, слика 3-6) [12], [60].

Табела 1 Промена брзине акустичког сигнала у зависности од температуре минералног уља, за минерално уље *Texaso 55*

Температура минералног уља [$^{\circ}\text{C}$]	Брзина акустичког сигнала [m/s]
-30	1578
-20	1572
-10	1542
0	1501
10	1457
20	1414
30	1374
40	1337
50	1301
60	1266
70	1231
80	1197
90	1164
100	1134
110	1106
120	1082
130	1058



Слика 3-6 Графички приказ промене брзине акустичког сигнала у зависности од температуре минералног уља, за минерално уље *Texaso 55*.


У доступној литератури примећено је да са старењем минералног уља (изван експлоатације) брзина акустичког сигнала расте, што је последица повећања густине минералног уља [107], што је утврђено поређењем узорака старости преко две деценије и мање од пет година. Већа вредност густине старијег минералног уља објашњава се пропадањем и прекидима угљоводоничких ланаца што доводи до хидратације. Одговарајући теоријски модели такође указују на разлику у брзини акустичког сигнала кроз неексплоатисано, експлоатисано, регенерисано и отпадно минерално уље [108].

Са обзиром да је у реалним условима експлоатације, температура минералног уља нестаационарна, нехомогена и зависна од утицајних спољних фактора, претпоставка о константној вредности брзине акустичког сигнала (температури минералног уља) може бити извор велике мерне несигурности при одређивању локације ПП неитеративно све-акустичком методом.

3.11. Типичне врсте парцијалног пражњења у минералном уљу

Парцијална пражњења у шупљинама диелектрика настају као последица природне несавршености диелектрика или неадекватног технолошког процеса израде изолатора. Шупљине могу бити испуњене гасом, укључцима (опиљцима), нечистоћама или капљицама воде тако да се на тим местима веома често јавља локално јачање електромагнетног поља што је предуслов за настанак ПП. Парцијална пражњења у облику короне се појављују на оштрим ивицама електрода и последица су локалног јачања електромагнетног поља на датој површини. Парцијална пражњења могу настати и као последица присуства проводних честица (нечистоћа) у изолатору [50], [49], [109].

На слици 3-7 приказане су типичне врсте ПП које се најчешће појављују у минералном изолационом уљу: на оштрим ивицама електрода (а), услед постојања проводног материјала (честице) у уљу (б) и у шупљинама испуњеним мехурићима гаса или капљицама воде (ц, д и е) [109].



Слика 3-7 Илустрација типичних извора ПП у минералном уљу.

4. Вештачка интелигенција

Вештачка интелигенција постала је једна од најважнијих технологија нашег времена. Дата технологија је револуционизовала индустрије попут финансијске, здравствене, образовне и сл., мењајући начин на који људи живе и раде. Данас ВИ напредује брзином без преседана захваљујући напретку у дисциплинама МО, дубоких неуралних мрежа и сродним областима науке и технике.

У датом поглављу представљени су актуелни трендови и најзначајнији концепти из доступне литературе из области ВИ и МО (обучавање на основу примера, дефиниције одговарајућих функција губитка, коефицијента детерминације R^2 , обучавања стабала одлучивања, регресионог и скупног обучавања). На крају, описан је програмски оквир *ML.NET* за имплементацију машинског обучавања у *.NET* програмском окружењу.

4.1. Увод

Вештачка интелигенција је једна од најновијих области науке и технике чије проучавање је озбиљно започето убрзо после Другог светског рата, док је актуелни назив добила 1956. године [18].

Уопштено говорећи, појам „вештачка интелигенција“ се односи на широку област науке која обухвата не само информатику већ и психологију, филозофију, лингвистику и друге науке. Дати појам „интелигенције“ се односи на способности планирања, одлучивања, учења, перцепције осећања (знања) и комуникације на природном језику. Суштински гледано, ВИ је покушај да се људска интелигенција замени интелигенцијом машине. Развој ВИ је неизбежан и доноси са собом како могућности значајних бенефита за појединце и друштво у целини, тако и одређене ризике које треба препознати и контролисати. Зато је изузетно важно разумети начине употребе, одржавања, карактеристике попут поузданости и потенцијалне недостатке метода ВИ [18], [110], [111].

Данас је тешко пронаћи сферу људског живота у којој се не примењује неки од метода ВИ. Вештачка интелигенција може драматично да побољша ефикасност обављања репетитивних послова или да одмени човека у обављању послова који су опасни по људско здравље. Уз боље могућности праћења и дијагностике, вештачка интелигенција може драматично утицати и на здравствену заштиту, побољшањем рада здравствених установа и смањењем оперативних трошкова [20]. Употреба ВИ може довести до повећања продуктивности радне снаге увођењем аутономног транспорта и решавања проблема гужви у саобраћају. Такође, може се користити и за унапређење откривање криминалних активности и решавање злочина (технологија препознавања лица). У индустрији, ВИ заузима једну од централних позиција у тзв. „четвртој индустријској револуцији“ односно њеној дигиталној трансформацији. Из наведених примера није тешко увидети да ће утицај ВИ на друштво имати далекосежне економске, правне, политичке и друге последице у наредном периоду [20], [110].

У информатици, област ВИ се бави проучавањем „интелигентних агената“ односно уређаја који имају способност опажања окружења и предузимања радњи које максимизирају вероватноћу успешног постизања циља. Интелигентни агент може бити чисто софтверски систем који обавља функције у виртуелном окружењу или софтвер уграђен у одговарајућу машину (хардвер) који функционише у реалном окружењу [18].

Перманентно увећавање брзине обраде података у савременим уређајима као и доступност огромне количине података путем интернета омогућили су убрзан развој метода ВИ. Са друге стране дати трендови су актуализирали питања енергетске ефикасности хардвера и алгоритама ВИ као и могућности оптималне примене ВИ у реалном времену на мобилним уређајима (аутономним аутомобилима, мобилним телефонима и сл.). Поред

енергетске ефикасности актуелне су теме које обрађују проблеме могућности изненадног престанка рада, доношења погрешних одлука, саботирања и превара као и оптималних техника одржавања интелигентних агената. Једноставније речено, истраживачи покушавају да одговоре на све чешће постављано питање: „Да ли се и у којој мери може веровати интелигентним агентима (ВИ)?“. Не постоји једноставан одговор на ово питање, јер он подразумева процену интелигентних агената (метода ВИ) са аспекта транспарентности, могућности контроле, доступности, употребљивости, отпорности, поузданости, прецизности, сигурности, приватности, квалитета итд. [20], [22], [110], [112].

У центру процеса трансформације индустрије у оквиру „четврте индустријске револуције“, као једна од кључних технологија, налази се научна дисциплина ВИ која се бави проучавањем, обрадом, откривањем скривених информација (знања) и предвиђањем одговарајућих карактеристика података са циљем доношења одлука. Дата дисциплина је машинског учење односно машинско обучавање [113].

4.2. Машинско обучавање (учење)

Машинско обучавање је дисциплина ВИ која укључује развој алгоритама и статистичких модела који омогућавају рачунарима да уче из података без експлицитног програмирања. То је метода учења (обучавања) машина да препознају одговарајуће обрасце и предвиђају на основу примера или прошлих искустава. Развој машинског обучавања је један од главних покретача напретка у области ВИ последњих година. Ово је делимично због доступности великих скупова података и развоја моћних рачунарских ресурса који могу анализирати и обрадити дате податке брзо и ефикасно. Као резултат тога, машинско обучавање се све више користи у широком спектру апликација у индустрији, а очекује се да ће играти још већу улогу у технологијама будућности.

У овом потпоглављу представљени су актуелни трендови и најзначајнији концепти из доступне литературе у вези МО (обучавање на основу примера, бирање „најбоље“ хипотезе, дефиниције одговарајућих функција губитка, регуларизација, коефицијент детерминације R^2 , обучавање стабала одлучивања, регресионо и скупно обучавање).

4.2.1. Увод

Дубоке неуралне мреже захтевају велике количине података за тренирање. Тренирање датих мрежа за апликације у реалном времену је захтеван задатак који најчешће подразумева коришћење технологије рачунарских облака и најсавременијих графичких процесорских јединица. Потрошња електричне енергије за извршавање алгоритама дубоких неуралних мрежа на актуелним уређајима је значајна. Нова генерација алгоритама ВИ и уређаја који их користе треба да превазиђе поменути недостатак. На пољу оптимизације енергетске ефикасности ВИ алгоритама актуелна истраживања су фокусирана на домен дистрибуираног/удруженог учења (енгл. *federated learning*). Дати начин учења се заснива на сарадњи више аутономних агената насупрот централизованом приступу учења на једном агенту [110].

На пољу хардвера, велики истраживачки напори су посвећени развоју енергетски ефикасних архитектура заснованих на неуроморфним рачунарским концептима и алгоритмима инспирисаним начином функционисања човечијег нервног система [110].

Поред енергетске ефикасности, актуелни модели машинског обучавања се проучавају са аспекта сигурности и интероперабилности добијених резултата што је од велике важности при примени у нпр. медицини и економији.

4.2.2. Обучавање на основу примера

Агент у области ВИ се односи на софтверски ентитет који опажа своје окружење и доноси одлуке (предузима акције) како би постигао одговарајући циљ.

Ако после посматрања окружења унапређује своје перформансе на наредним задацима, кажемо да се агент обучава. У одређеним случајевима унапређење обучавањем је могуће директно испрограмирати у агента, међутим то није случај у највећем броју случајева. Наиме, ни сами пројектанти не могу да предвиде све ситуације у којима се агент може наћи, не могу да предвиде све могуће промене окружења током времена или не знају како да испрограмирају побољшање. Из наведеног се види да у одређеним случајевима би било пожељно да агент може самостално да се обучава (учи) [18].

Обучавање на основу примера је једна врста проблема обучавања која је широко применљива и заснива се на обучавању функције на основу скупа парова улаз-излаз која предвиђа излазе за нове улазе.

Свака компонента агента може да се унапреди функционалношћу обучавања (користећи одговарајуће податке). Побољшања и методе да се оне постигну зависе од следећих фактора [18]:

- које компоненте је потребно унапредити,
- које претходно знање агент поседује,
- која врста представљања се користи за компоненте и податке,
- која повратна спрега (информација) се користи за обучавање.

У петом поглављу су приказане поједине компоненте различитих врста агената: „ако-онда правила“, „како се окужење развија?“, „шта раде моје акције?“, информације о корисности агента, информације о степену пожељности акција и циљеви агента. Свака од датих компоненти се може унапредити обучавањем [18].

Представљање знања агента зависи од врсте агента, нпр. за логичког агента знање се представља исказима и логичким реченицама првог реда, за агенте који користе теорију одлучивања, Бајесовим мрежама и сл. За поједине врсте представљања знања агента осмишљени су специфични алгоритми обучавања.

Начин обучавања може бити такав да полази од конкретних парова улаз-излаз ка општој функцији обучавања (индуктивни приступ обучавању) или да полази од једног познатог општег правила ка новим правилима која логички произилазе из њега (дедуктивни приступ).

Три врсте повратне спреге које дефинишу три главне врсте обучавања су [18]:

- Ненадгледано обучавање,
- Обучавање појачавањем (награда и казна),
- Надгледано обучавање.

У случају ненадгледаног обучавања агент се обучава по улазним правилима иако није дата никаква експлицитна повратна информација (спрега). Најчешћи задатак ненадгледаног обучавања је груписање тј. идентификација група улазних примера које могу бити корисне.

Агент се обучава појачавањем ако учи из низа појачавања односно награда или казни. Додељивање нпр. једног поена агенту који је победио у партији „мице“ указује му да је урадио нешто пожељно.

Код надгледаног обучавања, агент посматра неке примере улазно-излазних парова и на основу тога тренира функцију мапирања улаз-излаз.

У пракси, ове разлике нису толико изражене. Код полунадгледаног обучавања узима се неколико означених примера на основу којих треба да се обради велики број неозначених примера (слика 4-1).



Слика 4-1 Илустрација врста обучавања на основу типа повратне спреге.


4.2.3. Надгледано обучавање

Задатак надгледаног обучавања може се описати као у наставку. Ако је дат скуп парова улаз-излаз који има N чланова и кога називамо скуп обучавања:

$$(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N), \quad (4.1)$$

где је сваки излаз y_i резултат једне непознате функције $y=g(x)$, потребно је наћи h која представља апроксимацију функције g . Функција h се назива хипотеза. Уопштено гледано x и y не морају да буду бројчане вредности. Обучавање представља претрагу по скупу свих могућих хипотеза како би се пронашла хипотеза која ће имати добре перформансе чак и за оне примере који су изван скупа обучавања. Како би измерили прецизност хипотезе дајемо јој тест скуп примера изван скупа обучавања. Кажемо да хипотеза добро уопштава ако правилно предвиђа излазне вредности у новим примерима.

Када су могуће вредности излаза y из коначног скупа вредности проблем обучавања се назива класификација. У случају да је y бројчана вредност обучавање називамо регресијом.




Слика 4-2 Пример две конзистентне хипотезе различитих сложености за исти скуп података.

На слици 4-2 и плава и црвена линија се поклапају са свим тачкама скупа обучавања. Такве хипотезе се називају конзистентним. Узимајући у обзир да су обе хипотезе конзистентне потребно је одговарајуће правило које би упућивало коју хипотезу треба изабрати. Дато правило (принцип) којим се даје одговор на ово питање се назива Окамова (енгл. *Oskahomova*) оштрица по којем је потребно одабрати хипотезу која је најједноставнија. Једноставност није увек лако дефинисати. На примеру са слике 4-2 очигледно је да је хипотеза представљена плавом линијом (полином првог степена), једноставнија од хипотезе представљене црвеном линијом (полином вишег степена).

Поред особине једноставности, хипотеза треба добро да уопштава тј. да добро предвиђа вредности излаза за нове улазе. На слици 4-3 приказан је пример једне конзистентне хипотезе (црвена боја) и једне која није конзистентна (зелена боја) али која би боље могла да уопштава податке. У општем случају, потребно је да постоји компромис између сложености хипотезе која је добро прилагођења подацима обучавања и једноставније хипотезе која боље уопштава [18].

У датим примерима простор у којем смо тражили хипотезе је скуп полинома над x . Међутим, дати простор може бити доста сложенији (скуп полинома над x и $\cos(x)$, класа свих C# програма и сл.). Коју хипотезу ћемо одабрати можемо одредити ако у обзир узмемо рачунску сложеност обучавања. Потребно је да постоји компромис између изражајности простора хипотеза и сложености проналажења добрих хипотеза унутар тог простора. Проналажење датог компромиса може бити захтеван задатак.



Слика 4-3 Илустрација једне конзистентне и једне хипотезе која није конзистентна али која може боље да уопштава нове улазе.

4.2.4. Процењивање и бирање најбоље хипотезе

Како би се одредила хипотеза која је најбоље прилагођена будућим подацима (која најбоље уопштава) потребно је дефинисати „будуће податке“ и „најбоље прилагођење“. Прво, претпоставка је да примери над којима се врши обучавање имају заједничку расподелу вероватноће и да су статистички независни. Како би се дефинисало најбоље прилагођење потребно је дефинисати (изразити) износ грешке хипотезе као проценат случајева када $h(x) \neq y$.

Ако хипотеза има мали износ грешке на скупу података за обучавање то уопште не мора да значи да ће добро да уопштава. Како би се добила процена уопштавања хипотезе потребно је тестирати на скупу примера које још није видела. Најједноставнији приступ је поделити расположиве примере на случајан начин на скуп за обучавање (за генерисање h) и тест скуп на коме се процењује тачност хипотезе (унакрсна провера са изостављањем). Мана датог приступа је што не користи све расположиве податке. Тако нпр. ако 10% примера користимо за тест можемо добити лошу процену прецизности хипотезе док ако користимо 50% добићемо добру процену прецизности хипотезе али пошто се за генерисање хипотезе користи много мање примера можемо добити много лошију хипотезу него у првом примеру.

Процена уопштавања може да се уради и на другачији начин, тако што ће се сваки расположиви пример искористити за обе улоге и за тестирање и као податак за обучавање. Прво се доступни примери поделе на k једнаких подскупова. Затим се изврши k експеримената обучавања и то тако да у сваком експерименту узима $1/k$ примера за тест а остали се користе за обучавање. Просек резултата свих k експеримената требало би да да бољу оцену уопштавања хипотезе од само једног резултата (уобичајене вредности за k су 5 или 10).

Као што се може уочити из претходног, хипотеза се бира на основу износа грешке њеног тест скупа па су на тај начин информације из тест скупа процуреле у алгоритам обучавања. Дата појава се назива „завиривање“ и последица је употребе тест скупа како за избор хипотезе тако и за њену процену. Завиривање се може избећи ако се заиста изостави тест скуп тј. да се негде склони док се не заврши обучавање. Ако после тестирања хипотеза не буде задовољавајућа, потребно је обезбедити потпуно нови тест скуп за проналажење боље хипотезе.

Ако је тест скуп склоњен и постоји потреба да се мере перформансе на невиденим подацима (што може бити корисно за иницијалну проверу хипотезе пре него што се пошаље на тестирање) онда расположиве примере (без тест скупа) можемо поделити на скуп за обучавање и скуп за проверу.

Задатак проналажења најбоље хипотезе може се посматрати као два задатка: избор простора хипотеза (модела) и проналажење најбоље хипотезе у изабраном моделу (оптимизација). Пример избора степена полинома може послужити као илустрација избора модела (простора хипотеза). Избор између модела може се вршити по параметру *величина* (степен полинома, број чворова стабла и сл.). Циљ је пронаћи вредност параметра *величина* која даје најбољи баланс потприлагођавања (енгл. *underfitting*) и преприлагођавања (енгл. *overfitting*) за најбољу прецизност на скупу за тестирање.

Алгоритам за избор модела и проналажење најбоље хипотезе у изабраном простору хипотеза може функционисати на следећи начин. Алгоритам прво набраја моделе према параметру *величина*. За сваку вредност параметра *величина* израчунава се просечна вредност грешке за скуп обучавања и за скуп провере. Затим, почевши од најједноставнијих модела (највероватније потприлагођених) итерира се разматрајући у сваком кораку све сложеније моделе док модели не почну да се преприлагођавају. У типичном случају, просечна грешка скупа обучавања монотонно опада док просечна грешка скупа провере прво опада па креће да расте по појави преприлагођености. Када износ грешке скупа за обучавање почне да тежи правој линији тада бирамо модел (параметар *величина*) са минималном грешком скупа за проверу. Када смо одредили величину модела онда бирамо хипотезу из изабраног скупа хипотеза коју на крају треба да проверимо користећи податке за тестирање [18].

4.2.5. Функција губитка

Уобичајено је да се корисност код машинског обучавања изражава помоћу функције губитка L . Дата функција се дефинише као количина корисности изгубљене због предвиђања $h(x)=\tilde{y}$ када је исправан одговор $g(x)=y$.

$$L(y, \tilde{y}) = \text{Korisnost}(y) - \text{Korisnost}(\tilde{y}). \quad (4.2)$$

У општем случају мање грешке су боље од већих [18]. Две функције које прате дату логику су апсолутна вредност разлике (L_1 губитак) и квадрат разлике (L_2 губитак).

$$L_1(y, \tilde{y}) = |y - \tilde{y}|, \quad L_2(y, \tilde{y}) = (y - \tilde{y})^2, \quad (4.3)$$

Теоретски гледано, агент може да максимизује своју очекивану корисност бирањем хипотезе која минимизира очекивани губитак над свим паровима улаз-излаз које разматра. Агент обучавања може да процени губитак уопштавања за хипотезу h (у односу на функцију L губитка) са емпиријским губитком на скупу од N примера, E :

$$\text{EmpGub}_{L,E}(h) = \frac{1}{N} \sum_{(x,y) \in E} L(y, \tilde{y}). \quad (4.4)$$

У датом случају процењена најбоља хипотеза из скупа хипотеза H је она са минималним емпиријским губитком:

$$\hat{h}^* = \arg \min_{h \in H} EmpGub_{L,E}(h). \quad (4.5)$$

Процењена најбоља хипотеза $\hat{h}^*$ може да се разликује од праве функције g због следећих разлога (извора грешака):

- неостварљивост
- варијанса
- шум
- рачунска сложеност.

Функција g није остварљива ако није у скупу H или ако је присутна а друге хипотезе добију предност над њом. Такође, алгоритам обучавања може да враћа различите хипотезе за различите скупове примера иако су ти скупови добијени истом правом функцијом g . Варијанса међу предвиђањима, што је већа, већа је и вероватноћа значајне грешке. Случајна варијанса опада према нули са повећањем броја примера за обучавање. Ако функција g враћа различите излазе за поновљену вредност улаза кажемо да је функција зашумљена. Шум не може да се предвиђа. Може да се јави као последица деловања атрибута на излаз који нису обухваћени (разматрани) на улазу. Ако је простор H довољно сложен може бити рачунски неоствариво да се претражи цео простор хипотеза па се прибегава локалном претраживању које ће истражити само један део датог простора.

Код машинског обучавања на случајевима малих димензија (десетак до неколико хиљада примера), грешка уопштавања углавном потиче од грешке апроксимације. Код обучавања већих димензија (за милионе примера) на грешку уопштавања највише утиче ограничење рачунања тј. иако има довољно примера да се пронађе хипотеза блиска правој функцији g рачун за проналажење је исувише сложен па ће се користити субоптимална апроксимација.

4.2.6. Регуларизација

Модел може да се бира на основу унакрсне провере по атрибуту *величина* (поглавље 4.2.4). Други начин бирања модела би могао бити директно минимизирање збира емпиријског губитка и сложености хипотезе, односно укупног трошка [18]:

$$Trošak(h) = EmpGub(h) + \lambda Složenost(h), \quad (4.6)$$

$$\hat{h}^* = \arg \min_{h \in H} Trošak(h). \quad (4.7)$$

Позитиван број λ служи као фактор конверзије између губитка и сложености јер немају исту јединицу мере. На дати начин губитак и сложеност се обједињују у једну јединицу мере. Да би се нашла хипотеза која најбоље уопштава потребно је претраживање унакрсне провере али са различитим вредностима λ уместо атрибута *величина*. Вредност λ се бира као она која даје најбољу оцену на скупу провере.

Дати поступак којим се кажњава одабир сложених хипотеза већ се фаворизује избор функције која је мање сложена тј. регуларнија назива се регуларизација. Укупан трошак подразумева одабир функције губитка и мере сложености тј. функције регуларизације. Избор функције регуларизације зависи од простора хипотеза (нпр. добра функција регуларизације за полиноме је збир квадрата коефицијената јер за мале вредности збира избегавају се таласasti полиноми и сл.).

4.2.7. Коефицијент детерминације- R^2

Процену губитка уопштавања хипотезе изражавамо са емпиријским губитком. Ако се за процену грешке користи квадрат грешке губитка тада формални израз за емпиријски губитак за посматраних N примера је:

$$EmpGub(h) = \frac{1}{N} \sum_{i=1}^N (y(x_i) - h(x_i))^2. \quad (4.8)$$

Дати израз се у литератури најчешће назива средње квадратна грешка модела и означава са MSE (енгл. *Mean Square Error*):

$$MSE = \frac{1}{N} \sum_{i=1}^N (y(x_i) - h(x_i))^2. \quad (4.9)$$

Ако посматрамо MSE из угла варијансе функције y , онда MSE уместо варијансе средње вредности y представља варијансу хипотезе h .

Још један начин процене уопштавања хипотезе који се помиње у литератури јесте квантификација напретка остварена учењем (хипотезом h) у односу на неки тривијални предиктивни метод који је доступан и без обучавања. Такав један тривијалан метод је узимање средње вредности излаза $\bar{y}$ на неком скупу примера и коришћење те вредности за предикцију (уопштавање). Дати метод је једноставан и не узима у обзир вредност улаза при предвиђању за разлику хипотезе добијене обучавањем.

Коефицијент детерминације, односно R^2 , пореди средње квадратну грешку када се за уопштавање користи хипотеза h и средње квадратну грешку у случају коришћења средње вредности излаза $\bar{y}$ (варијансе) за посматраних N примера [114]:

$$R^2 = 1 - \frac{MSE}{\text{var}[y]} = 1 - \frac{\sum_{i=1}^N (y(x_i) - h(x_i))^2}{\sum_{i=1}^N (y(x_i) - \bar{y})^2}. \quad (4.10)$$

4.2.8. Обучавање стабала одлучивања

Стабла одлучивања су популаран алгоритам машинског обучавања који се широко користи у задацима класификације и регресије. Она су предиктивни модел који користи структуру налик стаблу да представи низ одлука и њихових могућих исхода. Једна од главних предности стабала одлучивања је њихова интерпретабилност. Структура стабла је једноставна за разумевање и може се визуализовати, што је чини корисним алатом за објашњавање процеса доношења одлука заинтересованим странама. Стабла одлучивања се користе у широком спектру апликација, укључујући сегментацију купаца, откривање превара, медицинску дијагностику и предиктивно одржавање.

У овом потпоглављу акценат је стављен на регресију, скупно обучавање, подстицање опадањем градијента, случајне шуме и ДАРТ алгоритам.

4.2.8.1. Увод

Индукција на стаблу одлучивања је једноставан али врло успешан и популаран облик машинског обучавања за проблеме класификације и регресије.

Под стаблом одлучивања подразумевамо функцију која за улазну вредност узима вектор вредности атрибута док за излазну вредност враћа једну вредност тј. „одлуку“. Улазне и излазне вредности могу бити континуалне или дискретне. У стаблу одлучивања одлука се

доноси након низа испитивања атрибута. Сваки унутрашњи чвор у стаблу представља испитивање вредности једног од атрибута улаза. Гране чворова су означене са могућим вредностима атрибута. Листови (крајњи чворови којима се завршавају гране) представљају вредности које треба вратити функцијом.


Приказ у облику стабала одлучивања људима изгледа природно. Стабла одлучивања пружају приказ података у разумљивом облику који се једноставно може директно интерпретирати људским језиком или користити у неком од језика за рад са базама података. Стабла одлучивања се генерално не сматрају моделима који имају високу прецизност. За већину проблема обучавања прецизност је од пресудног значаја. Међутим, читљивост приказа података може бити од пресудног значаја за проблеме у нпр. области маркетинга. Такође, треба имати у виду да неке функције не могу концизно да се представе стаблом одлучивања (нпр. функција „већине“) тј. да не постоји идеална врста представљања која је ефикасна за све врсте функција [114].

4.2.8.2. Индукција стабла одлучивања из примера

У случају да улази стабла одлучивања узимају само дискретне вредности док излаз има тачно две могуће вредности у питању је Буловска класификација. Код дате класификације сваки пример улаза се класификује као тачан (позитиван) или нетачан (негативан). Буловско стабло одлучивања представља логички еквивалент тврђењу да је атрибут циља тачан ако и само ако атрибути улаза задовољавају једну од путања до листа чија је вредност позитивна односно тачна [18]:

$$Cilj \Leftrightarrow (Pu \text{ tan } ja_1 \vee Pu \text{ tan } ja_2 \vee \dots), \quad (4.11)$$

где је свака *Putanja* коњукција испитивања атрибут-вредност потребних да би се следила та путања. Значи, дати израз је еквивалентан дисјунктивној нормалној форми, из чега следи да се свака функција у логици исказа може изразити као стабло одлучивања.



Слика 4-4 Пример једноставног Буловског стабла одлучивања за одлуку да ли препоручити одређени модел лаптоп рачунара муштерији.

За пример приказан на слици 4-4, путања крајње лево је:

$$Pu\ tan\ ja = (Radnistatus = Nezaposlen \wedge Student = Da). \quad (4.12)$$

Буловско стабло одлучивања се представља паром (x,y) где је x вектор вредности улазних атрибута а y једна Буловска излазна вредност. Примери за обучавање из домена продавнице рачунара дати су у табели 2. Позитивни примери су они у којима је вредност циља Препорука тачно и обратно.

Табела 2 Примери за обучавање из домена продавнице рачунара.


Пример	Радни статус	Студент	Висина примања	Године старости	Препорука (Циљ)
x_1	Незапослен	Да	<50,000	>18	Да
x_2	Незапослен	Не	<50,000	<18	Не
x_3	Запослен	Да	<50,000	>18	Да
x_4	Пензионер	Не	>50,000	>18	Да
x_5	Пензионер	Не	<50,000	>18	Не

На основу датих примера потребно је пронаћи стабло које је што је могуће мање. Без обзира на који начин меримо атрибут *величина*, проналажење најмањег конзистентног стабла

је неукротив проблем јер не постоји довољно ефикасан начин да се претражи свих 2^{2^n} стабала.


Међутим, може се пронаћи добро апроксимативно решење које представља мало (али не и најмање) конзистентно стабло. Ово се може постићи нпр. ако се користи грамзива стратегија претраживања подели и савладај односно да се увек испитује најважнији атрибут. На овај начин проблем се дели на мање потпроблеме који се надаље решавају рекурзивно.

Остаје питање одређивања „најважнијег атрибута“. Најважнијим атрибутом се сматра онај који прави највећу разлику при класификацији примера. Ово обезбеђује да постоји што мањи број испитивања односно да ће све путање у стаблу бити кратке и стабло у целини да ће бити плитко.



Слика 4-5 Подела примера испитивањем атрибута. Позитивни примери су означени светлим оквиром док су негативни примери означени тамнијим оквиром. На сваком чвору је означено колико позитивних и негативних примера преостаје.

На слици 4-5 се уочава да је атрибут који најбоље дели примере *Радни статус*. Дати атрибут дели примере тако да имамо два мешана скупа са по 2 примера и скуп са једним позитивним примером који већ може да пружи одговор „Да“ и тиме заврши дату грану. Затим се рекурзивно понавља поступак избора „најважнијег атрибута“ за преостале атрибуте. На слици 4-6 је приказано стабло одлучивања које представља резултат претраживања подели и савладај односно испитивања најважнијег атрибута.



Слика 4-6 Стабло одлучивања индуковано из скупа обучавања са пет примера из табеле 1.

Стабло са слике 4-6 се доста разликује од првобитног стабла са слике 4-4. Ово је последица тога да је скуп примера пресудан за конструисање стабла. Хипотеза новог стабла је конзистентна са улазним примерима и једноставнија је од првобитног стабла. Новодобијено стабло је настало индукцијом из примера и није му циљ да буде тачно као што је случај са првобитним стаблом. Поступком избора најважнијег атрибута уочено је да се класификација може извршити и без атрибута *Године старости*.

Проблем преинтерпретације може настати када имамо више атрибута сличног значаја па је избор атрибута донекле произвољан. Са незнатно другачијим улазним примерима изабран би био други атрибут у одговарајућем кораку рекурзије па би цело стабло изгледало потпуно другачије иако би функција стабла остала слична.

За дати алгоритам обучавања прецизност расте са повећањем броја примера у скупу обучавања [18].

4.2.8.3. Бирање тестова атрибута

Неформална мера која описује на који начин атрибут дели стабло одлучивања може бити „доста добар“, „бескористан“ и сл. Међутим, потребно је увести формалну меру за дати опис атрибута што се дефинише помоћу појма информационог појачања, које се дефинише помоћу ентропије основне величине у теорији информација Шенона и Вивера (енгл. *Shannon & Weaver*) [115].

Ентропија се дефинише као мера неизвесности случајне променљиве. Што више информација постоји о променљивој ентропија се смањује. Број бита ентропије је онај број који је потребан да би се описали сви вероватни исходи (за бацање новчића потребан нам је један бит ентропије да би се описала два исхода, за четири исхода потребна су два бита ентропије итд.).

У општем случају ентропија случајне променљиве V чије су вредности v_k , са одговарајућим вероватноћама $P(v_k)$, означена са $H(V)$, дефинише се као:

$$H(V) = -\sum_k P(v_k) \log_2 P(v_k). \quad (4.13)$$

Ентропија једне Буловске случајне променљиве која је тачна са вероватноћом q :

$$B(q) = -(q \log_2 q + (1-q) \log_2 (1-q)). \quad (4.14)$$

Узимајући у обзир обучавање стабла одлучивања чији скуп обучавања има p позитивних и n негативних примера, следи да је ентропија атрибута циља над целим скупом обучавања:

$$H(Cilj) = B\left(\frac{p}{p+n}\right). \quad (4.15)$$

Нека атрибут A са d различитих вредности дели скуп обучавања на $E_1, \dots, E_d$ подскупова. Сваком поскупу E_k одговара p_k тачних и n_k нетачних примера, и ако кренемо кроз дату грану биће потребно додатних $B\left(\frac{p_k}{p_k+n_k}\right)$ битова како би дали одговор на питање обучавања. Случајно изабран пример из скупа обучавања има k -ту вредност за атрибут са вероватноћом $\frac{p_k+n_k}{p+n}$ из чега следи да је преостала ентропија након испитивања атрибута A [18]:

$$Ostatak(A) = \sum_{k=1}^d \frac{p_k+n_k}{p+n} B\left(\frac{p_k}{p_k+n_k}\right). \quad (4.16)$$

Информационо побољшање од испитивања атрибута над A је очекивани износ смањења ентропије [18]:

$$Poboljsanje(A) = B\left(\frac{p}{p+n}\right) - Ostatak(A). \quad (4.17)$$

Информационо побољшање је параметар који представља формалну меру која описује на који начин атрибут дели стабло одлучивања.

Сада се може проверити да ли је стабло одлучивања приказано на слици 4-6 заиста минимално конзистентно стабло на скупу примера.


$$Poboljsanje(GodineStarosti) = B\left(\frac{3}{5}\right) - \left(\frac{1}{5} B(0) + \frac{4}{5} B\left(\frac{3}{4}\right)\right) = 0,32b. \quad (4.18)$$

$$Poboljsanje(RadniStatus) = 0,17b. \quad (4.19)$$

$$Poboljsanje(Student) = 0,41b. \quad (4.20)$$


$$Poboljsanje(Vi sin a Pr imanja) = 0,17b. \quad (4.21)$$

Као што се види из датог прорачуна информационог побољшања, највећу вредност има атрибут *Студент* и то 0,41 бита. Атрибут *Радни статус* има најлошије информационо побољшање заједно са атрибутом *Висина примања* од 0,17 бита. За дати скуп примера, минимално конзистентно стабло одлучивања је приказано на слици 4-7.



Слика 4-7 Стабло одлучивања индуковано из скупа обучавања са пет примера из табеле 2 помоћу прорачуна информационог побољшања за сваки од атрибута.

Може се приметити да је атрибут *Године старости* други по информационом побољшању рачунатим над целим скупом примера, међутим у минималном конзистентном стаблу користи се атрибут *Висина примања*. Разлог томе је што се у наредном рекурзивном пролазу кроз алгоритам скуп примера смањило на три члана x_2 , x_4 и x_5 (слика 4-8).



Слика 4-8 Подела примера атрибута после одабира атрибута *Студент* за почетни чвор стабла одлучивања.

Новe вредности информационог побољшања су:

$$Poboljšanje(ВисинаПримања) = 0,92b. \quad (4.22)$$

$$Poboljšanje(ГодинеСтарости) = Poboljšanje(РадниСтатус) = 0,42b. \quad (4.23)$$

На новом скупу примера атрибут *Висина примања* има највишу вредност од 0,92 бита. За вредност *Запослен* атрибута *Радни статус* изабрана је негативна вредност јер су примери у осталим гранама већином негативни (два негативна примера и један позитиван).

4.2.8.4. Преприлагођавање

Преприлагођавање (енгл. *overfitting*) је раширен феномен који се јавља код свих врста обучавањих система, чак и када циљна функција уопште није случајна.

За стабла одлучивања техника која спречава преприлагођавање се назива одсецање стабла одлучивања. Одсецање се заснива на елиминисању чворова за које се утврди да нису јасно важни. Техника почиње од потпуног (комплетног) стабла на коме се посматрају чворови који за подређене чворове имају само листове. Ако испитивање изгледа ирелевантно онда се то испитивање елиминише тако што се испитивани чвор замени листом. Дати поступак се понавља док чворови који имају само листове буду или прихваћени или одсечени.

Ако неки атрибут сматрамо ирелевантним то би значило да је његово информационо побољшање блиско нули. Ово је испуњено ако дати атрибут дели примере на исти проценат позитивних примера као што је случај када посматрамо цео скуп примера $p/(p+n)$.

Како би се одредило колико побољшање треба захтевати по одговарајућем атрибуту употребљава се статистички тест значајности. Дати тест креће од претпоставке да не постоји правило у основи тзв. нулта хипотеза. Затим се анализирају реални подаци да би се израчунало колико они одступају од потпуног одсуства правила. У случају да је степен одступања статистички невероватан (вероватноћа $<5\%$) то се сматра добрим доказом за присуство значајног правила у подацима.

У случају стабла одлучивања, нулта хипотеза јесте да је атрибут неважан и да би у складу са тим информационо побољшање за бесконачно велики узорак било једнако нули. Под нултом хипотезом вредност укупног одступања има χ^2 (хи-квадрат) расподелу са $\nu-1$ степена слободе где је ν величина узорка. Дата техника одсецања назива се χ^2 одсецање.

Када стабла обучавања велику количину шума, стабла добијена одсецањем имају много боље перформансе и често су много мања од стабала без одсецања. Такође, комбиновање χ^2 одсецања и информационог побољшања које се назива рано одсецање може довести до непрепознавања комбинација атрибута који су информационо важни због детекције појединачног атрибута који није информативан. Ово се не дешава код одсецања стабла након генерисања целог стабла [18].

4.2.9. Линеарна регресија

У случају линеарне регресије простор хипотеза чине линеарне функције са улазима чије су вредности непрекидне. Регресија са линеарном функцијом са једном променљивом представља најједноставнији пример линеарне регресије и назива се „прилагођавање праве линије“.

Линеарна функција са једном променљивом има облик:

$$y = w_1 x + w_0, \quad [w_0, w_1] \in R, \quad (4.24)$$

где коефицијенте w_0 и w_1 треба одредити током процеса обучавања. Ако се користи N тачака у дводимензионалном простору променљивих онда задатак проналажења хипотезе

$$h_w(x) = w_1 x + w_0, \quad [w_0, w_1] \in R, \quad (4.25)$$

која је најбоље прилагођена разматраним подацима називамо линеарна регресија. Како би се пронашла најбоље прилагођена хипотеза потребно је пронаћи оне вредности w_0 и w_1 за које је емпиријски губитак минималан. Најчешће се користи L_2 функција губитка сумирана по свим примерима обучавања:

$$Gubitak(h_w) = \sum_{j=1}^N L_2(y_j, h_w(x_j)) = \sum_{j=1}^N (y_j - h_w(x_j))^2 = \sum_{j=1}^N (y_j - (w_1 x + w_0))^2. \quad (4.26)$$

Тако да је потребно пронаћи:

$$[w_0, w_1] = \arg \min_w Gubitak(h_w). \quad (4.27)$$


Минимална вредност функције губитка се може наћи када се нађе решење система од две једначине:

$$\frac{\partial}{\partial w_0} \sum_{j=1}^N (y_j - (w_1 x + w_0))^2 = 0, \quad \frac{\partial}{\partial w_1} \sum_{j=1}^N (y_j - (w_1 x + w_0))^2 = 0. \quad (4.28)$$

Дате једначине имају јединствено решење:

$$w_1 = \frac{N(\sum x_j y_j) - (\sum x_j)(\sum y_j)}{N(\sum x_j^2) - (\sum x_j)^2}, w_0 = \frac{\sum y_j - w_1 \sum x_j}{N}. \quad (4.29)$$

Функција губитка је конвексна за сваки проблем линеарне регресије са L_2 функцијом губитка тј. не постоје локални минимуми функције (слика 4-9).



Слика 4-9 Пример линеарне регресије функције очекиваног животног века становника Босне и Херцеговине на основу јавно доступних података Светске здравствене организације за период 2000.-2015. године. Хипотеза је означена испрекиданом црвеном линијом и има коефицијенте $w_0=-285,67647$ и $w_1=0,18015$. Предвиђена вредност животног века за 2022. годину износи 78,58 година старости.

У општијем случају за моделе који нису линеарни биће општији и проблем оптимизације претраживања. У датом случају могуће је употребити технику опадања градијента за налажење минималне вредности функције губитка. Полази се од било које тачке у простору тежина, а затим се прелази на суседну тачку која је ниже и дати поступа се понавља до конвергенције на минимални могући губитак [18].

4.2.10. Скупно обучавање


Један од најуспешнијих приступа машинском обучавању је скупно обучавање (енгл. *ensemble*). Неки од приступа скуповном обучавању су по прецизности међу најбољим методама за обучавање различитих проблема (за податке представљене векторима обично прецизнији, ефикаснији и једноставнији за обучавање од неуралних мрежа) [114].

Код методе скупног обучавања из простора хипотеза се уместо једне, изабере колекција или скуп хипотеза па се њихова предвиђања комбинују. Предвиђања у скупу хипотеза могу да се комбинују нпр. помоћу једноставног већинског гласања. Тако нпр. од скупа од седам хипотеза четири хипотезе би било потребно да погрешно класификују неки податак. При одабиру хипотеза за скуп важно је да се оне довољно разликују како одговарајући аспекти података који могу да „преваре“ једну хипотезу не би урадили исто и са другим хипотезама из скупа. Дакле, пожељно је да грешке хипотеза буду што је могуће више независне тј. да не постоји корелација између њихових грешака.

Са аспекта простора хипотеза, скуп хипотеза се може посматрати као један члан новог простора хипотеза кога чине сви могући скупови појединачних хипотеза. На дати начин се добија простор хипотеза повећане изражајне снаге и сличне сложености као првобитни простор од појединачних хипотеза.

Метод који се најчешће користи у скуповном обучавању назива се подстицање (енгл. *boosting*). Сваком примеру у скупу обучавања се придружују тежина $w_j \geq 0$ (пондерисани скуп обучавања). На основу придружене тежине, сваком примеру се даје одређени значај при обучавању. Подстицање започиње тако што се свим примерима из скупа обучавања додели почетна тежина $w_j=1$. На основу датог скупа се генерише прва хипотеза, h_1 . За оне примере које је хипотеза h_1 класификовала на погрешан начин повећава се одговарајућа тежина, док се за правилно класификоване примере одговарајућа тежина смањује. Затим се на основу овог новог пондерисаног скупа генерише наредна хипотеза, h_2 . Дати поступак се понавља док се не генерише жељени број хипотеза K (ово се може посматрати и као грађење скупа тако што хипотезе које се додају надомешћују слабости текуће хипотезе односно да је „подстичу“). Коначан скуп хипотеза чине K хипотеза које су такође пондерисане при чему се њима придружују тежине на основу њихових перформанси на скупу обучавања. Коначна скупна хипотеза је пондерисана већина добијена комбинацијом свих хипотеза (слика 4-10) [18].

Постоје многе, различите, варијације основне замисли методе подстицања са различитим начинима за подешавање тежина и начина на које се хипотезе комбинују. Алгоритам Ада Буст (енгл. *AdaBoost*) је први и најпознатији алгоритам подстицања. Алгоритми скупног обучавања нису интерпретабилни за разлику од нпр. стабала одлучивања.



Слика 4-10 Илустрација начина функционисања алгоритма подстицања. Сваки правоугаоник одговара једном примеру. Тамнији правоугаоници су они које тренутна хипотеза није правилно класификовала и обратно. Висина правоугаоника одговара додељеној тежини. Висина стабла одлучивања одговара тежини коју хипотеза добија у коначном скупу.

4.2.10.1. Подстицање опадањем градијента

На основу параметра прецизности, методе подстицања опадања градијента су међу најбољим методама подстицања и машинског обучавања уопште, и због тога су врло популарне. Основна идеја потиче из градијентних метода оптимизације у области математике, које почивају на поправљању текућег решења оптимизационог проблема

додавањем вектора пропорционалног негативној вредности градијента функције која се минимизује (нпр. метод најбржег пада) [114].

У контексту подстицања, ова идеја се реализује тако што се нова (m -та) хипотеза означена са f_m , којом се допуњује тренутни скуп хипотеза, односно тренутна укупна хипотеза означена са F_{m-1} одреди тако да апроксимира градијент грешке по укупној тренутној хипотези скупа, F_{m-1} . [114].

У пракси се најчешће користи подстицање опадањем градијента стабала одлучивања (МАРТ алгоритам) [116]. Улазни подаци датог алгоритма су скуп података обучавања (x_i, y_i) , $i=1 \dots N$, и функција губитка $L(y_i, F(x))$ која се може изабрати произвољно. Формални кораци алгоритма у случају регресије су следећи:

1. Иницијализација почетне хипотезе константном вредношћу:

$$F_0(x) = \arg \min_{\gamma} \sum_{i=1}^N L(y_i, \gamma).$$

2. За $m=1$ до M понављати:

- Израчунати $r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)}$, $i=1 \dots N$.
- Обучити регресивно стабло одлучивања на скупу података (x_i, r_{im}) , $i=1 \dots N$, и формирати завршне регионе стабла R_{jm} за $j=1 \dots J_m$.
- За $j=1 \dots J_m$ израчунати $\gamma_{jm} = \arg \min_{\gamma} \sum_{x_i \in R_{jm}} L(y_i, F_{m-1}(x_i) + \gamma)$.
- Ажурирати скуп хипотеза $F_m(x) = F_{m-1}(x) + \nu \sum_{j=1}^{J_m} \gamma_{jm} I(x \in R_{jm})$, $0 < \nu < 1$.

3. Излаз алгоритма је $F_M(x)$.

У конкретном случају, ако за избор функције грешке изаберемо L_2 функцију тј. квадрат грешке губитка кораци алгоритма постају:

1. Иницијализација почетне хипотезе константном вредношћу: $F_0(x) = \frac{1}{N} \sum_{i=1}^N y_i$.
2. За $m=1$ до M понављати:
 - Израчунати $r_{im} = y_i - F_{m-1}(x_i)$, $i=1 \dots N$.
 - Обучити регресивно стабло одлучивања на скупу података (x_i, r_{im}) , $i=1 \dots N$, и формирати завршне регионе стабла R_{jm} за $j=1 \dots J_m$.
 - За $j=1 \dots J_m$ израчунати $\gamma_{jm} = \text{median}_{x_i \in R_{jm}} (y_i - F_{m-1}(x_i))$.
 - Ажурирати скуп хипотеза $F_m(x) = F_{m-1}(x) + \nu \sum_{j=1}^{J_m} \gamma_{jm} I(x \in R_{jm})$, $0 < \nu < 1$.
3. Излаз алгоритма је $F_M(x)$.

4.2.10.2. Случајне шуме

Једноставна агрегација подразумева скупно обучавање код кога појединачне хипотезе не морају имати високу прецизност али чије су грешке независне. Предвиђање скупа је једноставна агрегација појединачних предвиђања хипотеза, нпр. узимањем просечне вредности, „гласањем“ и сл.. Предност датог метода лежи у идеји да ће се приликом агрегације грешке које хипотезе независно праве међусобно поништити (смањење варијансе без повећања систематског одступања у односу на појединачне хипотезе) [18], [114].

Хипотезе које самостално нису довољно добре, али представљају довољно добру основу за креирање скупа називају се слабе хипотезе (енгл. *weak learners*). Дате хипотезе имају предност што их је релативно једноставно генерисати. У случају регресије слабирим хипотезама се сматрају оне које имају високу варијансу предвиђања док код проблема класификације оне које имају произвољно малу, али већу од нуле, предност у односу на случајно погађање [18], [114].

У уобичајеном случају резултати које постиже скуп су бољи са порастом броја хипотеза, што са друге стране повећава рачунарску захтевност обучавања и предвиђања. Један од најуспешнијих и највише коришћених у пракси алгоритама једноставне агрегације и скуповног обучавања уопште, јесу случајне шуме (енгл. *random forest*) [18], [114].

Алгоритам случајних шума се заснива на једноставној агрегацији стабала одлучивања. Скуп се састоји од m стабала одлучивања који су обучавањем на различитим подскуповима скупа за обучавање. Појединачно стабло се обучава тако што се изабере подскуп скупа за обучавање одређене величине, при чему се не морају користити сви атрибути већ само њихов подскуп. Примери који улазе у подскуп се случајно бирају и могу се понављати унутар истог подскупа. Стабла се обучавају на различитим подскуповима како би њихове грешке биле што је могуће мање корелисане. Дата техника при којој се у свакој итерацији ствара нови скуп за обучавање тј. врши се његово ресетовање (енгл. *bootstrap*) и користи агрегација за предвиђање скупа, се у литератури означава као кованица дата два термина на енглеском језику, багинг (енгл. *bagging*, *bootstrap*, *aggregation*) [18], [114].

Број стабала m се може посматрати и као параметар регуларизације чије високе вредности су уобичајено боље. Коришћењем већег броја стабла уобичајено се смањује преприлагођавање али по цену рачунаског времена [18], [20], [114].

4.2.10.3. Онлајн обучавање

У случају када се подаци мењају у времену важан је тренутак када се обавља предвиђање па се таква врста скупног обучавања назива онлајн обучавање. Агент за улаз x_j добија вредност из природе, предвиђа одговарајуће y_j и затим добија исправан одговор. Исти поступак се понавља за наредне улазе. На први поглед предвиђање може деловати да је безнадежно јер улазни подаци не морају бити независни и идентично расподељени па свако предвиђање може бити погрешно.

Ако се посматра случај да је улаз скуп појединачних предвиђања групе експерата. На пример сваког дана група експерата даје појединачна мишљења о временским приликама за наредни дан, док је задатак агента обучавања да прикупи дата предвиђања и понуди властито. Један начин да се то уради јесте да се прате перформансе сваког експерта, па да им поклања поверење у складу са њиховим претходним перформансама. Дати поступак се назива алгоритам насумичне пондерисане величине.

Дати алгоритам се може описати следећим корацима:

- доделити скуп тежина са вредношћу један,
- прихватити предвиђања од експерата,
- насумично изабрати једног експерта сразмерно његовој тежини,
- извршити предвиђање идентично насумично изабраном експерту,
- прихватити тачан одговор,
- за сваког експерта чије се предвиђање разликује од тачног, доделити његовој тежини нову вредност тако што се постојећа вредност помножи са бројем β .

Број β има вредност $0 < \beta < 1$ и представља износ казне за експерта који је дао погрешно предвиђање.

Ако је са M^* број грешака експерта који је има највише успеха у предвиђању од укупно K експерата, број грешака M насумично пондерисане већине ограничен је са [18]:

$$M < \frac{M^* \ln(1/\beta) + \ln(K)}{1 - \beta}. \quad (4.30)$$

Онлајн обучавање се користи када се подаци нагло мењају у времену. Такође, корисно је и за примене које укључују велику колекцију података која стално расте, чак и када су промене постепене [18].

4.2.10.4. ДАРТ алгоритам

Као што је констатовано у поглављу 4.2.10 алгоритми скупног обучавања постижу високу прецизност за бројне задатке машинског обучавања. Да би скупови постигли бољу тачност од појединачних хипотеза од којих су састављени, хипотезе треба да буду са некорелисаним грешкама. Ово помаже да се повећа прецизност скупа смањењем осетљивости на специфичне карактеристике или случајеве који могу постојати у појединачним хипотезама. Док неке класе алгоритама скупног обучавања као што су насумичне шуме независно додају сваку хипотезу у скуп, алгоритми који користе подстицање као што су Ада Буст (енгл. *Ada Boost*) [117] и МАРТ (енгл. *Multiple Additive Regression Trees*) [118] инкрементално додају хипотезе [41]–[45].

Алгоритми који користе подстицање додају хипотезе које су фокусиране на побољшање тренутног скупа хипотеза, што се постиже модификацијом проблема обучавања између итерација. Иако ово гарантује да је додана хипотеза другачија од оних у скупу, нове хипотезе се обично фокусирају на мали подскуп проблема и стога немају значајну предикцију на оригиналном проблему. Ово повећава ризик од додавања хипотеза које се превише уклапају у специфичне случајеве. То је добро познат проблем у контексту обучавања подстицањем као и у алгоритму МАРТ који користи скупно обучавање подстицањем регресионих стабала одлучивања. У датом алгоритму, стабла додата у каснијим итерацијама имају тенденцију да утичу на предвиђање само неколико хипотеза, и дају занемарљив допринос предвиђању свих преосталих хипотеза. Ово, заузврат, може негативно утицати на перформансе алгоритма на новим подацима повећањем капацитета скупа без значајног побољшања његове грешке у обучавању. Ово такође чини скуп преосетљивим на доприносе неколицине, у почетку додатих стабала. Ово питање накнадних стабала које утичу на предвиђање само малог дела хипотеза називамо прекомерном специјализацијом [122].

Најчешћи приступ који се користи у борби против проблема прекомерне специјализације у алгоритму МАРТ је умањење [118]. Овде се допринос сваког новог стабла умањује константном вредношћу која се назива фактор умањења. Умањење помаже у смањењу утицаја првих стабала, међутим, како се величина скупа повећава, проблем прекомерне специјализације поново се појављује.

У алгоритму ДАРТ (енгл. *Dropout Additive Regression Trees*) [123], чија је основа алгоритам МАРТ, предлаже се другачији приступ за решавање питања прекомерне специјализације него у алгоритму МАРТ. Дати приступ подразумева употребу изостављања (енгл. *dropout*), технике која је предложена у контексту регуларизације дубоких неуралних мрежа. У неуралним мрежама, изостављање се користи за утишавање случајног дела неуралних веза током процеса обучавања. Овај метод је значајно допринео успеху дубоких неуралних мрежа за многе задатке укључујући, на пример, класификацију објеката на сликама [121], [124].

Техника изостављања успешно се користи у другим алгоритмима машинског обучавања, на пример, у логистичкој регресији. У овим случајевима, изостављање се користи за утишавање случајног дела улазних карактеристика током фазе обучавања. У контексту обучавања скупа стабала одлучивања, дати приступ је сличан приступу који користе

насумичне шуме за диверсификацију, са тим што се свако дрво у скупу обучава независно користећи другачији случајни део карактеристика [120], [125], [126].

Код алгоритма ДАРТ уведен је нови начин употребе изостављања за скуп стабала одлучивања: утишавање комплетних стабала за разлику од утишавања карактеристика. У доступној литератури [116] резултати процене ДАРТ алгоритма на три различита задатка: рангирање, регресија и класификација, користећи јавно доступне скупове података великог обима, показују да ДАРТ надмашује MART и случајну шуму у сваком од задатака, са значајним маргинама. Алгоритам MART и случајна шума су познати као веома успешни алгоритми за многе задатке обучавања, на пример, победници „*Yahoo! learning to rank*“ изазова су користили MART алгоритам [127]. Један од разлога за побољшане перформансе алгоритма ДАРТ је тај што се бави питањем прекомерне специјализације и резултира уравнотеженијим доприносом свих стабала у скупу хипотеза [119].

Алгоритам MART је алгоритам подстицања опадањем градијента стабала одлучивања који је описан у поглављу 4.2.10.1. Алгоритам ДАРТ се разликује од алгоритма MART на два места. Прво место на коме се разликује је у кораку одређивања градијента који ће одговарати новододатом стаблу. Уместо узимања у обзир целокупног скупа хипотеза у одговарајућој итерацији, узима се случајно одабран подскуп тренутног скупа хипотеза. Начин на који ће се формирати случајно одабрани подскуп хипотеза може бити следећи. Сваком стаблу одлучивања у скупу се придружи јединствена константна вероватноћа изостављања. У случају да се ниједно стабло не изостави датим поступком онда се на случајан начин изостави једно стабло како би се осигурало креирање подскупа хипотеза.

Друго место на коме се ДАРТ разликује од MART је додавање новог стабла у скуп где ДАРТ изводи корак нормализације. Како би се обезбедило да утицај изостављених стабала и новододатог стабла остане исти као утицај изостављених стабала пре додавања новог стабла у скуп, прво се новододато стабло скалира са $1/k$ и потом заједно са изостављеним стаблима са $k/k+1$. Број k представља број изостављених стабала у датом кораку итерације алгоритма.

Алгоритам ДАРТ умањује проблем прекомерне специјализације. Стога се може посматрати као регуларизација где број изостављених стабала контролише степен регуларизације. На једној страни, ако ниједно стабло није изостављено, ДАРТ се не разликује од MART алгоритма. Са друге стране, ако се сва стабла изоставе, ДАРТ се не разликује од насумичне шуме. Стога, величина изостављеног скупа омогућава алгоритму ДАРТ да варира између „агресивног“ MART режима до „конзервативног“ режима случајне шуме [123].

4.3. Технологија ML.NET за имплементацију машинског обучавања

Програмски оквир *ML.NET* је оквир за машинско обучавање који је развила компанија *Microsoft*. Првобитно је креиран као интерни пројекат унутар компаније, са циљем да машинско обучавање учини више доступним *.NET* програмерима. Пројекат је започео 2018. године, а постао је пројекат отвореног кода у 2019. години, чиме је постао доступан широј заједници програмера.

Циљ *ML.NET* је да обезбеди платформу за обучавање и примену модела машинског обучавања на начин који је више прилагођен *.NET* програмерима. Ово укључује обезбеђивање интеграције са постојећим *.NET* алатима и библиотекама, као и олакшавање коришћења алгоритама и модела машинског обучавања у оквиру *.NET* апликација.

Од свог лансирања, *ML.NET* се константно унапређивао тако да данас укључује широк спектар алгоритама и функција, а *.NET* програмерска заједница га је прихватила као вредан алат за обучавање и примену модела машинског обучавања.

Најважније карактеристике *ML.NET* су:

- Подршка за више оперативних система: *Windows*, *macOS* и *Linux*, омогућавајући програмерима да изграде моделе машинског обучавања на жељеној платформи.

- Отворени код: отвореног је кода и бесплатан за употребу, што га чини доступним широком спектру програмера.
- Интеграција са *.NET* програмским оквиром: дизајниран је да се интегрише са *.NET* екосистемом, омогућавајући програмерима да користе познате алате и библиотеке за прављење модела машинског обучавања.
- Подршка за широк спектар алгоритама: подржава различите алгоритме, укључујући линеарну регресију, логистичку регресију, стабла одлучивања и неуралне мреже.
- Једноставан за коришћење: има једноставан и интуитиван АПИ који програмерима олакшава да почну да праве моделе машинског обучавања.
- Скалабилност: може да ради са великим скуповима података и дизајниран је да се скалира да задовољи потребе сложених модела машинског обучавања.
- Тумачење и унапређење модела: пружа функције за тумачење и разумевање резултата модела машинског обучавања, помажући програмерима да донесу информисане одлуке о избору и примени модела.

Програмски оквир *ML.NET* нуди више алгоритама за машинско обучавање. Избор алгоритма требало би да буде условљен проблемом који се решава, карактеристикама коришћених података, рачунарских и ресурса за складиштење података који су на располагању. Важно је поновити да је обучавање итеративни процес. Такође, дати програмски оквир има могућност аутоматског обучавања по више алгоритама и њиховог рангирања по одговарајућим мерама перформансе. На овај начин кориснику се предлаже рангирана листа алгоритама који најбоље обучавају на основу вредности коефицијента детерминације R^2 (најбољих пет).

У програмском оквиру *ML.NET* за решавање проблема (задатка) регресије доступне су следеће класе које имплементирају одговарајуће алгоритме машинског обучавања и које се називају тренери (енгл. *trainers*):

- За линеарну регресију:
 1. *FastTreeRegressionTrainer*
 2. *FastTreeTweedieTrainer*
 3. *FastForestRegressionTrainer*
 4. *GamRegressionTrainer*
 5. *LbfgsPoissonRegressionTrainer*
 6. *LightGbmRegressionTrainer*
 7. *OlsTrainer*
 8. *OnlineGradientDescentTrainer*
 9. *SdcaRegressionTrainer*
- За бинарну логистичку регресију
 1. *LbfgsLogisticRegressionBinaryTrainer*
 2. *SdcaLogisticRegressionBinaryTrainer*
 3. *SdcaNonCalibratedBinaryTrainer*
 4. *SymbolicSgdLogisticRegressionBinaryTrainer*

Програмски оквир *ML.NET* је вредан ресурс за *.NET* програмере који желе да укључе машинско обучавање у своје апликације, а његов континуирани развој и растућа примена у пракси указују на перспективну будућност за овај програмски оквир [128], [129].

5. Интелигентни агенти

Област ВИ је усресређена на развој интелигентних агената и њихове примене у различитим доменама. Дати агенти су способни да уче из искуства, прилагођавају се променљивим окружењима и доносе одлуке на основу сложених података. Интелигентни агенти се састоје од неколико компоненти, укључујући перцепцију, представљање знања, закључивање, планирање, доношење одлука и сл. У овом поглављу акценат је стављен на концепте једноставног рефлексног агента, агента заснованог на моделу и агента са функционалношћу обучавања.

5.1. Увод

У информатици, појам интелигентног агента је централни појам области вештаче интелигенције [18].

У ширем смислу, агентом се може сматрати било шта што опажа своје окружење преко „сензора“ и делује на исто окружење помоћу „актуатора“ или уопштеније речено било шта што може да доноси одлуке (нпр. људско биће се може назвати природним агентом). За описивање понашања агента користи се одговарајућа функција агента која мапира (преводи) његове опажајне секвенце у одговарајуће акције. Функција агента за вештачког агента реализује се програмом агента. На основу тога, под функцијом агента се подразумева апстрактан математички опис, док се под програмом агента подразумева конкретна реализацију која се извршава на неком физичком систему (хардверу).

Рационални агент је онај агент који ради „праву ствар у право време“. Није једноставно дефинисати значење појма „праву ствар у право време“ јер би дати појам требало да представља објективан концепт. У доступној литератури дати појам се најчешће поистовећује са појмом рационалности [18]. Оно што се сматра рационалним у било ком тренутку зависи од следеће четири појединости:

1. Критеријума успеха који се дефинише мером перформансе.
2. Агентовог иницијалног знања о окружењу.
3. Способности агента (акција које су му на располагању и које може извршавати).
4. Опажајне секвенце агента до посматраног тренутка.

Узимајући у обзир претходно, једна од могућих дефиниција рационалног агента гласи:

„За сваку могућу опажајну секвенцу, рационални агент треба да изабере деловање за које се очекује да максимизира његову меру перформансе, за чињенице дате опажајном секвенцом и за било које уграђено знање које агент има“ [18].

Треба имати у виду да не постоји једна универзална мера перформансе за све задатке и агенте и да обично пројектант осмишљава одговарајућу меру у складу са околностима и природом проблема који се решава. Ово може представљати веома захтеван подухват. Мере перформансе је најбоље дефинисати на основу онога што се стварно жели постићи а не на основу тога како неко мисли да агент треба да се понаша (субјективног утиска). Такође, треба имати у виду да исти агент за различите мере перформансе може да се понаша и рационално и ирационално.

Постоји значајна разлика између појма рационалности и свезнања (перфекције), јер је свезнање немогуће постићи у пракси. Рационалношћу се максимизирају очекиване перформансе, док се перфекцијом максимизира стварна перформанса. Рационалност није исто што и перфекција. Ако је агент свезнајући, он зна стварне исходе својих акција. Рационалност се бави очекиваним успехом с обзиром на опажајну секвенцу. Другим речима, не може се кривити агент што није узео у обзир нешто што није могао да уочи или што није предузео радњу коју није у стању да предузме.

Спровођење акција агента са циљем модификације будућег понашања (тј. прикупљање информација) је једна од кључних особина рационалности и уско је повезана са истраживањем окружења задатка. Према дефиницији рационалности, рационални агент треба да прикупља информације као и да се обучава колико год је то могуће на основу онога што опажа.

Додатно, рационални агент је пожељно да буде аутономан тј. треба да учи оно што му помаже да надомести непотпуно или некоректно претходно знање. У оној мери у којој се агент ослања на претходно испрограмирано знање свог пројектанта уместо на сопствене опажаје, у тој мери агенту недостаје аутономност. У пракси, ретко се захтева потпуна аутономија агента на самом почетку рада. Агент у почетку због недовољног искуства делује случајно или уз помоћ испрограмираног знања пројектанта. Зато је агенту потребно обезбедити почетно знање и способност да учи (да се обучава), па након што стекне довољно новог искуства и знања он може постати независан од претходног знања [18].

5.2. Окружење задатка

Код пројектовања агента први корак треба да буде спецификација окружења задатка што је могуће темељније. Окружење задатка чине [18]:

- мера перформансе
- окружење
- актуатори
- сензори

У табели 3 су дати неки примери типова агената са описом окружења задатка.

Табела 3 Примери типова агената са описима окружења задатка.

Тип агента	Мера перформансе	Окружење	Актуатори	Сензори
Аутономно возило без посаде	Безбедност, поштовање прописа, удобност путовања, минимизирање потрошње горива	Путеви, пешаци, други саобраћај, путна сигнализација	Волан, гас, кочница, мигавци, сирена, екран, радио, мењач	Камере, сонар, мерач брзине, ГПС, мерач пређеног растојања, сензори мотора, тастатура, мерач убрзања, мерач потрошње горива
Медицински дијагностички систем	Излечен пацијент, задовољан пацијент, минимизација трошкова, минимизација времена чекања на преглед	Пацијент, болница, особље, дијагностички апарати	Приказ питања, тестови, дијагнозе, терапије, упуту	Унос података о симптомима преко одговарајућег интерфејса, налази, одговори пацијента

Робот за одстрањивање компоненти	Проценат компоненти у коректним контејнерима	Покретна трака са компонентама, контејнери	Механичка рука	Камера, сензори углова чланака
Управљање рафинеријом која производи минерално уље	Максимизирање производње, максимизирање квалитета нафтних деривата, безбедност	Рафинерија, оператери, сировине	Вентили, пумпе, грејачи, дисплеји	Температура, притисак, хемијски сензори, безбедносни сензори
Дијагностика стања опреме у којој се користи изолационо минерално уље	Максимизирање оперативног рада опреме, благовремено обавештавање у случају сумње на квар	Постројење, мрежна инфраструктура	СМС порука, порука путем мејла, дисплеји	Мониторинг системи, извештаји о периодичним испитивањима, визуелни преглед, фабричка испитивања, мишљење експерта, погонски догађаји, списак бројева телефона и мејл адреса за обавештавање

Потребно је напоменути да битна разлика која постоји између „вештачких“ (виртуелних) и „стварних окружења“ јесте првенствено сложеност релација између понашања агента, опажајне секвенце коју окружење генерише и мере перформансе. Нека стварна окружења су у ствари веома једноставна (робот за одстрањивање компоненти) док поједини софтверски (виртуелни) агенти постоје у богатим неограниченим доменама нпр. интернету. Интернет као окружење је сложености која конкурише сложености физичког света а међу чијим „становницима“ су многи виртуелни и људски (природни) агенти. Са становишта рационалности и виртуелни и људски агенти се могу понашати и рационално и ирационално у окружењу као што је интернет.

Опсег различитих окружења задатка који се могу појавити у ВИ је неисцрпан. Постоји неколико аспеката по којима се могу разликовати окружења задатка. Формат и учесталост података, природа проблема, количина знања доступног у било ком тренутку су неки од елемената који разликују једну врсту окружења агента од другог. У циљу успешног пројектовања агента, карактеристике окружења је пожељно темељно разумети што се може постићи категоризацијом окружења по појединим особинама.

Код потпуно опсервабилног окружења сензори успешно детектују све аспекте који су од важности за избор акције (важност зависи од мере перформансе) у сваком временском тренутку. Потпуно опсервабилна окружења су погодна јер агент нема потребе да одржава било које унутрашње стање ради праћења стања окружења. На пример, у шаховској партији, стање окружења, односно позиција играча на шаховској табли је доступно све време тј. у сваком тренутку. Делимично опсервабилно окружење би могло настати због неисправности (недоступности) сензора, или због немогућности детекције свих аспеката који су од

важности. Агент који уопште не поседује сензоре је у неопсервабилном окружењу (циљеви агента и даље могу бити оствариви али уз одговарајуће присуство неизвесности) [18].

Пример за једноагентно окружење је агент који самостално решава укрштене речи. Агент који игра шах је у двоагентном окружењу. Да ли се поједини ентитет из окружења треба третирати као агент јесте чињеница да ли минимизирање мере перформансе датог агента зависи од неког другог агента. У шаху, претпостављени ентитет Б покушава да максимизира своју меру перформансе чиме минимизира меру перформансе агента А. Из овога произилази да је шах компететивно вишеагентно окружење. У случају аутономног возила без посаде, агенти желе да избегну саобраћајну несрећу али се такмиче за ограничен број паркинг места. Дато окружење можемо описати као делимично кооперативно вишеагентно окружење. Други пример кооперативног окружења би било интерактивно функционисање сензора у паметним кућама. Неке особине су карактеристичне за вишеагентно окружење насупрот једноагентном нпр. постојање комуникације али и насумично понашање јер се њиме избегава предвидљивост [18].

За окружење се каже да је детерминистичко ако је следеће стање окружења у потпуности одређено тренутним стањем и одговарајућом акцијом агента. Иначе, кажемо да је окружење стохастичко (насумично). Агенти не би требало да се баве неизвесношћу у потпуно опсервабилном, детерминистичком окружењу. Другим речима, у датом окружењу је занемарена неизвесност. Међутим, ако је окружење делимично опсервабилно, онда се може показати као стохастичко. Већина ситуација у стварном свету је толико сложена да је немогуће пратити све неопсервабилне аспекте, а из практичних разлога ове ситуације се морају третирати као стохастичке (нпр. аутономно возило без посаде). За окружење се каже да је неизвесно ако није у потпуности опсервабилно или није детерминистичко [18].

Карактеристика окружења епизодичних задатака је подела искуства агента на епизоде. У свакој епизоди, агент прима секвенцу опажаја и предузима одговарајућу акцију. Следећа епизода не зависи од реакција предузетих у претходним епизодама (робот за одстрањивање компоненти). Свака акција агента се извршава „атоично“. У секвенцијалном окружењу, тренутне одлуке могу утицати на наредну и све будуће одлуке. У секвенцијалном окружењу, агент треба да размишља унапред (шах, аутономно возило без посаде) [18].

Ако се окружење може мењати док агент доноси одлуку о предузимању акције кажемо да је окружење динамичко, иначе је статичко. Ако се окружење задатка не мења али се учинак агента мења током времена онда је окружење полудинамичко. Решавање укрштених речи је добар пример статичког окружења док аутономно возило без посаде, систем за опажање спољашње околине код дронова и играње фудбала у коме се позиције играча мењају током игре имају динамичко окружење [18].

Дискретно насупрот континуалном примењује се на стање окружења, на начин третирања времена и на опажаје и акције агента. Код дискретног окружења постоји ограничен број различитих, јасно дефинисаних правила и акција. Окружење игре шаха је дискретно јер има коначан скуп стања. Са друге стране вожња аутономног возила без посаде се одвија у континуалном окружењу [18].

У познатом окружењу исходи (одговарајуће вероватноће исхода) за све акције су познати. Ако је окружење непознато агент ће морати да учи како у њему да функционише. Треба имати у виду да познато окружење може бити делимично опсервабилно („таблић“) тако и да непознато окружење може бити потпуно опсервабилно (видео игра приказана на екрану али са непознатим контролама). Дата особина није строга особина окружења задатка [18].

Најтежи случај окружења задатка је делимично опсервабилано, више-агентно, стохастичко, секвенцијалано, динамично, континуално и непознато. Као пример датог окружења може послужити вожња изнајмљеног аутомобила, у непознатој земљи, са непознатом географијом и непознатим саобраћајним прописима [18].

У табели 4, приказане су особине окружења задатака из табеле 3. Наводи у табели нису увек фиксни. Дати наводи значајно зависе од тога како је дефинисано окружење задатка. На пример, код епизодичног окружења ако робот има способност обучавања и ако се појави велика серија неисправних делова на траци, робот може научити да се расподела неисправности значајно променила и тиме окружење задатка може постати секвенцијално.

Табела 4 Примери типова агената са описима окружења задатка.

Окружење задатка	Опсервабилно	Агент и	Детерминистичко	Епизодичко	Статично	Дискретно
Аутономно возило без посаде	делимично	више	стохастичко	секвенцијално	динамично	континуално
Медицински дијагностички систем	динамично	један	стохастичко	секвенцијално	динамично	континуално
Робот за одстрањивање компоненти	динамично	један	стохастичко	епизодичко	динамично	континуално
Управљање рафинеријом која производи минерално уље	динамично	један	стохастичко	секвенцијално	динамично	континуално
Дијагностика стања опреме у којој се користи изолационо минерално уље	делимично	један	стохастичко	секвенцијално	динамично	континуално

5.3. Структура агента

Агентске функције имплементирају агенти помоћу програма агента (пресликавањем опажаја у акције). Задати програм се извршава на рачунарском уређају са одговарајућим сензорима и актуаторима. Дакле, агент се састоји од програма и одговарајуће архитектуре. Архитектура агента може ићи од једноставног персоналног рачунара до роботског возила са више уграђених рачунара, камера и сензора.

Агенти се могу разликовати на основу степена перципиране интелигенције и способности. Четири основна типа агената који отелотворују фундаменталне принципе скоро свих интелигентних система према [18] су:

- једноставни рефлексни агенти
- рефлексни агенти засновани на моделу
- агенти засновани на циљу
- агенти засновани на корисности


Све четири врсте агената могу унапредити своје перформансе функционалношћу обучавања.

У доступној литератури могу се пронаћи и друге поделе интелигентних агената као на пример у [130].

5.4. Једноставни рефлексни агенти

Главна карактеристика једноставних рефлексних агената је занемаривање историје опажаја и коришћење једино тренутних опажаја при доношењу одлуке о одговарајућој акцији агента. Функција датих агената је заснована на ако-онда (енгл. *if-then*) правилима. Дата правила служе за пресликавање очитане ситуације о тренутном стању окружења са сензора у одговарајућу акцију. Акција ће бити извршена само ако је услов за одређену акцију испуњен.

Једноставни рефлексни агенти имају добру особину да су „једноставни“ али ту једноставност плаћају ценом ограничене интелигенције. Дати агенти функционишу само ако се на основу тренутног опажаја може донети конкретна одлука о акцији тј. ако је окружење потпуно опсервабилно. Чак и мали поремећај у опсервабилности може изазвати значајан проблем који се манифестује у настанку бесконачних петљи. Излазак из бесконачних петљи је могућ ако агент може бирати своја деловања на случајан начин. Понашање агента засновано на бирању деловања на случајан начин може бити рационално у више-агентном окружењу (као што је напоменуто у поглављу 5.2). Међутим, уобичајено је да се у једноагентним окружењима дато понашање сматра ирационалним тј. само „корисним триком“ који помаже агенту у специфичним ситуацијама. Такође, треба имати у виду да свака промена окружења захтева и преиспитивање скупа ако-онда правила. Једноставни рефлексни агент је обично превелик за генерисање и чување [18]. На слици 5-1 приказана је илустрација главних компоненти једноставног рефлексног агента.




Слика 5-1 Илустрација једноставног рефлексног агента.

5.5. Рефлексни агенти засновани на моделу

Начин третирања делимичне опсервабилности, који даје најбољи резултат састоји се у томе да агент прати кретање оних делова света које не може видети. То се може постићи тако што ће агент успоставити неку врсту унутрашњег стања која зависи од историје опажаја и стога осликава бар неке неопажене аспекте тренутног стања (нпр. вођење аутономног возила без посаде агент треба да бележи положај мењача). За потребе чувања стања агенту ће бити потребан одговарајући меморијски простор [18].

Како би се чувале информације о унутрашњем стању са протоком времена потребно је чувати две врсте знања. На првом месту потребно је чувати информације о развијању окружења независно од агента. На другом месту је чување информација о томе како акције агента делују на окружење. Дато знање о начину функционисања света назива се моделом окружења. Детаљи и околности начина на који је модел представљен ће увелико варирати у зависности од врсте окружења и појединачних техника које се користе у дизајну агената [18].

Без обзира која врста представљања стања окружења се користи, за делимично опсервабилно окружење ретко је могуће одредити тачно стање окружења већ је у питању најбоља процена агента. Такође, треба имати у виду да унутрашње стање не мора да опише окружење у дословном смислу. Тренутно стање се чува унутар агента који одржава неку врсту структуре која описује део окружења који није опсервабилан. Треба имати у виду да дата структура не може бити „савршена“ већ да представља најбољу могућу апроксимацију од стране агента [18]. На слици 5-2 приказана је илустрација главних компоненти рефлексног агента заснованог на моделу.



Слика 5-2 Илустрација рефлексног агента заснованог на моделу.

5.6. Агенти засновани на циљу

Понекад одлуку о томе шта треба да се уради није могуће донети само на основу тренутне секвенце опажаја. Права одлука умногоме зависи од тога где агент треба да стигне, тј. од циља. То значи да поред описа тренутног стања агенту је потребна нека информација везана за циљ, којом се описују ситуације које се сматрају пожељним. Понекад избор акција које воде до циља може бити једноставан међутим у осталим случајевима агент мора користити технике претраживања и планирања (области ВИ посвећене проналажењу низа акција којима се остварују циљеви агента). Основна разлика између ако-онда начина одлучивања јесте у томе што одлучивање код датог агента обухвата разматрање будућности. Знање које подржава његове одлуке је експлицитно представљено и може се модификовати, што чини ове агенте флексибилнијим у односу на агенте који доносе одлуке на основу ако-онда правила [18].

5.7. Агенти засновани на корисности

У већини окружења за постизање висококвалитетног понашања сами циљеви нису довољни. Многе секвенце деловања ће довести агента до циља али се може поставити питање која од тих секвенци је нпр. сигурнија, бржа, поузданија или економски исплативија. Зато је потребно увести уопштенију меру перформансе (не само засновану на испуњењу циља) која треба да омогући поређење различитих стања окружења односно колико би она учинила агента корисним. Код агента заснованих на корисности спољна мера перформансе се може интернализовати функцијом корисности. Када постоје конфликтни циљеви (нпр.

брзина и безбедност) функцијом корисности се специфицира одговарајући компромис. Ако постоји више циљева којима се тежи а ниједан не може бити са извесношћу постигнут, корисност даје начин на који се вероватноћи успеха могу доделити тежински фактори узимајући у обзир важност циљева. Агент заснован на корисности има многе предности у погледу флексибилности и учења (нпр. у случају супротстављених циљева и случајева када постоји више циљева). Треба напоменути да бирање правца деловања којим се максимизира корисност је веома захтеван задатак и да је савршена рационалност обично неостварива у пракси [18].


5.8. Агенти са обучавањем

Агент са обучавањем је тип агента који има способност учења или може да учи из сопственог искуства. Дати агент почиње да извршава акције са основним знањем, а затим је у стању да делује и прилагођава се аутоматски кроз учење. За произвољног агента може бити конструисан механизам обучавања у циљу побољшања сваког дела агента. Агент са обучавањем поседује четири главне концептуалне (појмовне) компоненте [18]:

1. елемент перформансе,
2. елемент обучавања,
3. елемент критике,
4. генератор проблема.

Елемент перформансе је онај део чију перформансу треба да унапредимо обучавањем тј. то може бити било који наведени тип агента без обучавања. Елемент обучавања је одговоран за генерисање побољшања. Дати елемент користи повратну спрегу из критике у вези са деловањем агента и одређује како треба модификовати елемент перформансе у циљу побољшања рада агента. Елемент критике говори елементу обучавања колико добро агент делује у односу на фиксирани стандард перформансе. Критика је неопходна јер опажаји сами по себи не дају индикацију о успеху агента (нпр. агент који решава укрштеницу може примити опажај да је укрштеница решена, међутим треба му стандард перформансе који ће му рећи да је то „добра ствар“). Генератор проблема предлаже деловања која ће водити ка новим и информативним искуствима. Дати генератор има функцију да предлаже акције истраживања. На неки начин он ради исто што и раде научници када врше експерименте.

Сажето посматрано, обучавање код интелигентних агената је процес модификације сваке компоненте ради довођења компоненте у већу сагласност са расположивом информацијом добијеном повратном спрегом, чиме се побољшава укупна перформанса агента. Стога, агенти са обучавањем су у стању да уче, анализирају учинак и траже нове начине за побољшање учинка агента [18]. На слици 5-3 приказана је илустрација главних компоненти агента са обучавањем.



Слика 5-3 Илустрација уопштеног агента са обучавањем.

6. Асистент за прорачун мерне несигурности

У овом поглављу описан је развој софтверског агента за квантификацију утицаја промене температуре минералног уља на буџет комбиноване мерне несигурности неитеративног алгоритма за све-акустичко лоцирање ПП у минералном уљу применом вештачке интелигенције односно методе МО. Приказане су одговарајуће фазе еволутивног животног циклуса датог агента који је конструисан (осмишљен) за потребе предметног истраживања. Додатно, описана је новопредложена метода „на основу процене“ за изражавање мерне несигурности модела машинског обучавања заснована на изражавању мерне несигурности типа Б и аналогiji између модела МО и реалног мерног инструмента.

6.1. Формирање алгоритма за процену доприноса температуре уља стандардној комбинованој мерној несигурности неитеративног алгоритма

За процену утицаја температуре минералног уља на стандардну комбиновану мерну несигурност неитеративног алгоритма потребно је израчунати осетљивост неитеративног алгоритма на средњу вредност (математичко очекивање) и стандардно одступање (статистичку дисперзију) температуре минералног уља. Осетљивост неитеративног алгоритма на температуру минералног уља се може проценити нумеричким, Монте Карло и методама вештачке интелигенције док се стандардно одступање односно дисперзија вредности температуре уља може проценити статистичким методама.


6.1.1. Анализа осетљивости неитеративног модела

У овом потпоглављу описан је начин математичког моделовања физичких појава у предметном истраживању. Описане су релевантне улазне и излазне информације разматраног модела као и начин квантификације (процене) коефицијента осетљивости температуре минералног уља у неитеративном алгоритму.

6.1.1.1. Увод

Математичко моделовање се у широком обиму користи за решавање проблема у физици, хемији, инжењерству итд. Поједини детаљи сваког проблема ће се, наравно, умногоме разликовати, али постоји драгоцена општа перспектива заједничка за све дате области моделовања. Ова заједничка додирна тачка је илустрована на слици 6-1, која, у форми блок дијаграма, приказује генерални начина на који се моделовање изводи [131].

Први корак је математичка дефиниција модела која укључује параметарско представљање улазних информација. Следећи корак је дефинисање математичких једначина које ће довести до решења тј. повезати улаз са излазом. Решење ових једначина води директно до скупа посматраних излазних вредности. Са прикупљеним информацијама можемо проценити елементарне параметре осетљивости што ће на крају довести до систематског и моћног рачуна осетљивости способног да испита fine детаље, као и укупне грубе карактеристике проблема [131].



Слика 6-1 Илустрација математичког моделовања физичких појава.

Циљ анализе осетљивости је испитивање односа између излазних и улазних променљивих система. Из шире перспективе, све променљиве, и улазне и излазне, могу се посматрати као целина, и међусобне везе између њих бити испитане [132]. Анализа осетљивости се може извршити или свеобухватно или само делимично, узимајући у обзир само одабране променљиве.

У најједноставнијем случају, осетљивости на улазне променљиве система су еквивалентне парцијалним дериватима првог реда одзива система у односу на улазне променљиве система, израчунате по номиналним вредностима улазних променљивих [131], [132].


Описани кораци математичког моделирања представљају основу за конструкцију и имплементацију алгоритма. У наредним поглављима, приказани су сви елементи математичког моделовања за случај неитеративне све-акустичке методе.

6.1.1.2. Улазне и излазне информације модела

Као што је описано у Поглављу 3.5, одређивање локације ПП се врши индиректно. Улазне и излазне променљиве неитеративног алгоритма су:

- брзина акустичког сигнала v_s ,
- координате акустичких сензора: x_{si}, y_{si}, z_{si} ($i = 1, \dots, 4$),
- временске разлике доласка акустичког сигнала ПП на сензоре: $\tau_{12}, \tau_{13}, \tau_{14}$,
- координате извора ПП: x, y, z .

У датом случају постоји 16 улазних и 3 излазне променљиве (слика 6-2).



Слика 6-2 Илустрација улазних и излазних променљивих неитеративног алгоритма.

Осим наведених променљивих, које су директно повезане са неитеративним алгоритмом, друге информације као што су:

- облик и димензије разматране области испуњене минералним уљем,
- опсег могућих (разматраних) вредности за v_s ,
- опсег могућих (разматраних) вредности за температуру минералног уља,
- странице разматране области које се користе (које су доступне) за постављање сензора,
- координате (места) на која је могуће поставити акустичке сензоре,

такође представљају вредне улазне информације о моделу.

Математичке једначине које се користе за одређивање локације ПП неитеративном све-акустичком методом су детаљно приказане у поглављу 3.6.

6.1.1.3. Коефицијент осетљивости температуре минералног уља

Будући да су координате резултата одређивања локације ПП (x, y, z) функције више променљивих одређивање локације ПП се може представити следећом генерализованом формулом:

$$g = f_g(x, y, z, x_{s_i}, y_{s_i}, z_{s_i}, v_s, \tau_{12}, \tau_{13}, \tau_{14}), \quad g \equiv x \equiv y \equiv z. \quad (6.1)$$

Узимајући у обзир зависност (корелацију) између брзине акустичког сигнала и температуре минералног уља, T , дата формула на основу теореме о изводу сложене функције постаје:

$$g = f_g(x, y, z, x_{s_i}, y_{s_i}, z_{s_i}, T, \tau_{12}, \tau_{13}, \tau_{14}), \quad g \equiv x \equiv y \equiv z. \quad (6.2)$$

Стандардна комбинована мерна несигурност за функцију f_g , $u_c(f_g)$, без корелације између параметара, где u_x , u_{s1} , u_T , ..., u_{t14} представљају стандардна одступања одговарајућих параметара, изражава се на следећи начин:

$$u^2_c(f_g) = \left(\frac{\partial f_g}{\partial x}\right)^2 u^2_x + \dots + \left(\frac{\partial f_g}{\partial x_{s1}}\right)^2 u^2_{x_{s1}} + \dots + \left(\frac{\partial f_g}{\partial T}\right)^2 u^2_T + \dots + \left(\frac{\partial f_g}{\partial \tau_{14}}\right)^2 u^2_{\tau_{14}}. \quad (6.3)$$

На основу разматрања у поглављу 2.9, за процену мерне несигурности типа Б ако су познате једино горња и доња граница опсега несигурности температуре ($T_{\text{доња граница}}$, $T_{\text{горња граница}}$) или (T , T^+), при чему је $T^+ > T$, оправдано је придружити равномерну расподелу температуре минералног уља. Одговарајући коефицијент осетљивости на основу (2.13) је дат изразом:

$$c_{Tg} = \left| \frac{fg(T^+) - fg(T^-)}{T^+ - T^-} \right| = \left| \frac{g(T^+) - g(T^-)}{\Delta T} \right| = \frac{|g|}{\Delta T}, \quad g \equiv x \equiv y \equiv z. \quad (6.4)$$

Дати израз представља вектор вредности (c_{Tx} , c_{Ty} , c_{Tz}).

У предметном истраживању, за процењену вредност коефицијента осетљивости температуре минералног уља у одговарајућој тачки простора стања неитеративног алгоритма (средња вредност температуре минералног уља) узима се максимална вредност од вредности датих коефицијената осетљивости по осама координатног система:


$$c_{T\max} = \max(c_{Tx}, c_{Ty}, c_{Tz}) = \frac{\max(|\Delta g|)}{\Delta T} = \frac{\Delta g \max}{\Delta T}. \quad (6.5)$$

6.1.2. Алгоритам један по један


У поглављима 6.1.1.2 и 6.1.1.3 су приказани сви елементи математичког модела неитеративног алгоритма за све-акустичко лоцирање ПП у минералном уљу. Како би се проценио коефицијент осетљивости температуре минералног уља изабран је систематичан приступ чији је први корак формирање алгоритма један по један (енгл. *one-at-a-time*) [98].

Приступ један по један за одређивање осетљивости улазне променљиве модела се заснива на одређивању парцијалних деривата првог реда одзива модела у односу на улазне променљиве система, израчунате по номиналним вредностима улазних променљивих. Дати приступ не истражује у потпуности улазни простор неитеративног алгоритма, јер не узима у обзир истовремену варијацију свих улазних променљивих, већ само једне променљиве-температуре минералног уља. Међутим, он представља основу алгоритма који се може конструисати у сврху истовремених варијација свих променљивих.

На слици 6-3 приказана је илустрација прорачуна максималне вредности коефицијента осетљивости температуре минералног уља користећи алгоритам један по један. За доњу границу опсега несигурности T све остале променљиве задржавају вредности и преносе се у следећи корак алгоритма у коме се уместо T уноси вредност горње границе несигурности T^+ . Дата промена у вредности једне променљиве тј. температуре минералног уља проузрокује промену у излазним вредностима положаја ПП. На основу дате промене проузроковане променом температуре минералног уља израчунава се одговарајућа максимална вредност коефицијента осетљивости. Као што је већ истакнуто, дати прорачун узима у обзир промену вредности само једне улазне променљиве тј. температуре минералног уља.



Слика 6-3 Илустрација прорачуна максималне вредности коефицијента осетљивости температуре минералног уља користећи алгоритам један по један. Дати прорачун узима у обзир промену вредности само једне променљиве тј. температуре минералног уља.



Слика 6-4 Алгоритам за прорачун максималне вредности коефицијента осетљивости температуре минералног уља за N различитих опсегу несигурности температуре минералног уља.

Алгоритам један по један за температуру минералног уља је илустрован блок дијаграмом приказаним на слици 6-4. Први блок на датој слици описује потребне улазне информације за рад алгоритма. Све вредности дефинисане у овом блоку ће остати непромењене до краја извршавања алгоритма. Циљ алгоритма је да за сваки разматрани опсег несигурности температуре минералног уља израчуна максималну вредност коефицијента осетљивости минералног уља. Број различитих опсега несигурности температуре уља је означен са N . Дати процес је представљен петљом од N понављања. Петља се завршава када тренутни број понављања n достигне N . Ово производи скуп упарених вредности $\Delta T_n, \Delta x_n, \Delta y_n, \Delta z_n, \Delta g_{max_n}, \Delta g_{max_n}/\Delta T_n, n=1...N$ (6.6). Дате вредности представљају коначни резултат алгоритма.

$$\begin{bmatrix} \Delta T_1 & \Delta x_1 & \Delta y_1 & \Delta z_1 & \Delta g_{max_1} & \Delta g_{max_1}/\Delta T_1 \\ \Delta T_2 & \Delta x_2 & \Delta y_2 & \Delta z_2 & \Delta g_{max_2} & \Delta g_{max_2}/\Delta T_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \Delta T_N & \Delta x_N & \Delta y_N & \Delta z_N & \Delta g_{max_N} & \Delta g_{max_N}/\Delta T_N \end{bmatrix}. \quad (6.6)$$

6.1.3. Алгоритам за истовремене варијације улазних променљивих


Алгоритам за истовремене варијације улазних променљивих користи Монте Карло методу и алгоритам један по један за температуру минералног уља.

На слици 6-5 описана је прва верзија алгоритма. Дата верзија истовремено варира четири променљиве T, x, y и z . Број Монте Карло симулација тј. различитих локација ПП које се разматрају означен је са N_{MC} .


На слици 6-6 приказана је друга верзија алгоритма. Дата верзија истовремено варира тринаест променљивих $T, x_{si}, y_{si}, z_{si}, (i = 1,..4)$. Број различитих разматраних конфигурација акустичких сензора такође је означен са N_{MC} .

У обе верзије алгоритма, број различитих вредности за температуру уља која се користи за одређивање локације ПП означен је са N . Резултат је скуп упарених вредности: $\Delta T_{(n, n_{MC})}, \Delta g_{max_{(n, n_{MC})}}, \Delta g_{max}/\Delta T_{(n, n_{MC})}, l_{sr(n, n_{MC})}, n = 1,..., N, n_{MC} = 1,..., N_{MC}$.

У приказане две верзије алгоритма број променљивих које се варирају је различит. Ово је урађено јер постоји велики број променљивих које могу отежати запажања; неитеративни алгоритам има шеснаест улазних и три излазне променљиве. Једноставније је уочити потенцијалне интеракције између променљивих ако се користи овакав, систематичан приступ [8].



Слика 6-5 Прва варијанта алгоритма за истовремене варијације улазних променљивих, где позиције акустичких сензора остају непромењене.



Слика 6-6 Друга варијанта алгоритма за истовремене варијације улазних променљивих, где позиција ПП остаје непромењена.


6.2. Имплементација алгоритама у софтверског агента

Софтверски агент који имплементира алгоритме описане у поглављима 6.1.2 и 6.1.3 је назван „Асистент за прорачун мерне несигурности“ (енгл. *Measurement uncertainty assistant*). Дати софтвер је развијан у више фаза, у складу са еволутивним моделом животног циклуса. Свака од фаза развоја одговарала је једном типу агента, и то од најједноставнијег рефлексног агента, ка сложенијем рефлексном агенту заснованог на моделу, са функцијом обучавања (табела 5, слика 6-7).

Табела 5 Приказ најзначајнијих фаза развоја током животног циклуса „Асистента за прорачун мерне несигурности“.

Фаза	Фаза имплементирана	Захтев	Кратак опис најзначајнијих функционалности
Једноставни рефлексни агент	Да	Прорачун локације ПП помоћу неитеративног алгорита.	Унос локација сензора, брзине акустичког сигнала. Прорачун локације ПП и приказ оба решења која даје алгорита. Избор решења од стране оператера и прорачун одступања резултата у односу на номиналне вредности.
Рефлексни агент заснован на моделу	Да	Монте Карло симулација. Процена доприноса температуре минералног уља буџету мерне несигурности неитеративног алгорита	Извршавање Монте Карло симулација. База података за чување и обраду резултата Монте Карло симулација. Аутоматизација одабира решења неитеративног алгорита, прорачуна максималног одступања резултата, просечне вредности коефицијента осетљивости температуре минералног уља и осталих релевантних параметара.
Рефлексни агент заснован на моделу, са обучавањем	Да	Имплементација машинског обучавања.	Тренирање, валидација и тестирање модела машинског обучавања. Предвиђање одговарајућих вредности. База података за чување

			скупова за обуку. Извоз вредности које предвиђа модел машинског обучавања у одговарајући фајл или табелу у бази података. Прорачун мерне несигурности одговарајућег модела машинског обучавања.
--	--	--	---



Слика 6-7 Приказ еволутивног модела животног циклуса „Асистента за прорачун мерне несигурности“.

Дата апликација написана је у програмском језику *Visual C#*, развојно окружење *Microsoft Visual Studio Community 2019*. Одговарајуће фазе у развоју софтвера су раздвојене на одговарајућим картицама корисничког интерфејса (енгл. *Calculate PD location, Simulation 1: sensors' positions unchanged, Simulation 2: partial discharge position unchanged, Machine Learning*).

6.2.1. Прва фаза: једноставни рефлексни агент

Прва фаза у развоју „Асистента за прорачун мерне несигурности“ одговара по типу једноставном рефлексном агенту и служи за прорачун локације ПП помоћу неитеративног алгорита (табела 6).

Да би се израчунала локација ПП потребно је да сви улазни подаци буду дефинисани (унети) тј. окружење задатка мора бити потпуно опсервабилно. Прорачуни локације ПП се врше независно (атомски) из чега произилази да је окружење епизодичко (табела 7).

Табела 6 Опис окружења задатка.

Тип агента	Мера перформансе	Окружење	Актуатори	Сензори
Асистент за прорачун мерне несигурности	Израчунавање положаја ПП	Рачунар, оперативни систем, оператор	Текстуална поља корисничког интерфејса	Текстуална поља и дугмад корисничког интерфејса

Табела 7 Особине окружења задатка.

Окружење задатка	Асистент за прорачун мерне несигурности (прорачун локације ПП помоћу неитеративног алгоритма)
Опсервабилно	потпуно опсервабилно
Агенти	једноагентно
Детерминистичко	детерминистичко
Едизодичко	епизодичко
Статично	статично
Дискретно	континуално

„Асистент за прорачун мерне несигурности“ за улазне променљиве узима положаје сензора, временске разлике кашњења сигнала и брзину акустичког сигнала. Излазне променљиве су 2 положаја парцијалног пражњења од којих оператер бира један, као прихватљиво (могуће) решење. Дата функционалност софтвера не поседује меморију у коме чува податке између прорачуна. Помоћу дате функционалности софтвера добијени су резултати симулације приказани у поглављу 7.1.1 (слика 6-8).

Слика 6-8 Приказ картице *Calcucate PD location* „Асистента за прорачун мерне несигурности“ која приказује прорачун локације ПП помоћу неитеративног алгоритма; 1- временске разлике кашњења сигнала ПП на сензоре за доњу границу опсега несигурности температуре минералног уља (подразумевана вредност је 20 °C); 2-вредност брзине акустичког сигнала која одговара горњој граници опсега несигурности минералног уља (приказана вредност одговара температури од 60 °C); 3-прорачуната вредност локације ПП користећи вредност брзине акустичког сигнала која одговара вредности горње границе опсега несигурности температуре минералног уља; 4-номинална вредност положаја ПП (прорачуната за вредност доње границе опсега несигурности температуре минералног уља); 5- одступање резултата по осам координатног система.

6.2.2. Друга фаза: рефлексни агент заснован на моделу

Друга фаза у развоју „Асистента за прорачун мерне несигурности“ одговара по типу рефлексном агенту заснованом на моделу и служи за процену вредности коефицијента осетљивости температуре минералног уља (табела 8). Дати агент имплементира алгоритам за истовремене варијације улазних променљивих описан у поглављу 6.1.3.

Монте Карло симулација користи одговарајући (коначан) број симулација и не може генерисати све могуће тачке у простору стања неитеративног алгоритма што је разлог делимично опсервабилног окружења задатка. Дата апликација поседује меморију у облику одговарајуће базе података, међутим окружење задатка је епизодичко јер претходно стање задатка не утиче на тренутно стање тј. прорачун просечне вредности коефицијента осетљивости температуре минералног уља се врши епизодично. Свака Монте Карло симулација генерише насумичне бројне вредности за одређени скуп параметара (положај ПП или положаје акустичких сензора) тако да се окружење задатка може описати као делимично стохастичко (табела 9).


Табела 8 Опис окружења задатка.

Тип агента	Мера перформансе	Окружење	Актуатори	Сензори
Асистент за прорачун мерне несигурности	Процена вредности коефицијента осетљивости температуре минералног уља	Рачунар, оперативни систем, систем за управљање базом података, оператор	Текстуална поља, табеле, трака напретка корисничког интерфејса	Текстуална поља и дугмад корисничког интерфејса


Табела 9 Опис окружења задатка.

Окружење задатка	Асистент за прорачун мерне несигурности (процена просечне вредности коефицијента осетљивости температуре минералног уља)
Опсервабилно	делимично опсервабилно
Агенти	једноагентно
Детерминистичко	делимично стохастичко
Едизодичко	епизодичко
Статично	статично
Дискретно	континуално

У односу на претходну фазу, дата апликација поседује аутоматизован избор тачног решења неитеративног алгоритма, прорачуне максималног одступања резултата, средње вредности коефицијента осетљивости температуре минералног уља и осталих релевантних параметара (слика 6-9 и слика 6-10).



Слика 6-9 Приказ картице *Simulation 1: sensors' positions unchanged* „Асистента за прорачун мерне несигурности“ која приказује Монте Карло симулацију за фиксирани положај сензора и насумични положај ПП; 1- приказ вредности најзначајнијих параметара; 2- редни број Монте Карло симулације; 3- положаји сензора остају непромењени док се њихов распоред од најближег до најдаљег у односу на ПП мења у зависности од положаја ПП; 4-насумични положај ПП.




Слика 6-10 Приказ картице *Simulation 2: partial discharge position unchanged* „Асистента за прорачун мерне несигурности“ која приказује Монте Карло симулацију за фиксирани положај ПП и насумични положај сензора; 1- позиције сензора се бирају насумично; 2- положај ПП остаје непромењен; 3- резултат алгоритма један по један за 5 опсега несигурности температуре минералног уља (реално 4 опсега јер се опсег од 0 °C не разматра) у оквиру једне Монте Карло симулације;

6.2.3. Мерна несигурност модела машинског обучавања

Код нагледаног обучавања, скуп за обуку се састоји од улазно-излазних парова. Дати скуп се може посматрати као да је за сваку улазну вредност измерена одговарајућа излазна вредност. Уопштено говорећи (без шума у подацима), један улаз одговара једном излазу. Оригиначне излазне вредности из скупа за обуку могу се сматрати тачним вредностима, док су вредности добијене моделом машинског обучавања измерене вредности. Пошто се за једну улазну вредност мери само једна излазна вредност, немогуће је изразити мерну несигурност типа А. Међутим, могуће је изразити мерну несигурност типа Б јер је за њено изражавање довољно само једно мерење [19].

Један од уобичајених извора за одређивање мерне несигурности типа Б су упутства произвођача мерног инструмента. Упутства садрже максималне грешке које је произвођач одредио за специфичне опсеге мерне величине. Аналогија са моделом машинског обучавања би била максимални губитак L_1 на скупу података за обуку (слика 6-11).



Слика 6-11 Предложена аналогија између модела машинског обучавања и мерног уређаја за изражавање мерне несигурности типа Б [19]².

Под претпоставком униформне расподеле, стандардна мерна несигурност типа Б модела машинског обучавања једнака је стандардној девијацији s [19]:

$$u = \sqrt{u_A^2 + u_B^2} = |u_B| = s = \frac{\max_{(x,y) \in E} L_1(y, \tilde{y})}{\sqrt{3}}, \quad (6.7)$$

са статистичком сигурношћу од 57,7%.

Додатни извори мерне несигурности типа Б поменути у поглављу 2.6 и представљени у [38] такође могу пронаћи аналогију са моделом машинског обучавања. На пример, несигурност услед читавања индикације (скеле) мерног уређаја од стране оператора може бити аналогна узимању мањег броја значајних цифара или неадекватном заокруживању предвиђених вредности од стране модела машинског обучавања. Модели машинског обучавања се извршавају на одговарајућем хардверу који опционо посматра околину преко актуатора. Несигурност прорачуна ЦПУ-а, мерна несигурност актуатора, итд., такође могу бити додатни извори мерне несигурности типа Б модела машинског обучавања [19]. Дати додатни извори мерне несигурности нису узети у обзир у оквиру предметног истраживања

6.2.4. Трећа фаза: рефлексни агент заснован са моделу, са обучавањем

Трећа фаза у развоју „Асистента за прорачун мерне несигурности“ одговара по типу рефлексном агенту заснованом на моделу, са обучавањем (табела 10). Као што је напоменуто у поглављу 5.8 сваки тип агента своје перформансе може унапредити функционалношћу обучавања. Мотив обучавања у датом истраживању је, између осталог, потреба да се у процес квантификације коефицијента осетљивости температуре минералног уља c_T , укључи средња вредност растојања акустичких сензора од ПП, l_{sr} . Такође, потребно је израчунати и одговарајућу процену мерне несигурности коришћеног модела машинског обучавања (слика 6-12).

Табела 10 Опис окружења задатка.

Тип агента	Мера перформансе	Окружење	Актуатори	Сензори
Асистент за прорачун мерне несигурности	Процена вредности коефицијента осетљивости температуре минералног уља помоћу одговарајућег модела машинског обучавања. Процена мерне несигурности модела машинског обучавања.	Рачунар, оперативни систем, систем за управљање базом података, скуп података за тренинг модела машинског обучавања, програмски оквир <i>ML.NET</i> , оператор	Текстуална поља корисничког интерфејса	Текстуална поља и дугмад корисничког интерфејса

Measurement uncertainty assistant v3.1

Calculate PD location | Simulation 1: sensors' positions unchanged | Simulation 2: partial discharge position unchanged | **Machine learning**

ML parameters

Calculate ML parameters

L1 [m/°C]
0.0037

avg (cT) [m/°C]
0.0005

Out of uB
83 of 4897

uB [m/°C]
0.0022 **1**

Prediction

Isr [m]
0.49

cT [m/°C]
0.0040 **2**

Predict

Слика 6-12 Приказ картице *Machine learning* „Асистента за прорачун мерне несигурности“ која се односи на модел машинског обучавања; 1- приказ мерне несигурности модела машинског обучавања; 2- приказ предвиђене вредности коефицијента осетљивости температуре минералног уља на основу вредности l_{sr} .

7. Резултати истраживања

Ово поглавље приказује резултате предметног истраживања у складу са током истраживања. Прво су представљени сумарни резултати софтверских симулација добијени помоћу „Асистента за прорачун мерне несигурности“, затим експериментална провера (верификација) добијених резултата на реалном моделу. Због обима, део експерименталних резултата приказан је у Прилогу 1. На основу добијене сагласности експерименталних и резултата одговарајућих симулација извршено је тренирање, валидација и тестирање одговарајућих модела машинског обучавања. На основу вредности коефицијента детерминације R^2 , употреба метода машинског обучавања је унапредила процену доприноса температуре минералног уља буџету мерне несигурности неитеративног алгорита за више од два пута.

7.1. Резултати софтверских симулација

У симулацијама је разматран замишљен простор у облику коцке испуњен минералним уљем дужине странице од 0,60 m. Вредност температуре минералног уља од 20°C је подразумевана вредност доње границе опсега несигурности. Разматрани опсеги несигурности температуре уља су: 20°C-30°C, 20°C-40°C, 20°C-50°C и 20°C-60°C. Температуре уља (брзине звука) које одговарају горњим границама разматраних опсега несигурности су: 30 °C (1374 m/s), 40 °C (1337 m/s), 50 °C (1301 m/s), и 60 °C (1266 m/s). Доњој граници опсега несигурности од 20 °C одговара брзина звука од 1414 m/s. Опсеги несигурности температуре минералног уља ΔT узимају вредности од 10 °C, 20 °C, 30 °C и 40 °C, респективно.

7.1.1. Почетна симулација

Почетна симулација је извршена помоћу „Асистента за прорачун мерне несигурности“ у фази развоја еквивалентној једноставном рефлексном агенту.

У почетној симулацији разматрано је 6 различитих слободно изабраних положаја акустичких сензора док је положај ПП остао непромењен (табела 11). Координате ПП су изабране као потенцијално место високонапонског намотаја у случају да замишљен простор представља енергетски трансформатор. Сви сензори су постављани на више од 0,03 m удаљености од ивица замишљене области. Резултати симулација представљени су у Табели 12 [2].

Табела 11 Слободно изабрани положаји сензора и положај ПП у почетној симулацији [2].


Бр.	Координате акустичких сензора [m]											
	x_{s1}	y_{s1}	z_{s1}	x_{s2}	y_{s2}	z_{s2}	x_{s3}	y_{s3}	z_{s3}	x_{s4}	y_{s4}	z_{s4}
1	0,60	0,39	0,36	0,22	0,60	0,24	0,18	0,00	0,23	0,00	0,56	0,16
2	0,50	0,60	0,30	0,00	0,36	0,20	0,60	0,11	0,19	0,15	0,00	0,10
3	0,60	0,31	0,19	0,47	0,60	0,19	0,38	0,00	0,13	0,00	0,52	0,20
4	0,00	0,29	0,43	0,13	0,60	0,34	0,60	0,36	0,19	0,46	0,00	0,20
5	0,54	0,60	0,31	0,00	0,07	0,26	0,35	0,00	0,06	0,60	0,28	0,05
6	0,00	0,42	0,53	0,42	0,00	0,55	0,60	0,44	0,51	0,17	0,60	0,37
Координате ПП [m]												
					x	y	z					
					0,30	0,30	0,48					

Табела 12 Резултати симулација [2]

Бр. \ Δg_{max} [m]	Температура минералног уља [°C]				
	20	30	40	50	60
	Опсег несигурности температуре минералног уља [°C]				
	-	10	20	30	40
1	-	-	-	-	-
2	-	-	-	-	-
3	0,00	0,04	0,07	0,09	0,11
4	0,00	0,01	0,03	0,04	0,05
5	0,00	0,00	0,01	0,01	0,02
6	0,00	0,00	0,00	0,00	0,00


За позиције сензора 1 и 2 нису добијена валидна решења за локацију ПП. У овим случајевима неитеративни алгоритам је дао или позитивне корене (два могућа решења) или резултат који је ван граница разматране области. Дате позиције се могу сматрати неприменљивим за постављање сензора за разматрани положај ПП.

Као што се види на слици 7-1, положаји сензора од 3 до 6, дају значајну разлику у максималном апсолутном одступању резултата у односу на промену температуре уља. Овај диспарат се кретао од 0,00 m за положај 6, до 0,11 m за положај 3 за температуру од 60°C (опсег несигурности температуре минералног уља од 40°C).




Слика 7-1 График промене максималног одступања резултата одређивања локације ПП у зависности од температуре минералног уља за четири различита положаја акустичких сензора и исти положај ПП (табела 12) [2]³.


На сликама од 7-2 до 7-7 су представљене илустрације разматраних положаја сензора у тродимензионалном простору (од 1 до 6, респективно) и ПП у замишљеној области испуњеној минералним уљем. Положај ПП је означен са *PD*.




Слика 7-2 Илустрација положаја сензора и ПП за положај бр. 1 [2]⁴.




Слика 7-3 Илустрација положаја сензора и ПП за положај бр. 2 [2]⁴.




Слика 7-4 Илустрација положаја сензора и ПП за положај бр. 3 [2]⁵.



Слика 7-5 Илустрација положаја сензора и ПП за положај бр. 4 [2]⁵.



Слика 7-6 Илустрација положаја сензора и ПП за положај бр. 5 [2]⁶.




Слика 7-7 Илустрација положаја сензора и ПП за положај бр. 6 [2]⁶.

⁶<https://creativecommons.org/licenses/by-nc-nd/3.0/rs/>

7.1.2. Прва симулација

Прва, друга и додатне симулације су извршене помоћу „Асистента за прорачун мерне несигурности“ у фази развоја која одговара агенту заснованом на моделу. У односу на једноставног рефлексног агента, дати агент поседује меморију у смислу одговарајуће базе података која служи за чување и обраду резултата Монте Карло симулација.

У првој симулацији, положаји сензора остају непромењени док локација ПП узима случајне вредности унутар разматраног простора. Да би се илустровала корелација максималне промене у резултату одређивања локације ПП и средње вредности удаљености ПП од акустичких сензора (l_{sr}), изабран је пример у коме су сензори постављени близу једне ивице разматраног простора у облику коцке (слика 7-8). Почетне позиције сензора су S_a (0,15 m, 0,00 m, 0,20 m), S_b (0,10 m, 0,00 m, 0,10 m), S_c (0,00 m, 0,07 m, 0,15 m) и S_d (0,00 m, 0,15 m, 0,15 m). Број Монте Карло симулација је $NMC=10000$.



Слика 7-8 Илустрација почетног положаја сензора S_a , S_b , S_c и S_d ; паралелопипед означен испрекиданом линијом, који укључује ПП са Δg_{max} мањим од 0,05 m за промену температуре од 40 °C, у првој симулацији [8]⁷.

За сваку Монте Карло симулацију, пет различитих температура је узето у обзир унутар алгоритма да би се израчунао ефекат промене температуре уља на тачност локализације ПП. На основу тога, укупан број итерација алгоритма је 50000. Приближно половина симулација даје валидан резултат. Резултати симулације су приказани на сликама 7-9 и 7-10 и укључују само валидне резултате за ПП која су удаљена од ивица разматране области у облику коцке за више од 0,03 m.

Максимално одступање резултата локализација ПП има максималну вредност од 0,30 m за $l_{sr}=0,51$ m и $\Delta T=40$ °C и минималну вредност од 0,00 m за $l_{sr} = 0,12$ m и $\Delta T = 10$ °C. Просечна вредност Δg_{max} је 0,09 m.



На основу резултата прве симулације приказаних на слици 7-9, максимално одступање резултата за одређивање локације ПП има ниже вредности за позиције ПП са нижим средњим растојањем између ПП и акустичких сензора, чак и за најшири опсег несигурности температуре минералног уља. На пример, за позиције ПП са средњим растојањем између сензора мањим од 0,20 m, максимално одступање резултата је мање од 0,05 m, чак и за температурни опсег несигурности од 40 °C. Постоји око 600 позиција ПП које испуњавају овај критеријум, а подручје које заузимају означено је непрекиданом линијом паралелограма са дужинама страница од 0,23 m, 0,22 m и 0,26 m на слици 7-8.

За опсег несигурности температуре од 10 °C, постоје позиције ПП са релативно великим средњим растојањем од акустичких сензора са максималним одступањем резултата мањим од 0,10 m. То није случај са опсег несигурности температуре од 40 °C, где се максимално одступање резултата повећава много брже са повећањем средњег растојања између ПП и акустичких сензора.

На слици 7-10 приказана је максимална процењена вредност коефицијента осетљивости температуре минералног уља, $\Delta g_{max}/\Delta T$, у зависности од средњег растојања између ПП и акустичких сензора и опсега несигурности температуре минералног уља. Максимална вредност датог коефицијента има вредност од 0,0228 m/°C за $l_{sr}=0,49$ m и $\Delta T=10$ °C. Просечна вредност датог коефицијента има вредност од 0,0042 m/°C.



Табела 13 Резултати прве симулације, вредности одговарајућих параметара.

Променљива	Вредност	l_{sr} [m]	ΔT [°C]
$\max(\Delta g_{max})$ [m]	0,30	0,51	40
$\min(\Delta g_{max})$ [m]	0,00	0,12	10
$\text{avg}(\Delta g_{max})$ [m]	0,09	—	—
$\max(\Delta g_{max}/\Delta T)$ [m/°C]	0,0228	0,49	10
$\text{avg}(\Delta g_{max}/\Delta T)$ [m/°C]	0,0042	—	—
$\max(l_{sr})$ [m]	0,83	—	—



Слика 7-9 Максимално одступање резултата за одређивање локације ПП Δg_{max} у зависности од средњег растојања између ПП и акустичких сензора l_{sr} и опсега несигурности температуре минералног уља ΔT , у првој симулацији [8]⁸.

⁸<https://creativecommons.org/licenses/by/4.0/>



Слика 7-10 Максимална процењена вредност коефицијента осетљивости температуре минералног уља, $\Delta g_{\max}/\Delta T$, у зависности од средњег растојања између ПП и акустичких сензора, l_{sr} и опсега мерне несигурности температуре минералног уља, ΔT , у првој симулацији [8]⁹.

На основу прорачунатих података у случају прве симулације израчунате су вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма за одговарајуће опсеге несигурности минералног уља (табела 14). Процена датог коефицијента осетљивости урађена је на основу средње вредности $\Delta g_{max}/\Delta T$. Дати начин процене не узима у обзир удаљеност акустичких сензора и положаја ПП, lsr .


Табела 14 Процењене вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма у случају прве симулације (процена коефицијента осетљивости је урађена на основу средње вредности на одговарајућем опсегу несигурности).

Променљива	Опсег несигурности температуре минералног уља [$^{\circ}\text{C}$]			
	10	20	30	40
$c_{Tmax} = \text{avg}(\Delta g_{max}/\Delta T)$ [$\text{m}/^{\circ}\text{C}$]	0,0054	0,0044	0,0037	0,0033
u_T [$^{\circ}\text{C}$]	$5/\sqrt{3}$	$10/\sqrt{3}$	$15/\sqrt{3}$	$20/\sqrt{3}$
$c_{Tmax} u_T$ [m]	0,01	0,02	0,03	0,03

У табели 15 и слици 7-11 приказане су минимална, максимална и средња вредност процењене вредности коефицијента осетљивости температуре минералног уља, $\Delta g_{max}/\Delta T$. Средња вредност датог коефицијента је ближа минималној вредности за све 4 вредности опсега несигурности температуре минералног уља, док је за вредности од 10°C и 20°C изразито ближа.

Табела 15 Минимална, максимална и средња вредност процењене вредности коефицијента осетљивости температуре минералног уља у случају прве симулације.

Променљива	Опсег несигурности температуре минералног уља [$^{\circ}\text{C}$]			
	10	20	30	40
$\min(\Delta g_{max}/\Delta T)$ [$\text{m}/^{\circ}\text{C}$]	0	0	0	0
$\max(\Delta g_{max}/\Delta T)$ [$\text{m}/^{\circ}\text{C}$]	0,0250	0,0146	0,0104	0,0081
$\text{avg}(\Delta g_{max}/\Delta T)$ [$\text{m}/^{\circ}\text{C}$]	0,0054	0,0044	0,0037	0,0033




Слика 7-11 Минимална, максимална и средња вредност процењене вредности коефицијента осетљивости температуре минералног уља у случају прве симулације.

У табели 16 и слици 7-12 приказане су минимална, максимална и средња вредност процењене вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма, $c_{T_{\max}} u_T$. Као у претходном случају, средња вредност датог доприноса је ближа минималној вредности за све 4 вредности опсега несигурности температуре минералног уља.

Табела 16 Минимална, максимална и средња вредност процењене вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма $c_{T_{\max}} u_T$ у случају прве симулације.

Променљива	Опсег несигурности температуре минералног уља [°C]			
	10	20	30	40
$\min(c_{T_{\max}} u_T)$ [m]	0	0	0	0
$\max(c_{T_{\max}} u_T)$ [m]	0,07	0,08	0,09	0,09
$\text{avg}(c_{T_{\max}} u_T)$ [m]	0,01	0,02	0,03	0,03



Слика 7-12 Минимална, максимална и средња вредност процењене вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма у случају прве симулације.

Типичан минималан број симулација потребан за Монте Карло анализу је 1000 [133]. У датој симулацији број Монте Карло симулација је био $NMC=10000$. Број симулација може значајно временски продужити извршење симулације, тако да је пожељно направити оптималан компромис између жељене прецизности резултата и броја симулација. У табели 17 је приказана просечна прорачуната вредност коефицијента осетљивости температуре минералног уља изражена са 4 значајне цифре у зависности од броја Монте Карло симулација. Симулације су извршаване на рачунару са 64-битним *Windows 10* оперативним системом, *Intel Core i7-8750H* процесором и 16 GB радне меморије.

Табела 17 Зависност прорачуна просечне вредности коефицијента осетљивости температуре минералног уља $\text{avg}(\Delta g_{\max}/\Delta T)$ изражене са 4 значајне цифре, од броја Монте Карло симулација NMC са одговарајућим временима извршавања симулације.


NMC	1000	10000	100000	1000000
$\text{avg}(\Delta g_{\max}/\Delta T)$ [m/°C]	0,0040	0,0042	0,0042	0,0042
Приближно време извршавања прве симулације [s]	7	57	538	5500

Као што се види из табеле 17, прецизност прорачуна $\text{avg}(\Delta g_{\max}/\Delta T)$ изражена са 4 значајне цифре се није побољшала коришћењем већег броја Монте Карло симулација од

10000, док се време извршавања прве симулације значајно повећало за приближно 10 и 100 пута. За дати ниво прецизности прорачуна $\text{avg}(\Delta g_{\text{max}}/\Delta T)$ и времена извршавања прве симулације, задовољавајућим се може сматрати коришћени број Монте Карло симулација од $NMC = 10000$.

7.1.3. Друга симулација

За другу симулацију изабрана је једна позиција ПП из прве симулације која има високу вредност максималног одступања резултата за одређивање локације ПП. На пример, изабрана је позиција ПП (0,05 m, 0,54 m, 0,14 m), која има средњу удаљеност од акустичких сензора од 0,49 m (слика 7-13). За ову позицију ПП, максимално одступање резултата се кретало од 0,19 m за опсег несигурности температуре од 10 °C до 0,28 m за опсег несигурности од 40 °C.




Слика 7-13 Илустрација позиције ПП (означеног са PD), почетне позиције сензора (S_a , S_b , S_c и S_d) и оптималне позиција сензора (S_a^* , S_d^* , S_c^* и S_d^*), у другој симулацији [8]¹⁰.

Затим су позиције сензора мењане на случајан начин, док је позиција ПП остала непромењена. Проблем са рандомизирањем положаја сензора на сличан начин као у првој симулацији јесте да два предуслова морају бити испуњена приликом постављања акустичких сензора. Прво, сензори не би требало да буду близу један другом. Друго, треба избегавати било какву симетрију у позиционирању ПП и акустичких сензора [15]. Да би се испунила ова два предуслова и избегло одбацивање великог броја појединачних симулација, користе се сличне позиције сензора онима из прве симулације као почетне позиције рандомизације. Дати положаји сензора су S_a (0,15 m, 0,60 m, 0,20 m), S_b (0,10 m, 0,60 m, 0,10 m), S_c (0,00 m, 0,07 m, 0,15 m) и S_d (0,00 m, 0,15 m, 0,15 m). Разлика у односу на прву симулацију је у томе што су сензори S_a и S_b сада постављени на наспрамни зид области у облику коцке (слика 7-13). Затим су положаји S_a и S_b насумично мењани дуж z осе задржавањем релативног растојања између сензора непромењеним и независно на исти начин за S_c и S_d дуж y осе. Број

Монте Карло симулација био је $NMC = 10000$. Резултати симулација приказани су на слици 7-14.

На пример, на слици 7-14, за позиције сензора са l_{sr} од 0,15 m, максимално одступање резултата за одређивање локације ПП креће се од 0,01 m за опсег несигурности температуре од 10 °C до 0,06 m за опсег несигурности од 40 °C. Овај резултат је значајно побољшање у односу на прву симулацију, које је постигнуто приближавањем акустичких сензора локацији ПП. На слици 7-13 дата акција је илустрована приказом почетних позиција сензора и нових (оптималних) положаја сензора: $S_a^*(0,15 \text{ m}, 0,60 \text{ m}, 0,24 \text{ m})$, $S_b^*(0,10 \text{ m}, 0,60 \text{ m}, 0,14 \text{ m})$, $S_c^*(0,00 \text{ m}, 0,32 \text{ m}, 0,15 \text{ m})$ и $S_d^*(0,00 \text{ m}, 0,40 \text{ m}, 0,15 \text{ m})$. За оптималну позицију, $l_{sr}=0,14 \text{ m}$, максимално одступање резултата за одређивање локације ПП креће се од 0,01 m за опсег несигурности температуре од 10 °C до 0,03 m за опсег несигурности од 40 °C. Максимална вредност l_{sr} у другој симулацији је 0,33 m.



Слика 7-14 Максимално одступање резултата за детекцију локације ПП Δg_{max} у другој симулацији у зависности од средњег растојања између ПП и АЕ сензора l_{sr} за опсег несигурности температуре (ΔT) од 10 °C и 40 °C [8]¹¹.

¹¹<https://creativecommons.org/licenses/by/4.0/>

Табела 18 Процењене вредности просечног доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма у случају друге симулације (укључујући и оптимални положај сензора)

Променљива	Опсег несигурности температуре минералног уља [°C]	
	10	40
$c_{Tmax} = \text{avg}(\Delta g_{max} / \Delta T)$ [m/°C]	0,0040	0,0016
u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
$c_{Tmax} u_T$ [m]	0,01	0,01

За оптималан положај сензора просечне вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма су значајно ниже од одговарајућих вредности почетног положаја који је узет из прве симулације.

Табела 19 Вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма за почетни и оптимални положај сензора у другој симулацији.

	Променљива	Опсег несигурности температуре минералног уља [°C]	
		10	40
Почетни положај сензора	c_{Tmax}	0,0190	0,0070
	u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
	$c_{Tmax} u_T$ [m]	0,05	0,08
Оптималан положај сензора	c_{Tmax}	0,0010	0,0007
	u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
	$c_{Tmax} u_T$ [m]	0,00	0,00

На основу резултата из Табеле 19 оптималан положај сензора има допринос температуре минералног уља буџету мерне несигурности неитеративног алгоритма за ред величине мањи од почетног положаја.


7.1.4. Додатне симулације

Узимајући у обзир да се у другој симулацији насумично бирају положаји акустичких сензора док положај ПП остаје непромењен може се симулирати конфигурација сензора из почетне симулације и одредити просечни допринос температуре минералног уља буџету мерне несигурности неитеративног алгоритма. Положај ПП у почетној симулацији је (0,30 m, 0,30 m, 0,48 m) док у овом случају положаји сензора се бирају насумично и могу се налазити на свим странама замишљене области облика коцке. Разматрани су регуларни положаји

сензора који су удаљени од ивица замишљене области за више од 0,03 m. Резултати симулације су приказани у Табели 20 и на слици 7-15.

Табела 20 Резултати почетне симулације, вредности одговарајућих параметара.

Променљива	$\Delta T=10\text{ }^{\circ}\text{C}$	$\Delta T=40\text{ }^{\circ}\text{C}$
$\max(\Delta g_{\max})\text{ [m]}$	0,42	0,40
$\min(\Delta g_{\max})\text{ [m]}$	0,00	0,00
$\text{avg}(\Delta g_{\max})\text{ [m]}$	0,04	0,06
$\min(l_{sr})\text{ [m]}$	0,16	
$\max(l_{sr})\text{ [m]}$	0,46	



Слика 7-15 Максимално одступање резултата за детекцију локације ПП $\Delta g_{\max}$ у почетној симулацији у зависности од средњег растојања између ПП и АЕ сензора l_{sr} за опсег несигурности температуре (ΔT) од 10 °C и 40 °C.

Обзиром на конфигурацију сензора и извора ПП у почетној симулацији, минимална средња вредност растојања на коју се могу поставити сензори у односу на ПП је 0,16 m, док је максимално средње растојање 0,46 m. График приказан на слици 7-15 се на први поглед визуелно значајно разликује од графика са слике 7-9 за прву симулацију и графика са слике 7-14 за другу симулацију.

У табели 21 приказане су просечне вредности средњег доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма у случају прве симулације за опсег l_{sr} од 0,16 m до 0,46 m и почетне симулације.

Табела 21 Просечне вредности средњег доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма у случају прве симулације за опсег l_{sr} од 0,16 m до 0,46 m и почетне симулације.

	Променљива	Опсег несигурности температуре минералног уља [°C]	
		10	40
Прва симулација за опсег l_{sr} од 0,16 m до 0,46 m	c_{Tmax} [m/°C]	0,0035	0,0022
	u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
	$c_{Tmax} u_T$ [m]	0,01	0,02
Почетна симулација	c_{Tmax} [m/°C]	0,0044	0,0017
	u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
	$c_{Tmax} u_T$ [m]	0,01	0,01

Резултати из табеле 21 показују да се процењене вредности c_{Tmax} разликују за мање од 0,001 m/°C (односно 0,0005 m/°C за $\Delta T=10$ °C и 0,0009 m/°C за $\Delta T=40$ °C) за две различите симулације, почетну (непромењен положај ПП) и прву симулацију (непромењен положај сензора) али за исти опсег l_{sr} . Доприноси температуре минералног уља буџету мерне несигурности неитеративног алгоритма се разликују за 0,00 m за $\Delta T=10$ °C и 0,01 m за $\Delta T=40$ °C.

У другој симулацији су разматране вредности l_{sr} до 0,33 m док су у првој разматране вредности до 0,83 m. У табели 22 приказане су вредности датог доприноса у случају прве симулације узимајући у обзир само положаје ПП са $l_{sr}<0,33$.

Табела 22 Процењене вредности средњег доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма у случају прве симулације за $l_{sr}<0,33$ m.

Променљива	Опсег несигурности температуре минералног уља [°C]	
	10	40
$c_{Tmax}=avg(\Delta g_{max}/\Delta T)$ [m/°C]	0,0015	0,0010
u_T [°C]	$5/\sqrt{3}$	$20/\sqrt{3}$
$c_{Tmax} u_T$ [m]	0,00	0,01

Из овога се може приметити да одређивање коефицијента осетљивости температуре минералног уља на основу просечне вредности, зависи од димензија области која се испитује тј. од максималне вредности разматраног l_{sr} . До сличних закључака дошло се и у истраживању приказаном у [134]. Зато је пожељно да се при процени датог коефицијента

узме у обзир и вредност просечног растојања ПП и акустичких сензора l_{sr} , што се може постићи применом метода машинског обучавања.

Претходне симулације су разматране за доњу границу опсега температуре минералног уља од 20 °C. У табели 23 приказане су процењене средње вредности коефицијента осетљивости температуре минералног уља у случају прве симулације али са доњим границама опсега температуре минералног уља од 40 °C и -10 °C (најшири разматрани опсег несигурности од 40 °C је остао непромењен тако да су максималне горње границе опсега температуре минералног уља 80 °C и 30 °C, респективно).


Табела 23 Упоредни приказ процењене средње вредности коефицијента осетљивости температуре минералног уља у случају прве симулације са различитим доњим границама опсега температуре минералног уља.

Променљива	Опсег несигурности температуре минералног уља (границе опсега) [°C]			
	10 (20°C,30°C)	20 (20°C,40°C)	30 (20°C,50°C)	40 (20°C,60°C)
$c_{Tmax}=avg(\Delta g_{max}/\Delta T)$ [m/°C]	0,0054	0,0044	0,0037	0,0033
	10 (40°C,50°C)	20 (40°C,60°C)	30 (40°C,70°C)	40 (40°C,80°C)
$c_{Tmax}=avg(\Delta g_{max}/\Delta T)$ [m/°C]	0,0052	0,0043	0,0037	0,0033
	10 (-10°C,0°C)	20 (-10°C,10°C)	30 (-10°C,20°C)	40 (-10°C,30°C)
$c_{Tmax}=avg(\Delta g_{max}/\Delta T)$ [m/°C]	0,0053	0,0045	0,0039	0,0034

На основу резултата из табеле 23 максимална разлика процењених средњих вредности коефицијента осетљивости температуре минералног уља у случају прве симулације за 3 различите доње границе опсега температуре минералног уља је 0,0002 m/°C.


7.2. Експериментална поставка

Експерименти су изведени у Електротехничком Институту Никола Тесла у Београду. Експериментална поставка се састојала од резервоара од нерђајућег челика димензија (0,60 m, 0,60 m, 0,65 m) испуњеног минералним уљем, рачунара опремљеног Пикоскоп 5444Д четвороканалном осцилоскопском картицом (енгл. *Picoscope 5444D Pico Technology, St Neots, United Kingdom*), прилагодне електронике, четири Повер Диагностик АС 75л пиезоелектрична ултразвучна сензора (енгл. *Power Diagnostix AS 75l, Power Diagnostix Systems GmbH, Aachen, Germany*) и извора корона ПП који је био причвршћен на крај металног метра (слике 7-16, 7-17 и 7-18).




Слика 7-16 Фотографија експерименталне поставке: (a) резервоар од нерђајућег челика испуњен минералним уљем; (b) Осцилоскопска картица Пикоскоп 5444Д; (c) прилагодна електроника; и (d) извор ПП причвршћен на крај металног метра уроњеног у минерално уље [8]¹².

У експериментима, време стицања акустичког сигнала на одговарајући сензор је одређивано ручно. Дата метода ручног одабирања може се користити у експериментима, али је непрактична за примену на терену [99]. Амплитуда шума је била релативно мала. Амплитуда индиректног сигнала је била релативно мала у поређењу са амплитудом директног сигнала. Јасно је био уочљив долазак јачег директног сигнала ПП. Директни сигнал се састојао од главних импулса од којих је први значајни негативни импулс биран за референтни импулс доласка акустичког сигнала на сензор [8].



Слика 7-17 Фотографија четири сензора Повер Диагностик АС 75л постављена на зид резервоара; сензори су подмазани уљем ради бољег приањања на зид резервоара (e); означени су претпостављени правци оса x , y и z [8]¹³.



Слика 7-18 Фотографија извора корона ПП (f) [8]¹³.

7.3. Експериментални резултати

У овом поглављу приказана је верификација резултата прве и друге софтверске симулације на реалном експерименталном моделу. Верификована је уочена појава да ПП која су релативно ближа (у околини) АЕ сензора имају мање максимално одступање резултата од удаљених ПП. Затим, верификовано је значајно смањење (за ред величине) вредности максималног коефицијента осетљивости температуре минералног уља које се може постићи померањем извора ПП из неоптималног у оптималан положај (ниже вредности средњег растојања ПП и АЕ сензора).

Због обима, део експерименталних резултата верификације резултата прве симулације приказан је у Прилогу 1. Експериментални резултати су показали сагласност са резултатима одговарајућих софтверских симулација.

7.3.1. Верификација резултата прве симулације

Експеримент је започет постављањем четири акустичка сензора на њихове номиналне позиције, које су биле исте као у првој симулацији (слика 7-8). Измерена температура минералног уља помоћу лабораторијског живиног термометра била је приближно 20 °С. Извор ПП је постављан на десет различитих позиција, које су одабране унутар области означене испрекиданим паралелопипедом на слици 7-8 ($\Delta g_{max} < 0,05$ m). За сваку од десет позиција ПП извршено је по десет мерења доласка акустичких сигнала на сензоре и израчунате су њихове просечне вредности и стандардне девијације. Резултати датих појединачних мерења су табеларно приказани у Прилогу 1. Затим су израчунате средње вредности Δg_{max} у одговарајућој функцији промене температуре (табела 24).

Табела 24 Експериментална верификација резултата прве симулације [8].

Бр.	Номиналне позиције ПП [m]			Средње измерене вредности [μ s]			Стандардна девијација [μ s]			$\Delta g_{max} (\Delta T[^\circ\text{C}])$ [m]			
	x	y	z	τ_{12}	τ_{13}	τ_{14}	σ_{12}	σ_{13}	σ_{14}	10	20	30	40
1	0,06	0,08	0,15	15,30	33,76	47,90	0,30	1,66	1,97	0,00	0,01	0,01	0,01
2	0,06	0,18	0,15	39,44	83,66	92,05	1,18	2,99	3,74	0,01	0,01	0,01	0,01
3	0,18	0,19	0,14	11,28	20,43	23,25	0,08	0,14	0,42	0,01	0,01	0,01	0,02
4	0,17	0,09	0,14	11,61	46,10	52,16	0,10	0,13	0,07	0,00	0,01	0,01	0,01
5	0,05	0,18	0,08	35,89	69,37	103,75	0,18	0,24	0,22	0,00	0,01	0,01	0,01
6	0,22	0,19	0,07	6,58	9,04	25,28	0,28	0,18	0,10	0,01	0,01	0,02	0,02
7	0,10	0,13	0,07	6,62	9,66	44,27	0,17	0,09	0,18	0,00	0,01	0,01	0,01
8	0,26	0,08	0,03	15,55	64,63	69,05	0,82	3,13	4,84	0,01	0,02	0,03	0,04
9	0,14	0,08	0,07	38,57	43,84	52,20	2,33	2,81	3,81	0,01	0,01	0,01	0,01
10	0,07	0,07	0,06	21,80	36,03	60,20	0,89	0,88	0,73	0,01	0,01	0,01	0,01

Резултати приказани у табели 24 показују да за позиције ПП постављене близу сензора, Δg_{max} узима вредност мању од 0,05 m (у опсегу од 0,00 m до 0,04 m) чак и за опсег несигурности температуре минералног уља од 40 °С. Дати експериментални резултати су у сагласности са резултатима прве симулације и показују да се флукуација промене максималног одступања резултата Δg_{max} смањује када се ПП постави у околини сензора (ниже вредности l_{sr}) [8].

7.3.2. Верификација резултата друге симулације

Експеримент је настављен тестирањем резултата друге симулације. Парцијално пражњење је постављено на позицију приказану на слици 7-13, док је позиција сензора остала непромењена. Затим, након мерења, сензори су померени у оптимални положај. За обе локације сензора извршено је десет мерења кашњења сигнала ПП на АЕ сензоре и израчунате су њихове просечне вредности и стандардне девијације. Дати резултати мерења су приказани у табелама од 25 до 30.

Табела 25 Резултати симулације бр. 1

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,15	0,15
S_2	0,00	0,07	0,15
S_3	0,10	0,00	0,10
S_4	0,15	0,00	0,20
ПП	0,05	0,54	0,14

Табела 26 Измерене вредности бр. 1

Измерене вредности			
Температура минералног уља [°C]	18		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	55,81	104,80	108,90
2	55,81	104,60	108,20
3	55,46	104,10	108,30
4	55,63	104,60	109,10
5	55,10	104,80	108,00
6	55,81	104,80	108,70
7	56,17	104,30	108,00
8	55,81	103,90	107,80
9	55,46	105,10	108,20
10	55,99	104,60	108,20
Средња вредност	55,70	104,56	108,34
Стандардна девијација	0,3042	0,3627	0,4221

Табела 27 Израчунате вредности бр. 1

Израчунате вредности на основу измерених вредности $\tau_{12}, \tau_{13}, \tau_{14}$									
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$	$\Delta g_{max}/\Delta T [m/^\circ C]$
20	0,06	0,47	0,15	1413	0,00	0,00	0,00	0,00	/
30	0,07	0,34	0,15	1374	0,01	0,13	0,00	0,13	0,0130
40	0,07	0,30	0,15	1337	0,02	0,17	0,00	0,17	0,0085
50	0,07	0,27	0,16	1301	0,02	0,20	0,01	0,20	0,0066

60	0,07	0,26	0,16	1266	0,02	0,21	0,01	0,21	0,0052
							Средња вредност		0,0083

Табела 28 Резултати симулације бр. 2

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,10	0,60	0,14
S_2	0,15	0,60	0,24
S_3	0,00	0,40	0,15
S_4	0,00	0,32	0,15
ПП	0,05	0,54	0,14

Табела 29 Измерене вредности бр. 2

Измерене вредности			
20			
Температура минералног уља [°C]			
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	18,54	35,76	84,56
2	17,83	33,45	82,08
3	18,01	33,45	82,25
4	17,66	33,27	81,72
5	17,66	31,32	80,66
6	18,19	30,79	80,12
7	18,37	33,63	82,43
8	18,37	33,81	82,43
9	18,37	33,10	82,08
10	18,01	31,32	80,48
Средња вредност	18,10	32,99	81,88
Стандардна девијација	0,3156	1,4789	1,2726

Табела 30 Израчунате вредности бр. 2

Израчунате вредности на основу измерених вредности $\tau_{12}, \tau_{13}, \tau_{14}$									
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$	$\Delta g_{max}/\Delta T [m/^\circ C]$
20	0,08	0,51	0,18	1413	0,00	0,00	0,00	0,00	/
30	0,08	0,50	0,17	1374	0,00	0,01	0,01	0,01	0,001
40	0,09	0,50	0,17	1337	0,01	0,01	0,01	0,01	0,0005
50	0,10	0,50	0,17	1301	0,02	0,01	0,01	0,02	0,0006
60	0,10	0,49	0,17	1266	0,02	0,02	0,01	0,02	0,0005
								Средња вредност	0,0006


Резултати у табелама 27 и 30 показују да су се вредности $\Delta g_{max}/\Delta T$ промениле са 0,0083 m/°C за сензоре постављене као у првој симулацији (неоптималан положај) на 0,0006 m/°C за сензоре у оптималном положају. Дати резултати су у сагласности са резултатима друге

софтверске симулације и показују значајно смањење (за ред величине) вредности максималног коефицијента осетљивости температуре минералног уља које се може постићи постављањем сензора у оптималну позицију (ниже вредности l_{sr}) [8].

7.4. Резултати тренирања, валидације и тестирања модела машинског обучавања

Тренирање, валидација и тестирање модела машинског обучавања извршено је помоћу „Асистента за прорачун мерне несигурности“ у фази развоја која одговара агенту заснованом на моделу са могућношћу обучавања.

Скуп података за обуку (тренирање) има један улазни параметар (карактеристику) и један излазни параметар (ознаку). Прво се обучавао модел код којег је средње растојање између ПП и акустичких сензора l_{sr} предвиђена вредност, док је температурни коефицијент осетљивости $c_T = c_{Tmax}$ карактеристика. За скуп података за обуку коришћен је скуп података из друге симулације у којој је разматрана површина у облику коцке испуњена минералним уљем са дужином стране од 0,60 m. Локација ПП је остала непромењена (0,05 m, 0,54 m, 0,14 m), док су позиције сензора биране насумично. Температурни коефицијент осетљивости је израчунат коришћењем максималне промене резултата за детекцију локације ПП Δg_{max} и промене температуре минералног уља ΔT , $c_T = \Delta g_{max} / \Delta T$. Разматрани подаци су за опсег несигурности температуре минералног уља од $\Delta T = 40$ °C. Карактеристике скупа података су визуализоване на слици 7-19, док су његова основна статистичка својства дата у Табели 31.



Слика 7-19 Визуализација карактеристика скупа података за обучавање [19]¹⁴.

Табела 31 Основна статистичка својства коришћеног скупа података [19].

Број података	1799	1799
	c_T [m/°C]	l_{sr} [m]
Средња вредност	0,0016	0,20
Стандардна девијација	0,0011	0,05
Минимум	0,0002	0,10
25%	0,0007	0,15
50%	0,0014	0,21
75%	0,0023	0,25
Максимум	0,0060	0,33


Као развојно окружење коришћен је *Microsoft Visual Studio Community 2019*. Време обуке је било 120 s на 64-битном *Windows 10* рачунару са *Intel Core i7-8750H* процесором и 16 GB радне меморије. Резултати обуке су представљени на слици 7-20.

Top 5 models explored							
	Trainer	RSquared	Absolute-loss	Squared-loss	RMS-loss	Duration	#Iteration
1	FastTreeRegression	0.7666	0.02	0.00	0.03	1.0	1
2	FastForestRegression	0.7658	0.02	0.00	0.03	1.3	2
3	FastForestRegression	0.7658	0.02	0.00	0.03	1.3	3
4	FastForestRegression	0.7658	0.02	0.00	0.03	1.7	4
5	FastForestRegression	0.7658	0.02	0.00	0.03	1.6	5

Слика 7-20 Резултати тренирања над скупом података из друге симулације за опсег несигурности температуре минералног уља ΔT од 40 °C употребом *ML.NET* програмског оквира при чему је предвиђена вредност l_{sr} [19]¹⁵.

Тренери су рангирани на основу вредности коефицијента детерминације R^2 . Тренер *FastTreeRegression* који имплементира ДАРТ алгоритам ($R^2=0,7666$) постигао је најбољи резултат. Други најбољи био је *FastForestRegression* тренер који имплементира алгоритам случајне шуме ($R^2=0,7658$). Предвиђања модела који имплементира ДАРТ алгоритам приказана су на слици 7-21.

¹⁵<https://creativecommons.org/licenses/by/4.0/>



Слика 7-21 Предвиђене вредности l_{sr} од стране модела који имплементира ДАРТ алгоритам (црвена боја); излазне вредности из скупа података за обуку (црна боја) [19]¹⁶.

Да би се израчунао допринос датог модела машинског обучавања буџету комбиноване мерне несигурности неитеративног алгоритма потребно је одредити максимални губитак L_I на разматраном скупу података. Програмски оквир *ML.NET* не укључује ову метрику у излазне резултате, па је додатно израчуната. Максимални L_I губитак датог модела на разматраном скупу података био је 0,1078 m.

Уз претпоставку дискретне униформне расподеле, стандардна мерна несигурност типа Б модела је $u_B=0,06$ m са степеном статистичке сигурности од 57,7%. Број предвиђања која нису ушла у стандардни интервал мерне несигурности био је 53, односно 2,9%. Додатно, израчуната је проширена мерна несигурност. За фактор проширења $\sqrt{3}$, $U_B \approx 0,11$ m, са степеном статистичке сигурности од 100%.

Претходни тренинг користио је све улазно-излазне парове. Следеће тренирање модела користило је 90% улазно-излазних парова (слика 7-22). Осталих 10% (180) насумично одабраних улазно-излазних парова коришћено је за процену израчунате стандардне мерне несигурности.

Top 5 models explored							
	Trainer	RSquared	Absolute-loss	Squared-loss	RMS-loss	Duration	#Iteration
1	FastTreeRegression	0.7640	0.02	0.00	0.03	0.9	1
2	FastForestRegression	0.7639	0.02	0.00	0.03	3.5	2
3	FastForestRegression	0.7639	0.02	0.00	0.03	3.5	3
4	FastTreeRegression	0.7612	0.02	0.00	0.03	0.7	4
5	LightGbmRegression	0.7611	0.02	0.00	0.03	0.8	5

Слика 7-22 Резултати тренирања над 90% скупом података [19]¹⁶.


Максимални губитак L_I модела обученог на 90% скупа података био је 0,1060 m, односно, $u_B=0,06$ m. Модел је коришћен за предвиђања у скупу података од 10%. Број предвиђања која нису ушла у стандардни интервал мерне несигурности у скупу 10% података био је 5, односно 2,7%, слично као у претходној случају [19].

У наредној симулацији је трениран модел машинског обучавања на истом скупу података али са замењеним местима карактеристике и ознаке у односу на претходни модел тј. c_T је вредност која се предвиђа на основу вредности l_{sr} .

Top 5 models explored							
	Trainer	RSquared	Absolute-loss	Squared-loss	RMS-loss	Duration	#Iteration
1	FastForestRegression	0.5106	0.00	0.00	0.00	5.0	1
2	FastForestRegression	0.5077	0.00	0.00	0.00	3.8	2
3	FastTreeTweedieRegression	0.5059	0.00	0.00	0.00	3.2	3
4	FastForestRegression	0.5057	0.00	0.00	0.00	2.2	4
5	FastForestRegression	0.5054	0.00	0.00	0.00	2.4	5

Слика 7-23 Резултати тренирања над скупом података из друге симулације за опсег несигурности температуре минералног уља ΔT од 40 °C употребом *ML.NET* програмског оквира при чему је предвиђена вредност c_T .

Тренер *FastForestRegression* који имплементира алгоритам случајне шуме ($R^2=0,5106$) постигао је најбољи резултат (слика 7-23). Предвиђања модела који имплементира алгоритам случајне шуме приказана су на слици 7-24.



Слика 7-24 Предвиђене вредности c_T од стране модела који имплементира алгоритам случајне шуме (црвена боја); излазне вредности из скупа података за обуку (црна боја).

Максимални L_I губитак модела био је 0,0036 m/°C, односно, уз претпоставку дискретне униформне расподеле, стандардна мерна несигурност типа Б модела је $u_B=0,0020$ m/°C. Број

предвиђања која нису ушла у стандардни интервал мерне несигурности био је 68, односно 3,7%.

У табели 32 су приказане вредности коефицијента осетљивости температуре минералног уља c_T за оптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40 °C. У датој табели приказане су вредност симулације датог коефицијента, процењена вредност на основу средње вредности и процењена вредност помоћу модела машинског обучавања.

Табела 32 Вредност симулације, процењена вредност на основу средње вредности и процењена вредност помоћу модела машинског обучавања c_T за оптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40°C.


Променљива	Вредност симулације	$\text{avg}(\Delta g_{\text{max}}/\Delta T)$	Одговарајући модел машинског обучавања
$c_T [\text{m}/^\circ\text{C}]$	0,0006	0,0016	$0,0007 \pm 0,0020$

У наредној симулацији је трениран модел машинског обучавања на скупу података који одговара првој симулацији, c_T је вредност која се предвиђа на основу вредности lsr .

	Trainer	RSquared	Absolute-loss	Squared-loss	RMS-loss	Duration	#Iteration
1	FastForestRegression	0.7534	0.00	0.00	0.00	4.4	1
2	FastForestRegression	0.7528	0.00	0.00	0.00	9.6	2
3	FastForestRegression	0.7523	0.00	0.00	0.00	5.1	3
4	FastForestRegression	0.7514	0.00	0.00	0.00	4.6	4
5	LightGbmRegression	0.7511	0.00	0.00	0.00	1.5	5

Слика 7-25 Резултати тренирања над скупом података за опсег несигурности температуре минералног уља од 40°C у случају прве симулације.

Тренер *FastForestRegression* који имплементира алгоритам случајне шуме ($R^2=0,7534$) постигао је најбољи резултат (слика 7-25). Предвиђања модела који имплементира алгоритам случајне шуме трениран на скупу података из прве симулације за опсег несигурности температуре уља од 40 °C приказана су на слици 7-26.



Слика 7-26 Предвиђене вредности c_T од стране модела који имплементира алгоритам случајне шуме (црвена боја); излазне вредности из скупа података за обуку (црна боја); скуп за обуку одговара првој симулацији за опсег несигурности температуре минералног уља од 40 °C.

Максимални L_I губитак модела био је 0,0037 m/°C, односно, уз претпоставку дискретне униформне расподеле, стандардна мерна несигурност типа Б модела је $u_B=0,0021$ m/°C. Број предвиђања која нису ушла у стандардни интервал мерне несигурности био је 83 од укупно 4897, односно 1,6%.

У табели 33 су приказане вредности коефицијента осетљивости температуре минералног уља c_T за неоптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40 °C. У датој табели приказане су вредност симулације датог коефицијента, процењена вредност на основу средње вредности и процењена вредност помоћу модела машинског обучавања обученог на подацима из прве симулације.

Табела 33 Вредност симулације, процењена вредност на основу средње вредности и процењена вредност помоћу модела машинског обучавања c_T за неоптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40 °C.

Променљива	Вредност симулације	$\text{avg}(\Delta g_{\text{max}}/\Delta T)$	Одговарајући модел машинског обучавања
$c_T [\text{m}/^\circ\text{C}]$	0,0062	0,0033	$0,0040 \pm 0,0022$

8. Анализа и дискусија добијених резултата

Резултати почетне симулације су указали да максимално одступање резултата одређивања локације ПП за разматране опсеге несигурности температуре минералног уља може значајно да варира (од 0,00 m до 0,11 m) за различите конфигурације ПП и сензора. Уочено је да са повећањем опсега несигурности температуре дато одступање брже расте за поједине конфигурације ПП и сензора. Дата симулација је указала да постоје такви међусобни положаји ПП и акустичких сензора за које неитеративни алгоритам не може да пружи решење (нерегуларни положаји). Додатно, посматрањем илустрација просторног распореда разматраних положаја акустичких сензора и ПП на тродимензионалном моделу разматране области, није уочена карактеристична разлика (правило) између нерегуларних и регуларних положаја. Иако су резултати почетне симулације изразито ограничени (разматрано је само 6 слободно изабраних конфигурација сензора и ПП) у погледу доношења било каквих закључака, дали су смернице за наставак предметног истраживања.

Резултати прве и друге симулације су за разлику од почетне симулације добијени Монте Карло методом тј. разматран је велики број (10000) конфигурација сензора и ПП. Како би се илустровала корелација између максималног одступања резултата при одређивању локације ПП Δg_{max} и средњег растојања ПП и акустичких сензора l_{sr} сензори су постављени ближе једној од ивица разматране области у облику коцке. Положаји ПП су бирани насумично. Добијени резултати су показали да за конфигурације сензора и ПП код којих је $l_{sr} < 0,20$ m, вредност Δg_{max} узима вредности мање од 0,05 m чак и за најширу разматрану вредност опсега несигурности температуре минералног уља ΔT од 40 °C. На слици 7-8 је илустрована област у којој се налазе ПП са датом особином где се може приметити да су дата ПП релативно близу (у околини) сензора. Са друге стране, за опсег несигурности ΔT од 10 °C, ПП са релативно великим средњим растојањем од акустичких сензора су имала вредности Δg_{max} мање од 0,10 m, за разлику од опсега ΔT од 40 °C где су вредности Δg_{max} расле значајно брже са повећањем l_{sr} (слика 7-9). За разматрани положај акустичких сензора у првој симулацији, узимајући у обзир регуларне конфигурације ПП и сензора, у табели 34 су приказане процењене средње вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма са релативним односом вредности димензије разматране области ($a=0,60$ m).

Табела 34 Процењене средње вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма за одговарајуће опсеге несигурности температуре минералног уља, са релативним односом вредности димензије разматране области ($a=0,60$ m), у случају прве симулације.

Променљива	Опсег несигурности температуре минералног уља ΔT [°C]			
	10	20	30	40
$c_{Tmax} u_T$ [m]	0,01	0,02	0,03	0,03
$(c_{Tmax} u_T)/a$ [%]	1,6	3,3	5,0	5,0

У другој симулацији да би се додатно указало на корелацију између l_{sr} и Δg_{max} изабрана је једна конфигурација сензора и ПП из прве симулације са релативно високом вредношћу максималног одступања резултата Δg_{max} (од 0,19 m за опсег несигурности температуре од 10 °C до 0,28 m за опсег несигурности од 40 °C) са циљем да се за дати положај ПП пронађу такви положаји акустичких сензора за које је максимално одступање резултата значајно ниже од почетног положаја. Положај ПП је остао непромењен док су положаји акустичких сензора

бирани насумично уз одговарајућа ограничења. Приближавањем сензора у околину ПП са l_{sr} мањим од 0,15 m, максимално одступање резултата за одређивање локације ПП се смањило на 0,01 m за опсег несигурности температуре од 10 °C и 0,06 m за опсег несигурности од 40 °C. Дато приближавање је смањило Δg_{max} за одговарајуће опсеге несигурности температуре минералног уља за ред величине у односу на почетни положај. Више међусобних положаја сензора има l_{sr} мање од 0,15 m, па је за илустрацију изабран један положај са $l_{sr}=0,14$ m (слика 7-13). У табели 19 су приказане одговарајуће вредности доприноса температуре минералног уља буџету мерне несигурности неитеративног алгоритма за почетни и оптималан положај ПП које јасно показују значајно смањења датог доприноса оптималног положаја ПП у односу на почетни.


Наредни корак у додатним симулацијама је био да се изврши додатни увид у почетну симулацију коришћењем Монте Карло методе. Положај ПП је узео вредности исте као у почетној симулацији док су положаји акустичких сензора бирани насумично и то тако да су сензори могли да заузимају положаје на свим страницама разматраног простора облика коцке. На слици 7-15 приказан је график Δg_{max} у зависности од средњег растојања између ПП и акустичких сензора l_{sr} за опсег несигурности температуре (ΔT) од 10 °C и 40 °C. Увидом у график са дате слике на први поглед је примећено да се он разликује од одговарајућих графика из претходних симулација. У датој симулацији вредности l_{sr} су биле у опсегу од 0,16 m до 0,46 m тако да се приступило поређењу резултата из прве симулације за исти опсег l_{sr} , који су приказани у Табели 21. Резултати су показали да се процењене вредности c_{Tmax} разликују за мање од 0,001 m/°C за поређене симулације, почетну (непромењен положај ПП) и прву симулацију (непромењен положај сензора) али за исти опсег l_{sr} . Овај резултат је додатно потврдио корелацију између l_{sr} и Δg_{max} односно c_{Tmax} . График са слике 7-15 се визуелно разликовао због разматраног опсега l_{sr} односно положаја ПП који није био близу ивица разматране области али то није довело до значајне разлике у просечној вредности c_{Tmax} у односу на прву симулацију за исти опсег l_{sr} .

Затим су се на сличан начин поредили резултати друге симулације код које је $l_{sr}<0,33$ m (табела 18) и резултати прве симулације за исту вредност l_{sr} (табела 22). Разлика у датим доприносима је 0,01 m. Слично као у претходном случају није било значајне разлике у датим доприносима за прву и другу симулацију за исти опсег l_{sr} .

Из овога се може приметити да одређивање коефицијента осетљивости температуре минералног уља на основу просечне вредности, зависи од димензија области која се испитује тј. од максималне вредности разматраног l_{sr} . Због уочене корелације између l_{sr} и Δg_{max} приступљено је процени датог коефицијента применом метода машинског обучавања које узима у обзир и l_{sr} при процени Δg_{max} , односно c_{Tmax} .

Резултати обучавања су показали унапређење (на основу вредности одговарајућих коефицијената детерминације R^2) у односу на прорачун средње вредности предвиђаних параметара (l_{sr} у првом и c_{Tmax} у другом и трећем случају) за више од 4, више од 2 и више од 4 пута респективно. У првом случају најбољи резултат је постигао ДАРТ алгоритам док је у другом и трећем случају алгоритам случајне шуме. У сва три случаја процењена је мерна несигурност одговарајућих модела машинског обучавања на основу поступка изложеног у поглављу 6 (0,06 m, 0,0020 m/°C и 0,0022 m/°C респективно).

На основу датих резултата на слици 8-1 илустрован је поступак за одређивање доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма применом методе машинског обучавања.



Слика 8-1 Илустрација корака при прорачуну (квантификацији) доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгорита применом методе машинског обучавања.

У случају да се таргетира одговарајући допринос температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгорита за место (област) појаве ПП у разматраном простору испуњеним минералним уљем, за одабир конфигурације сензора може се користити модел машинског обучавања код кога је l_{sr} предвиђена вредност (слика 7-21).

У табели 35 приказан је изглед реда у буџету комбиноване мерне несигурности неитеративног алгорита која одговара доприносу температуре минералног уља процењене

помоћу модела машинског обучавања за оптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40 °C.

Табела 35 Илустрација изгледа реда у буџету комбиноване мерне несигурности неитеративног алгоритма која одговара доприносу температуре минералног уља, процењене помоћу модела машинског обучавања за оптималан положај сензора у другој симулацији. Температурни коефицијент осетљивости је предвиђен помоћу модела машинског обучавања за $l_{sr}=0,14$ m. Опсег несигурности температуре минералног уља је 40 °C, модел је обучаван на скупу података код кога је опсег l_{sr} од 0,10 m до 0,33 m.

Променљива	Процена	Стандардно одступање	Расподела вероватноће	Коефицијент осетљивости	Допринос
Температура минералног уља, T	40 °C	$20/\sqrt{3}$ °C	Униформна	$0,0007\pm 0,0020$ m/°C	$0,00\pm 0,02$ m

У табели 36 приказан је изглед реда у буџету комбиноване мерне несигурности неитеративног алгоритма која одговара доприносу температуре минералног уља процењене помоћу модела машинског обучавања за неоптималан положај сензора у другој симулацији и опсег несигурности температуре минералног уља од 40 °C.

Табела 36 Илустрација изгледа реда у буџету комбиноване мерне несигурности неитеративног алгоритма која одговара доприносу температуре минералног уља, процењене помоћу модела машинског обучавања за неоптималан положај сензора у другој симулацији. Температурни коефицијент осетљивости је предвиђен помоћу модела машинског обучавања за $l_{sr}=0,49$ m. Опсег несигурности температуре минералног уља је 40 °C, модел је обучаван на скупу података из прве симулације код кога је опсег l_{sr} од 0,09 m до 0,82 m.

Променљива	Процена	Стандардно одступање	Расподела вероватноће	Коефицијент осетљивости	Допринос
Температура минералног уља, T	40 °C	$20/\sqrt{3}$ °C	Униформна	$0,0040\pm 0,0022$ m/°C	$0,04\pm 0,02$ m

Анализирајући резултате у табелама 35 и 36 јасно се уочава смањење доприноса буџету комбиноване мерне несигурности неитеративног алгоритма за оптималан положај ПП у односу на почетни (неоптималан) у другој симулацији.

Мерна вредност температуре (процена) у табелама 35 и 36 једнака је средњој вредности на разматраним опсезима температуре минералног уља у првој и другој симулацији. Резултати приказани у табели 23 показали су мале варијације у средњој вредности температурног коефицијента осетљивости (0,0002 m/°C) за 3 различита разматрана температурна опсега минералног уља. Дати резултат је у складу са зависношћу брзине акустичког сигнала од температуре минералног уља која је приближно линеарна (слика 3-6).

У светлу резултата предметног истраживања, да ли је оправдана препорука из доступне литературе која потиче из стандарда *IEEE C.57.127-2007* која упућује оператера (експерта) да занемари утицај промене температуре минералног уља при одређивању локације ПП акустичким методама? У реалним мерењима резултат локације ПП је тродимензионална област у којој се са одговарајућом вероватноћом налази тачан резултат мерења. Одређивање локације ПП је индикативно тј. резултат се може сматрати прихватљивим ако указује на област квара унутар опреме. Ако резултат мерења са укупном мерном несигурношћу која обухвата и друге утицаје осим температуре минералног уља даје довољно информација да указује на област где се ПП налази онда се може сматрати да се одговарајући доприноси

укупној мерној несигурности могу толерисати али се не смеју занемарити. Узимајући наведено у обзир а првенствено да је резултат индикативан за експерта, онда је у његовој надлежности да тумачи вредност доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма (заједно са осталим резултатима) који до сада у доступној литератури није био квантификован.

9. Закључак и смернице будућег истраживања

Приказана предметна истраживања из области примене вештачке интелигенције у изражавању мерне несигурности неитеративног алгоритма за акустичко лоцирање парцијалног пражњења у минералном уљу су довела до значајних резултата (доприноса) у областима вештачке интелигенције и метрологије. Такође, отворене су нове смернице за даља истраживања у областима поузданости модела машинског обучавања, изражавања мерне несигурности, унапређења дијагностичких метода локализације ПП у електроенергетској опреми и мониторинга електроенергетске опреме у оквиру ИоТ.

9.1. Закључак

Примена вештачке интелигенције односно машинског обучавања у области мерења и анализе при акустичком лоцирању парцијалног пражњења у минералном уљу доприноси унапређењу процеса квантификације комбиноване мерне несигурности неитеративног алгоритма. Примена предложеног метода изражавања мерне несигурности регресионог модела „на основу процене“ машинског обучавања, повећава поверење у резултате модела. Предложени поступци и резултати су, према доступној релевантној литератури, значајни доприноси у областима вештачке интелигенције и метрологије.

Допринос температуре минералног уља буџету комбиноване мерне несигурности може се квантификовати (проценити) коришћењем предложеног поступка (слика 8-1) за прорачун мерне несигурности неитеративног алгоритма и одговарајућег софтверског агента (употребом нумеричких, статистичких, Монте Карло и методе машинског обучавања). Контролисање и квантификовање доприноса температуре минералног уља комбинованој мерној несигурности неитеративног алгоритма побољшава поузданост резултата одређивања локације ПП. Такође, повећава поверење у одлуке о одржавању опреме у којој се минерално уље користи као изолациони материјал. У склопу тумачења резултата реалних мерења од стране експерта, дати допринос се може толерисати али се не сме занемарити (табела 34). Предложени поступак за квантификацију датог доприноса се може, на пример, користити као допуна препоруке из доступне литературе која потиче из стандарда *IEEE C.57.127-2007* о употреби константне вредности температуре минералног уља од 20 °C при прорачуну локације ПП.

Са аспекта доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма, за специфичан положај сензора постоје више и мање оптималне позиције ПП (и обрнуто) у разматраној области испуњеној минералним уљем облика коцке. Резултати симулација су показали значајно побољшање у доприносу температуре минералног уља комбинованој мерној несигурности неитеративног алгоритма за неоптималну позицију акустичких сензора и оптималну позицију акустичких сензора (Табеле 35 и 36). Дати допринос је мањи када су акустички сензори постављени релативно ближе (у околини) ПП (ниже вредности средњег растојања акустичких сензора и ПП). Овакав начин постављања акустичких сензора је такође повољан и са аспекта детекције (слабљења) акустичког сигнала. Показана корелација између средњег растојања акустичких сензора и ПП и максималног одступања резултата односно температурног коефицијента осетљивости минералног уља може се искористити за обучавање одговарајућег модела машинског обучавања.

Модел машинског обучавања је у процену температурног коефицијента осетљивости минералног уља укључио и вредност средњег растојања акустичких сензора и ПП насупрот тривијалног израчунавања средње вредности датог коефицијента у разматраној области. Употреба модела машинског обучавања на основу вредности одговарајућих коефицијената детерминације R^2 довела је до унапређења у одређивању вредности параметара (l_{sr} у првом и c_{Tmax} у другом и трећем случају) за више од 4, више од 2 и више од 4 пута респективно.

Додатно, употреба одговарајућег модела машинског обучавања је проузроковала нови извор мерне несигурности која потиче од самог модела. У предметном истраживању је предложен нови поступак („на основу процене“) за изражавање дате мерне несигурности користећи мерну несигурност типа Б и вредност максималног емпиријског губитка хипотезе на скупу за обучавање.

Сумирајући све добијене резултате, представљена је илустрација поступка (по корацима) за квантификацију доприноса температуре минералног уља буџету комбиноване мерне несигурности неитеративног алгоритма применом методе машинског обучавања (слика 8-1). Такође, у табелама 35 и 36 приказан је потенцијални изглед реда у буџету комбиноване мерне несигурности неитеративног алгоритма који одговара доприносу температуре минералног уља процењене помоћу модела машинског обучавања за одговарајућу конфигурацију сензора и ПП (I_{sf}) и опсег несигурности температуре минералног уља (ΔT).

Нова метода за одређивање мерне несигурности модела машинског обучавања „на основу процене“ која је представљена у предметном истраживању је једноставна за имплементацију и може се применити и на моделима који користе концепт великих података за обучавање. Ограничење предложене методе је то што је она применљива само у регресионим моделима надгледаног обучавања. Додатно, метода не узима у обзир друге изворе мерне несигурности типа Б модела МО, као што су неадекватно заокруживање одговарајућих вредности од стране модела МО, несигурност прорачуна процесорске јединице, мерну несигурност актуатора, сензора и сл.

Предметно истраживање је ограничено на разматрану област коцке испуњене минералним уљем димензије 0,60 m. Разматран је максимални температурни опсег несигурности минералног уља од 40 °C који у пракси може бити шири. Поред потврде на експерименталном моделу изазов је да се резултати истраживања провере и на електроенергетској опреми у погону.

С обзиром да је предметно истраживање по природи мултидисциплинарно тако и смернице будућег истраживања могу ићи у више смерова.

9.2. Смернице будућег истраживања

Будуће истраживање се може одвијати у више праваца. Први правац је унапређење постојећег софтверског решења кроз нове фазе развоја (аутоматизација извршавања корака, узимање у обзир препрека на које акустички сигнал може наићи у реалним условима експлоатације, шири опсег несигурности температуре минералног уља и сл.). Други правац је одређивање доприноса осталих параметара на буџет комбиноване мерне несигурности неитеративног алгоритма. Трећи правац, примена предложене методе процене мерне несигурности модела машинског обучавања на скупове великих података који су јавно доступни и поређење са резултатима из доступне литературе. Затим, примена предложеног решења у осталим методама за одређивање локације ПП као нпр. неитеративне акустичко-електричне методе, методе која користи пиезокерамичке сензоре или недавно предложене методе код које је довољно користити само један сензор и рачунарску симулацију за локализацију ПП. Резултати наведених истраживања и предложени поступак могу бити имплементирани у системе мониторинга електроенергетске опреме са циљем унапређења поузданости одређивања резултата локализације ПП у оквиру ИоТ.

ЛИТЕРАТУРА

- [1] X. J. Jing and A. F. Vakakis, "Exploring nonlinear benefits in engineering," *Mech. Syst. Signal Process.*, vol. 125, pp. 1–3, 2019, doi: 10.1016/j.ymssp.2019.01.059.
- [2] V. S. Poluzanski, U. D. Kovacevic, and B. D. Nikolic, "Algorithm for calculating influence of power transformer oil temperature change on the accuracy of all-acoustic non-iterative partial discharge localization," *FME Trans.*, vol. 46, no. 2, pp. 183–193, 2018, doi: 10.5937/fmet1802183P.
- [3] A. Hekmati and R. Hekmati, "Optimum acoustic sensor placement for partial discharge allocation in transformers," *IET Sci. Meas. Technol.*, vol. 11, no. 5, pp. 581–589, 2017, doi: 10.1049/iet-smt.2016.0417.
- [4] K. N. Khalid, M. N. K. H. Rohani, B. Ismail, M. Isa, C. C. Yii, and W. N. A. W. Muhammad, "Analysis of acoustic sensor placement for PD location in power transformer," *Turkish J. Electr. Eng. Comput. Sci.*, vol. 28, no. 3, pp. 1303–1313, 2020, doi: 10.3906/elk-1907-187.
- [5] O. El Mountassir, B. G. Stewart, A. J. Reid, and S. G. McMeekin, "Quantification of the performance of iterative and non-iterative computational methods of locating partial discharges using RF measurement techniques," *Electr. Power Syst. Res.*, vol. 143, pp. 110–120, 2017, doi: 10.1016/j.epsr.2016.10.036.
- [6] Q. Liu *et al.*, "UHF antenna array arrangement optimization for partial discharge direction finding in air-insulated substation based on phased array theory," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 24, no. 6, pp. 3657–3668, 2017, doi: 10.1109/TDEI.2017.006615.
- [7] C. P. Beura, M. Beltle, and S. Tenbohlen, "Positioning of UHF PD sensors on power transformers based on the attenuation of UHF signals," *IEEE Trans. Power Deliv.*, vol. 34, no. 4, pp. 1520–1529, 2019, doi: 10.1109/tpwr.2019.2909588.
- [8] V. Polužanski, N. Kartalović, and B. Nikolić, "Impact of Power Transformer Oil-Temperature on the Measurement Uncertainty of All-Acoustic Non-Iterative Partial Discharge Location," *Materials (Basel)*, vol. 14, no. 6, 2021, doi: 10.3390/ma14061385.
- [9] D. Antony and G. S. Punekar, "Noniterative method for combined acoustic-electrical partial discharge source localization," *IEEE Trans. Power Deliv.*, vol. 33, no. 4, pp. 1679–1688, 2018, doi: 10.1109/TPWRD.2017.2769159.
- [10] S. M. Markalous, S. Tenbohlen, and K. Feser, "Detection and location of partial discharges in power transformers using acoustic and electromagnetic signals," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 15, no. 6, pp. 1576–1583, 2008, doi: 10.1109/TDEI.2008.4712660.
- [11] R. Zhao, R. Yan, Z. Chen, K. Mao, P. Wang, and R. X. Gao, "Deep learning and its applications to machine health monitoring," *Mech. Syst. Signal Process.*, vol. 115, pp. 213–237, 2019, doi: 10.1016/j.ymssp.2018.05.050.
- [12] E. T. Norton, "Parameters affecting the velocity of sound in transformer oil," *IEEE Trans. Power Appar. Syst.*, vol. 103, no. 5, pp. 1111–1115, 1984, doi: 10.1109/TPAS.1984.318719.
- [13] "Power transformers. Temperature rise for liquid-immersed transformers," IEC 60076-2, 2011
- [14] PE/TR - Transformers, *IEEE guide for the detection, location and interpretation of sources of acoustic emissions from electrical discharges in power transformers and power reactors*. 2019. doi: 10.1109/IEEESTD.2019.8664690.
- [15] L. Zhou, J. Cai, J. Hu, G. Lang, L. Guo, and L. Wei, "A Correction-Iteration Method for Partial Discharge Localization in Transformer Based on Acoustic Measurement," *IEEE*

Trans. Power Deliv., vol. 36, no. 3, pp. 1571–1581, 2021, doi: 10.1109/TPWRD.2020.3011455.

- [16] S. Raychaudhuri, “Introduction to Monte Carlo simulation,” in *2008 Winter Simulation Conference*, Dec. 2008, pp. 91–100. doi: 10.1109/WSC.2008.4736059.
- [17] A. de Lataillade, S. Blanco, Y. Clergent, J. . Dufresne, M. El Hafi, and R. Fournier, “Monte Carlo method and sensitivity estimations,” *J. Quant. Spectrosc. Radiat. Transf.*, vol. 75, no. 5, pp. 529–538, Dec. 2002, doi: 10.1016/S0022-4073(02)00027-4.
- [18] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 3rd ed. Prentice Hall, 2010.
- [19] V. Polužanski, U. Kovacevic, N. Bacanin, T. A. Rashid, S. Stojanovic, and B. Nikolic, “Application of Machine Learning to Express Measurement Uncertainty,” *Appl. Sci.*, vol. 12, no. 17, 2022, doi: 10.3390/app12178581.
- [20] Z. Ullah, F. Al-Turjman, L. Mostarda, and R. Gagliardi, “Applications of Artificial Intelligence and Machine learning in smart cities,” *Comput. Commun.*, vol. 154, pp. 313–323, Mar. 2020, doi: 10.1016/J.COMCOM.2020.02.069.
- [21] R. H. Hariri, E. M. Fredericks, and K. M. Bowers, “Uncertainty in big data analytics: survey, opportunities, and challenges,” *J. Big Data*, vol. 6, no. 1, p. 44, 2019, doi: 10.1186/s40537-019-0206-3.
- [22] I. H. Sarker, “Machine Learning: Algorithms, Real-World Applications and Research Directions,” *SN Comput. Sci.*, vol. 2, no. 3, p. 160, 2021, doi: 10.1007/s42979-021-00592-x.
- [23] M. K. Shende, S. Q. Salih, N. D. Bokde, M. Scholz, A. Y. Oudah, and Z. M. Yaseen, “Natural Time Series Parameters Forecasting: Validation of the Pattern-Sequence-Based Forecasting (PSF) Algorithm; A New Python Package,” *Appl. Sci.*, vol. 12, no. 12, 2022, doi: 10.3390/app12126194.
- [24] T. Siddique, M. S. Mahmud, A. M. Keese, C. M. Ngwira, and H. Connor, “A Survey of Uncertainty Quantification in Machine Learning for Space Weather Prediction,” *Geosciences*, vol. 12, no. 1, 2022, doi: 10.3390/geosciences12010027.
- [25] T. Siddique and M. S. Mahmud, “Classification of fNIRS Data Under Uncertainty: A Bayesian Neural Network Approach,” in *2020 IEEE International Conference on E-health Networking, Application & Services (HEALTHCOM)*, 2021, pp. 1–4. doi: 10.1109/HEALTHCOM49281.2021.9398971.
- [26] W. E. Walker *et al.*, “Defining Uncertainty: A Conceptual Basis for Uncertainty Management in Model-Based Decision Support,” *Integr. Assess.*, vol. 4, no. 1, pp. 5–17, 2003, doi: 10.1076/iaij.4.1.5.16466.
- [27] M. Van Asselt and J. Rotmans, “Uncertainty in integrated assessment modelling,” *Clim. Change*, vol. 54, no. 1, pp. 75–105, 2002.
- [28] M. Cox and A. O’Hagan, “Meaningful expression of uncertainty in measurement,” *Accredit. Qual. Assur.*, vol. 27, no. 1, 2022, doi: 10.1007/s00769-021-01485-5.
- [29] D. Yu, J. Wu, W. Wang, and B. Gu, “Optimal performance of hybrid energy system in the presence of electrical and heat storage systems under uncertainties using stochastic p-robust optimization technique,” *Sustain. Cities Soc.*, vol. 83, p. 103935, Aug. 2022, doi: 10.1016/J.SCS.2022.103935.
- [30] G. Fangjie, G. Jianwei, Z. Yi, H. Ningbo, and W. Haoyu, “Community decision-makers’ choice of multi-objective scheduling strategy for integrated energy considering multiple uncertainties and demand response,” *Sustain. Cities Soc.*, vol. 83, p. 103945, Aug. 2022, doi: 10.1016/J.SCS.2022.103945.

- [31] Q. Yan *et al.*, “Many-objective charging optimization for electric vehicles considering demand response and multi-uncertainties based on Markov chain and information gap decision theory,” *Sustain. Cities Soc.*, vol. 78, p. 103652, Mar. 2022, doi: 10.1016/J.SCS.2021.103652.
- [32] V. Volodina and P. Challenor, “The importance of uncertainty quantification in model reproducibility,” *Philos. Trans. R. Soc. A Math. Phys. Eng. Sci.*, vol. 379, no. 2197, p. 20200071, 2021, doi: 10.1098/rsta.2020.0071.
- [33] D. Levi, L. Gispan, N. Giladi, and E. Fetaya, “Evaluating and Calibrating Uncertainty Prediction in Regression Tasks,” *Sensors*, vol. 22, no. 15, 2022, doi: 10.3390/s22155540.
- [34] C. Pires, M. Barandas, L. Fernandes, D. Folgado, and H. Gamboa, “Towards Knowledge Uncertainty Estimation for Open Set Recognition,” *Mach. Learn. Knowl. Extr.*, vol. 2, no. 4, pp. 505–532, 2020, doi: 10.3390/make2040028.
- [35] G. Fotis, V. Vita, and L. Ekonomou, “Machine Learning Techniques for the Prediction of the Magnetic and Electric Field of Electrostatic Discharges,” *Electronics*, vol. 11, no. 12, 2022, doi: 10.3390/electronics11121858.
- [36] A. Heidari, N. J. Navimipour, and M. Unal, “Applications of ML/DL in the management of smart cities and societies based on new trends in information technologies: A systematic literature review,” *Sustain. Cities Soc.*, vol. 85, p. 104089, Oct. 2022, doi: 10.1016/J.SCS.2022.104089.
- [37] A. Heidari, N. Jafari Navimipour, M. Unal, and S. Toumaj, “The COVID-19 epidemic analysis and diagnosis using deep learning: A systematic literature review and future directions,” *Comput. Biol. Med.*, vol. 141, p. 105141, Feb. 2022, doi: 10.1016/J.COMPBIOMED.2021.105141.
- [38] G. Fotis, V. Vita, and T. I. Maris, “Rise Time and Peak Current Measurement of ESD Current from Air Discharges with Uncertainty Calculation,” *Electronics*, vol. 11, no. 16, 2022, doi: 10.3390/electronics11162507.
- [39] Uroš Kovačević, “Izražavanje merne nesigurnosti kapacitivnih razdelnika napona sa koncentrisanim parametrima u oblasti visokih frekvencija,” Fakultet tehničkih nauka, Univerzitet u Novom Sadu, Novi Sad, 2017.
- [40] P. . Osmokrović, K. . Stanković, and M. Vujisić, *Merna nesigurnost*. Akademska misao, 2009.
- [41] Kartalović N., Kovačević U., and Stanković K., *Izražavanje merne nesigurnosti merenja brzih naponskih talasa*. Beograd: Elektrotehnički institut Nikola Tesla, 2018.
- [42] ISO, “Guide to the Expression of Uncertainty in Measurement,” 2008.
- [43] Maja Đ Grbić, “Metodologija za ocenu izloženosti ljudi električnom i magnetskom polju nadzemnih elektroenergetskih vodova, zasnovana na rezultatima merenja i proračuna,” Univerzitet u Beogradu, Elektrotehnički fakultet, Beograd, 2021.
- [44] A. Kovacevic, D. Despotovic, Z. Rajovic, K. Stankovic, A. Kovacevic, and U. Kovacevic, “Uncertainty evaluation of the conducted emission measurements,” *Nucl. Technol. Radiat. Prot.*, vol. 28, no. 2, pp. 182–190, 2013, doi: 10.2298/NTRP1302182K.
- [45] S. R. R. da Costa, F. S. G. Ribeiro, M. T. Salles, R. B. Endre, and others, “EA-4/02 Expression of the Uncertainty of Measurement in Calibration,” 1999.
- [46] “Guidance Notes EL 001: Guidelines on the Evaluation and Expression of Measurement Uncertainty for Electrical Testing Field.” Singapore Accreditation Council, Singapore, 2019.
- [47] A. Kovacevic, A. Kovacevic, K. Stankovic, and U. Kovacevic, “The combined method for

uncertainty evaluation in electromagnetic radiation measurement,” *Nucl. Technol. Radiat. Prot.*, vol. 29, no. 4, pp. 279–284, 2014, doi: 10.2298/NTRP1404279K.

- [48] Ćirović N., *Numerička matematika*. Beograd: Elektrotehnički fakultet Univerziteta u Beogradu, 2018.
- [49] Osmokrović P., *Elektrotehnički materijali*. Akademski misao, 2003.
- [50] N. Kartalovic, K. Stankovic, and B. Loncar, “Numerical modeling of partial discharges parameters,” *Tehnika*, vol. 71, no. 3, pp. 423–430, 2016, doi: 10.5937/tehnika1603423K.
- [51] E. Rusinski, J. Czmochocki, P. Moczko, and D. Pietrusiak, “Challenges and strategies of long-life operation and maintenance of technical objects,” *FME Trans.*, vol. 44, no. 3, pp. 219–228, 2016, doi: 10.5937/fmet1603219R.
- [52] D. Kovacevic, S. Skundric, and J. Lukic, “Monitoring and diagnostics of power transformer insulation,” *Therm. Sci.*, vol. 10, no. 4, pp. 43–54, 2006, doi: 10.2298/TSCI0604043K.
- [53] S. Strachan, S. Rudd, S. McArthur, M. Judd, S. Meijer, and E. Galski, “Knowledge-based diagnosis of partial discharges in power transformers,” *IEEE Trans. Dielectr. Electr. Insul.*, vol. 15, no. 1, pp. 259–268, 2008, doi: 10.1109/T-DEI.2008.4446759.
- [54] Osmokrović P. and Kartalović N., “Applicability of simple expressions for electrical breakdown probability increase in vacuum and gas,” *IEEE Trans. Power Syst.*, vol. 12, no. 4, pp. 1455–1460, 1997.
- [55] R. Hancox and H. Tropper, “The breakdown of transformer oil under impulse voltages,” 1958.
- [56] IEC 60270, “*High-voltage test techniques – Partial discharge measurements*”. 1986. doi: 10.1007/s00104-005-1047-5.
- [57] Prasanta Kundu, N.K. Kishore, and A.K. Sinha, “Classification of Acoustic Emission Based Partial Discharge in Oil Pressboard Insulation System Using Wavelet Analysis,” *Int. J. Electr. Comput. Eng.*, vol. 2, no. 10, pp. 2355–2362, 2008.
- [58] S. Kumar, P. Gupta, A. Venkatasami, and K. Udayakumar, “Design parameter based method of partial discharge detection and location in power transformers,” *Serbian J. Electr. Eng.*, vol. 6, no. 2, pp. 253–265, 2009, doi: 10.2298/SJEE0902253K.
- [59] J. Posada-Roman, J. A. Garcia-Souto, and J. Rubio-Serrano, “Fiber Optic Sensor for Acoustic Detection of Partial Discharges in Oil-Paper Insulated Electrical Systems,” *Sensors*, vol. 12, no. 4, pp. 4793–4802, Apr. 2012, doi: 10.3390/s120404793.
- [60] “High voltage test techniques – Measurement of partial discharges by electromagnetic and acoustic methods,” *IEC TS 62478*. 2016.
- [61] T. Y. Ji, W. H. Tang, and Q. H. Wu, “Partial discharge location using a hybrid transformer winding model with morphology-based noise removal,” *Electr. Power Syst. Res.*, vol. 101, pp. 9–16, Aug. 2013, doi: 10.1016/J.EPSR.2013.03.003.
- [62] H. M. Muhr and CIGRE WG D1.33, *Guide for Electrical Partial Discharge Measurements in compliance to IEC 60270*, vol. 366. ., 2008.
- [63] H. H. Sinaga, B. T. Phung, and T. Blackburn, “Recognition of single and multiple partial discharge sources in transformers based on ultra-high frequency signals,” *Iet Gener. Transm. Distrib.*, vol. 8, pp. 160–169, 2014.
- [64] R. Sarathi, A. J. Reid, and M. D. Judd, “Partial discharge study in transformer oil due to particle movement under DC voltage using the UHF technique,” *Electr. Power Syst. Res.*, vol. 78, no. 11, pp. 1819–1825, Nov. 2008, doi: 10.1016/J.EPSR.2008.03.022.

- [65] H. Qiang, Q. Wang, H. Niu, Z. Wang, and J. Zheng, "A Partial Discharge Localization Method Based on the Improved Artificial Fish Swarms Algorithm," *Energies*, vol. 16, no. 6, p. 2928, Mar. 2023, doi: 10.3390/en16062928.
- [66] J. Ramírez-Niño and A. Pascacio, "Acoustic measuring of partial discharge in power transformers," *Meas. Sci. Technol.*, vol. 20, no. 11, p. 115108, Nov. 2009, doi: 10.1088/0957-0233/20/11/115108.
- [67] Phung H, Blackburn TR, and Liu Z, "Acoustic Measurements of Partial Discharge Signals," *J. Electr. Electron. Eng.*, vol. 21, pp. 41–48, 2001.
- [68] O. Santos Filho, S. Zaghetto, and G. Pereira, "Case Studies of Electric Power Equipment Diagnostics Using Acoustic Emission," in *17th World Conference on Nondestructive Testing*, Oct. 2008, pp. 25–28.
- [69] P. Kundu, N. K. Kishore, and A. K. Sinha, "A non-iterative partial discharge source location method for transformers employing acoustic emission techniques," *Appl. Acoust.*, vol. 70, no. 11–12, pp. 1378–1383, 2009, doi: 10.1016/j.apacoust.2009.07.001.
- [70] W. Sikorski and W. Ziomek, "Detection, recognition and location of partial discharge sources using acoustic emission method," in *Acoustic Emission*, London, UK: IntechOpen, 2012, pp. 49–74. doi: 10.5772/31394.
- [71] M. MacAlpine, Z. Zhiqiang, and M. S. Demokan, "Development of a fibre-optic sensor for partial discharges in oil-filled power transformers," *Electr. Power Syst. Res.*, vol. 63, no. 1, pp. 27–36, Aug. 2002, doi: 10.1016/S0378-7796(02)00091-3.
- [72] W. Sikorski, "Active Dielectric Window: A New Concept of Combined Acoustic Emission and Electromagnetic Partial Discharge Detector for Power Transformers," *Energies*, vol. 12, no. 1, p. 115, Dec. 2018, doi: 10.3390/en12010115.
- [73] S. Coenen and S. Tenbohlen, "Location of PD sources in power transformers by UHF and acoustic measurements," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 19, no. 6, pp. 1934–1940, Dec. 2012, doi: 10.1109/TDEI.2012.6396950.
- [74] R. Pietsch *et al.*, *High-Voltage On-Site Testing with Partial Discharge Measurement*, vol. 502. , 2012.
- [75] E. Gulski *et al.*, "Guidelines for Unconventional Partial Discharge Measurements." 2009.
- [76] B. Danouj, S. A. Tahan, E. David, and M. Lotfi, "Partial discharges location in power transformers using piezoceramic sensors," *Int. J. Electr. Comput. Eng.*, vol. 11, no. 3, pp. 1942–1950, 2021, doi: 10.11591/ijece.v11i3.pp1942-1950.
- [77] V. B. Rathod, G. B. Kumbhar, and B. R. Bhalja, "Performance analysis of acoustic sensors based time reversal technique for partial discharge localization in power transformers," *Electr. Power Syst. Res.*, p. 108965, Nov. 2022, doi: 10.1016/J.EPSR.2022.108965.
- [78] J. Jia *et al.*, "Acoustic-Electrical Joint Localization Method of Partial Discharge in Power Transformer Considering Multi-Path Propagation Impact," *Front. Energy Res.*, vol. 10, Apr. 2022, doi: 10.3389/fenrg.2022.851299.
- [79] M. Beltle, M. Siegel, and S. Tenbohlen, "Investigations of in-oil Methods for PD Detection and Vibration Measurement," in *Conference: International Symposium on High Voltage Engineering*, Aug. 2013.
- [80] Iva Salom *et al.*, "Laboratory Experimental System for Examination of Acoustic Emission Generated by Partial Discharges," *Telfor J.*, vol. 5, no. 2, pp. 134–139, 2013.
- [81] X. Tan, X. Hu, and Y. Lu, "PD detection and localisation by acoustic measurements in an oil-filled transformer," *IEE Proc. - Sci. Meas. Technol.*, vol. 147, no. 2, pp. 81–85, Mar.

2000, doi: 10.1049/ip-smt:20000223.

- [82] S. M. Markalous and K. Feser, "All-acoustic PD measurements of oil/paper-insulated transformers for PD-localization," in *Scientific Papers of the Institute of Electrical Engineering Fundamentals of Wroclaw Technical University Conferences*, 2004, no. 40, pp. 106–112.
- [83] G. S. Kil, I. K. Kim, D. W. Park, S. Y. Choi, and C. Y. Park, "Measurements and analysis of the acoustic signals produced by partial discharges in insulation oil," *Curr. Appl. Phys.*, vol. 9, no. 2, pp. 296–300, 2009, doi: 10.1016/j.cap.2008.01.018.
- [84] G. F. C. Veloso, L. E. Borges Da Silva, G. Lambert-Torres, and J. O. P. Pinto, "Localization of partial discharges in transformers by the analysis of the acoustic emission," in *IEEE International Symposium on Industrial Electronics*, 2006, pp. 537–541. doi: 10.1109/ISIE.2006.295515.
- [85] H. L. Liu, "Acoustic partial discharge localization methodology in power transformers employing the quantum genetic algorithm," *Appl. Acoust.*, vol. 102, pp. 71–78, 2016, doi: 10.1016/j.apacoust.2015.08.011.
- [86] H. L. Liu and H. D. Liu, "Partial discharge localization in power transformers based on the sequential quadratic programming-genetic algorithm adopting acoustic emission techniques," *EPJ Appl. Phys.*, vol. 68, no. 1, pp. 1–16, 2014, doi: 10.1051/epjap/2014140318.
- [87] L. Tang, R. Luo, M. Deng, and J. Su, "Study of partial discharge localization using ultrasonics in power transformer based on particle swarm optimization," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 15, no. 2, pp. 492–495, 2008, doi: 10.1109/TDEI.2008.4483469.
- [88] T. Boczar, S. Borucki, A. Cichoń, and D. Zmarzły, "Application possibilities of artificial neural networks for recognizing partial discharges measured by the acoustic emission method," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 16, no. 1, pp. 214–223, 2009, doi: 10.1109/TDEI.2009.4784570.
- [89] C. C. Kuo, "Artificial recognition system for defective types of transformers by acoustic emission," *Expert Syst. Appl.*, vol. 36, no. 7, pp. 10304–10311, 2009, doi: 10.1016/j.eswa.2009.01.046.
- [90] K. C. Meka, A. V. Giridhar, and D. V. S. S. Siva Sarma, "PD source location utilizing acoustic TDOA signals in power transformer by fuzzy adaptive Particle Swarm Optimization," *Radioengineering*, vol. 27, no. 4, pp. 1119–1127, 2018, doi: 10.13164/re.2018.1119.
- [91] M. K. Chakravarthi, A. V. Giridhar, and D. V. S. S. S. Sarma, "Localization of partial discharge source in power transformer using bat algorithm," in *2017 7th International Conference on Power Systems, ICPS 2017*, 2018, pp. 382–385. doi: 10.1109/ICPES.2017.8387324.
- [92] K. J. Moore, M. Kurt, M. Eriten, D. M. McFarland, L. A. Bergman, and A. F. Vakakis, "Direct detection of nonlinear modal interactions from time series measurements," *Mech. Syst. Signal Process.*, vol. 125, pp. 311–329, 2019, doi: <https://doi.org/10.1016/j.ymssp.2017.09.010>.
- [93] C. Wei, K. Zhang, C. Hu, Y. Wang, H. Taghavifar, and X. Jing, "A tunable nonlinear vibrational energy harvesting system with scissor-like structure," *Mech. Syst. Signal Process.*, vol. 125, pp. 202–214, 2019, doi: <https://doi.org/10.1016/j.ymssp.2018.06.007>.
- [94] T. Yang, Q. Cao, and Z. Hao, "A novel nonlinear mechanical oscillator and its application in vibration isolation and energy harvesting," *Mech. Syst. Signal Process.*, vol. 155, p. 107636, 2021, doi: <https://doi.org/10.1016/j.ymssp.2021.107636>.

- [95] B. Castro *et al.*, “Partial discharge monitoring in power transformers using low-cost piezoelectric sensors,” *Sensors (Switzerland)*, vol. 16, no. 8, 2016, doi: 10.3390/s16081266.
- [96] S. Bancroft, “An algebraic solution of the GPS equations,” *IEEE Trans. Aerosp. Electron. Syst.*, vol. 21, pp. 56–59, 1985, doi: 10.1109/TAES.1985.310538.
- [97] I. Bua-Nunez, J. E. Posada-Roman, J. Rubio-Serrano, and J. A. Garcia-Souto, “Instrumentation System for Location of Partial Discharges Using Acoustic Detection With Piezoelectric Transducers and Optical Fiber Sensors,” *IEEE Trans. Instrum. Meas.*, vol. 63, no. 5, pp. 1002–1013, May 2014, doi: 10.1109/TIM.2013.2286891.
- [98] I. B. Nunez, J. E. P. Roman, J. R. Serrano, and J. A. Garcia-Souto, “Multichannel acquisition system and denoising for the detection and location of partial discharges using acoustic emissions,” in *2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, May 2013, pp. 1135–1140. doi: 10.1109/I2MTC.2013.6555591.
- [99] Y. B. Wang *et al.*, “Arrival time estimation methodology for partial discharge acoustic signals in power transformers based on a double-threshold technique,” *Meas. Sci. Technol.*, vol. 30, no. 2, 2019, doi: 10.1088/1361-6501/aaf554.
- [100] Y. Wang *et al.*, “Partial discharge localisation methodology for power transformers based on improved acoustic propagation route search algorithm,” *IET Sci. Meas. Technol.*, vol. 12, no. 8, pp. 1023–1030, Nov. 2018, doi: 10.1049/iet-smt.2018.5092.
- [101] Velinka Pejović, *Hemija u elektroenergetici-transformatorska ulja*. Beograd: Elektrotehnički institut Nikola Tesla, 2005.
- [102] D. Mihajlovic, V. Ivancevic, V. Vasovic, and J. Lukic, “Cellulose Degradation and Transformer Fault Detection by the Application of Integrated Analyses of Gases and Low Molecular Weight Alcohols Dissolved in Mineral Oil,” *Energies*, vol. 15, no. 15, p. 5669, Aug. 2022, doi: 10.3390/en15155669.
- [103] J. Jankovic, J. Lukic, J. Planojevic, D. Kolarski, and D. Janackovic, “Application of Highly Selective Adsorbent in the Removal of Elemental Sulfur and Other Corrosive Sulfur Compounds From Mineral Insulating Oils,” *IEEE Trans. Dielectr. Electr. Insul.*, vol. 29, no. 1, pp. 54–61, Feb. 2022, doi: 10.1109/TDEI.2022.3148479.
- [104] M. Rafiq, M. Shafique, A. Azam, M. Ateeq, I. A. Khan, and A. Hussain, “Sustainable, renewable and environmental-friendly insulation systems for high voltages applications,” *Molecules*, vol. 25, no. 17, 2020, doi: 10.3390/molecules25173901.
- [105] Darko M Knežević and Zdravko Milovanovic, “Analysis of Changes of Bulk Modulus of Mineral Oil- Effects on the Dynamic behavior od hydraulic Actuators,” in *12th International Conference on Tribology*, 2011.
- [106] Q. Jane Wang and Y.-W. Chung, Eds., *Encyclopedia of Tribology*. Springer US, 2013. doi: 10.1007/978-0-387-92897-5.
- [107] R. R. Meena, S. H. Chaki, and M. P. Deshpande, “Thermo-acoustic study of transformer oils through ultrasonic technique,” *Pet. Sci. Technol.*, vol. 38, no. 5, pp. 493–500, Mar. 2020, doi: 10.1080/10916466.2020.1739708.
- [108] A. V. Konoshenko and E. V. Shvedova, “Study of Dependence of Nonlinear Acoustic Parameter in Transformer Oil on Medium Temperature,” in *2019 International Russian Automation Conference (RusAutoCon)*, Sep. 2019, pp. 1–5. doi: 10.1109/RUSAUTOCON.2019.8867758.
- [109] Ake Carlson, Jitka Fuhr, Gottfried Schemel, and Franz Wegscheide, *Testing of Power Transformers*, 1st ed. Düsseldorf: Pro Print GmbH for ABB, 2003.
- [110] R. Chellappa, S. Theodoridis, and A. Van Schaik, “Advances in Machine Learning and Deep

Neural Networks,” *Proc. IEEE*, vol. 109, no. 5, pp. 607–611, 2021, doi: 10.1109/JPROC.2021.3072172.

- [111] S. Pokorni, “Current state of the application of artificial intelligence in reliability and maintenance,” *Vojnoteh. Glas.*, vol. 69, no. 3, pp. 578–593, 2021, doi: 10.5937/vojtehg69-30434.
- [112] P. P. Shinde and S. Shah, “A Review of Machine Learning and Deep Learning Applications,” in *Proceedings - 2018 4th International Conference on Computing, Communication Control and Automation, ICCUBEA 2018*, 2018. doi: 10.1109/ICCUBEA.2018.8697857.
- [113] P. Louridas and C. Ebert, “Machine Learning,” *IEEE Softw.*, vol. 33, no. 5, pp. 110–115, Sep. 2016, doi: 10.1109/MS.2016.114.
- [114] Mladen Nikolić and Anđelka Zečević, *Mašinsko učenje*. Beograd: Matematički fakultet Univerzitet u Beogradu, 2019.
- [115] C. E. Shannon and W. Weaver, *The mathematical theory of communication*. Champaign, IL, US: University of Illinois Press, 1949.
- [116] J. H. Friedman and J. J. Meulman, “Multiple additive regression trees with application in epidemiology,” *Stat. Med.*, vol. 22, no. 9, pp. 1365–1381, 2003, doi: <https://doi.org/10.1002/sim.1501>.
- [117] Y. Freund and R. E. Schapire, “A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting,” *J. Comput. Syst. Sci.*, vol. 55, no. 1, pp. 119–139, Aug. 1997, doi: 10.1006/JCSS.1997.1504.
- [118] J. H. Friedman, “Greedy function approximation: A gradient boosting machine,” *Ann. Stat.*, vol. 29, no. 5, Oct. 2001, doi: 10.1214/aos/1013203451.
- [119] R. Caruana and A. Niculescu-Mizil, “An empirical comparison of supervised learning algorithms,” in *Proceedings of the 23rd international conference on Machine learning - ICML '06*, 2006, pp. 161–168. doi: 10.1145/1143844.1143865.
- [120] L. Breiman, “Random Forests,” *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/A:1010933404324.
- [121] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, and R. R. Salakhutdinov, “Improving neural networks by preventing co-adaptation of feature detectors,” Jul. 2012.
- [122] G. Enderlein, “Miller, I., and J. E. Freund: Probability and Statistics for Engineers. Prentice-Hall, Englewood Cliffs, New Jersey 1965. 432 S., Preis 96. s.,” *Biom. Z.*, vol. 10, no. 1, pp. 89–90, 1968, doi: 10.1002/bimj.19680100125.
- [123] K. V. Rashmi and R. Gilad-Bachrach, “DART: Dropouts meet Multiple Additive Regression Trees,” *CoRR*, vol. abs/1505.01866, 2015, [Online]. Available: <http://arxiv.org/abs/1505.01866>
- [124] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, May 2017, doi: 10.1145/3065386.
- [125] C. L. Masten, N. I. Eisenberger, J. H. Pfeifer, and M. Dapretto, “Neural responses to witnessing peer rejection after being socially excluded: fMRI as a window into adolescents’ emotional processing,” *Dev. Sci.*, vol. 16, no. 5, pp. 743–759, Sep. 2013, doi: 10.1111/desc.12056.
- [126] S. Wang and C. Manning, “Fast dropout training,” in *Proceedings of the 30th International Conference on Machine Learning*, Feb. 2013, vol. 28, no. 2, pp. 118–126. [Online].

Available: <https://proceedings.mlr.press/v28/wang13a.html>

- [127] O. Chapelle and Y. Chang, “Yahoo! Learning to Rank Challenge Overview,” in *Proceedings of the Learning to Rank Challenge*, Feb. 2011, vol. 14, pp. 1–24. [Online]. Available: <https://proceedings.mlr.press/v14/chapelle11a.html>
- [128] Z. Ahmed *et al.*, “Machine learning at microsoft with ML.Net,” in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2019. doi: 10.1145/3292500.3330667.
- [129] Jarred Capellman, *Hands-On Machine Learning with ML.NET: Getting started with Microsoft ML.NET to implement popular machine learning algorithms in C#*. Packt Publishing, 2020.
- [130] Gerhard Weiss, *Multiagent Systems, Second Edition*. The MIT Press, 2016.
- [131] H. Rabitz, “Chemical sensitivity analysis theory with applications to molecular dynamics and kinetics,” *Comput. Chem.*, vol. 5, no. 4, pp. 167–180, Jan. 1981, doi: 10.1016/0097-8485(81)80104-0.
- [132] D. G. Cacuci, “Introduction,” in *Sensitivity and Uncertainty Analysis Theory*, 1st ed., Chapman and Hall/CRC, 2003. doi: 10.1201/9780203911396.ch10.
- [133] R. Heijungs, “On the number of Monte Carlo runs in comparative probabilistic LCA,” *Int. J. Life Cycle Assess.*, vol. 25, no. 2, pp. 394–402, Feb. 2020, doi: 10.1007/s11367-019-01698-4.
- [134] Polužanski V., Kartalović N., Stanković K., Nikolić B., and Miladinović N., “Istraživanje uticaja promene temperature mineralnog ulja na budžet merne nesigurnosti sveakustičkog neiterativnog algoritma za lociranje parcijalnog pražnjenja,” 35. *Savetov. CIGRE Srb.*, Oct. 2021.

ПРИЛОГ 1

Експериментална верификација резултата прве симулације Резултати симулације, измерене и израчунате вредности за десет различитих положаја ПП

Табела 37 Резултати симулације бр. 1

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,07	0,15
S_2	0,00	0,15	0,15
S_3	0,10	0,00	0,10
S_4	0,15	0,00	0,20
ПП	0,05	0,10	0,14

Табела 38 Измерене вредности бр. 1

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	15,58	34,44	48,53
2	15,86	37,20	51,96
3	14,82	31,29	44,91
4	15,10	33,49	47,49
5	15,48	33,87	47,87
6	15,39	33,87	48,25
7	15,10	33,20	47,39
8	15,00	31,48	45,20
9	15,39	34,53	48,82
10	15,29	34,25	48,63
Средња вредност	15,30	33,76	47,90
Стандардна девијација	0,3057	1,6612	1,9731

Табела 39 Израчунате вредности бр. 1

Израчунате вредности на основу измерених средњих вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,06	0,08	0,15	1413	0,00	0,00	0,00	0,00
30	0,06	0,08	0,15	1374	0,00	0,00	0,00	0,00
40	0,06	0,09	0,15	1337	0,00	0,01	0,00	0,01
50	0,06	0,09	0,15	1301	0,00	0,01	0,00	0,01
60	0,06	0,09	0,15	1266	0,00	0,01	0,00	0,01

Табела 40 Резултати симулације бр. 2

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,15	0,15
S_2	0,00	0,07	0,15
S_3	0,10	0,00	0,10
S_4	0,15	0,00	0,20
ПП	0,05	0,20	0,14

Табела 41 Измерене вредности бр. 2

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	38,00	80,35	87,78
2	38,15	79,78	87,30
3	42,15	90,54	100,50
4	39,87	84,82	93,68
5	38,82	82,16	89,97
6	39,77	84,44	93,11
7	39,87	84,44	93,11
8	39,49	83,97	92,54
9	39,68	84,00	92,63
10	38,63	82,16	89,97
Средња вредност	39,44	83,66	92,05
Стандардна девијација	1,1860	2,9929	3,7465

Табела 42 Израчунате вредности бр. 2

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,06	0,18	0,15	1413	0,00	0,00	0,00	0,00
30	0,06	0,17	0,15	1374	0,00	0,01	0,00	0,01
40	0,07	0,17	0,15	1337	0,01	0,01	0,00	0,01
50	0,07	0,17	0,15	1301	0,01	0,01	0,00	0,01
60	0,07	0,17	0,15	1266	0,01	0,01	0,00	0,01

Табела 43 Резултати симулације бр. 3

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,15	0,15
S_2	0,15	0,00	0,20
S_3	0,10	0,00	0,10
S_4	0,00	0,07	0,15
ПП	0,15	0,20	0,14

Табела 44 Измерене вредности бр. 3

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	11,17	20,49	23,15
2	11,35	20,58	24,39
3	11,17	20,31	23,00
4	11,35	20,58	23,42
5	11,26	20,67	23,24
6	11,44	20,40	22,97
7	11,26	20,49	23,00
8	11,26	20,22	23,15
9	11,26	20,31	22,97
10	11,35	20,31	23,24
Средња вредност	11,28	20,43	23,25
Стандардна девијација	0,0853	0,1481	0,4256

Табела 45 Израчунате вредности бр. 3

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,18	0,19	0,14	1413	0,00	0,00	0,00	0,00
30	0,17	0,18	0,14	1374	0,01	0,01	0,00	0,01
40	0,17	0,18	0,14	1337	0,01	0,01	0,00	0,01
50	0,17	0,18	0,14	1301	0,01	0,01	0,00	0,01
60	0,17	0,17	0,14	1266	0,01	0,02	0,00	0,02

Табела 46 Резултати симулације бр. 4

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,15	0,00	0,20
S_2	0,10	0,00	0,10
S_3	0,00	0,07	0,15
S_4	0,00	0,15	0,15
ПП	0,15	0,10	0,14

Табела 47 Измерене вредности бр. 4

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	11,62	46,04	52,26
2	11,71	46,13	52,08
3	11,53	46,22	52,08
4	11,44	46,04	52,26
5	11,62	45,96	52,08
6	11,79	46,13	52,26
7	11,62	46,31	52,17
8	11,53	45,96	52,08
9	11,53	45,96	52,17
10	11,71	46,31	52,17
Средња вредност	11,61	46,10	52,16
Стандардна девијација	0,1058	0,1374	0,0788

Табела 48 Израчунате вредности бр. 4

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,17	0,09	0,14	1413	0,00	0,00	0,00	0,00
30	0,17	0,09	0,14	1374	0,00	0,00	0,00	0,00
40	0,16	0,09	0,14	1337	0,01	0,00	0,00	0,01
50	0,16	0,09	0,14	1301	0,01	0,00	0,00	0,01
60	0,16	0,09	0,14	1266	0,01	0,00	0,00	0,01

Табела 49 Резултати симулације бр. 5

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,15	0,15
S_2	0,00	0,07	0,15
S_3	0,10	0,00	0,10
S_4	0,15	0,00	0,20
ПП	0,03	0,22	0,06

Табела 50 Измерене вредности бр. 5

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	36,12	69,93	104,30
2	35,77	69,31	103,60
3	35,86	69,22	103,80
4	35,77	69,40	103,80
5	35,77	69,31	103,60
6	35,86	69,40	103,80
7	35,59	69,13	103,50
8	35,94	69,04	103,80
9	36,12	69,49	103,60
10	36,12	69,49	103,70
Средња вредност	35,89	69,37	103,75
Стандардна девијација	0,1814	0,2450	0,2223

Табела 51 Израчунате вредности бр. 5

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,05	0,18	0,08	1413	0,00	0,00	0,00	0,00
30	0,05	0,18	0,08	1374	0,00	0,00	0,00	0,00
40	0,05	0,17	0,08	1337	0,00	0,01	0,00	0,01
50	0,06	0,17	0,09	1301	0,01	0,01	0,01	0,01
60	0,06	0,17	0,09	1266	0,01	0,01	0,01	0,01

Табела 52 Резултати симулације бр. 6

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,10	0,00	0,10
S_2	0,00	0,15	0,15
S_3	0,15	0,00	0,20
S_4	0,00	0,07	0,15
ПП	0,22	0,22	0,06

Табела 53 Измерене вредности бр. 6

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	6,52	8,97	25,34
2	6,30	8,70	25,16
3	6,35	8,88	25,07
4	6,57	9,01	25,34
5	6,44	9,05	25,30
6	7,24	9,37	25,43
7	6,88	9,23	25,34
8	6,44	9,05	25,25
9	6,48	8,97	25,34
10	6,62	9,19	25,25
Средња вредност	6,58	9,04	25,28
Стандардна девијација	0,2811	0,1884	0,1041

Табела 54 Израчунате вредности бр. 6

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,22	0,19	0,07	1413	0,00	0,00	0,00	0,00
30	0,21	0,18	0,07	1374	0,01	0,01	0,00	0,01
40	0,21	0,18	0,08	1337	0,01	0,01	0,01	0,01
50	0,20	0,17	0,08	1301	0,02	0,02	0,01	0,02
60	0,20	0,17	0,08	1266	0,02	0,02	0,01	0,02

Табела 55 Резултати симулације бр. 7

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,00	0,15	0,15
S_2	0,10	0,00	0,10
S_3	0,00	0,07	0,15
S_4	0,15	0,00	0,20
ПП	0,08	0,14	0,06

Табела 56 Измерене вредности бр. 7

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	6,73	9,84	44,54
2	6,55	9,57	44,09
3	6,30	9,66	44,09
4	6,64	9,66	44,36
5	6,64	9,57	44,00
6	6,64	9,57	44,27
7	7,00	9,75	44,45
8	6,64	9,75	44,45
9	6,55	9,66	44,27
10	6,55	9,57	44,18
Средња вредност	6,62	9,66	44,27
Стандардна девијација	0,1748	0,0948	0,1800

Табела 57 Израчунате вредности бр. 7

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,10	0,13	0,07	1413	0,00	0,00	0,00	0,00
30	0,10	0,13	0,07	1374	0,00	0,00	0,00	0,00
40	0,10	0,13	0,08	1337	0,00	0,00	0,01	0,01
50	0,10	0,13	0,08	1301	0,00	0,00	0,01	0,01
60	0,10	0,12	0,08	1266	0,00	0,01	0,01	0,01

Табела 58 Резултати симулације бр. 8

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,10	0,00	0,10
S_2	0,15	0,00	0,20
S_3	0,00	0,07	0,15
S_4	0,00	0,15	0,15
ПП	0,25	0,10	0,05

Табела 59 Измерене вредности бр. 8

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	15,08	63,35	65,55
2	15,15	61,64	64,84
3	15,06	62,26	65,64
4	14,79	62,09	65,10
5	15,77	61,91	65,19
6	17,28	62,18	65,55
7	15,15	68,17	74,77
8	15,48	68,66	75,01
9	16,75	68,50	74,69
10	15,01	67,55	74,22
Средња вредност	15,55	64,63	69,05
Стандардна девијација	0,8257	3,1326	4,8434

Табела 60 Израчунате вредности бр. 8

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,26	0,08	0,03	1413	0,00	0,00	0,00	0,00
30	0,25	0,08	0,04	1374	0,01	0,00	0,01	0,01
40	0,24	0,09	0,05	1337	0,02	0,01	0,02	0,02
50	0,23	0,09	0,06	1301	0,03	0,01	0,03	0,03
60	0,22	0,09	0,06	1266	0,04	0,01	0,03	0,04

Табела 61 Резултати симулације бр. 9

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,10	0,00	0,10
S_2	0,15	0,00	0,20
S_3	0,00	0,07	0,15
S_4	0,00	0,15	0,15
ПП	0,15	0,10	0,05

Табела 62 Измерене вредности бр. 9

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	38,34	41,99	49,30
2	38,82	42,15	49,85
3	44,05	48,02	54,68
4	39,60	40,55	48,33
5	39,28	42,46	48,49
6	36,90	41,35	47,70
7	35,16	46,75	56,11
8	37,54	46,27	57,38
9	38,81	47,06	53,89
10	37,22	41,82	56,29
Средња вредност	38,57	43,84	52,20
Стандардна девијација	2,3349	2,8186	3,8119

Табела 63 Израчунате вредности бр. 9

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,14	0,08	0,07	1413	0,00	0,00	0,00	0,00
30	0,14	0,08	0,08	1374	0,00	0,00	0,01	0,01
40	0,14	0,08	0,08	1337	0,00	0,00	0,01	0,01
50	0,14	0,08	0,08	1301	0,00	0,00	0,01	0,01
60	0,13	0,08	0,08	1266	0,01	0,00	0,01	0,01

Табела 64 Резултати симулације бр. 10

Резултати симулације			
Ознака	Координате		
	$x[m]$	$y[m]$	$z[m]$
S_1	0,10	0,00	0,10
S_2	0,00	0,07	0,15
S_3	0,00	0,15	0,15
S_4	0,15	0,00	0,20
ПП	0,05	0,10	0,05

Табела 65 Измерене вредности бр. 10

Измерене вредности			
Температура минералног уља [°C]	20		
Редни број мерења	$\tau_{12}[\mu s]$	$\tau_{13}[\mu s]$	$\tau_{14}[\mu s]$
1	22,46	37,38	60,24
2	21,51	36,90	60,56
3	22,14	35,63	58,49
4	22,46	34,68	59,92
5	22,78	36,59	60,56
6	21,98	35,79	61,35
7	21,03	36,27	59,92
8	22,78	36,74	60,56
9	20,39	35,16	60,04
10	20,55	35,16	60,4
Средња вредност	21,80	36,03	60,20
Стандардна девијација	0,8923	0,8824	0,7347

Табела 66 Израчунате вредности бр. 10

Израчунате вредности на основу измерених вредности τ_{12} , τ_{13} , τ_{14}								
$T[^\circ C]$	$x_r[m]$	$y_r[m]$	$z_r[m]$	$v[m/s]$	$\Delta x[m]$	$\Delta y[m]$	$\Delta z[m]$	$\Delta g_{max}[m]$
20	0,07	0,07	0,06	1413	0,00	0,00	0,00	0,00
30	0,08	0,07	0,06	1374	0,01	0,00	0,00	0,01
40	0,08	0,08	0,06	1337	0,01	0,01	0,00	0,01
50	0,08	0,08	0,07	1301	0,01	0,01	0,01	0,01
60	0,08	0,08	0,07	1266	0,01	0,01	0,01	0,01

БИОГРАФСКИ ПОДАЦИ О АУТОРУ ДИСЕРТАЦИЈЕ

Владимир Полужански је рођен 20. маја 1982. године у граду Лозници, где је са одличним успехом завршио основну школу „Анта Богићевић“ и гимназију „Вук Караџић“. Добитник је дипломе „Вук Караџић“.

У новембру 2008. године дипломирао је на Електротехничком факултету у Београду на смеру за Рачунарску технику и информатику са просечном оценом 7,83 и оценом 10 на дипломском испиту са темом „Информациони систем за дијагностику стања изолационих система на турбо и хидро генераторима“.

Докторске студије на модулу за софтверско инжењерство је први пут уписао 2010. године, а затим поново 2018. године. Током докторских студија остварио је просечну оценом 9,80.

Био је ангажован на научно-истраживачком пројекту технолошког развоја „Повећање енергетске ефикасности у одабраном индустријском сектору кроз имплементацију система менаџмента у малим и средњим предузећима“ (пројектни циклус 2010-2015). Два пута је биран у звање „истраживач сарадник“.

Од октобра 2007. године је ангажован у Центру за Електромерења, Електротехничког института Никола Тесла а.д. Београд, где је примљен у стални радни однос у новембру 2008. године. Тренутно ради на позицији вишег стручног сарадника и ангажован је на пословима примене информационих технологија за потребе основних делатности Института. Од 2022. године је руководилац функције за дигиталну трансформацију Института у оквиру САИГЕ пројекта који се одвија уз подршку Министарства науке, технолошког развоја и иновација, Светске банке и Европске уније.

Учествовао је у више комерцијалних пројеката и студија у сарадњи са привредом од којих су најзначајнији: развој надзорно дијагностичког центра електроенергетске опреме ЈП ЕПС, развој методе и уређаја за акустичка и електрична мерења парцијалних пражњења, развој метода и уређаја за мерење електромагнетних поља и развој уређаја за испитивање класе тачности мерних трансформатора.

У оквиру научноистраживачког рада, радио је на мултидисциплинарним проблемима везаним за методе мерења и обраду података електричних пражњења у изолационим срединама у оквиру којих је развијао алгоритме и софтверска решења која имплементирају аналитичке, статистичке и методе вештачке интелигенције за процену мерне несигурности. Објавио је 25 радова у међународним и домаћим часописима и конференцијама, од којих 11 као првоименовани аутор. Као коаутор публиковао је један рад у врхунском међународном часопису, док је као првоименовани аутор публиковао два рада у истакнутим међународним часописима, један рад у међународном часопису и један рад међународном часопису верификованом посебном одлуком.

Течно говори енглески језик и има почетни ниво знања француског језика.

Изјава о ауторству

Име и презиме аутора Владимир Полужански

Број индекса 5037/2018

Изјављујем

да је докторска дисертација под насловом

Примена вештачке интелигенције у изражавању мерне несигурности неитеративног
алгоритма за акустичко лоцирање парцијалног пражњења у минералном уљу

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

Потпис аутора

У Београду, _____

Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора Владимир Полужански

Број индекса 5037/2018

Студијски програм Софтверско инжењерство

Наслов рада Примена вештачке интелигенције у изражавању мерне несигурности
неитеративног алгорита за акустичко лоцирање парцијалног пражњења
у минералном уљу

Ментор др Бошко Николић, редовни професор

Ментор др Ковиљка Станковић, ванредни професор

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

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

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

Потпис аутора

У Београду, _____

Изјава о коришћењу

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

Примена вештачке интелигенције у изражавању мерне несигурности неитеративног
алгоритма за акустичко лоцирање парцијалног пражњења у минералном уљу

која је моје ауторско дело.

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

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

1. Ауторство (CC BY)

☒ 2. Ауторство – некомерцијално (CC BY-NC)

3. Ауторство – некомерцијално – без прерада (CC BY-NC-ND)

4. Ауторство – некомерцијално – делити под истим условима (CC BY-NC-SA)

5. Ауторство – без прерада (CC BY-ND)

6. Ауторство – делити под истим условима (CC BY-SA)

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

Потпис аутора

У Београду, _____

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