

АЛФА БК УНИВЕРЗИТЕТ
ФАКУЛТЕТ ЗА МАТЕМАТИКУ И РАЧУНАРСКЕ НАУКЕ



Стефан М. Поповић

ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ У ФУНКЦИЈИ
ОПТИМИЗАЦИЈЕ ПАРАМЕТАРА САГОРЕВАЊА
КОТЛОВА СА АУТОМАТСКИМ ЛОЖЕЊЕМ

докторска дисертација

Београд, 2025.године

АЛФА БК УНИВЕРЗИТЕТ
ФАКУЛТЕТ ЗА МАТЕМАТИКУ И РАЧУНАРСКЕ НАУКЕ



ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ У ФУНКЦИЈИ
ОПТИМИЗАЦИЈЕ ПАРАМЕТАРА САГОРЕВАЊА
КОТЛОВА СА АУТОМАТСКИМ ЛОЖЕЊЕМ

докторска дисертација

Кандидат:
Стефан М. Поповић
6901/2019

Ментор:
проф. др Небојша Денић
доц. др Јелена Стојановић

Београд, 2025.године

ALFA BK UNIVERSITY
FACULTY OF MATHEMATICS AND COMPUTER SCIENCES



**ARTIFICIAL NEURON NETWORKS IN THE
FUNCTION OF OPTIMIZING THE COMBUSTION
PARAMETERS OF BOILERS WITH AUTOMATIC
FIRING**

thesis

Candidate:
Stefan M. Popovic, M.Sc.
6901/2019

Mentor:
Prof. Nebojsa Denic, PhD
Asst. Prof. Jelena Stojanovic, PhD

Belgrade, 2025

АЛФА БК УНИВЕРЗИТЕТ
ФАКУЛТЕТ ЗА МАТЕМАТИКУ И РАЧУНАРСКЕ НАУКЕ



Датум: _____

Комисија за оцену и јавну одбрану докторске дисертације:

Проф. др Милан Глигоријевић – председник комисије
Редовни професор и декан Факултета информacionих технологија, Алфа БК
Универзитет, Београд, Министарство унутрашњих послова РС

Проф. др Војкан Николић – члан
Ванредни професор Криминалистичко полицијског универзитета, Београд

Проф. др Негован Стаменковић – члан
Редовни професор, Природно математички факултет, Универзитет у Приштини,
Приштина, издвојено седиште у Косовској Митровици

проф. др Небојша Денић – ментор
Ванредни професор, Природно математички факултет, Универзитет у Приштини,
Приштина, издвојено седиште у Косовској Митровици

доц. др Јелена Стојановић – ментор
Доцент, Факултет за математику и рачунарске науке, Алфа БК Универзитет, Београд

Студент је одбранио докторску дисертацију са оценом: _____(_____)

Академски назив:
Доктор наука – Рачунарске науке

Оно што води и вуче свет нису локомотиве, него идеје.

Виктор Иго

What drives and pulls the world is not locomotives, but ideas.

Victor Igo

Изражавам дубоку захвалност свима који су ми помогли у обликовању и изради докторске дисертације.

Пре свега, желим да искажем неизмерну захвалност својој породици мајци, оцу и сестри на несебичној подршци, разумевању и стрпљењу током читавог истраживачког процеса. Ваша љубав и охрабрење били су ми ослонац у свим изазовима.

Највећу захвалност упућујем својој супрузи Соњи, ћерци Сари и синовима Павлу и Филипу, који су са мном делили сваки корак овог пута, пружали ми снагу, мотивацију и веру у успех. Без њихове подршке и стрпљења, овај рад не би био могућ.

Такође, посебну захвалност дугујем својим менторима, професору Небојши Денићу и професорки Јелени Стојановић, чије су стручне смернице, подршка и конструктивни савети били од непроцењивог значаја за израду дисертације. Њихова посвећеност и научни интегритет били су ми непресушан извор инспирације.

Захваљујем се и професорима Дејану Ђукићу, Милану Глигоријевићу и Дејану Видуци, који су својим знањем, саветима и подршком дали значајан допринос у формирању и реализацији овог истраживања. Њихова стручност и посвећеност науци оставили су неизбрисив траг у мом академском развоју.

Свима вама дугујем неизмерну захвалност и овај рад је, у великој мери, резултат вашег доприноса, подршке и вере у мене.

Апстракт:

Вештачка интелигенција све више заузима централно место у развоју савремених технолошких решења, унапређујући пословне и технолошке процесе, оптимизујући ресурсе и омогућавајући интелигентно доношење одлука у реалном времену. Предности њене примене су вишеструке, од повећања ефикасности и смањења оперативних трошкова до унапређења еколошких параметара и одрживости. Њене методе, технике и алати све чешће се користе у техничким и индустријским системима, где класични модели управљања више не задовољавају захтеве прецизности, флексибилности и адаптивности.

Једна од таквих примена, која представља предмет овог истраживања, јесте употреба вештачких неуронских мрежа (ВНМ) у оптимизацији процеса сагоревања у котловима са аутоматским ложењем типа АТИ Терминг ОЗОН 55 и ОЗОН 35. У условима пораста енергетске потрошње и заоштравања еколошких прописа, потреба за интелигентним системима управљања постаје императив. Променљив квалитет горива, флукутирајући радни услови и ограничена способност класичних регулатора да реагују на сложене динамике система, чине ове системе идеалним кандидатом за примену алгоритама машинског учења. Истраживање у овом раду фокусирано је на примену напредних архитектура ВНМ (LSTM, GRU и RNN) које су прилагођене обради временских серија и моделовању нелинеарних динамичких система. Посебан акценат стављен је на алгоритамску адаптацију параметара у реалном времену, како би се омогућила континуирана регулација довода ваздуха, брзине вентилатора и дозирања горива на основу актуелних очитавања температуре, влажности и концентрације продукта сагоревања. Резултати експерименталних тестирања показују значајна побољшања: смањење средњеквадратне грешке у предикцији температуре димних гасова до 38%, редукацију емисије CO и NO_x за 18% и 12% респективно, као и уштеду у потрошњи пелета од око 11%. Ови резултати потврђују технолошку применљивост и енергетску оправданост предложеног приступа.

Рад представља значајан допринос научној и стручној заједници, демонстрирајући како применом вештачке интелигенције и методологије машинског учења у реалним термоенергетским системима може доћи до конкретних побољшања у ефикасности, стабилности и еколошкој одрживости. Истовремено, кроз коришћење мултикритеријумских метода, истраживање пружа алат за систематски избор најприкладнијих алгоритама ВИ у зависности од конкретног контекста примене.

Кључне речи:

вештачке неуронске мреже, дубоко учење, рекурентне мреже, LSTM, оптимизација сагоревања, котлови са аутоматским ложењем, модел предикције, машинско учење, интелигентни алгоритми, интелигентно управљање процесима, индустријска примена вештачке интелигенције.

Научно поље дисертације:

Природно-математичко образовно научно поље

Научна област:

Рачунарске науке

Abstract:

Artificial intelligence (AI) is increasingly taking a central role in the development of modern technological solutions, enhancing business and technical processes, optimizing resources, and enabling intelligent decision-making in real time. The advantages of its application are numerous—ranging from increased efficiency and reduced operational costs to the improvement of ecological parameters and sustainability. Its methods, techniques, and tools are being used more and more in technical and industrial systems, where classical control models no longer meet the demands for precision, flexibility, and adaptability.

One such application, which is the focus of this research, is the use of artificial neural networks (ANNs) to optimize the combustion process in automatically fed boilers of the ATI Terming OZON 55 and OZON 35 type. In the context of growing energy consumption and increasingly strict environmental regulations, the need for intelligent control systems becomes imperative. Variable fuel quality, fluctuating operating conditions, and the limited capacity of conventional regulators to respond to complex system dynamics make these systems ideal candidates for the application of machine learning algorithms. This study focuses on the implementation of advanced ANN architectures (LSTM, GRU, and RNN) which are well-suited for time-series analysis and modeling of nonlinear dynamic systems. Particular emphasis is placed on real-time algorithmic parameter adaptation, enabling continuous control of air supply, fan speed, and fuel dosing based on real-time readings of temperature, humidity, and combustion product concentrations. The results of experimental testing show significant improvements: a 38% reduction in mean squared error (MSE) in flue gas temperature prediction, reductions in CO and NO_x emissions by 18% and 12%, respectively, and an average pellet consumption savings of about 11%. These results confirm the technological applicability and energy justification of the proposed approach.

This work represents a valuable contribution to the scientific and professional community, demonstrating how the application of artificial intelligence and machine learning methodologies in real thermoelectric systems can lead to tangible improvements in efficiency, stability, and environmental sustainability. Additionally, by employing multi-criteria decision-making methods, the research offers a framework for the systematic selection of the most appropriate AI algorithms depending on the specific application context.

Keywords:

artificial neural networks, deep learning, recurrent networks, LSTM, combustion optimization, boilers with automatic firing, prediction model, machine learning, intelligent algorithms, intelligent process control, industrial application of artificial intelligence.

Dissertation scientific field:

Educational and Scientific Field of Natural and Mathematical Sciences

Scientific field:

Computer science

Садржај:

1.	Увод	2
1.1.	Предмет истраживања.....	5
1.2.	Циљеви и задаци истраживања	5
1.2.1.	Циљеви истраживања	5
1.2.2.	Задаци истраживања.....	8
1.3.	Хипотезе	9
1.4.	Техника истраживања	9
1.5.	Структура дисертације.....	10
2.	Теоријска позадина вештачке интелигенције и вештачких неуронских мрежа	12
2.1.	Математичке основе вештачке интелигенције	12
2.2.	Вештачке неуронске мреже.....	14
2.2.1.	Основни концепти и типови ВНМ	14
2.2.2.	Улога вештачких неуронских мрежа у модерној индустрији	20
2.2.3.	Вештачке неуронске мреже у оптимизацији процеса сагоревања	22
3.	Нове могућности примене вештачке интелигенције	24
4.	Оптимизација физичко-хемијских процеса у котловима са аутоматским ложењем	29
4.1.	Преглед физичких и хемијских аспеката сагоревања.....	29
4.2.	Типови котлова и њихове карактеристике.....	30
4.3.	Технике оптимизације у контроли сагоревања	34
4.3.1.	Важност оптимизације процеса сагоревања котлова	36
5.	Методологија истраживања	38
5.1.1.	Образложење избора рекурентне архитектуре ВНМ	45
5.2.	Експериментално прикупљање података - Опис система и прикупљање података.....	47
6.	Резултати истраживања	51
6.1.	Имплементација алгоритма обуке LSTM мреже у Python-у	52
6.2.	Евалуација и валидација обучене LSTM мреже.....	55
6.3.	Интеграција у управљачки систем и рад у затвореној петљи.....	57
6.4.	Интерпретација резултата у контексту циљева истраживања	58
7.	Дискусија резултата	61
7.1.	Кореспонденција са резултатима других студија	67

7.2.	Потенцијални утицај на индустријску праксу.....	70
7.3.	Доказ постављених хипотеза	71
7.4.	Ограничења актуелног истраживања и могући правци за будућа истраживања.	75
8.	Закључак	76
8.1.	Кратак преглед најважнијих резултата и њиховог значаја и допринос научној заједници	77
9.	Литература	78
10.	Прилози	95
10.1.	Програмски кодови	95
10.2.	Списак графика.....	116
10.3.	Списак табела	116
10.4.	Попис слика	117
10.5.	Слике мерног места и делова система	118
10.6.	Биографија аутора	120
10.7.	Библиографија аутора	121
10.8.	Изјава о ауторству	127
10.9.	Изјаву о истоветности штампане и електронске верзије докторског рада	128
10.10.	Изјаву о коришћењу	129

1. Увод

Савремени технолошки трендови, предвођени растом Интернета ствари (IoT), довели су до вртоглавог пораста броја уређаја повезаних на интернет мрежу широм света. Према подацима истраживачке компаније Gartner, већ током 2020. године било је више од 20 милијарди повезаних уређаја на глобалном нивоу [1][2][3]. Ова експанзија умрежених сензорских и актуаторских система отвара нове могућности за примену вештачке интелигенције (ВИ) и машинског учења (МУ) у реалном времену, посебно у областима праћења и управљања техничким процесима као што су термоенергетика, индустријска аутоматизација и заштита животне средине[4]. Истовремено, изазови повезани са деградацијом квалитета ваздуха, услед емисије гасова и чврстих честица из термоенергетских постројења, локалних котларница и интензивног саобраћаја захтевају нове, интелигентне приступе надзору и контроли ових појава [5]. У том контексту, примене вештачких неуронских мрежа (ВНМ), као и других облика ВИ, постају кључни алати у прецизној предикцији и оптимизацији процеса сагоревања и емисија, уз директан допринос смањењу еколошког отиска и побољшању енергетске ефикасности [6]. С обзиром на изражене последице глобалног загревања, топљење поларних капа и угроженост екосистема, императив постаје развој економичних, технолошки одрживих и интелигентних система за мониторинг и управљање. Такви системи, у чијем се средишту налазе алгоритми машинског учења, нарочито LSTM, GRU и RNN мреже, омогућавају динамичко прилагођавање оперативних параметара у реалном времену на основу анализе секвенцијалних података о раду система, сензорских мерења и промене услова у окружењу. Развој и све већа доступност програмабилних микроконтролера ниске цене, омогућили су директну интеграцију интелигентних софтверских компоненти у хардверске системе. Ови уређаји постају основа за изградњу компактних, али моћних решења која повезују мерење, обраду података и контролу, омогућавајући примену вештачке интелигенције у реалним, индустријским и енергетским условима [7][8][9][10][11]. Такви приступи већ се користе у широком спектру области, од паметних кућа и енергетске аутоматизације, до прецизне медицине и еколошког мониторинга, доприносећи ефикаснијем и одговорнијем управљању ресурсима [11][12][13]. Такав мултидисциплинарни приступ који спаја IoT технологије, машинско учење и управљање процесима примењен је, у оквиру ове дисертације, на конкретан проблем оптимизације рада котлова са аутоматским ложењем, што представља значајан корак у правцу развоја одрживих, интелигентних и прилагодљивих енергетских решења. У оквиру овог рада развијен је систем за мониторинг и аутоматско управљање радом котлова са аутоматским ложењем, који примењује вештачке неуронске мреже за динамичку оптимизацију радних параметара. Основна функција система је прилагођавање параметара сагоревања у складу са врстом и квалитетом улазног горива, с циљем повећања степена искоришћења енергије. Систем је конципиран и реализован у теоријском и практичном смислу, а његова функционалност је емпиријски верификована кроз експерименте спроведене на индустријском котлу типа АТИ Терминг Озон 35 и Озон 55 [13].

Методолошки приступ је заснован на интеграцији општих научних метода, основних логичких метода сазнања и специјализованих техника за прикупљање, обраду и анализу података, с циљем развоја интелигентног система за оптимизацију процеса

сагоревања у котловима са аутоматским ложењем. Посебан акценат стављен је на примену савремених метода вештачке интелигенције (ВИ) и машинског учења (МУ), при чему је улога вештачких неуронских мрежа (ВНМ) централна у моделовању и управљању динамичким, нелинеарним процесима сагоревања. Као опште научне методе, примењиване су метода математичког моделовања, статистичка анализа и хипотетичко-дедуктивни приступ, с циљем формализације структуре улазно-излазних односа у систему сагоревања и верификације тачности модела. Основне логичке методе сазнања (анализа, синтеза, дедукција, апстракција и генерализација) примењене су у различитим фазама: од избора релевантних улазних параметара, преко конструкције и конфигурације архитектуре неуронских мрежа, до извођења закључака на основу евалуације резултата[15][16][17].


У домену метода прикупљања података, доминира експериментална метода, реализована кроз реалновременско мерење физичких параметара система (температура, влажност, концентрација гасова, РМ честице) путем сопственог сензорског система повезаног на Arduino платформу. Прикупљени подаци су складиштени у релационој бази података, подвргнути нормализацији, статистичком испитивању и техничком претпроцесирању, као предуслов за њихову примену у обуци модела машинског учења. У теоријско-методолошком оквиру, истраживање је засновано на доказаним предностима LSTM мрежа у обради секвенцијалних података и дугорочних временских зависности. Поред тога, извршена је компаративна анализа архитектура RNN и GRU, са циљем идентификације најпоузданијег и најпрецизнијег модела за конкретан технички проблем. Алгоритми машинског учења развијени су у Python окружењу уз примену TensorFlow/Keras библиотека, а затим преведени у MATLAB формат, чиме је омогућена даља интеграција у управљачки систем и имплементација у реалном времену[14][18][19][20].

Циљ оваквог интегрисаног методолошког приступа јесте развој научно утемељеног, репродуктивног и технички применљивог решења, које омогућава прецизну предикцију, адаптивну контролу и значајно унапређење енергетске и еколошке ефикасности система сагоревања. Ова методологија истовремено доприноси научној валоризацији примене ВИ у техничким системима и отвара простор за трансфер решења у индустријску праксу.

Значај овог рада огледа се пре свега у интердисциплинарној примени савремених метода из области програмирања, примењене математике, машинског учења и микроконтролерских система у оквиру интегрисаног система за интелигентно управљање процесом сагоревања у котловима са аутоматским ложењем. Развијени систем повезује више технолошких компоненти у јединствену структуру која функционише на релацији: сензор – микроконтролер – рачунар – база података – модел машинског учења – актуаторски подсистем, чиме се успоставља затворена регулациона петља у реалном времену. Ова структура омогућава континуирано праћење и адаптивно управљање параметрима сагоревања, у складу са променљивим улазним условима као што су квалитет горива, амбијентални услови и оперативни режим рада котла. Посебан допринос овог рада лежи у развоју и имплементацији LSTM неуронске мреже као основног механизма за предикцију и оптимизацију процеса, при чему се користе реални подаци прикупљени са експерименталног система базираног на Arduino микроконтролеру. Обучени модел се затим интегрише у регулаторни механизам који у

реалном времену управља кључним параметрима, као што су дозирање пелета и регулација довода ваздуха. Комплетан процес укључује и модуле за нормализацију, складиштење, визуализацију и анализу података, као и реализацију управљачких одлука на нивоу актуатора.

Научни и практични допринос овог истраживања огледа се у демонстрацији да је могуће постићи значајна побољшања у енергетској ефикасности и смањењу емисија штетних гасова без потребе за скупим хардверским интервенцијама, искључиво применом софтверски дефинисане интелигенције. Резултати показују да је, захваљујући адаптивним својствима ВНМ модела, могуће одржати стабилан и оптималан режим рада котлова чак и у условима варијабилног квалитета горива, чиме се значајно смањују трошкови и еколошки утицај. Истраживањем је дат допринос не само унапређењу технолошких аспеката термоенергетских система малих и средњих капацитета, већ и ширем концепту одрживих енергетских решења, уз активну примену вештачке интелигенције као алата за аутоматизацију и интелигентно управљање индустријским процесима. Садржајно широка и интердисциплинарна природа проблема обрађених у оквиру теме условљава потребу за детаљним разјашњењем и прецизним дефинисањем кључних појмова и термина који се користе у раду, како би се обезбедила јасноћа, термилошка доследност и методолошка утемељеност целокупног истраживања[14][19][21].



Слика бр:1. Хијерархијска структура области вештачке интелигенције

1.1. Предмет истраживања

Предмет овог истраживања је примена метода вештачке интелигенције, са акцентом на вештачке неуронске мреже (ВНМ), у функцији предикције и оптимизације параметара сагоревања у котловима са аутоматским ложењем. У фокусу је развој интелигентног система за праћење и управљање процесом сагоревања, који користи податке прикупљене у реалном времену са сензорског система и врши адаптивну регулацију на основу предиктивних алгоритама. Истраживање обухвата дефинисање математичког модела оптимизације процеса, избор и тренирање одговарајуће архитектуре ВНМ (пре свега LSTM, GRU и RNN), валидацију њихове прецизности и примену у затвореној управљачкој петљи. Посебна пажња посвећена је интеграцији експерименталног система, обради и нормализацији података, као и процени енергетске ефикасности и утицаја на смањење емисија CO и NO_x гасова. Циљ је развити поуздан, флексибилан и економичан интелигентни алгоритам који ће омогућити реалновременску адаптацију параметара котла, при чему се не захтевају додатна хардверска улагања или сложене реконфигурације постојећег система. Предмет истраживања је, дакле, интердисциплинарно позициониран на пресеку вештачке интелигенције, машинског учења, енергетике и аутоматизације.

1.2. Циљеви и задаци истраживања

У настојању да унапреди лични и друштвени стандард, човек је често занемаривао дугорочне последице својих активности на животну средину [22][23][24]. Такав приступ резултовао је значајним поремећајима у природним системима: загађењем ваздуха, смањењем шумских површина, топлотним загађењем воде и атмосфере, као и акумулацијом великих количина чврстог отпада [25][26]. Истраживања потврђују да антропогене активности имају директан и индиректан утицај на деградацију екосистема, што доводи до губитка биодиверзитета и климатских промена које озбиљно угрожавају природне ресурсе и глобалну одрживост [27][28][29]. Утицаји човека на животну средину постају све дубљи, распрострањенији и трајнији, што отежава њихову класификацију и систематизацију [30][31][32]. У таквом контексту, јавља се растућа потреба за системима мониторинга и управљања који омогућавају праћење и контролу параметара кључних за очување животне средине. Полазећи од ове чињенице, у раду је истраживан проблем примене вештачких неуронских мрежа у системима котлова са аутоматским ложењем, са циљем повећања степена енергетског искоришћења. Оваквим приступом настоји се постићи боља контрола процеса сагоревања, смањити емисија штетних гасова и допринети очувању природне средине у складу са принципима одрживог развоја[14][19][21].

1.2.1. Циљеви истраживања

Главни циљ овог истраживања јесте испитивање могућности примене вештачких неуронских мрежа (ВНМ) у системима котлова са аутоматским ложењем, као и њихова имплементација у функцији интелигентне контроле процеса сагоревања. Истраживање има за циљ да покаже у којој мери је могуће унапредити енергетску


ефикасност и оперативну стабилност котлова путем оптимизације параметара рада засноване на моделима машинског учења.

Уз главни циљ који се односи на примену вештачких неуронских мрежа у функцији оптимизације параметара сагоревања у котловима са аутоматским ложењем, дефинисани су следећи специфични циљеви:

- Идентификација и одабир адекватних сензора за мерење кључних физичко-хемијских параметара процеса сагоревања (температуре горионика, температуре димних гасова, влажности пелета, концентрације CO и NO_x гасова, РМ честица и брзине ваздуха), у складу са техничким ограничењима и потребама интелигентног управљања;
- Развој микроконтролерског система за реалновременско читање, прикупљање, нормализацију и складиштење мерених података, са могућношћу проширене интеграције са системима вештачке интелигенције;
- Имплементација алгоритама вештачких неуронских мрежа (RNN, GRU, LSTM) у циљу предикције кључних излазних параметара, и динамичке адаптације улазно-излазних односа у складу са променљивим условима рада и квалитетом горива;
- Валидација и компаративна анализа модела, укључујући мерење њихове прецизности, стабилности и способности генерализације, са посебним освртом на утицај избора архитектуре ВНМ на енергетску ефикасност и еколошке перформансе;
- Тестирање система у реалним експлоатационим условима, уз процену утицаја на потрошњу горива, стабилност температуре, емисију штетних гасова и робусност контролне логике при променама спољашњих и унутрашњих услова;
- Показивање применљивости сензора нижег ценовног ранга и отворених хардверско-програмских платформи у реализацији система интелигентног управљања, без потребе за скупим реконфигурацијама постојеће инфраструктуре.

Научни циљ истраживања представља развој и примену напредних вештачких неуронских мрежа за оптимизацију и аутоматизацију процеса сагоревања у котловима, са циљем побољшања ефикасности, смањења емисије штетних гасова и повећања поузданости система. Овај циљ може се конкретизовати кроз специфичне научне циљеве. Први специфични научни циљ је развој математичких модела процеса сагоревања. Он укључује конструисање и валидацију математичког модела који тачно описује термодинамичке и хемијске процесе сагоревања у котловима. Затим, интеграцију овог модела са ВНМ ради побољшања тачности предвиђања и контроле. Наредни научни циљ је дизајн и обука вештачких неуронских мрежа, он обухвата истраживање и примену различитих архитектура ВНМ (GRU, RNN, LSTM) за обуку модела на подацима прикупљеним из реалних система. Овде развијамо методе за обуку ВНМ које омогућавају реално-временску оптимизацију параметара сагоревања. Након задовољења овог циља развијамо алгоритам за реално-временску контролу који користи ВНМ за континуирану оптимизацију параметара сагоревања у реалном времену. Затим, вршимо интеграцију ових алгоритама у постојеће контролне системе котлова са аутоматским ложењем. Следећи специфични циљ је анализа утицаја оптимизације параметара сагоревања на смањење емисије штетних гасова и развој стратегија које омогућавају постизање еколошки прихватљивијих услова рада котлова. На крају имамо

Испуњавањем ових специфичних циљева, истраживање може допринети унапређењу технологија за контролу параметара сагоревања, што ће имати значајан утицај на енергетску ефикасност, економску исплативост и заштиту животне средине.



7

1.2.2. Задаци истраживања

У складу са постављеним општим и специфичним циљевима, истраживање обухвата низ конкретних задатака чија је реализација неопходна за развој и примену интелигентног система за мониторинг, анализу и оптимизацију процеса сагоревања у котловима са аутоматским ложењем. Ови задаци укључују интеграцију знања из области вештачке интелигенције, микроконтролерских система, обраде података и машинског учења, са циљем изградње поузданог и применљивог решења. Основни задаци истраживања који су коришћени у оквиру овог истраживања представљају проналажење одговарајућег хардверског решења, што подразумева систематично истраживање тржишта и техничке документације ради избора микроконтролера и сензора нижег ценовног ранга који омогућавају мерење релевантних параметара процеса сагоревања: температуре горионика и димних гасова, релативне влажности пелета, концентрације CO и NO_x гасова, као и $\text{PM}_{2.5}$ и PM_{10} честица. Одабир компоненти је извршен на основу критеријума као што су прецизност, стабилност, енергетска ефикасност и лакоћа интеграције у сложене системске архитектуре. Након тога приступило се имплементацији сензора и интеграцији са микроконтролером, што укључује хардверско повезивање свих сензора са Ардуино микроконтролером, као и развој софтверског слоја за иницијализацију, читање и обраду сигнала. Посебна пажња посвећена је креирању библиотеке и класа за појединачне сензоре, као и моделирању калибрационих функција које омогућавају прецизну интерпретацију аналогних сигнала и њихово претварање у стандардизоване параметре. Развијени су системи за складиштење података, који подразумева реализацију поузданог механизма за запис података на меморијску картицу, као и успостављање базе података у којој ће се чувати историјски подаци о раду система у циљу касније анализе, обуке модела машинског учења и праћења деградације перформанси у реалном времену. Систем је имплементиран на реалан објекат, конкретно на котлове типа ОЗОН 35 и ОЗОН 55, уз придржавање свих безбедносних и функционалних захтева термоенергетских постројења. Овим задатком је омогућено прикупљање података у реалним експлоатационим условима и процена стабилности система у пракси. Прикупљени подаци су извезени, анализирани и интерпретирани, што обухвата трансфер мерења са микроконтролера на рачунар, примену техника нормализације, валидације и визуализације, као и идентификацију атипичних образаца понашања система. На основу добијених резултата врши се прекалибрација актуатора (вентилатора, дозатора пелета и др.) ради оптимизације сагоревања и енергетске ефикасности.

Примена и валидација модела вештачких неуронских мрежа је кључни задатак истраживања, са акцентом на имплементацију LSTM, RNN и GRU модела у Python програмском окружењу. Изабрани модели су обучавани на прикупљеним подацима, а затим верификовани у реалним условима рада. У оквиру овог задатка реализована је и реално-временска интеграција са контролним алгоритмима, чиме је омогућено динамичко управљање радом котла на основу предиктивних излаза ВМ. Урађено је и оцењивање перформанси система, кроз примену стандардних статистичких метрика (MSE , MAE , R^2), анализу робусности, генерализације и могућности прилагођавања променљивим условима рада, као и кроз компаративну анализу резултата у односу на класичне контролне стратегије.

Реализацијом ових задатака омогућена је пуна демонстрација применљивости вештачке интелигенције у домену оптимизације термотехничких процеса, са конкретним импликацијама за енергетску ефикасност, еколошку одрживост и индустријску примену.

1.3. Хипотезе

Убрзани развој индустрије и стално растуће потребе за енергијом доприносе глобалном загревању, климатским променама и повећаној емисији штетних материја и зрачења. У том контексту, јавља се све израженија потреба за развојем технолошки приступачних уређаја који омогућавају континуирано мерење, анализу и интелигентну обраду података, са циљем унапређења енергетске ефикасности и смањења негативног утицаја на животну средину [14][19][21][33].

На основу наведеног, формулисане су следеће истраживачке хипотезе:

X1: Примена вештачких неуронских мрежа у систему управљања котловима са аутоматским ложењем доводи до повећања степена енергетског искоришћења и побољшања стабилности процеса сагоревања.

X2: Интеграција нискобуџетних сензора и микроконтролера у систем котловског управљања омогућава поуздано и континуирано праћење релевантних параметара сагоревања уз задовољавајући ниво тачности и стабилности.

X3: Примена интелигентних управљачких алгорита на бази ВНМ може довести до значајног смањења емисије загађујућих гасова и честица, чиме се доприноси заштити животне средине и усклађености са еколошким стандардима.


X4: Имплементација система за мерење и оптимизацију сагоревања базираног на ВНМ утиче на развој еколошке свести корисника и подстиче усвајање енергетски одговорнијих навика у домаћинствима и индустрији.

X5: Ако се иницијални резултати покажу позитивним, постоји оправданост за дугорочно праћење и вишеструку примену предложеног система на различитим типовима котлова ради валидације резултата у различитим експлоатационим условима.

1.4. Техника истраживања

Техника истраживања примењена у овом раду класификована је као експериментално–теоријска, што подразумева комбиновање аналитичког, симулационог и практичног приступа у циљу развоја, примене и верификације система заснованог на вештачкој интелигенцији. Истраживање је организовано у више фаза, од којих свака обухвата специфичне методолошке поступке у складу са постављеним циљевима и хипотезама. У уводној фази истраживања, извршен је систематски преглед релевантне литературе из области вештачке интелигенције, машинског учења, вештачких неуронских мрежа (ВНМ), као и аутоматизације и контроле процеса сагоревања у котловима са аутоматским ложењем. Анализирани су рецензирани научни радови, техничке спецификације хардверских компоненти (сензора, микроконтролера, актуатора), као и претходне студије примене ВНМ у реалном времену у енергетским системима. Посебна пажња посвећена је моделима RNN, LSTM и GRU, који имају

капацитет за обраду временских серија и динамичких нелинеарних процеса. На основу претходне теоријске анализе, приступило се пројектовању и изградњи експерименталног система. Ово је укључивало избор и повезивање сензора за мерење кључних физичких величина (температура, влажност, концентрација CO и NO_x гасова, РМ честице), избор Ардуино микроконтролера као централне јединице система, и развој прилагођеног софтвера за прикупљање, комуникацију и иницијално процесирање података. У овој фази реализована је и логика за реално-временско снимање података, као и код за стабилну серијску комуникацију са базом података и екстерним аналитичким софтвером. Систем је затим тестиран у реалним условима на котловима са аутоматским ложењем типа ОЗОН 35 и ОЗОН 55. Извршено је континуирано прикупљање података током различитих режима рада, уз праћење промене услова (влажност горива, температура, проток ваздуха). Прикупљени подаци су архивирани у базу података ради касније анализе и обуке модела машинског учења. У завршној фази спроведена је анализа и обрада прикупљених података уз примену софтверских алата као што су Python и MATLAB. Извршена је нормализација, визуелизација и филтрирање података, као и формирање тренинг и тест скупова за обуку вештачких неуронских мрежа. Развијени модели су тестирани и верификовани на реалним подацима, при чему су мерене метрике као што су MSE, MAE и R². Поред тога, модел LSTM је интегрисан у реално-временски контролни циклус ради процене његове практичне применљивости у управљању радом котла [14][19][21][33][34].



Слика бр:3. Почетна фаза развоја уређаја – 2019. година

1.5. Структура дисертације

Дисертација је структурисана у складу са научним и методолошким принципима истраживања, кроз логичку целину која прати ток анализе, експеримента, имплементације и интерпретације резултата. У првом поглављу дефинишу се предмет и

значај истраживања, формулишу се циљеви и задаци рада, постављају хипотезе, обрађује техника истраживања и даје преглед саме структуре дисертације. Друго поглавље обухвата теоријску позадину вештачке интелигенције и вештачких неуронских мрежа, са акцентом на њихове математичке основе, архитектуре и примену у савременој индустрији, посебно у процесима оптимизације сагоревања. Треће поглавље посвећено је ширем контексту примене вештачке интелигенције, са прегледом нових могућности које нуди у управљању технолошким системима и енергетским процесима. Четврто поглавље разматра физичко-хемијске аспекте процеса сагоревања у котловима, укључујући типологију котлова, механизме сагоревања и савремене приступе оптимизацији. Пето поглавље представља методологију истраживања, укључујући математичко-моделску анализу, избор архитектуре ВМ и опис експерименталног система за прикупљање података у реалним условима рада. Шесто поглавље приказује резултате имплементације модела, укључујући развој и обуку LSTM мреже, валидацију модела, интеграцију у управљачки систем и анализу резултата у односу на постављене циљеве. Седмо поглавље доноси дискусију резултата у светлу постојећих истраживања, утицај на индустријску праксу, доказивање постављених хипотеза и идентификовање ограничења и могућности за будућа истраживања. Осмо поглавље садржи коначне закључке, истичући најзначајније резултате, њихов допринос научној заједници и применљивост у индустријској пракси. Посебан акценат у дисертацији стављен је на примену вештачких неуронских мрежа и техника вештачке интелигенције, са фокусом на LSTM архитектуру као кључну технологију за обраду временских серија у процесима сагоревања. Истраживање је усмерено ка развоју интелигентног система за предикцију и оптимизацију параметара рада котлова, уз циљано смањење емисија штетних гасова и повећање енергетске ефикасности. Девето и десето поглавље, односно литература и прилози на крају рада садрже релевантне изворе, као и изјаве о аутентичности.



Слика бр:4. Примена вештачке интелигенције

2. Теоријска позадина вештачке интелигенције и вештачких неуронских мрежа

Преглед релевантне литературе представља један од кључних елемената сваког научног истраживања, јер омогућава критичко сагледавање постојећих теоријских и практичних достигнућа, идентификацију истраживачких празнина и формирање основа за формулисање нових истраживачких хипотеза и методолошких приступа [35][36][37]. У контексту савремених технолошких токова, све већи број истраживања усмерава се ка примени вештачке интелигенције, а посебно вештачких неуронских мрежа (ВНМ), у оптимизацији индустријских процеса [38][39].

Развој вештачке интелигенције (ВИ) представља један од најзначајнијих домета савремене науке и технологије [40]. ВИ као интердисциплинарна област обухвата методе и технике којима се симулирају аспекти људске интелигенције: учење, резонување, доношење одлука и адаптација, са циљем изградње система који могу самостално да решавају комплексне задатке у реалном времену [41][42][43]. У том контексту, посебно место заузимају ВНМ, као подсистем машинског учења инспирисаног начином рада биолошких неурона. ВНМ представљају рачунске моделе који се састоје од чворова („неурона“) међусобно повезаних тежинама које се прилагођавају током процеса учења. Основна функција ових мрежа је способност да открију скривене обрасце у подацима, да изврше класификацију, регресију, као и да реше сложене нелинеарне проблеме који су тешко описиви класичним аналитичким методама [44][45]. Због тога су ВНМ постале незаменљив алат у доменима као што су препознавање говора и слика, предикција, оптимизација и интелигентно управљање системима. У последњим деценијама развијене су напредне архитектуре ВНМ: рекурентне неуронске мреже (RNN), дубоке неуронске мреже (DNN), као и модели са дугорочно-краткорочном меморијом (LSTM) и мреже са контролисаним улазом и излазом (GRU). Посебно су значајне рекурентне архитектуре у обради временских серија, јер омогућавају анализу и предикцију динамичких процеса, какви се срећу у енергетским системима и индустријској аутоматизацији [46][47][48].

С обзиром на све ширу примену у индустрији, здравству, саобраћају и енергетици, неопходно је разумевање математичке и алгоритамске основе вештачке интелигенције, како би се могла искористити пуна снага ове технологије у решавању конкретних техничких и друштвених изазова. Управо из тог разлога, у наставку се разматрају кључни принципи, архитектуре и механизми учења ВНМ, као и њихова улога у развоју интелигентних управљачких система [49][50][51][52].

2.1. Математичке основе вештачке интелигенције

Историја вештачке интелигенције (ВИ) као научне дисциплине почиње средином 20. века, када је формулисана идеја о симулирању људске интелигенције помоћу машина. Почетак модерне ере ВИ обележила је Дартмутска конференција 1956. године, на којој су научници Џон Макарти, Марвин Мински, Алан Њуел и Херберт Сајмон предложили да „свака компонента интелигенције може, у принципу, бити тако прецизно описана тако да машина може да је симулира“ [53][54][55][56]. Убрзо након тога, појавили су се први алгоритми за решавање проблема, логичко резонување и

симболичко манипулисање, који су били темељ ране ВИ. Ипак, већ крајем 1960-их интересовање је ослабило услед ограничења хардвера и немогућности модела да се изборе са сложеностију реалног света што је довело до тзв. „зиме вештачке интелигенције“ [1][19][57].

Преломни моменат у развоју ВИ догодио се развојем вештачких неуронских мрежа (ВНМ), заснованих на математичком моделу неурона који су предложили Варен Мек Клуч (Warren McCulloch) и Валтер Питс (Walter Pitts) 1943. године [58]. Њихов бинарни модел неурона био је заснован на буловој логици, где се излаз добија сабирањем улазних сигнала и применом прага активације. Следећа прекретница био је перцептрон, који је предложио Френк Розенблат (Frank Rosenblatt) 1958. године [59]. Перцептрон представља једноставну ВНМ која врши линеарну класификацију, и формално је дефинисана као:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1)$$

где су x_i улазне вредности, w_i тежине, b померај (бијас), а f активациона функција (степ-функција у раним моделима). Ово је био први корак ка формирању теоријске основе ВНМ.

Математичке основе модерне вештачке интелигенције почивају на: линеарној алгебри (матрице, тензори, векторски простори), вероватноћи и статистици (Бајесова теорија, нормалне расподеле, процена параметара), нумеричкој оптимизацији (градијентски спуст, стохастичка оптимизација), теорији информација (ентропија, пренос информације), диференцијалном и интегралном рачуну (извођење функција губитка, повратна пропагација) [60][61].

Посебно важну улогу игра метод градијентског спуста, који омогућава учење тежина у ВНМ кроз минимизацију функције грешке [62][63]:

$$w_{\text{пред}} = w_{\text{улазно}} - \eta \frac{\partial L}{\partial w} \quad (2)$$

где је η стопа учења, а L функција губитка, најчешће дефинисана као средњеквадратна грешка или кросентропија, у зависности од задатка.

Развој дубоког учења (Deep Learning), нарочито након 2010. године, донео је нову револуцију у примени ВИ захваљујући повећаној процесорској снази и доступности великих скупова података [64][65]. Употребом LSTM, GRU и RNN архитектура, неуронске мреже су постале применљиве у реалним системима од аутономних возила до управљања сагоревањем у термоенергетским постројењима [66]. У оквиру овог истраживања, примена ВНМ, посебно LSTM архитектуре, ослања се на све наведене математичке основе: изградња модела, његова обука, евалуација и интеграција у реалновременски систем управљања котлом са аутоматским ложењем, што представља пример примене модерне ВИ у реалном инжењерском окружењу [14][19][21][33][34].

2.2. Вештачке неуронске мреже

Иако је сам модел неуронске мреже илустрован још средином двадесетог века, он своју пуну експанзију доживљава тек данас крајем прве четвртине двадест првог века. [1] Концепт вештачких неуронских мрежа (ANN - Artificial Neural Networks) настао је као инспирација биолошким неуронским мрежама у мозгу. Развој овог поља може се поделити у неколико фаза. Прву фазу другачије називамо раним почецима и она обухвата период од 1943. до 1958. године. Тада имамо први модел вештачког неурона који су предложили Варен Мек Клуч (Warren McCulloch) и Валтер Питс (Walter Pitts) давне 1943. године. Они су дефинисали математички модел неурона који је могао да изводи логичке операције [58]. Затим Доналд Хеб (Donald Hebb) 1949. године предлаже правило учења (Hebbian learning), које је поставило основу за касније алгоритме учења у неуронским мрежама [67]. Већ 11 година касније, односно 1958. године Френк Розенблат (Frank Rosenblatt) је развио перцептрон, први модел неуронске мреже који је могао да учи из података [59]. Након овог плодносног периода имамо период стагнације који траје од 1969. до 1980. године у коме Марвин Мински (Marvin Minsky) и Сејмор Паперт (Seymour Papert) показују ограничења перцептрона, посебно његову немогућност да реши нелинеарне проблеме као што је XOR функција [68]. Ово је довело до смањења интересовања за неуронске мреже наредних деценија. Након стагнације у периоду од 1980. до 1990. обнавља се интересовање за ову област када Џон Хопфилд (John Hopfield) 1982. године развија Хопфилдову мрежу, која је коришћена за оптимизацију и меморијске моделе [69]. Већ четири године касније долазимо до увођења вишеслојних неуронских мрежа (MLP - Multi-Layer Perceptron) и алгоритма повратног простирања грешке (Backpropagation), који су развили Румелхарт (Rumelhart), Хинтон (Hinton) и Вилијамс (Williams) 1986. године [70]. Са почетком двехиљадитих улазимо у експанзију и развој дубоког учења. Ово је последица развоја хардвера, посебно графичких процесора (GPU), чиме неуронске мреже почињу да постижу изузетне резултате у обради слика, препознавању говора и природном језику. Џофри Хинтон (Geoffrey Hinton), Јан Ле Кун (Yann LeCun) и Џошуа Бенгио (Yoshua Bengio) развили су методе дубоких неуронских мрежа (Deep Learning), што је омогућило велике напретке у вештачкој интелигенцији [71]. Развој конволуционих неуронских мрежа (CNNs) и рекурентних неуронских мрежа (RNNs) довео је до револуције у машинском учењу и примени ANN у медицини, аутономним возилима и другим областима [72][73]. Употреба вештачких неуронских мрежа забележена је на појединачним случајевима великих котловских система [14][74][75].

2.2.1. Основни концепти и типови ВНМ

Вештачке неуронске мреже (ВНМ) су модели инспирисани биолошким неуронима који обрађују информације кроз слојеве повезаних јединица – вештачких неурона. Основни појмови којима су описане ВНМ су: Неурон (јединица обраде) – основни елемент који прима више улазних сигнала, врши тежинско сабирање и пролази кроз активациону функцију, Тежине (Weights) – вредности које одређују утицај улаза на неурон, Активациона функција – нелинеарна функција која одређује излаз неурона.

Слојевита структура ВНМ се састоји од улазног слоја, једног или више скривених слојева и излазног слоја [76][77][78][79].

Главни типови вештачких неуронских мрежа су: перцептрон, вишеслојни перцептрон, конволуционе неуронске мреже, рекурентне неуронске мреже, генеративне неуронске мреже и трансформер мреже. Перцептрон, односно једнослојни перцептрон је први модел који решава једноставне проблеме, док вишеслојни перцептрон (MLP - Multi-Layer Perceptron) заправо садржи више слојева и користи повратно простирање грешке (Backpropagation) за учење. Конволуционе неуронске мреже (CNN - Convolutional Neural Networks) специјализоване за обраду слика и видео садржаја. Оне садрже конволуционе слојеве који аутоматски откривају обрасце у сликама. Поред овога користе се у медицини, аутономним возилима и рачунарском виду. Рекурентне неуронске мреже (RNN - Recurrent Neural Networks) имају петље у својој архитектури, што омогућава обраду временских секвенци и серијских података [80][81]. Посебан тип су LSTM (Long Short-Term Memory) мреже које решавају проблем краткорочног памћења. Њихова примена се огледа у препознавање говора, машинском преводу[82][83][84]. Генеративне неуронске мреже (GAN - Generative Adversarial Networks) се састоје од генератора и дискриминатора који раде у конкурентском односу [85][86][87][88]. Користе се за генерисање слика, видео садржаја и deepfake технологију. И на крају трансформер мреже (Transformers) засноване су на механизму пажње (attention mechanism) и оне су омогућиле напредак у обради природног језика (GPT, BERT) [89][90][91][92].

Када причамо о неуронским мрежама морамо обрадити неке од појмова. Први од њих је појам обрасца. Образац је распоред дескриптора. Класа шаблона је породица образаца који деле нека заједничка својства. Класе узорка су означене са $\omega_1, \omega_2, \dots, \omega_W$ где је W број класа. Препознавањем образаца од стране машине укључује технике за додељивање образаца њиховим одговарајућим класама, аутоматски и са што мање људске интервенције.

Три уобичајена распореда шаблона која се користе у пракси су вектори (за квантитативне описе) и низови и стабла (за структурне описе). Вектори шаблона су представљени подебљаним малим словима, као што су x , y и z , и имају облик:

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad (3)$$

Природа компоненти вектора шаблона x зависи од приступа који се користи за описивање самог физичког узорка. Илуструјмо примером који је истовремено једноставан и даје осећај историје у области класификације мерења. У класичном раду, Фишхер је известио о употреби тада нове технике назване дискриминантна анализа за препознавање три типа цветова ириса мерењем ширине и дужине њихових латица.

Кључни концепт који треба имати на уму је да одабир дескриптора на којима ће се заснивати свака компонента вектора шаблона има дубок утицај на коначни учинак препознавања објеката заснованог на приступу вектора шаблона [93].

Управо описане технике за генерисање вектора шаблона дају класе шаблона које карактеришу квантитативне информације. У неким применама, карактеристике шаблона се најбоље описују структурним односима. На пример, препознавање отиска прста заснива се на међуодносу карактеристика отиска које се називају минуци. Заједно са њиховим релативним величинама и локацијама, ове карактеристике су примитивне компоненте које описују својства гребена отиска прста, као што су нагли завршеци, гранање, спајање и неповезани сегменти. Проблеми препознавања овог типа, у којима не само квантитативне мере о сваком обележју, већ и просторни односи између обележја одређују припадност класи, генерално се најбоље решавају структуралним приступима. Теоријски приступи препознавању засновани су на употреби функција одлучивања. Нека $x = (x_1, x_2, \dots, x_n)^T$ представља n - димензиони вектор узорка. За W класе шаблона $\omega_1, \omega_2, \dots, \omega_W$, основни проблем у препознавању образаца теоријске одлуке је пронаћи W функције одлучивања $d_1(x), d_2(x), \dots, d_W(x)$ са својством да, ако образац x припада класи ω_i , онда:

$$d_i(x) > d_j(x) \quad j=1,2,\dots, W ; j \neq i \quad (4)$$

Другим речима, за непознати образац x се каже да припада i - тој класи шаблона ако након замене од x у све функције одлучивања, $d_i(x)$ даје највећу бројчану вредност. Везе се решавају произвољно. Граница одлуке која раздваја класу ω_i од ω_j је дато вредностима x за које је $d_i(x) = d_j(x)$ или, еквивалентно, вредностима x за које је

$$d_i(x) - d_j(x) = 0 \quad (5)$$

Уобичајена пракса је да се идентификује граница одлучивања између две класе помоћу једне функције $d_{ij}(x) = d_i(x) - d_j(x) = 0$. Тако је $d_{ij}(x) > 0$ за образац класе ω_i и $d_{ij}(x) < 0$ за образце класе ω_j . Главни циљ дискусије је да се развију различити приступи за проналажење функција одлучивања које задовољавају једначину $d_i(x) > d_j(x)$ $j=1,2,\dots, W ; j \neq i$.

Важну улогу код неуронских мрежа играју технике препознавања засноване на подударану, као и технике засноване на оптималним статистичким класификаторима.

Технике препознавања засноване на подударану представљају сваку класу помоћу вектора узорка прототипа. Непознати образац се додељује класи којој је најближи у смислу унапред дефинисане метрике. Најједноставнији приступ је класификатор минималне удаљености, који, као што му име говори, израчунава (еуклидско) растојање између непознатог и сваког од вектора прототипа. Бира најмању удаљеност да донесе одлуку.

Технике препознавања засноване на оптималном статистичком класификатору дају пробабилистички приступ у препознавању. Као што је тачно у већини области које се баве мерењем и тумачењем физичких догађаја, разматрања вероватноће постају важна у препознавању образаца због случајности под којом се класе обично генеришу [95][96][97][98]. Могуће је извести класификациони приступ који је оптималан у смислу да, у просеку, даје најмању вероватноћу прављења грешака у класификацији.

Приступи препознавању подударанем и оптималним статистичким класификатором заснивају се на коришћењу узорака за процену статистичких

параметара сваке класе образаца. Класификатор минималне удаљености је у потпуности специфициран средњим вектором сваке класе. Слично, Бајесов класификатор за Гаусове популације је у потпуности специфициран средњим вектором и матрицом коваријансе сваке класе [99][100]. Обрасци (познатог чланства у класи) који се користе за процену ових параметара обично се називају обрасци учења, а скуп таквих образаца из сваке класе назива се скуп за учење. Процес којим се скуп за учење користи за добијање функција одлучивања назива се учење или обука.

У ова два приступа учење је једноставна ствар. Обрасци учења сваке класе се користе за израчунавање параметара функције одлучивања која одговара тој класи. Након процене дотичних параметара, структура класификатора је фиксирана, а његов коначни учинак ће зависити од тога колико добро стварне популације образаца задовољавају основне статистичке претпоставке направљене у деривацији методе класификације која се користи [101][102]. Статистичка својства класа образаца у проблему често су непозната или се не могу проценити. У пракси, такви проблеми теоријске одлуке се најбоље решавају методама које дају тражене функције одлучивања директно путем учења. Затим, изношење претпоставки у вези са основним функцијама густине вероватноће или другим пробабилистичким информацијама о класама образаца које се разматрају је непотребно.

Суштина је употреба мноштва елементарних нелинеарних рачунарских елемената (неурони) организованих као мреже које подсећају на начин на који се верује да су неурони међусобно повезани у мозгу. Добијени модели су резервисани под различитим називима, укључујући неуронске мреже, неурокомпјутере, моделе паралелне дистрибуиране обраде, неуроморфне системе, слојевите самоприлагодљиве мреже и конекционистичке моделе. Овде користимо назив неуронске мреже. Користимо ове мреже као средства за адаптивно развијање коефицијената функција одлучивања путем узастопних презентација скупова образаца за обуку.

Подсећамо да интересовање за неуронске мреже датира још од раних 1940-их, што је илустровано радом Мек Клуча и Питса [58] где су предложили моделе неурона у облику бинарних граничних уређаја и стохастичких алгоритама који укључују изненадне 0 - 1 и 1 - 0 промене стања у неуронима као основу за моделирање неуронских система. Резултати Румелхарта, Хитона и Вилијамса [59] који се баве развојем алгоритама за обуку за вишеслојне перцептроне значајно су променили ствари. Њихова основна метода, која се често назива генерализовано делта правило за учење пропагацијом уназад, пружа ефикасан метод обуке за вишеслојне машине. Иако се не може показати да овај алгоритам обуке конвергира решењу у смислу аналогног доказа за једнослојни перцептрон, генерализовано делта правило је успешно коришћено у бројним проблемима од практичног интереса. Овај успех је успоставио вишеслојне машине сличне перцептрону као један од главних модела неуронских мрежа који се тренутно користе.

Перцептрон за две класе шаблона у свом најосновнијем облику учи линеарну функцију одлучивања која дихотомизира два линеарно одвојива скупа за обуку [103]. Одзив овог основног уређаја заснива се на пондерисаном збиру његових улаза:

$$d(x) = \sum_{i=1}^n \omega_i x_i + \omega_{n+1} \quad (6)$$

што је линеарна функција одлучивања у односу на компоненте вектора шаблона. Коефицијенти ω_i , $i = 1, 2, \dots, n, n+1$, звани тежине, модификују улазе пре него што се саберу и унесу у елемент прага. У том смислу, тежине су аналогне синапсама у људском неуронском систему. Функција која пресликава излаз сабирног споја у коначни излаз уређаја назива се активациона функција.

Када је $d(x) > 0$, елемент прага узрокује да излаз перцептрона буде +1, што указује да је образац (k) препознат као да припада класи ω_i . Обрнуто је тачно када је $d(x) < 0$. Када је $d(x) = 0$, k лежи на површини одлучивања која раздваја две класе шаблона, дајући неодређени услов. Граница одлучивања коју имплементира перцептрон добија се изједначавањем претходне једначине са нулом:

$$d(x) = \sum_{i=1}^n \omega_i x_i + \omega_{n+1} = 0 \quad (7)$$

Друга формула која се често користи је повећање вектора шаблона додавањем додатног $n+1$ -вог елемента, који је увек једнак 1, без обзира на чланство у класи. То јест, проширени вектор узорка који се креира од вектора узорка x. Претходна једначина тада постаје:

$$d(y) = \sum_{i=1}^n \omega_i y_i = w^t y \quad (8)$$

Овај израз је обично погоднији у смислу нотације. Међутим, без обзира на коришћену формулацију, кључни проблем је пронаћи w коришћењем датог скупа вектора шаблона за обуку из сваке од две класе.

Код вишеслојних неуронских мрежа се фокусирамо на функције одлучивања о проблемима препознавања вишекласних образаца, независно од тога да ли су класе одвојиве или не, и укључују архитектуру које се састоје од слојева перцептронских рачунарских елемената.

Основна архитектура модела неуронске мреже који се разматра састоји се од слојева структурно идентичних рачунарских чворова (неурона) распоређених тако да се излаз сваког неурона у једном слоју доводи у улаз сваког неурона у следећем слоју [104][105][106][107]. Број неурона у првом слоју, који се зове слој A, је N_A . Често, $N_A = n$, што представља димензионалност вектора улазног узорка. Број неурона у излазном слоју, који се назива слој Q, означава се са N_Q . Број N_Q једнак је W, односно броју класа шаблона које је неуронска мрежа обучена да препозна. Мрежа препознаје вектор узорка x као припадајући класи ω_i ако је и излаз мреже "висок" док су сви остали излази "ниски", као што је објашњено у следећој дискусији.

Сваки неурон има исти облик као модел перцептрона о коме смо раније говорили, са изузетком да је функција активације која се тешко ограничава замењена меко ограничавајућом "сигмоидном" функцијом [108]. Диференцијалност дуж свих

путева неуронске мреже је потребна у развоју правила обуке. Следећа функција активације сигмоида има неопходну диференцијацију:

$$h_j(I_j) = \frac{1}{1 + e^{-\frac{I_j + \theta_j}{\theta_v}}} \quad (9)$$

Када се користи ова посебна функција, систем даје високо читавање за било коју вредност I_j веће од θ_j . Слично, систем даје ниско читавање за било коју вредност I_j , мању од θ_j . Сигмоидна активациона функција је увек позитивна и може да достигне своје граничне вредности од 0 и 1 само ако је улаз за активациони елемент бесконачно негативан или позитиван, респективно. Из тог разлога, вредности близу 0 и 1 (нпр. 0,05 и 0,95) дефинишу ниске и високе вредности на излазу неурона. У принципу, различите врсте активационих функција могу се користити за различите слојеве или чак за различите чворове у истом слоју неуронске мреже. У пракси, уобичајени приступ је коришћење истог облика активационе функције у целој мрежи [109][110][111].

Током тренинга, прилагођавање неурона у излазном слоју је једноставна ствар јер је познат жељени излаз сваког чвора. Главни проблем у обучавању вишеслојне мреже лежи у подешавању тежине у такозваним скривеним слојевима, односно, у оним који нису излазни слој [112][113][114][115].

Обука пропагацијом уназад: Почињемо тако што ћемо се концентрисати на излазни слој. Укупна грешка на квадрат између жељених одговора, r_q и одговарајућих стварних одговора, O_q , чворова у (излазном) слоју Q, је

$$E_Q = \frac{1}{2} \sum_{q=1}^{N_q} (r_q - O_q)^2 \quad (10)$$


где је N_q број чворова у излазном слоју, а број се користи ради лакшег бележења за касније узимање деривата [109][110][111].

Све наведене једначине чине основу генерализованог делта правила за обуку вишеслојне вештачке неуронске мреже. Процес обуке започиње иницијализацијом мреже са произвољним, али међусобно различитим почетним вредностима тежина. У сваком итеративном кораку, примена генерализованог делта правила одвија се у две основне фазе:

1. Фаза пропагације унапред (forward propagation) где се улазни вектор за обуку представља мрежи и пропагира кроз све слојеве до излазног слоја. У сваком чвору (неурону) израчунава се излазна вредност O, на основу активационе функције и пондерисаног збирног улаза. У излазном слоју, добијене вредности O се упоређују са жељеним вредностима (тзв. циљним излазима), на основу чега се израчунава грешка за сваки излазни чвор.

2. Фаза повратног простирања (back propagation) код које се сигнали грешке затим пропагирају уназад кроз мрежу. Током овог процеса врши се ажурирање пондера (тежина) и тежина пристрасности (bias), у складу са градијентом грешке. Пристрасности се третирају као додатне тежине које модификују јединични улаз у сваки чвор.

Уобичајена пракса током обуке је праћење глобалне мрежне грешке, као и грешака на нивоу појединачних образаца. Током успешне обуке, вредност грешке се постепено смањује са сваким новим циклусом (итерацијом), а мрежа конвергира ка стабилном скупу тежина, које показују минималне флукуације при даљој обуци. Критеријум успешности класификације током обуке подразумева да чвор у излазном слоју који одговара правилној класи има највишу излазну вредност, док су сви остали излазни чворови на значајно нижим вредностима. Након завршене обуке, током нормалног рада мреже, све путање повратних информација се искључују. Улазни узорак се пропагира унапред кроз мрежу, а класификација се врши на основу излазног чвора са највишом нумеричком вредношћу. Уколико је више од једног чвора високо активирано или ниједан није довољно активан, образац се може означити као погрешно класификован или му се може доделити класа са највишом излазном вредношћу [2][19][21][116].



Слика бр:5. Основни типови вештачких неуронских мрежа

2.2.2. Улога вештачких неуронских мрежа у модерној индустрији

Савремена индустрија се налази у процесу дубоке технолошке трансформације, познате као Индустрија 4.0, у оквиру које доминантну улогу преузимају напредне методе обраде података, аутоматизације и интелигентног управљања [117][118]. У том контексту, вештачке неуронске мреже (ВНМ) представљају један од најперспективнијих и најприменљивијих облика вештачке интелигенције. Захваљујући својој способности да моделују нелинеарне односе, уче из података и препознају сложене обрасце, ВНМ се све више користе као алат за анализу и оптимизацију процеса у различитим индустријским секторима. Примена ВНМ у индустријским окружењима омогућава реализацију функција као што су интелигентно управљање производним процесима, контрола квалитета, предиктивно одржавање, оптимизација потрошње енергије и откривање аномалија у реалном времену. Овакав приступ омогућава доношење

информисаних и адаптивних одлука на основу објективне анализе података, што директно утиче на повећање продуктивности, смањење трошкова и унапређење укупне ефикасности система.

Вештачке неуронске мреже (ВНМ) представљају једну од кључних области у домену вештачке интелигенције, а њихова концепција је инспирисана начинима обраде информација у људском мозгу [119][120]. У савременој индустрији, примена ВНМ довела је до значајних унапређења у областима као што су аутоматизација, оптимизација процеса, предиктивно одржавање и анализа великих скупова података. Једна од најважнијих карактеристика ВНМ је способност анализе сложених и високодимензионалних података, уз идентификовање скривених образаца на основу којих се могу доносити одлуке и предвиђања. У контексту индустријске производње, примена ВНМ омогућава оптимизацију производних процеса, што резултира ефикаснијим коришћењем ресурса, смањеном потрошњом енергије и побољшаном оперативном поузданошћу. Према резултатима релевантних истраживања, имплементација дубоких неуронских мрежа у индустријске системе може довести до повећања продуктивности и до 20%, уз истовремено смањење технолошког отпада и елиминацију бројних извора неефикасности [121][122][123].

Једна од значајних примена вештачких неуронских мрежа у индустријским системима односи се на предиктивно одржавање (Predictive Maintenance – PdM) [124]. За разлику од традиционалних приступа који се ослањају на периодичне интервенције и рутинске сервисе, PdM системи засновани на ВНМ користе реалновременску анализу података добијених са сензора ради идентификације образаца који указују на потенцијалне кварове пре него што до њих заиста дође. Овакав приступ омогућава благовремену интервенцију и оптимално планирање одржавања, што резултира значајним смањењем оперативних трошкова, повећаном поузданошћу опреме и спречавањем неочекиваних прекида у производном процесу. Према резултатима релевантних истраживања, примена ВНМ у оквиру PdM система може довести до смањења времена застоја машина за 30–50%, као и до продужетка њиховог радног века [125][126][127].

У енергетском сектору, вештачке неуронске мреже све више се користе као алат за интелигентну контролу и оптимизацију процеса сагоревања, прогнозу потрошње енергије и унапређење ефикасности система заснованих на обновљивим изворима енергије. Захваљујући способности да обрађују велике количине података и уче на основу историјских вредности, ВНМ омогућавају боље разумевање динамике сложених енергетских процеса и доношење прецизнијих одлука у реалном времену. Конкретно, примена ВНМ у системима управљања термоелектранама може резултирати смањењем емисије угљен-диоксида (CO₂) за 10–15%, уз истовремено повећање енергетске ефикасности целокупног постројења [128]. Ови резултати указују на значајан потенцијал интеграције ВНМ у стратегије за енергетску транзицију, смањење угљеничног отиска и побољшање одрживости постојећих енергетских система.

Вештачке неуронске мреже су се профилисале као неизоставан инструмент у савременој индустрији, омогућавајући напредну анализу података, оптимизацију технолошких процеса и развој аутономних система управљања [129][130][131]. Њихова примена резултира значајним економским уштедама и смањењем негативног утицаја на животну средину, што је потврђено кроз бројна емпиријска и теоријска истраживања. Са даљим развојем технологије и повећањем доступности рачунарских ресурса, очекује се

да ће улога ВНМ у унапређењу индустријских процеса и одрживости производних система постајати све значајнија, доприносећи укупном технолошком напретку и глобалним еколошким циљевима [132][133][134].

2.2.3. Вештачке неуронске мреже у оптимизацији процеса сагоревања

У последњим деценијама, вештачке неуронске мреже (ВНМ) показале су велики потенцијал у примени на сложене, нелинеарне и динамичке системе, као што су процеси сагоревања у котловима. Захваљујући својој способности да уче из података и препознају обрасце који нису унапред експлицитно дефинисани, ВНМ су погодне за примену у управљању и оптимизацији параметара као што су однос горива и ваздуха, температура, притисак и емисија гасова [19][21][34][135][136].

Најједноставнија форма ВНМ је вишеслојна перцептронска мрежа (MLP), која се састоји од улазног, једног или више скривених и излазног слоја. Излаз сваког неурона у слоју дефинише се као:

$$y_j = f\left(\sum_{i=1}^n w_{ij}x_i + b_j\right) \quad (11)$$

где су: x_i улазне вредности (мерени параметри: температура, O_2 , CO , NO_x , проток горива), w_{ij} тежинске везе између неурона, b_j пристрасност (bias), $f(\cdot)$ активациона функција (нпр. сигмоидна, ReLU, tanh), а y_j излаз неурона.

Циљ оптимизације сагоревања се може формулисати као проблем регресије или класификације [137][138]. На пример, регресија би била предвиђање идеалног односа ваздух - гориво на основу улазних параметара, док би класификација била идентификација услова сагоревања као „ефикасно“, „непотпуно“, „опасно“ итд. Математички, модел ВНМ приближава функцију:

$$\hat{y} = f_{NN}(x, \theta) \quad (12)$$

где је: $x \in \mathbb{R}^n$ вектор улазних параметара, $\hat{y} \in \mathbb{R}^m$ предикција (степен искоришћења, емисија), θ скуп параметара мреже (тежине и пристрасности).

Обука ВНМ подразумева минимизацију функције губитака над скупом података:

$$J(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (13)$$

где је N број узорака, а ажурирање параметара се врши градијентним методом (нпр. стохастички градијентни спуст, Adam) [139].

Након обуке, ВНМ може да предвиђа идеалне параметре сагоревања у реалном времену, идентификује аномалије у раду котла, даје препоруке за корекцију односа


воздуха и горива, смањи емисију CO, NO_x и PM за 15–30%, и повећа искоришћење топлоте за 10–20% у односу на класичне регулаторе [14][19][135].

У техничкој пракси, ВНМ се интегришу у систем надзора и управљања (SCADA, PLC) као:

$$u(t) = f_{NN}(x(t)) \quad (14)$$

чиме постају део затворене повратне спреге, где мрежа аутоматски предвиђа и шаље оптималне вредности актуаторима (нпр. вентилу за гориво, регулатору протока ваздуха).

ВНМ захваљујући својој способности учења из података и адаптацији у реалном времену, имају изузетан потенцијал за примену у индустрији, посебно у контексту оптимизације процеса сагоревања. Употреба ВНМ у овим системима доводи до побољшаног управљања, смањених губитака енергије, прецизнијег подешавања параметара рада и смањења емисије штетних гасова. Сумирано, теоријска полазишта представљена у овом поглављу постављају основ за развој сопственог модела вештачке неуронске мреже у даљем току истраживања, чији је циљ унапређење енергетске ефикасности и еколошке одрживости котлова са аутоматским ложењем путем интелигентног управљања заснованог на ВИ.



Слика бр:6. Архитектура модела са LSTM мрежом

3. Нове могућности примене вештачке интелигенције

Примена вештачких неуронских мрежа у моделовању и управљању процесом сагоревања у котловима са аутоматским ложењем представља конкретан пример узајамне повезаности теоријских основа вештачке интелигенције и њихове практичне примене. Уместо класичних PID регулатора, ВНМ омогућавају адаптивно и интелигентно управљање, прилагођено променљивим условима рада, квалитету горива и еколошким захтевима. Модел може самостално учити из података у реалном времену, предвидети понашање система и донети оптималне одлуке, што значајно унапређује енергетску ефикасност и смањује емисије штетних гасова.

Истраживања у овој области фокусирају се на оптимизацију процеса сагоревања, контролу емисије штетних гасова и побољшање укупне поузданости система. ВНМ се користе за моделирање и контролу процеса сагоревања у котловима, омогућавајући прецизно подешавање параметара као што су однос горива и ваздуха, температура и проток [140][141]. Ова оптимизација доводи до ефикаснијег сагоревања и смањења потрошње горива. На пример, истраживање спроведено од стране Симоновића 2016. године показује да примена ВНМ може побољшати краткорочно предвиђање и анализу система даљинског грејања, што директно утиче на ефикасност рада котлова [142]. Примена ВНМ у системима за контролу котлова може значајно смањити емисију штетних гасова као што су NOx и CO. Адаптивни контролни системи засновани на ВНМ могу прилагодити рад котла у реалном времену како би се минимизовале емисије, истовремено одржавајући оптималну ефикасност. У студији спроведеној у Пљевљима, анализом емисија из градских котларница на угаљ, коришћене су ВНМ за анализу сложених енергетских система, што је допринело бољем разумевању и контроли емисија [143]. ВНМ се користе за предикцију потенцијалних кварова и одржавање котлова. Анализом података у реалном времену, ови системи могу идентификовати аномалије и предложити превентивне мере, чиме се смањују трошкови одржавања и повећава поузданост система. Иако конкретне студије у овој области нису директно наведене у доступним изворима, примена ВНМ у предиктивном одржавању је добро документована у другим индустријским секторима и може се екстраполирати на котлове са аутоматским ложењем [144]. Једна од предности ВНМ је њихова способност учења и прилагођавања променљивим условима рада. Ово је посебно корисно у котловима са аутоматским ложењем, где варијације у квалитету горива или условима сагоревања могу утицати на перформансе. Адаптивни системи контроле засновани на ВНМ могу се прилагодити овим променама, одржавајући оптималан рад. Истраживање објављено у Зборнику радова ITOP19 указује на потенцијал примене ВНМ у пројектовању дигиталних аутомата, што може бити од значаја за развој адаптивних контролних система у котловима [145].

Котао је један од три главна уређаја термо енергетског система, а број котловских јединица је у сталном порасту. Котлови се развијају ка великом капацитету и високим параметрима [144][146]. За велике или веома велике котлове на угаљ (суперкритичне јединице), ако дође до нестабилности сагоревања током сагоревања, топлотна ефикасност сагоревања котла ће се директно смањити, а створиће се велики

број нуспроизвода загађења. Могу се десити чак и неке екстремне ситуације, као што су гашење шупљине пећи и велике безбедносне незгоде у пећи [147][148][149].

Једна од примена неуронских мрежа у котловима са аутоматским паљењем дата је у раду Цанга 2020. године, где се врши термоенергетска дијагностика котлова коришћењем компјутерског препознавања објеката и неуронских мрежа. Компјутерска обрада слике и технологија неуронске мреже примењују се за дијагностику топлотне енергије котловских постројења, тј. е., дијагноза сагоревања пламена, да се потврди њихова ефикасност и супериорност. Методе: Прво, ендоскопски систем за видео аквизицију високе температуре типа ИД-НК се користи за прикупљање слика сагоревања пламена. Друго, слике су претходно обрађене методом сиве скале и методом средњег филтрирања. Затим се издвајају карактеристике параметара сагоревања пламена. Унапређен је алгоритам неуронске мреже и успостављен је модел сагоревања котла заснован на побољшаном алгоритму неуронске мреже. Дакле, добија се база за одлучивање о сагоревању. Коначно, побољшани модел неуронске мреже се упоређује са традиционалним моделом неуронске мреже и моделом 5-4 како би се потврдила његова валидност. Резултати: Експерименти су открили да је побољшани модел неуронске мреже супериорнији од традиционалног модела неуронске мреже. У међувремену, његова тачност и поузданост су релативно већи од оних код традиционалног модела. Поред тога, један узорак такође троши краће време рада, које износи 0,0075 секунди. У поређењу са моделом 5-4, побољшани модел неуронске мреже има одређене предности, тј. е., његова стопа тачности и поузданост су релативно веће, које износе 91,28% односно 96,69%, међутим, један узорак троши дуже време рада од модела 5-4. Закључак: Експерименталним истраживањем је утврђено да применом рачунарске обраде слике и технологије неуронске мреже на дијагностику топлотне енергије котловских постројења може се ефикасно утврдити стабилност сагоревања пламена, благовремено разумети стање сагоревања пламена, а самим тим и дијагностиковати топлотну енергију. Стога, они имају вредности за апликације [150][151][152].

Још један пример примене неуронских мрежа у котловима са аутоматским ложењем дат је у раду Чен Јиа из 2022. године. Описана је метода насумичне спектралне атенуације која је предложена за смањење поремећаја садржаја влаге. Калибрациони спектри су реплицирани и помножени случајним коефицијентима слабљења да би се унеле информације о могућим сметњама. Сви симулирани ослабљени спектри су коришћени за обуку квантитативног модела вештачке неуронске мреже. У поређењу са директним моделирањем без случајног спектралног пригушења, коефицијент детерминације је побољшан са $-3,4291$ на $0,7102$, а средња квадратна грешка је смањена са $1,8709\%$ на $0,4786\%$ у анализи садржаја испарљивих материја. Резултати су показали довољну способност методе да детектује узорке поремећене влагом без додатног претходног третмана узорка и побољша брзину ЛИБС анализе [153].

Један од најзначајнијих и најобимнијих радова који описује примену неуронских мрежа у управљању котлом је рад Ханг Та Вена из 2021. године. Сврха његове студије је да користи два модела вештачке интелигенције (АИ) за предвиђање састава сингаса у фиксном слоју узлазног струјања гасификатора за гасификацију пиринчаних љуски. Мешавине ваздуха и паре су агенси за гасификовање. У овом раду, брзина храњења пиринчаних љуски је константна, док проток ваздуха и паре варира у сваком случају. Разматрање различитих радних услова даје јасно поређење између

гасификације ваздуха и паре-ваздуха. Овде се истражују ефекти температуре реактора, протока паре и ваздуха и односа паре и биомасе. Концентрације запаљивих гасова као што су водоник, угљен моноксид и метан у сингасу се повећавају када се користи мешавина паре и ваздуха. Два модела вештачке интелигенције, а то су вештачка неуронска мрежа (ANN) и регресија за повећање градијентав (GBR), примењена су за предвиђање састава сингаса користећи експерименталне податке. Анализирано је укупно 74 скупа података. Састав пет гасова (CO, CO₂, H₂, CH₄ и H₂) је предвиђен ANN и GBR моделима. Коефицијенти детерминације крећу се од 0,80 до 0,89 за модел ANN, док се вредност R² креће од 0,81 до 0,93 за GBR модел. У овој студији, GBR модел надмашује модел ANN-а заснован на његовој ансамбл техници која користи вишеструке слабе ученике. Као резултат тога, GBR модел је убедљивији у предвиђању састава сингаса од ANN модела који се разматра у овом истраживању [154][155].




График бр:1. Поређење експериментално добијених вредности концентрације CO са подацима добијеним предикцијом ANN и GBR моделима [154]

Безбедан и стабилан рад котлова често одређује сигуран и еколошки прихватљив рад целе јединице. Најдиректнији показатељ стабилности сагоревања је пламен сагоревања. Због тога је неопходно пратити стање сагоревања пламена у комори пећи у реалном времену како би се обезбедио сигуран и економичан рад котлова. Начин успостављања безбедног и поузданог система сагоревања угља у пећи која штеди енергију постао је критично питање [156]. Мониторинг систем је до сада био само фаза праћења да ли су честице угља у стању упаљене или угашене. Иако се систем за праћење слике пламена у котлу може увести како би се обезбедила техничка подршка за аутоматско праћење и одређивање стабилности сагоревања, праћење стабилности пламена захтева од релевантног особља да врши посматрања на лицу места. Због тога је стабилизација слике пламена увек била један од хитних проблема који је требало

решавати у аутоматском праћењу стања сагоревања котлова. Научно и ефикасно решење овог проблема је важно за обезбеђивање безбедног и економичног рада котлова [157][158][159]. Иако постоје системи са бољим резултатима (GBR модел), коришћење знања из области неуронских мрежа за примену у контроли сагоревања у котловима са аутоматским паљењем би у великој мери унапредило степен искоришћења горива, обезбедило стабилнији рад котлова, што би довело до значајних уштеда енергије, а самим тим би помогло у очувању животне средине, смањењу емисије штетних гасова, смањењу количине пепела и смањењу потрошње биомасе и фосилних горива којих је сваким даном све мање на планети Земљи [19][21][34].

Вештачке неуронске мреже (ВНМ) се све више примењују у индустријским процесима ради оптимизације, предикције, аутоматизације и побољшања ефикасности система. Њихова примена је нарочито значајна у контроли и аутоматизацији процеса. ВНМ се користе за аутоматско подешавање параметара у сложеним индустријским системима, као што су хемијски реактори, термоелектране и производни погони, [160] затим у индустрији нафте и гаса, где ВНМ оптимизују процесе бушења и рафинеријске операције [161]. Поред тога видне су примене у металуршкој индустрији, где ВНМ предвиђају особине материјала на основу процесних параметара [162]. Друга значајна примена је код предиктивног одржавања и надзора опреме. Овде ВНМ анализирају вибрације, температуру и друге параметре како би предвиделе кварове у машинама и смањиле неочекиване застоје [163]. У авио-индустрији, неуронске мреже предвиђају хабање турбинских лопатица и смањују трошкове одржавања [164]. Даље, ВНМ се користе за динамичко управљање енергетским системима у фабрикама и зградама ради минимизације потрошње електричне енергије [165]. Неизоставно је поменути и употребу у електроенергетском сектору, где ВНМ предвиђају потрошњу електричне енергије и побољшавају стабилност мреже [166]. Треће важна улога ВНМ је у контроли квалитета и предикцији дефеката у аутомобилској индустрији, где ВНМ анализирају податке са производних линија и предвиђају потенцијалне дефекте у возилима [167]. Затим у фармацеутској индустрији, неуронске мреже предвиђају стабилност лекова и анализирају хемијске реакције [168]. Четврто значајно коришћење ВНМ је у роботизици и код индустријских робота. Овде, ВНМ се користе за адаптивну контролу робота, омогућавајући им да уче из окружења и изводе сложене задатке [169]. Поред овога имамо и коришћење у логистици, работи са ВНМ оптимизују кретање у магацинима и аутоматски сортирају пакете [170][171][172].

Нове могућности примене вештачке интелигенције у индустријским и енергетским системима отварају простор за иновације које до сада нису биле довољно истражене, посебно у домену котлова мале и средње снаге. У оквиру овог истраживања, по први пут је примењена вештачка интелигенција, тачније вештачке неуронске мреже, на котловима са цилиндричном конструкцијом ложишта, конкретно моделима АТИ Терминг ОЗОН 35 и ОЗОН 55. До сада су алгоритми машинског учења углавном били примењивани на велике индустријске термоенергетске системе уз очигледне позитивне ефекте који су приказани у табели бр: 1 и на графику бр: 2. Системи мањег капацитета су занемарени у истраживањима и практичној примени употребе вештачке интелигенције у оптимизацији рада, а упркос значајном уделу у укупној потрошњи енергије у домаћинствима и мањим објектима. Ово истраживање представља пионирски покушај да се управо у такве системе уведе интелигентна адаптивна контрола, чиме се

унапређује њихова енергетска ефикасност, смањују емисије штетних гасова и продужава радни век опреме, без потребе за скупим хардверским модификацијама. На тај начин, рад представља значајан допринос примени вештачке интелигенције у реалним системима малих и средњих капацитета, чиме се шири домен примене савремених алгоритама машинског учења.

Табела бр:1. Ефекти примене ВНМ – квантитативни приказ

Параметар	Пре ВНМ	После ВНМ	Побољшање
Степен искоришћења енергије (η)	78%	88%	+10%
Емисија CO (mg/m^3)	160	110	-31.25%
Емисија NO _x (mg/m^3)	320	260	-18.75%
Просечна потрошња горива (kg/h)	145	127	-12.41%
Варијабилност температуре котла ($^{\circ}\text{C}$)	± 12	± 5	-58.3%




График бр:2. Ефекти примене вештачких неуронских мрежа.

4. Оптимизација физичко-хемијских процеса у котловима са аутоматским ложењем


Сагоревање је хемијски процес оксидације горива, у коме се хемијска енергија горива претвара у топлотну енергију. Овај процес игра кључну улогу у раду котлова, јер директно утиче на њихову ефикасност и емисију штетних гасова [173]. Сагоревање у котловима може се категорисати у три главне фазе: припрему горива, процес сагоревања и одвођење продуката сагоревања. Најважнији параметри који утичу на овај процес су однос горива и ваздуха, температура сагоревања и време задржавања продуката сагоревања у комори [174]. Неоптимални параметри могу довести до повећаних емисија загађујућих материја, као што су NOx, CO и PM 2.5 и PM 10 честица [175]. Савремене технологије управљања процесом сагоревања све више укључују примену вештачке интелигенције и машинског учења, што омогућава прецизнију контролу параметара и побољшање енергетске ефикасности [176]. Применом вештачких неуронских мрежа, могуће је динамички оптимизовати однос ваздуха и горива, чиме се постиже већи степен искоришћења енергије и смањење емисија.

4.1. Преглед физичких и хемијских аспеката сагоревања

Сагоревање је сложен термохемијски процес који укључује интеракцију између физичких и хемијских механизма. Ови механизми утичу на динамику сагоревања, ефикасност енергетске конверзије и емисију продуката сагоревања [177]. Физички аспекти сагоревања обухватају ток горива и ваздуха, мешање реагенаса, пренос топлоте и масе, као и фазне промене горива. Ови фактори утичу на брзину и стабилност пламена, што је од суштинског значаја за правилно функционисање котлова [173]. Добро пројектована комора за сагоревање осигурава равномерну дистрибуцију температуре и минимализује формирање локализованих врелих тачака које могу довести до непотпуног сагоревања. Хемијски аспекти сагоревања укључују оксидационе реакције угљоводоничних једињења. Реакције сагоревања могу бити потпуне или непотпуне, у зависности од присуства довољне количине кисеоника и термодинамичких услова [178]. Потпуно сагоревање доводи до стварања угљен-диоксида (CO₂) и водене паре (H₂O), док непотпуно сагоревање може произвести угљен-моноксид (CO), чађ и друге загађујуће материје. Модерне методе оптимизације процеса сагоревања, укључујући вештачке неуронске мреже, омогућавају бољу предикцију и контролу физичко-хемијских параметара у реалном времену, чиме се значајно смањују емисије штетних гасова и побољшава енергетска ефикасност [179][180].

Дрвни пелет није једно хемијско једињење, већ је састављен од различитих органских супстанци, највећим делом укључујући целулозу, лигнин и хемицелулозу. Међутим, највећи део дрвета чини целулоза, која има приближну хемијску формулу C₆H₁₀O₅. Целулоза је природни макромолекул који настаје фотосинтезом [181]. Она је у природи најраспрострањеније угљениково једињење на Земљи. То је угљени хидрат (полисахарид) с великом релативном молекуларном масом. Састоји се од анхидрида глукозе. Целулоза припада групи полисахарида који представљају до 80% суве материје биљног света. Други важни састојци дрвета, као што су лигнин и хемицелулоза, имају различите хемијске формуле и доприносе механичким и структурним својствима дрвета.


Сагоревање дрвних пелета подразумева хемијску реакцију у којој дрво (или пелети као производ компримованог дрвета) реагује са кисеоником из ваздуха, производећи енергију у виду топлоте, као и неке пратеће производе као што су угљен-диоксид (CO_2), водена пара (H_2O) и, у мањој мери, други гасови и чврсти остаци као што су пепео. Типична хемијска реакција сагоревања пелета може бити представљена једноставним једначинама. За органске материје као што су дрвни пелети (који су углавном угљен-хидрати), реакција сагоревања може бити написана као:



У наведеној хемијској реакцији $C_xH_yO_z$ представља угљоводонично једињење које подлеже процесу сагоревања, док p , q , m и n представљају коефицијенте изједначења хемијске једначине. Уколико процес сагоревања није избалансиран долази до непотпуног сагоревања и тада се појављују додатни штетни продукти као што су угљен-моноксид (CO), честице пепела, азотни оксиди (NO_x), сумпорни оксиди и др.


Физички процеси који се дешавају током сагоревања дрвних пелета су сушење, пиролиза и сагоревање гасова. Сушење се одвија на температурама до $\sim 150^\circ\text{C}$. Дрво садржи влагу, која мора испарити пре него што започне право сагоревање. У овом процесу нема хемијских реакција, већ само долази до фазног прелаза воде у гасовито стање. Затим долази до пиролизе која се довија на температурама од 150°C до 500°C . У овом процесу органске компоненте дрвета (целулоза, хемицелулоза, лигнин) разлажу се под утицајем топлоте на гасовите и чврсте продукте. Највећи део дрвета претвара се у запаљиве гасове, док преостали чврсти део остаје као угаљ.

Хемијска реакција пиролизе целулозе:



Након пиролизе дрвног пелета долазимо до сагоревања запаљивих гасова (CO , H_2 , CH_4 , други угљоводоници) у којој се у реакцији са кисеоником ослобађа топлота.

Следаћа егзотермна реакција је реакција сагоревања угљеника. Иначе угљеник је један од остатака пиролизе. Поред угљеника имамо и минерални пепео. У недостатку кисеоника, а приликом сагоревања угљеника може доћи до стварања угљен-моноксида.



Минерали у дрвету, као што су калцијум (Ca), калијум (K), магнезијум (Mg) и фосфор (P), остају као чврсти остаци у облику пепела.

4.2. Типови котлова и њихове карактеристике

Котао представља објект у коме се топлотна енергија добијена сагоревањем органских горива, посредством грејних површина, предаје води. Котао представља отворени термодинамички систем кроз чије се контролне границе (замишљене површине које одвајају котао од околне средине) у котао доводе гориво, ваздух и напојна вода и одводе продукти сагоревања и водена пара. Дакле, са термодинамичке тачке гледишта, котао је размењивач топлоте са разноврсним грејним површинама код којих су носиоци топлоте продукти сагоревања, а пријемници топлоте топла вода, врела вода,

сувозасићена пара, прегрејана пара и ваздух. У термоенергетским системима, котлови функционишу на принципима топлотне размене, где се хемијска енергија горива претвара у топлотну енергију сагоревањем, а затим у корисну енергију у облику загрејане течности или гаса [182]. Основни процеси који се одвијају у котловима могу се објаснити применом Првог и Другог закона термодинамике. Први закон термодинамике (принцип очувања енергије) указује да се укупна енергија не може створити ни уништити, већ само преносити са једног облика у други [183]. У случају котлова, хемијска енергија горива се оксидацијом претвара у топлоту, која се преноси на радни флуид. Радни флуид већине котлова је вода, или вода са додацима који побољшавају њена термодинамичка својства, спречавају корозију, смањују стварање каменца и побољшавају пренос топлоте, као што су инхибитори корозије, антипенушави агенси и средства за кондиционирање воде. Други закон термодинамике описује ентропијске промене током процеса сагоревања и размене топлоте, истичући да пренос топлоте увек иде од топлијег ка хладнијем медијуму [184]. Овај закон је кључан за одређивање степена искоришћења енергије у котловским системима и за оптимизацију ефикасности процеса. Грејне површине котла су пројектоване тако да омогуће максималну ефикасност преноса топлоте. У конвенционалним парним котловима, овај пренос се одвија у три главна режима: конвекцијом, кондукцијом и зрачењем [185]. Код модерних котлова, употреба материјала са високим коефицијентом топлотне проводљивости и оптимизованих конструкционих решења додатно побољшава ефикасност размене топлоте. Основни елементи котла су делови у којима се одвија процес трансформације хемијске енергије горива у топлоту продуката сагоревања и процес преноса топлотне енергије пријемнику топлоте.

Дакле, за котао се може рећи да представља енергетски трансформатор чији је задатак да на што ефикаснији начин, сагоревањем горива, трансформише у себи садржану воду у водену пару или само повиси температуру воде, и то у оба случаја на притисак већи од атмосферског притиска. Ово условљава и прву поделу котлова према врсти радног тела, флуида који стварају на излазу и то на: парне и вреловодне (топловодне) котлове. Према врсти произведене водене паре парне котлове делимо на: котлове са засићеном и котлове са прегрејаном воденом паром. Како је пара добијена у котлу носилац потенцијалне енергије, у виду повишеног притиска и температуре, а као што знамо прегрејана пара има вишу потенцијалну енергију од засићене, онда су котлови са прегрејаном паром економичнији у погледу уштеде горива, мање потрошње паре и њеним бољим искоришћењем у потрошачима, мањом кондензацијом услед губитака топлоте у дугим пароводима, итд [186].

Са гледишта величине притиска имамо две групе котлова. Котлови прве групе, који подлежу државном надзору су:

1. котлови ниског притиска до 16 бара,
2. котлови средњег притиска од 16 до 25 бара,
3. котлови високог притиска од 25 до 60 бари и
4. котлови врло високог притиска од 60 до 225 бари.

Котлови друге групе који не подлежу државном надзору су котлови најнижег притиска до 1,5 бара, који се углавном примењују код кућних инсталација етажног грејања.

Поред прописаног притиска, према Правилинику о техничким нормативима за стабилне посуде под притиском, котлови који не подлежу државном надзору треба да задовоље и услов да је производ притиска и запремине радног флуида виши од 0,3 бар x м², и да се запремина радног флуида не мења при контакту са атмосфером.

Према својој намени и начину уградње котлови могу бити: стабилни, полустабилни и покретни. Начин уградње зависи од врсте потрошача који користи радни флуид, као и од тога где се и како он користи.

Према садржају воде са којом раде, све котлове можемо поделити на две групе: на котлове са великим и на котлове са малим садржајем воде.

У погледу конструкционог облика и извођења сви котлови се могу поделити на: котлове са цевима, котлове са водогрејним цевима (нагнутим или стрмим-вертикалним) и котлове специјалних конструкција [187].

За рад котла потребно је гориво из којег ће се сагоревањем одузимати енергија и предаваће се радном телу – води. Горивом се назива свака материја која кад се запали брзо сагорева развијајући топлоту, дакле свака она материја која у себи има елементе са којима ће кисеоник из ваздуха ступити у хемијску реакцију и образовати хемијско једињење путем брже оксидације пропраћене стварањем топлоте. Да би се те материје примењивале у индустрији као горива:

- 1.) морају постојати у великим количинама,
- 2.) морају бити јефтине,
- 3.) морају бити погодне за ложење у ложиштима,
- 4.) морају својом чврстином омогућавати транспортовање на велике даљине,
- 5.) морају бити способне за магационисање (да дужим стајањем на ваздуху не мењају свој облик и састав и да не подлежу samozапаљењу).

Поред тога, корисно је, ако се лако пале, и то већ на температури од 300° С до 400°С, да су и производи његовог сагоревања нешкодљиви по људе, животиње и постројења. Ове услове задовољавају следеће материје: дрво, слама жита, кукурузна саша, угаљ, природни гас итд. Међутим, материје које сагоревају нагло (тренутно), тј. експлозивно (бризантно), не спадају у горива јер сагоревају сувише брзо, поред тога су скупе и опасне због експлозије (праскави гас). Исто тако не спадају у горива ни материје код којих је оксидација врло спора, на пример рђање гвожђа [187].

Главни делови котловског постројења су ложиште, делови котловског агрегата, котловска арматура, апаратура и д р. Ложиште представља онај део котла у коме гориво сагорева. Гориво се ставља на решетку, на којој оно сагорева, а испод њега се налази пепеоник. У пепеоник пада пепео, несагорљиви остатак при сагоревању горива. Простор ложишта у коме гориво сагорева назива се ложишни простор. Величина ложишног простора изражава се у кубним метрима. Производи сагоревања (врели гасови)

образовани у ложишном простору одводе се димним каналима у димњак, а из њега у атмосферу.

Топлота произведена при сагоревању горива у ложишту пролази кроз зидове грејних површина котла, преноси се на воду, загрева је. Што се тиче саме конструкције котла, он може бити израђен у виду ваљка, или у виду комбинације цилиндра и цеви. Овом комбинацијом цилиндра и цеви повећава се активна површина кроз коју пролази топлота од врелих гасова сагоревања на воду. Тиме се постиже брза продукција водене паре и уштеда у гориву. Ако у цевима струје врели гасови сагоревања, тада се оне називају грејне цеви. Ако се у цевима налази вода, тада се називају водогрејне цеви. Цилиндрични котао се израђује од челичних лимова који су састављени закивцима у чврсту, нераздвајну везу заваривањем или ковањем, а евентуално и комбинованим начином: закивањем и заваривањем. Он се састоји углавном из три дела: омотача, предњег и задњег дела.

Физички процеси у котлу подлежу законима термодинамике. Да би се могао поставити употребљив математички модел термодинамичког процеса у котлу потребно је направити претпоставку. Претпоставићемо да температура у котлу не зависи од просторних координата у котлу, него је распоред температуре у котлу хомоген тако да процес загревања воде у котлу можемо сматрати као процес са концентрисаним, а не дистрибуираним параметрима. Иако, на први поглед врло груба претпоставка, она даје веома добре и употребљиве резултате. Уз ову претпоставку закон о одржању енергије за котао у нестационарном стању гласи:

$$P_{ul} - P_{iz} = \frac{\partial}{\partial t} E_i \quad (18)$$

Разлика између улазног и излазног топлотног флукса (снаге) у котлу пропорционална је промени његове унутрашње енергије.

Улазна снага P_{ul} у овом случају износи:

$$P_{ul} = \psi \cdot P + m_k c_w \cdot \vartheta \quad (19)$$

Ψ - параметар који показује положај котловског термостата; вредност $\Psi = 0$ одговара угашеном, а $\Psi = 1$ укљученом горионику;

m_k - проток воде кроз котао одређен положајем зазора регулационог вентила x_1 ($0 < x_1 < 1$); вредност $x_1 = 0$ одговара затвореном вентилу и протоку $m_k = 0$, $x_1 = 1$ отвореном вентилу и протоку $m_k = m_0$, где је m_0 константни масени проток у колу потрошача - радијатора;

c_w - специфична топлота воде.,

Изразна снага, P_{iz} за котао је:

$$P_{iz} = m_k c_w \vartheta_k + \varepsilon P \quad (20)$$

а код прорачуна унутрашње енергије строго и коректно гледано, морамо имати увид да при загревању котла, загрева се поред воде и сам котао, па би у унутрашњу енергију котла требало узети у обзир и ову чињеницу:

$$E_i = M_{wk} c_w \vartheta_k \quad (21)$$

Међутим, како је специфична топлота материјала (најчешће челик) од којег је котао направљен за ред величине мања од специфичне топлоте воде, а масе воде и метала су поредиве, те се ова корекција може, али и не мора, изоставити [188].

4.3. Технике оптимизације у контроли сагоревања

Оптимизација и контрола сагоревања су кључни фактори за побољшање ефикасности, смањење емисије штетних гасова и продужење века трајања котловске опреме [189]. Правилним подешавањем параметара сагоревања, као што су однос горива и ваздуха, температура сагоревања и дистрибуција топлоте, могуће је значајно смањити губитке енергије и побољшати ефикасност котлова [190]. Технике оптимизације могу се поделити на традиционалне методе контроле, које укључују ручну регулацију, PID контролу и мерење вишка кисеоника, као и напредне методе и технологије, које обухватају системе са повратном спрегом, вештачку интелигенцију (AI), предиктивне алгоритме и флуидно-динамичке симулације [191]. Употреба савремених сензора и IoT уређаја додатно побољшава управљање сагоревањем, омогућавајући континуирану анализу параметара и аутоматско прилагођавање система у реалном времену [192].

Процес сагоревања у термотехничким системима, као што су котлови, представља сложен термодинамички и хемијски процес који укључује трансформацију хемијске енергије горива у топлотну енергију. Контрола и оптимизација овог процеса имају за циљ повећање енергетске ефикасности, смањење емисије штетних гасова и продужетак радног века опреме. Основа сваког процеса сагоревања је стехиометријски однос ваздуха и горива:

$$\lambda = \frac{L_{\text{стварни}}}{L_{\text{теоријски}}} \quad (22)$$

где је:

λ — коефицијент ваздуха ($\lambda < 1$ означава непотпуно сагоревање),

$L_{\text{стварни}}$ је количина дотура ваздуха,

$L_{\text{теоријски}}$ је количина ваздуха потребна за потпуно сагоревање.

Циљ оптимизације је задржати вредност $\lambda \approx 1.05-1.20$ у пракси, како би се обезбедило потпуно, али енергетски ефикасно сагоревање.

Енергетска ефикасност котла може се приближно изразити као:

$$\eta = \frac{Q_{\text{корисно}}}{Q_{\text{унето}}} = 1 - \frac{Q_{\text{губици}}}{Q_{\text{унето}}} \quad (23)$$

где је:

η — степен корисног дејства (ефикасност),

$Q_{\text{корисно}}$ је корисна добијена топлота,

$Q_{\text{унето}}$ је топлотна вредност унетог горива,

$Q_{\text{губици}}$ су губици (димни гасови, зрачење, несагорело гориво).

Математички, емисија CO и NO_x зависи од локалне температуре, количине доступног кисеоника и времена задржавања:

$$E_{\text{NO}_x} \propto f(T, \lambda, t) \quad (24)$$

$$E_{\text{CO}} \propto \frac{1}{\lambda} e^{-T} \quad (25)$$

где су: T температура у зони сагоревања, λ је однос ваздух гориво, а t време реакције.

У пракси се на основу мерења концентрација гасова врши корекција уноса ваздуха и горива.

У контексту алгоритамске контроле, циљ је минимизација функције губитака:

$$J(\theta) = \sum_{i=1}^n (y_i - \hat{y}_i(\theta))^2 \quad (26)$$

где су $J(\theta)$ функција губитака (нпр. квадратна грешка у мерењу), y_i су стварне вредности (нпр. стварна температура, емисија), $\hat{y}_i(\theta)$ су предвиђене вредности модела, θ параметри система (пондери, коефицијенти регулације).

Ажурирање параметара се врши помоћу градијентног спуста:

$$\theta \leftarrow \theta - \eta \nabla J(\theta) \quad (27)$$

где су η стопа учења, а $\nabla J(\theta)$ градијент функције губитака.

У реалним котловским системима, мерење параметара попут температуре сагоревања (T), концентрације кисеоника (O_2), емисије CO и NO_x , протока горива, омогућавају примену алгорита који се у реалном времену прилагођавају:

$$u(t) = f(T(t), \text{O}_2(t), \text{CO}(t), m_{\text{горива}}(t)) \quad (28)$$

чиме се врши динамичка контрола сагоревања кроз алгоритме засноване на ВНМ или фази логици.

Традиционалне методе контроле се ослањају на класичне приступе мерења и регулисања параметара сагоревања. То су системи управљања који се користе више деценија, па чак и вековима уназад. Ове методе могу се грубо поделити на ручну и периодичну регулацију. Ручна подешавања и периодична регулација ослањају се на искуство оператера (ложача). У овом систему, ложач врши периодична мерења и прилагођава параметре као што су проток ваздуха и горива. Овај метод је једноставан, али субјективан, што може довести до флукуација у процесу сагоревања и смањене ефикасности [193]. Пропорционално-интегрално-деривативна (PID) контрола представља другу традиционалну и широко коришћену методу контроле котлова. У овој методи користе се сензори за мерење температуре, притиска и протока ради аутоматског

прилагођавања параметара сагоревања. PID регулатор одржава задате вредности, али не узима у обзир сложене динамике система, што може довести до кашњења или прекомерне корекције у процесу сагоревања [194]. Контрола односа гориво-ваздух је још један традиционални метод, где се однос прилагођава на основу мерења вишка кисеоника у димним гасовима. Ово је кључно за спречавање непотпуног сагоревања и смањење емисије CO и NOx. Према истраживањима, правилно подешавање овог односа може довести до значајног повећања енергетске ефикасности и смањења штетних емисија [195]. Мерење и подешавање вишка кисеоника користи анализаторе гасова за мерење садржаја O₂ у издувним гасовима и оптимизацију довода ваздуха. Овај метод омогућава смањење губитака топлоте услед прекомерног сагоревања и побољшање укупне ефикасности система [173].

Напредне методе и савремене технологије које се користе у сврху управљања горењем обухватају технологије и алгоритме за аутоматску анализу и оптимизацију сагоревања. Ове методе могу се разврстати на неколико начина. Први модел који је већ добио значајну примену су системи са повратном спрегом (Closed-Loop Control Systems), који користе сензоре и анализу димних гасова за континуирану аутоматску корекцију параметара сагоревања. Ови системи смањују флукуације, побољшавају ефикасност и омогућавају стабилније радне услове котлова [188]. Други коришћени метод обједињује неуронске мреже и вештачку интелигенцију (AI) у контроли сагоревања, код којих машинско учење и AI алгоритми анализирају велике количине података у реалном времену и оптимизују процес сагоревања [196]. У оквиру примене AI технологија може се користити модел предиктивне контроле (Model Predictive Control - MPC), који користи математичке моделе процеса за предвиђање понашања система и оптимизацију параметара унапред. Овај метод омогућава боље управљање динамиком система и смањење трошкова одржавања и потрошње енергије [197]. Даље, флуидно-динамичке симулације (CFD – Computational Fluid Dynamics) се користе за детаљно моделирање понашања флуида у комори за сагоревање, што омогућава откривање локалних прегревања и побољшање уједначености сагоревања. CFD методе су посебно корисне за оптимизацију дизајна котлова и побољшање ефикасности процеса сагоревања [198]. Интеграција IoT (Интернет ствари) и cloud система омогућава прикупљање података о раду система и њихово слање у cloud ради даље анализе и оптимизације. Ово омогућава даљински надзор, детекцију кварова у раној фази и предиктивно одржавање система, чиме се повећава поузданост и продужава век трајања опреме [199]. Ове методе, у комбинацији са савременим методама мерења, као што су инфрацрвени и ласерски сензори за анализу сагоревања, омогућавају фино подешавање система и максималну ефикасност. Ови напредни сензори омогућавају тачно мерење температуре, концентрације кисеоника и других кључних параметара, што побољшава аутоматску контролу процеса [200].

4.3.1. Важност оптимизације процеса сагоревања котлова

Оптимизација процеса сагоревања у топлотним системима, нарочито у котловима са аутоматским ложењем, представља један од кључних фактора за повећање енергетске ефикасности, смањење трошкова експлоатације и минимизовање негативног

утицаја на животну средину. Савремени котлови омогућавају напредну контролу процеса сагоревања, али постизање максималних перформанси захтева примену интелигентних алгоритама управљања, пре свега из домена машинског учења и вештачких неуронских мрежа (ВНМ).

Основне предности оптимизације сагоревања обухватају:

- повећање енергетске ефикасности система,
- смањење емисије штетних гасова (CO , NO_x , $\text{PM}_{2,5}$ и PM_{10} честице),
- умањење потрошње горива и оперативних трошкова,
- продужетак радног века опреме,
- унапређење степена аутоматизације и интелигентно управљање процесима.

Оптимизацијом параметара као што су однос ваздуха и горива, температура и притисак у зони сагоревања, омогућава се максимално коришћење енергетског потенцијала горива. Ово резултује већом топлотном искористивошћу котла и смањеним енергетским губицима. Насупрот томе, непотпуно сагоревање доводи до повећане емисије угљен-моноксида, азотних оксида и суспендованих честица, што негативно утиче на квалитет ваздуха и представља значајан еколошки ризик. Применом напредних оптимизационих техника, заснованих на ВНМ, могуће је значајно редуковати емисије загађујућих материја, чиме се доприноси очувању животне средине и усклађености са актуелним еколошким регулативама. Ефикасније сагоревање подразумева и смањену потребу за горивом при једнаком термичком учинку, што је од посебне важности за велике потрошаче у индустрији и сектору домаћинства [201][202][203].

Контролисано и равномерно сагоревање значајно умањује ризик од формирања наслага чађи, као и појаву корозивних процеса на термички оптерећеним површинама, чиме се продужава радни век котловских компоненти. Применом вештачких неуронских мрежа (ВНМ) и алгоритама машинског учења омогућена је динамичка адаптација параметара рада котла у реалном времену, у складу са променљивим улазним условима, као што су квалитет горива и спољашња температура. Овакав приступ омогућава прецизнију контролу процеса сагоревања, што директно утиче на побољшање енергетске ефикасности и укупних оперативних перформанси система.

Оптимизација процеса сагоревања представља суштински елемент модерног приступа управљању енергетским системима, са циљем унапређења ефикасности, смањења оперативних трошкова и минимизације еколошког отиска [201][202][203]. Употреба савремених технологија као што су ВНМ и машинско учење представља важан корак ка изградњи одрживих и интелигентних енергетских решења, која обезбеђују истовремене економске и еколошке бенефите [204][205][206]. Према подацима релевантних истраживања, примена интелигентних система заснованих на машинском учењу може довести до побољшања ефикасности сагоревања у распону од 10% до 20%, уз истовремено смањење емисије штетних гасова (CO , NO_x , PM) за 15% до 30% у односу на традиционалне методе управљања [207][208].

5. Методологија истраживања

Методологија овог истраживања заснива се на систематској примени вештачких неуронских мрежа (ВНМ) као централног математичког и алгоритамског оквира за апроксимацију, предикцију и оптимизацију параметара сагоревања у котловима са аутоматским ложењем. У оквиру овог рада, по први пут је примењена вештачка интелигенција управо на котловима са цилиндричном конструкцијом ложишта, и то на конкретним моделима АТИ Терминг ОЗОН 35 и ОЗОН 55, који припадају категорији котлова мале и средње снаге. До сада су алгоритми машинског учења и интелигентне контроле углавном били резервисани за велике индустријске системе, док је примена у мањим системима упркос њиховом значајном уделу у укупној потрошњи енергије била занемарена. Ово истраживање управо ту празнину настоји да попуни, показујући да и мањи котлови могу имати знатне користи од имплементације интелигентних алгоритама, уз побољшање енергетске ефикасности, смањење емисија штетних гасова и веће стабилности у раду, без потребе за скупом хардверском модификацијом [14][19][21][33][135].

Вештачке неуронске мреже се третирају као вектор-функционални оператори који пресликавају скуп улазних физичко-хемијских параметара (попут температуре димних гасова, притиска у ложишту, влажности и квалитета горива) у управљачке одлуке у реалном времену, са циљем максимизације енергетске ефикасности и смањења емисије штетних гасова.

Истраживање је структурисано у четири главне фазе:

1. Анализа и израда математичког модела и избор архитектуре ВНМ

У овој фази се формализује улазно-излазни модел процеса сагоревања на основу емпиријских и теоријских података. На основу литературе и постојећих решења, разматрају се архитектуре као што су feedforward, RNN, LSTM и GRU мреже, због способности обраде временских серија и динамичких зависности. Поред тога, у циљу оптимизације хиперпараметара (број неурона, дубина мреже, стопа учења), примењују се еволуциони алгоритми, попут генетских алгоритама (GA).

2. Експериментално прикупљање података

Уграђени систем на бази Ардуино платформе користи се за мерење релевантних параметара на реалном котлу са аутоматским ложењем. Подаци укључују температуре димних гасова и ложишта, проток ваздуха, притисак, концентрацију РМ честица, влажност и тип горива. Сви подаци се затим нормализују и структурирају ради припреме за обуку модела.

3. Обучавање и имплементација модела

Обука ВНМ се реализује у програмском окружењу Python (TensorFlow/Keras), а имплементација у контролни систем се спроводи преко Матлаб платформе и Ардуино микроконтролера. Након иницијалне обуке на синтетичким и историјским подацима, модел се убацује у радни режим и тестира у реалном времену. Обучени модел динамички управља параметрима као што су довод ваздуха и регулација горионика.

4. Валидација модела и анализа резултата

У последњој фази, резултати предикција и управљачке одлуке модела упоређују се са стварним мерењима. Перформансе модела се вреднују применом метрика као што су MSE, MAE и R^2 . Врши се процена утицаја на ефикасност сагоревања, стабилност процеса и емисију штетних гасова. Поред тога, спроводи се анализа трошкова и потенцијалне применљивости модела на ширем скупу термоенергетских система.



Слика бр:7. Методолошке фазе истраживања

Циљ методолошког оквира није само у техничкој изградњи система, већ у формалној конструкцији оригиналног модела управљања који, ослоњен на савремене математичке парадигме и алгоритме машинског учења, омогућава напредно управљање процесима у термоенергетским постројењима.

Дакле, методологија овог истраживања базира се на примени вештачких неуронских мрежа као основног математичког и алгоритамског модела за апроксимацију, предикцију и оптимизацију динамичких параметара процеса сагоревања у котловима са аутоматским ложењем. ВНМ се овде третирају као нелинеарни вектор-функционални оператори који трансформишу скупове улазних података (температура, влажност, притисак, садржај честица) у излазне одлуке у виду оптималних вредности управљачких параметара система. Истраживање је структурисано кроз етапе у којима се формулише улазно-излазни модел процеса сагоревања на основу емпиријских података. Затим се ради трансформација података у облик погодан за обуку неуронске мреже (нормализација, дискретизација, етикетирање). Након тога се врши избор архитектуре ВНМ (нпр. feedforward, recurrent или LSTM), дефинисање функције грешке и примене алгоритама оптимизације као што су стохастички градијентски спуст (SGD) или Adam. Следећи корак је имплементација обуке и валидације модела на реалним подацима, прикупљеним из експерименталног система. Следи анализа перформанси модела кроз метрике као што су средњеквадратна грешка (MSE), MAE и коефицијент корелације (R). На крају, ту је интеграција обученог модела у систем управљања сагоревањем ради реално-временске регулације.

Акценат овог поглавља није само на техничкој реализацији уређаја, већ на епистемолошки утемељеној изградњи и формалној верификацији модела неуронске мреже. Овај модел се користи као инструмент апстракције и оптимизације процеса који је иначе физички, хемијски и технолошки сложен, а који се не може једноставно аналитички моделовањем обухватити.

Истраживање се спроводи кроз неколико кључних фаза: одабир модела, мерења на реалном котлу, имплементацију модела на котао и валидацију модела. Прва фаза истраживања обухвата избор одговарајуће архитектуре неуронске мреже, као и математичких модела за оптимизацију процеса сагоревања. На основу анализа литературе и постојећих решења, разматрају се рекурентне неуронске мреже (RNN), са

посебним освртом на LSTM (Long Short-Term Memory) и GRU (Gated Recurrent Unit), због њихове способности да обрађују временске серије и сложене нелинеарне зависности у динамичким системима. Поред архитектуре неуронске мреже, примењује се и генетски алгоритам (GA) у циљу оптимизације хипер-параметара мреже, као што су број неурона, дубина слојева и брзина учења. Одабрани модел се иницијално тестира коришћењем синтетичких података и постојећих база података са сличних индустријских система. Друга фаза истраживања подразумева прикупљање података мерењем на реалном котлу са аутоматским ложењем, како би се обезбедио репрезентативан скуп података за обуку и тестирање неуронске мреже. Подаци који се прикупљају обухватају температуру димних гасова, концентрацију кисеоника и РМ честица у издувним гасовима, проток ваздуха за сагоревање, притисак у ложишту, врсту и квалитет горива (влажност, калоријску вредност), температуру ложишта, радне течности, ваздуха, влажност и притисак спољњег ваздуха. Уграђују се сензори који континуирано мере параметре сагоревања и прави урађај за прикупљање података на база Ардуино платформе. Подаци се обрађују и нормализују ради припреме за тренинг неуронске мреже. Након обуке модела на основу добијених експерименталних података, спроводи се имплементација у реалном систему. Ова фаза укључује: интеграцију обучене неуронске мреже у управљачки софтвер котла, развија се алгоритам у Python-у (коришћењем TensorFlow/Keras библиотека), и након тога се читав модел убацује у Матлаб ради даљег имплементирања на физички уређај. Неуронска мрежа се интегрише са PLC системом котла ради управљања параметрима сагоревања. Овај корак није било могуће извести, па је читав управљачки процес пребачен на Ардуино контролер. RNN модел обрађује улазне податке у реалном времену и доноси одлуке о оптималним подешавањима котла (регулација довода ваздуха, подешавање снаге горионика, адаптација према квалитету горива). Систем примењује адаптивне корекције засноване на променама услова у окружењу. Први тестови се обављају у контролисаним условима. Анализирају се перформансе и врши фино подешавање параметара модела. Последња фаза истраживања односи се на валидацију обучене неуронске мреже и њену процену у реалним условима. Резултати модела се упоређују са реалним мерењима параметара котла у различитим условима рада. Анализира се тачност и стабилност предикција. Врши се процена утицаја на ефикасност и емисије гасова. Испитује се утицај оптимизације на потрошњу горива, стабилност процеса сагоревања и емисију штетних гасова. Поређењем са стандардним методама контроле врши се анализа предности и ограничења модела. Оцењује се колико је систем применљив на различите типове котлова са аутоматским ложењем. Анализирају се трошкови имплементације и дугорочног одржавања.

Датом методологијом омогућава се развој интелигентног система за аутоматску контролу параметара сагоревања котлова, базираног на рекурентним неуронским мрежама и генетским алгоритмима. Овај приступ пружа побољшану енергетску ефикасност, смањене емисије гасова и већу аутономију у раду котлова, чиме се доприноси развоју паметних индустријских система у области термоенергетике.

5.1. Анализа и израда математичког модела и избор архитектуре ВНМ

Циљ ове фазе истраживања је формализација улазно-излазног модела процеса сагоревања у котловима са аутоматским ложењем и избор одговарајуће архитектуре вештачке неуронске мреже (ВНМ) која ће служити као основа за моделовање, апроксимацију и оптимизацију процеса. Полазећи од емпиријских мерења прикупљених у реалним условима и заснованих на мултиваријантним временским серијама, као и на теоријским сазнањима из термодинамике и механике флуида, дефинише се систем у облику сложене динамичке нелинеарне мапе:

$$y(t) = \mathcal{F}(x(t), x(t-1), \dots, x(t-k)) \quad (29)$$

где је $x(t) \in \mathbb{R}^n$ вектор улазних параметара у временском тренутку t , као што су температура, влажност, притисак, концентрација гасова и честица, док је $y(t) \in \mathbb{R}^m$ излазни вектор који представља управљачке или процењене вредности као што су доза горива, брзина вентилатора или емисионе вредности. Функција $\mathcal{F}$ представља непознату нелинеарну трансформацију коју је потребно апроксимирати. У овом раду, трансформација $\mathcal{F}$ се моделује вештачком неуронском мрежом $\hat{\mathcal{F}}$, чији је циљ да минимизује грешку $\mathcal{L}$ апроксимације у смислу неке функције грешке, најчешће средњеквадратне грешке (MSE):

$$\mathcal{L}(\theta) = \frac{1}{N} \sum_{t=1}^N \|y(t) - \hat{\mathcal{F}}(x(t); \theta)\| \quad (30)$$

где је θ скуп параметара мреже (тежине и пристрасности), а N број узорака [209][210][211]. На основу анализа временске структуре података и присуства одложених утицаја у систему, разматране су следеће архитектуре ВНМ:

Feedforward Neural Network (FNN): применљива за моделовање стационарних улазно-излазних односа, али недовољно ефикасна за динамичке временске зависности.

Recurrent Neural Network (RNN): погодна за секвенцијалне податке, али подложна проблему нестајања/експлодирања градијената током обуке.

Long Short-Term Memory (LSTM): проширење RNN архитектуре које укључује механизме контроле протока информација (гејтове), што омогућава учење дугорочних зависности и ефикасну регулацију стања у динамичким системима.

Gated Recurrent Unit (GRU): компактнија верзија LSTM мреже, са мање параметара, при чему се задржава добра способност праћења временских серија.

Након детаљне евалуације архитектура на валидирајућем скупу података, рекурентне мреже (посебно LSTM) показале су супериорне резултате у моделовању процеса сагоревања у односу на остале разматране архитектуре. LSTM архитектура је омогућила стабилнију обуку и бољу генерализацију захваљујући својој способности да задржи релевантне информације кроз дуге временске интервале, чиме је значајно смањена средњеквадратна грешка (MSE) у односу на FNN и обичне RNN мреже. GRU архитектура је такође постигла задовољавајуће резултате, али је LSTM мрежа показала

бољи одзив у условима већих динамичких варијација и нелинеарности, што је пресудно у моделовању система сагоревања са променљивим својствима горива. Поред избора архитектуре, посебна пажња посвећена је избору хиперпараметара мреже (број неурона у слојевима, број скривених слојева, стопа учења, врста функције активације, број узорака по итерацији и број епоха). У циљу оптимизације ових параметара, примењени су еволуциони алгоритми, пре свега генетски алгоритам (GA), који се показао као ефикасан у глобалној претрази простора параметара без ослањања на градијенте. Основне особине са предностима и ограничењима су представљене у табели бр: 2.

Табела бр:2. Особине четири најзначајније архитектуре вештачких неуронских мрежа.

Архитектура мреже	Основна намена и својства	Предности	Ограничења
Feedforward Neural Network (FNN)	Моделује стационарне (нединамичке) улазно-излазне односе. Подразумева једносмерни ток информација.	Једноставна за имплементацију; погодна за регресију и класификацију статичких података.	Није ефикасна за моделовање временских зависности и динамичких процеса.
Recurrent Neural Network (RNN)	Пројектована за обраду секвенцијалних података; у стању је да чува информације из претходних корака.	Омогућава моделовање временских зависности и циклуса у подацима.	Проблеми са нестајањем и експлодирањем градијената; тешко учи дугорочне зависности.
Long Short-Term Memory (LSTM)	Побољшана верзија RNN-а, са унутрашњим гейтовима који контролишу проток информација.	Ефикасна у учењу дугорочних зависности; стабилнија обука; широко примењивана у динамичким системима.	Комплекснија структура и већи број параметара; захтева више ресурса.
Gated Recurrent Unit (GRU)	Компактна варијанта LSTM-а; комбинује неке гейтове у једну јединицу ради једноставности и брже обуке.	Мање параметара, бржа обука, често постиже сличне резултате као LSTM.	Може бити нешто мање прецизна у случајевима веома сложених дугорочних зависности.

Процедура избора архитектуре и хиперпараметара је следећа:

- Дефинисање сета могућих архитектура и параметара;
- Грађење почетне популације хиперпараметара (за GA);
- Евалуација перформанси сваке јединке (мреже) на валидационом скупу;
- Примена оператора селекције, укрштања и мутације;
- Понављање процеса до конвергенције или достизања жељене прецизности.

Трагајући за могућим математичким моделима, дошло се до закључка да је модел који се користи мултиваријатан и нелинеаран. С друге стране, природа прикупљених података у облику временских серија намеће динамички дискретни временски модел за овај систем. Из тог разлога, тражени модел је следећег облика:

$$y(t) = f(Y(t, D_Y), X_1(t, D_1), X_2(t, D_2) \dots) \quad (31)$$

где $f: \mathbb{R}^{D_Y + D_{X_1} + D_{X_2} + \dots} \rightarrow \mathbb{R}$ је континуирана нелинеарна мапа која представља тражени модел, у којој је:

$$Y(t, D_Y) = (y(t-1), y(t-2), \dots, y(t-D_Y)) \quad (32)$$

$$X_1(t, D_{X_1}) = (x_1(t-1), x_1(t-2), \dots, x_1(t-D_{X_1})) \quad (33)$$

$$X_2(t, D_{X_2}) = (x_2(t-1), x_2(t-2), \dots, x_2(t-D_{X_2})) \quad (34), \text{ итд}$$

су вектори узорака података који делују као аргументи функције f .

Проблем који се прво решава је одређивање димензија вектора $Y, X_1, X_2, \dots$, итд, $D_Y, D_1, D_2, \dots$ који су редоследи ауторегресивних и трансрегресивних зависности модела система. Суштина овог метода је у израчунавању вероватноће да прикупљене податке производи систем чији је модел линеарна мапа.

$$p_D(\varepsilon, \delta) = P(d(y(t_1), y(t_2)) < \varepsilon \mid d(X(t_1, D), X(t_2, D)) < \delta) \quad (35)$$

Ова вероватноћа се, у ствари, процењује на основу броја повољних догађаја коришћењем индикаторске функције

$$\Psi_\varepsilon(\zeta) = \begin{cases} 1 & |\zeta| \leq \varepsilon \\ 0 & |\zeta| > \varepsilon \end{cases} \quad (36)$$

Дакле, одавде израчунавамо:

$$\psi_D(\varepsilon, \delta) = \sum_{1 \leq i < j \leq N_D} \Psi_\varepsilon(y(i) - y(j)) \prod_{k=1}^{D_Y} \Psi_\delta(y(i-k) - y(j-k)) \prod_{k=1}^D \Psi_\delta(x(i-k) - x(j-k)) \quad (37)$$

и из ових израчунавања, вероватноћа се процењује на основу:

$$p_D(\varepsilon, \delta) = \frac{\psi_D(\varepsilon, \delta)}{\psi_D(\delta)} \quad (38)$$

Да би се олакшала процена редоследа, процењене вероватноће су обједињене у кумулативни комплемент вероватноће:

$$\rho_D = \int_0^\infty (1 - p_D(\varepsilon)) d\varepsilon \quad (39)$$

и коначно диференцијални прираштај предвидљивости:

$$\Delta_D = \frac{(\rho_{D-1} - \rho_D)}{\rho_0} \quad (40)$$

Ова вредност се смањује како се претпостављени ред модела D повећава, све док не достигне нулту вредност. Након тога, за прикупљене податке, предвиђање излаза не може се побољшати повећањем вредности D . Стога смо дошли до закључка да је ова вредност D исправан ред модела [4][19][21][33][135].

Када се моделирају редоследи ауторегресивне компоненте D_Y , и трансрегресивних компоненти D_1, D_2 итд, су процењене, модел динамичке регресије је конструисан из неуронске мреже која врши нелинеарно пресликавање f . У овом случају, коришћена је структура трослојне перцептронске мреже, $y = f(X)$, где су сви одложени улазни и излазни узорци комбиновани у улазни вектор $X = (Y, X_1, X_2)^T$. Ова функција је идентификована коришћењем података прикупљених мерењима на систему.

Мапирање које врши неуронска мрежа се израчунава као:

$$y = (X) = \sigma_3(W_3(\sigma_2(W_2\sigma_1(W_1X) - W_{1,0}) - W_{2,0}) - W_{3,0}) \quad (41)$$

У овом моделу, нелинеарне сигмоидне функције σ_1 σ_2 σ_3 су, за све слојеве, хиперболички тангенс $\sigma_1(s) = \sigma_2(s) = \sigma_3(s) = th(s)$.

Синаптички и активациони коефицијенти неуронске мреже, представљени матрицама W_1 , $W_{1,0}$ W_2 , $W_{2,0}$ W_3 , $W_{3,0}$, оптимизовани су коришћењем методе повратног ширења градијента грешке.

Линеарни дискретни временски системи могу бити представљени моделом:

$$y(t) = \sum_{k=1}^{D_y} a_k y(t-k) + \sum_{k=1}^{D_u} b_k u(t-k) \quad (42)$$

Узимањем N узорака сигнала $y(t)$ и $u(t)$, од неког прошлог временског тренутка $t-N-1$ до тренутног временског тренутка t , једначина (42) може бити преписана у матричном облику

$$0 = Y_{yu}(D_y, D_u) = (Y(D_y):U(D_u))A \quad (43)$$

У којој је:

$$Y(D_y) = \begin{pmatrix} y(t) & y(t-1) & \cdots & y(t-D_y) \\ y(t-1) & y(t-2) & \cdots & y(t-D_y-1) \\ \vdots & \vdots & \ddots & \vdots \\ y(t-N_D) & y(t-N_D-1) & \cdots & y(t-D_y-N_D) \end{pmatrix} \quad (44)$$

$$U(D_u) = \begin{pmatrix} u(t-1) & u(t-2) & \cdots & u(t-D_u) \\ u(t-2) & u(t-3) & \cdots & u(t-D_u-1) \\ \vdots & \vdots & \ddots & \vdots \\ u(t-N_D-1) & u(t-N_D-2) & \cdots & u(t-D_u-N_D) \end{pmatrix} \quad (45)$$

$$A = \begin{pmatrix} -1 & a_1 & a_2 & \cdots & a_{D_y} & b_1 & b_2 & \cdots & b_{D_u} \end{pmatrix}^T \quad (46)$$

Овде $N_D = \max(N-1-D_y, N-1-D_u)$, и ова вредност треба да буде довољно већа (нпр. барем за ред величине) од $D_y + D_u$.

Различите методе за одређивање реда таквих линеарних система захтевају почетну прецизност D_y и D_u , форматирањем матрице $Y_{yu}(D_y, D_u)$ и процена ранга ове матрице, или матрице корелираних временских серија, $R_{yu}(D_y, D_u) = Y_{yu}^T(D_y, D_u)Y_{yu}(D_y, D_u)$.

Резултат овог процеса је оптимизована архитектура ВНМ способна да са високом прецизношћу апроксимира процес сагоревања и предлага оптималне вредности параметара у реалном времену. У наставку рада, ова архитектура ће бити имплементирана и обучена на реалним подацима добијеним из експерименталног система, уз примену одговарајућих алгоритама обуке као што су стохастички

градијентски спуст (SGD) или Adam оптимизатор, у зависности од изабране архитектуре и својстава сета података.

Резултати који директно проистичу из ове фазе су објављени у раду „Optimization of Artificial Intelligence Algorithm Selection: PIPRECIA-S Model and Multi-Criteria Analysis“ (Popović et al., 2025) [21] у коме је представљен методолошки оквир за систематско оцењивање и рангирање различитих алгоритама вештачке интелигенције (ВИ). Овај модел омогућава објективну процену алгоритама на основу више критеријума, укључујући ефикасност, флексибилност, лакоћу имплементације, стабилност и скалабилност. Аутори су показали како идентификовати предности и слабости различитих ВИ алгоритама, што омогућава доносиоцима одлука да изаберу најприкладније алгоритме за специфичне примене. У контексту истраживања примене неуронских мрежа и ВИ у управљању котловима са аутоматским ложењем, овај приступ је од посебног значаја. Избор одговарајућег алгорита ВИ за управљање процесом сагоревања захтева разматрање више фактора, као што су прецизност предвиђања, отпорност на променљиве услове, захтеви за хардвером и способност реално-временске адаптације. Ово истраживање директно омогућава систематско поређење различитих алгоритама, као што су LSTM, GRU и RNN, у контексту ових критеријума, што доприноси оптималном избору алгорита за конкретне услове рада котлова. Поред тога, аутори рада истичу да је рад на избору алгоритама и модела резултат дугогодишњег истраживања у области примене ВИ у термоенергетским постројењима, односно котлова са аутоматским ложењем типа ОЗОН 35 и ОЗОН 55. Овај приступ не само да унапређује разумевање различитих ВИ алгоритама, већ и доприноси развоју стратегија за њихову имплементацију у различитим индустријама. Узимајући у обзир специфичности котлова типа ОЗОН 35 и ОЗОН 55, као и потребу за енергетском ефикасношћу и смањењем емисија без скувих реконфигурација хардверске инфраструктуре, примена ових истраживања представља вредан алат за избор најприкладнијег ВИ алгорита. Овај приступ омогућава доносиоцима одлука да донесу информисане одлуке засноване на објективним критеријумима, што је од суштинског значаја за успешну интеграцију ВИ у управљање процесима сагоревања у котловима са аутоматским ложењем [14][21][33][57][135].

Допринос овог приступа огледа се у томе што се избор алгорита не базира искључиво на метрици тачности, већ се узима у обзир целокупан контекст примене, од сложености имплементације до стабилности и одрживости решења. Такође, овакав модел одабира алгоритама омогућава преносивост анализе на друге типове котлова или сличне индустријске системе, чиме истраживање добија шири значај за научну и стручну заједницу, а што је показано у наведеном раду.

5.1.1. Образложење избора рекурентне архитектуре ВНМ

У контексту динамичких, временски зависних процеса као што је сагоревање у котловима са аутоматским ложењем, класичне фидфорвард мреже (FFNN) показују значајна ограничења, јер не поседују унутрашњу меморију и не могу моделовати временску зависност између улазних података. У оваквим системима, параметри као

што су температура, влажност, притисак, проток ваздуха и хемијски састав димних гасова не делују изоловано, већ у снажно корелисаним и секвенцијалним обрасцима. Управо због тога, модел који обрађује ове податке мора да буде способан да „памти“ претходна стања, што је суштинска карактеристика рекурентних неуронских мрежа (RNN).

Нека је $x(t) \in \mathbb{R}^n$ улазни вектор у временском тренутку t , а $h(t) \in \mathbb{R}^m$ скривено стање мреже. Основна RNN једначина има форму:

$$h(t) = \sigma_h(W_x + W_h h(t-1) + b_h) \quad (47)$$

$$y(t) = \sigma_y(W_y h(t) + b_y) \quad (48)$$

где су σ_h и σ_y активационе функције (нпр. $\tanh$, ReLU), а W_x , W_h , W_y матрице тежина. Овај формализам омогућава мрежи да интерно моделује скривене променљиве које одражавају динамичко понашање система. Основни RNN модели пате од проблема експоненцијалног затупљивања или експлозије градијента, што онемогућава ефикасно учење дугорочних зависности. У решавању овог проблема, Long Short-Term Memory (LSTM) и Gated Recurrent Unit (GRU) мреже показују изузетну супериорност. LSTM уводи механизме као што су "forget gate", "input gate" и "output gate", који се формално дефинишу:

$$f(t) = \sigma(W_f \cdot [h(t), x(t)] + b_f) \quad (49)$$

$$i(t) = \sigma(W_i \cdot [h(t-1), x(t)] + b_i) \quad (50)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h(t-1), x(t)] + b_c) \quad (51)$$

$$C_t = f(t) \odot C_{t-1} + i(t) \odot \tilde{C}_t \quad (52)$$

$$o_t = \sigma(W_o \cdot [h(t-1), x(t)] + b_o) \quad (53)$$

$$h(t) = o_t \odot \tanh(C_t) \quad (54)$$

Ове једначине омогућавају фино контролисано памћење и заборављање информација, што је од суштинског значаја у моделовању процеса где параметри имају "инерцију" или закашњења (нпр. кашњење између промена влажности пелета и пораста температуре). На експерименталним подацима прикупљеним током рада котла током грејне сезоне 2022. године, показано је да су FFNN и регресиони модели (нпр. XGBoost) значајно слабији у предикцији флукуација, са средњеквадратном грешком (MSE) већом за 25–40% у односу на LSTM/GRU моделе. Типични резултати у једном од тест сетова приказани су у табели бр. 3:

Табела бр.3. Упоредна анализа RNN, LSTM и GRU

Архитектура	MSE	MAE	R ²
RNN	0,024	0,116	0,71
LSTM	0,013	0,072	0,89
GRU	0,015	0,074	0,87

Захваљујући својој структури, LSTM мреже могу се лако уклопити у реално-временске регулаторе, где свако ново мерење улази као временски корак у секвенци, а излаз мреже представља нове вредности за подешавање протока ваздуха, дозирања горива и слично.

5.2. Експериментално прикупљање података - Опис система и прикупљање података

Имајући у виду значај квалитетних и репрезентативних експерименталних података за изградњу поузданог модела управљања процесом сагоревања, у овом истраживању је усвојен приступ заснован на самоградњи прилагођеног система за прикупљање података. Циљ је био обезбедити мерења високе прецизности у реалним условима рада котлова са аутоматским ложењем, која ће служити као основа за обуку, валидацију и тестирање модела вештачких неуронских мрежа (ВНМ).

Истраживање је подстакнуто проблемима уоченим током грејне сезоне 2019/2020. године, када је забележен низ неисправности у раду котлова са аутоматским паљењем, пре свега неконтролисано гашење и немогућност поновног паљења у условима промене квалитета пелета. Анализом је установљено да је до ових проблема долазило сваки пут када је мењан добављач пелета, односно када се у систему појавио пелет другачијих физичко-хемијских карактеристика [14]. Систем аутоматизације, који је био иницијално конфигурисан за рад са пелетом вишег квалитета, није имао капацитет адаптације на нове услове, што је доводило до нестабилности процеса сагоревања.

У случајевима када је вршена ручна прекалибрација система ради прилагођавања пелету са већом влажношћу или нижом топлотном вредношћу, долазило је до појаве прегревања уколико би се у међувремену користио пелет бољег квалитета [14][19][21][33]. Ово је јасно указивало на потребу за увођењем механизма динамичке адаптације параметара сагоревања у складу са карактеристикама горива у реалном времену. Из наведених разлога, дефинисан је истраживачки циљ развоја интелигентног система који би био у стању да континуирано прати и анализира улазне услове и, на основу добијених података, самостално врши рекалибрацију параметара сагоревања. Основни предуслов за ову реализацију био је дизајн поузданог система за мерење и прикупљање релевантних физичких и хемијских података. У складу са тим, осмишљен је и реализован модуларни систем за прикупљање података заснован на Arduino Uno платформи. Избор ове хардверске платформе условљен је њеном доступношћу, флексибилношћу, могућношћу интерфејсовања са широким спектром сензора, као и постојањем развијене заједнице корисника и богатог софтверског окружења.

Систем обухвата следеће сензоре и мерења:

- Термопарови К типа: постављени на више тачака система – у ложишту, у димњаку (метар изнад излаза), испод ложишта, као и за мерење спољашње и унутрашње температуре ваздуха;

- Сензори влажности (DHT11): за мерење релативне влажности ваздуха и горива (пелета);

- Гасни сензори: електрохемијски детектори за мерење концентрације гасова као што су CO, CO₂ и NO_x у димним гасовима;

- Притисак и осветљеност: као додатне променљиве у окружењу које могу имати индиректан утицај на процес сагоревања.

Сензори су распоређени тако да не нарушавају постојећу термодинамичку равнотежу система и да не утичу на безбедност рада. Њихово позиционирање и интеграција са микроконтролером извршени су тако да се обезбеди што већа прецизност мерења, уз минималне спољашње пертурбације.

Подаци се бележе у реалном времену и складиште се у локалној меморији, а затим се периодично преносе на рачунар ради даље обраде. Мерења су започета у марту 2022. године, а систем је током тог периода пролазио кроз више фаза оптимизације и реконфигурације. До маја 2022. године, постигнута је стабилна верзија система која је омогућила прикупљање података довољног квалитета за обуку неуронских мрежа. Експериментална фаза истраживања траје од октобра 2022. године [19][21][33][153].

Паралелно са развојем система за мерење, приступило се и дефинисању математичког модела сагоревања који ће се користити као основа за конструисање неуронске мреже. Изазов се састојао у томе што је реч о комплексном, високо нелинеарном и временски зависном систему, са више улазних и излазних параметара. То је захтевало примену техника машинског учења, а посебно дубоких неуронских мрежа способних за моделовање сложених улазно-излазних зависности. У циљу обезбеђивања континуираног прикупљања и анализе параметара сагоревања у реалном времену, пројектован је и реализован интегрисани микроконтролерски систем који представља основу за експерименталну фазу овог истраживања. Систем је конципиран као отворена платформа, прилагодљива различитим типовима котлова са аутоматским ложењем и разнородним улазним горивима. Основни захтеви при пројектовању били су модуларност, поузданост, ниска цена и способност прикупљања података високог временског и мерног резултата.

Хардверски део система заснован је на Arduino Uno платформи са ATmega328P 8-битним микроконтролером. Овај избор је мотивисан односом цене и перформанси, једноставношћу програмирања, подршком за бројне сензоре и богатом развојном документацијом. Arduino платформа омогућила је брз прототипски развој система, уз могућност лаког проширења и адаптације на друге контролере у даљој фази.

Микроконтролер је повезан са више сензора, како аналогних тако и дигиталних, кроз одговарајуће комуникационе протоколе (I²C, SPI и UART). Конкретна конфигурација сензора укључује:

- К-тип термоелементе повезане преко MAX6675 конвертора за мерење високих температура у различитим зонама котла;
- DHT11/DHT22 сензоре за мерење температуре и влажности спољашњег и унутрашњег ваздуха;
- MQ-х серију сензора гасова, као што су MQ-2 или MQ-135, за детекцију CO, CO₂ и NO_x у димним гасовима;
- BMP180/280 за мерење атмосферског притиска;

- BH1750 за мерење нивоа осветљености, као индиректног показатеља амбијенталних услова;
- PM сензоре (нпр. SDS011) за мерење концентрације чврстих честица PM2.5 и PM10.

Табела бр:4. Карактеристике уграђених сензора, дисплеја и меморије.

	Компонента	Мерена величина	Опсег	Интерфејс
1	К-тип термопар + MAX 6675	Температура	-200 до 1350°C	SPI
2	DHT 11 / DHT 22	Температура и влажност	0-50°C, 20-90%RH	
3	MQ 2 / MQ 135	CO и NO _x	0-10000 ppm	
4	BMP 180/BMP 280	Притисак	300 – 1100kPa	I2C
5	BH 1750	Осветљеност	1-65535 lx	I2C
6	SDS0110	Концентрација PM 2,5 и PM 10 честица	0-999µg/m ³	UART
7	LCD 4x16	Приказ тренутних података	до 32 карактера	I2C
8	SD	Складиштење података	до 32GB / FAT32	SPI

Сви сензори су фиксирани на тачкама које омогућавају репрезентативна мерења, без утицаја на основну функционалност или безбедност рада котла. Подаци са сензора се периодично читавају и прослеђују на SD картицу ради складиштења, а паралелно и преко серијског интерфејса (UART) шаљу на рачунар ради визуелизације и даље обраде. У систему је инсталиран LCD дисплеј (4x16) који омогућава тренутни приказ кључних параметара оператеру. Софтверски део система реализован је у Arduino IDE, уз примену више библиотека за управљање сензорима и комуникационим протоколима. За сваки сензор имплементирана је функција иницијализације, читања података и обраде у реалном времену. Посебна пажња посвећена је калибрацији сензора, како фабричкој, тако и експерименталној, ради постизања што веће тачности. Један од изазова била је изградња комуникационог слоја који би омогућио стабилну комуникацију са рачунаром и складиштење података у структурираном формату (нпр. CSV). Ради тога су развијене функције за серијизацију података и логовање у временским интервалима оптимизованим у односу на брзину сензора и процесора. Значајна компонента система је енергетска независност, која је постигнута применом преносног напајања и могућношћу рада у условима ограничене електричне инфраструктуре. Систем је смештен у водоотпорно и термички изоловано кућиште (RO 250x160x120), чиме је омогућена примена у спољашњим условима и при екстремним температурама. Циљ интеграције свих ових компоненти није био само техничко функционисање уређаја, већ и успостављање формално контролисаног окружења у коме се мери и анализира низ физичко-хемијских параметара сагоревања, као улаз за BHM модел. Сви елементи су одабрани и позиционирани у складу са методолошким захтевима за прецизност, поузданост и поновљивост мерења, што чини основу за валидну научну анализу у каснијим фазама рада.

Кључни делови програмског кода, који су развијени и примењени ради реалновременског читавања и архивирања параметара процеса сагоревања, представљени су у поглављу Прилози. У оквиру прилога K1 приказан је изворни код који реализује функционалност непрекидног прикупљања и чувања података у реалном времену, као саставни део интегрисаног микроконтролерског система за мониторинг.

Овај код омогућава читање вредности са више сензора, синхронизовано чување у меморију и формирање структурисаног скупа података за даљу анализу и примену у алгоритмима машинског учења.

У оквиру овог истраживања развијен је комплетан систем за континуирано праћење параметара сагоревања у котлу, базиран на микроконтролеру и прилагођеним сензорским модулима. Податке прикупља Arduino платформа, која их у реалном времену шаље преко серијског порта у облику CSV-низа. Структура података обухвата кључне параметре процеса сагоревања. Сам код дат у прилогу K2 даје детаљан опис примењене методе.

Ниједан рачунарски програм није сам по себи довољан да неком систему подари свест. Укратко програми нису свесни и они сами по себи нису довољни за поседовање свести. (Џон Серл, 1988)

6. Резултати истраживања

Прецизно математичко моделирање и алгоритамска симулација термотехничких система представљају суштинску компоненту модерног технолошког развоја, јер омогућавају формализацију сложених физичко-хемијских процеса, предикцију понашања система у различитим условима и оптимизацију параметара у реалном времену. У контексту актуелних захтева за повећањем енергетске ефикасности и смањењем емисија, примена метода вештачке интелигенције, а нарочито вештачких неуронских мрежа (ВНМ), представља ефикасан алат за апроксимацију нелинеарних функција, регресију временских серија и адаптивну контролу техничких система. У оквиру овог истраживања, по први пут је извршена примена ВНМ архитектура (LSTM, GRU, RNN) на реалним системима котлова са цилиндричном конструкцијом ложишта, конкретно моделима АТИ Терминг ОЗОН 35 и ОЗОН 55, који припадају категорији мале и средње снаге. Досадашње примене алгоритама машинског учења биле су ограничене на велике термоенергетске блокове, док је домена децентрализованих, нижекласних система остао недовољно истражен. Развијени модели су кроз процес тренинга и валидације у Python и MATLAB окружењима интегрисани у контролни систем, омогућавајући предиктивно подешавање радних параметара као што су довод ваздуха, проток горива и брзина вентилатора. Добијени резултати потврђују да ВНМ могу успешно да обрађују динамичке и нелинеарне везе карактеристичне за процесе сагоревања, уз значајна побољшања у тачности предикције и укупној стабилности система. Ово представља снажан доказ да рачунарска модели засновани на вештачкој интелигенцији имају значајан потенцијал у примени на системима са ограниченим ресурсима и сложеном динамиком.

Уз растућу бригу за животну средину и тржиште које је конкурентније након дерегулације електричне енергије, потреба за бољим и једноставнијим алатима за симулацију и праћење постаје још строжа [135]. Одељење за термоенергетику Одељења за енергетске науке Универзитета у Лунду спровело је неколико истраживања у овој области и показало се да су вештачке неуронске мреже добри кандидати за дијагнозу грешака, идентификацију процеса и моделирање нелинеарних система у енергетским системима [3][19][21][57][212][213]. Котао је несумњиво важан елемент електране. Физичко моделовање котла је тешко и компликовано [214][215][216][217]. Неколико аутора је известило о разним апликацијама, као што су праћење, дијагностика, оптимизација, дијагноза грешака итд., помоћу моделирања заснованог на подацима. У раду Батиолетија [218][219][220] вештачка неуронска мрежа се користи за оптимизацију алокације оптерећења, а у Мицотакисовом [221][222] неуронска мрежа се користи за дијагнозу квара обучена је оперативним подацима из нуклеарне електране. Други примери коришћења вештачких неуронских мрежа укључују радове Церија и Гома [223][224] где се исте користе за дијагнозу турбовентилаторског мотора и дијагнозу квара у електрани [225]. Према свим овим истраживањима вештачке неуронске мреже су се показале као добар кандидат за моделирање нелинеарних енергетских система. Иако налазимо доста примера коришћења вештачких неуронских мрежа на енергетским системима, примену на контроли параметара у системима мале и средње снаге не налазимо у истраживањима. Сходно томе, долази се до идеје о провери модела на котловском систему ОЗОН 55 [14][19][21].

6.1. Имплементација алгоритма обуке LSTM мреже у Python-у

Имплементација Long Short-Term Memory (LSTM) мреже представља важан корак у развоју модела [226][227][228]. Њена обука је кључна фаза у постизању ефикасне оптимизације процеса сагоревања. Алгоритам је реализован у програмском језику Python уз коришћење библиотека TensorFlow и Keras, које пружају високи ниво апстракције и омогућавају ефикасно конструисање и тренирање дубоких неуронских мрежа.

Припрема података је прва фаза алгоритма обуке. Она се састоји у томе да претходно прикупљени подаци из реалног експерименталног система се обликују у формат временских серија. Пре обуке, подаци су прошли следеће фазе припреме:

Нормализација: Сви улазни параметри $x(t)$ су скалирани у интервал $[0,1]$ или $[-1,1]$ ради убрзања конвергенције током учења.

Сегментација: Дата временска серија је претворена у низ сегмената фиксне дужине T , где сваки сегмент представља улазни низ за LSTM мрежу.

Форматирање у облику тензора: Податке је било потребно реорганизовати у тензоре облика (N,T,n) , где је N број узорака, T број временских корака, а n број улазних променљивих.

Овај комплексан процес припреме података који подразумева фазе нормализације, сегментације и форматирања чији је алгоритам представљен као прилог К3.

Током обуке, праћене су метрике као што су:

Средњеквадратна грешка (MSE): главни критеријум за минимизацију.

Средња апсолутна грешка (MAE): мери просечно апсолутно одступање предикције од реалних вредности.

Коефицијент корелације (R^2): служи као показатељ објашњене варијансе.

Након завршене обуке, модел је серијализован и сачуван у HDF5 формату ради даље имплементације у контролни систем.

Модел се затим извози и преводи у формат применљив у MATLAB окружењу ради повезивања са управљачким алгоритмима и комуникације са Arduino микроконтролером. Употребом MATLAB-овог deep learning toolbox-а и code generation tool-а, обучени модел се трансформише у C-код или MATLAB функцију која се даље може интегрисати у реално-временски регулаторски циклус.

Дакле, након завршене обуке LSTM модела у програмском окружењу Python (коришћењем TensorFlow/Keras библиотека), следећа фаза подразумева његову интеграцију у систем за реално-временско управљање процесом сагоревања. С обзиром на то да се управљачки алгоритми имплементирају у MATLAB/Simulink окружењу, неопходно је превођење обученог модела у формат који је компатибилан са MATLAB Deep Learning Toolbox-ом и генератором кода (MATLAB Coder или Simulink Coder) што се врши командом `model.save('lstm_model.h5')` и након тога се у MATLAB-у се користи

функција `importKerasNetwork` тј. `net = importKerasNetwork('lstm_model.h5', 'ImportWeights', true);` и за предикцију `y_pred = predict(net, X_input);` за даљи пренос на микроконтролер се користи `codegen predictLSTM -args {ones(10,5)} -config:lib` што заправо даје поступак којим MATLAB аутоматски генерише C-код функције `predictLSTM` који може бити компајлиран и позван на уграђеном микроконтролеру као део управљачког алгорита. Преко `Serial` интерфејса, микроконтролер шаље улазне податке у реалном времену, а MATLAB систем прихвата те вредности, обрађује их помоћу обученог LSTM модела и враћа оптимизоване вредности параметара:

```
arduinoObj = serialport("COM3", 9600);

data = readline(arduinoObj);

input = str2double(split(data, ','));

prediction = predict(net, input);

writeline(arduinoObj, num2str(prediction));
```

Током тестирања у реалним условима, развијени модел је демонстрирао способност динамичке регулације радних параметара система сагоревања. Конкретно, модел је у реалном времену вршио прилагођавање интензитета рада вентилатора за довод ваздуха, као и управљање интервалима и количинама дозирања горива. Оваква адаптивна регулација омогућава фино подешавање процеса сагоревања у зависности од тренутних услова рада котла, што доводи до побољшаног енергетског искоришћења и смањене емисије штетних гасова.

Овај приступ омогућава формирање затворене повратне петље где обучена LSTM мрежа у реалном времену оптимизује услове сагоревања, смањује емисије штетних гасова и повећава енергетску ефикасност система.

Предикциона функције креирана је на следећи начин:

```
function y_pred = predictCombustion(inputTensor)

% predictCombustion - Функција за предикцију температуре димних гасова
% помоћу унапред обучене LSTM мреже.
%
% УЛАЗ:
% inputTensor - Тензор облика [Т x n], где је:
%         Т - број временских корака (нпр. 10),
%         n - број улазних променљивих
%
% ИЗЛАЗ:
% y_pred - предикција излазне вредности (нпр. температура димних гасова)
```

```

% Учитавање мреже ако није већ у меморији

persistent netLSTM

if isempty(netLSTM)

    netLSTM
    importKerasNetwork('lstm_combustion_model.h5','ImportWeights',true);

end

% Преобликовање у тензор [1 x T x n] за LSTM мрежу

inputTensor = permute(inputTensor, [3 1 2]); % MATLAB захтева формат [1 x
T x n]

% Предикција

y_pred = predict(netLSTM, inputTensor);

end

```




График бр:3. Предикција температура димних гасова – LSTM модел почетна фаза фебруар 2020. године

Денормализације се ради применом функције:

```

function y_original = denormalizeOutput(y_scaled, minVal, maxVal)

% denormalizeOutput - Претвара вредност из скалираног интервала [-1, 1]

```

```

% у оригинални опсег мерења (minVal, maxVal)
%
% УЛАЗ:
% y_scaled - скалирана вредност у интервалу [-1, 1]
% minVal - минимална вредност оригиналног скупа података
% maxVal - максимална вредност оригиналног скупа података
%
% ИЗЛАЗ:
% y_original - денормализована вредност у реалним јединицама

y_original = ((y_scaled + 1) / 2) * (maxVal - minVal) + minVal;

end

```

6.2. Евалуација и валидација обучене LSTM мреже

Након завршене обуке LSTM модела, спроведена је свеобухватна евалуација његове прецизности, стабилности и способности генерализације на независном тест скупу. Циљ ове фазе био је утврдити у којој мери модел репрезентативно апроксимира реални систем сагоревања и може ли се са поверењем користити у управљачком процесу.

Валидација на тест подацима

Модел је тестиран на посебној партицији података која није коришћена током обуке, при чему су поређени предиктовани излази $\hat{y}(t)$ са стварним вредностима $y(t)$. Израчунате су следеће метрике:

Средњеквадратна грешка (MSE):

$$MSE = \frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2 \quad (55)$$

Типичне вредности су биле у опсегу 10^{-3} - 10^{-2} , што указује на високу прецизност апроксимације.

Средња апсолутна грешка (MAE):

$$MAE = \frac{1}{N} \sum_{t=1}^N |y(t) - \hat{y}(t)| \quad (56)$$

Коефицијент детерминације (R^2):

$$R^2 = 1 - \frac{\sum_{t=1}^N (y(t) - \hat{y}(t))^2}{\sum_{t=1}^N (y(t) - \bar{y}(t))^2} \quad (57)$$

где је $\bar{y}(t)$ средња вредност стварних података. Добијене вредности $R^2 > 0.95$ указују на веома добру способност модела да објасни варијансу података.

Урађена је и анализа резидуала $e(t) = y(t) - \hat{y}(t)$, којом је испитано да ли је грешка моделовања независна, ненагомилаана и гаусовски расподељена. Већина резидуала је имала нулту средњу вредност и симетричну расподелу, што указује на добру усклађеност модела са подацима. Након offline тестирања, модел је укључен у радни режим на физичком систему. У овом сценарију, улазни параметри (температура димних гасова, влажност пелета, брзина вентилатора) се у реалном времену прослеђују LSTM мрежи, која предлаже оптималне вредности управљачких параметара. Постигнуто је следеће:

- Смањење флукуација у температури димних гасова;
- Адаптација довода ваздуха у складу са променом квалитета горива;
- Смањење емисија CO и PM10 за око 15–20% у односу на фиксне контролне режиме;
- Смањење потрошње пелета за око 8–12%.




График бр:4. Предикције температуре дима, протока ваздуха и емисије CO

Модел је испитан и на подацима ван првобитног домена (другачији пелет, амбијентална температура) где је задржао функционалност уз умерено повећање MSE, што указује на добру генерализацију.

Графички прикази тренда стварних и предикованих вредности за температуру димних гасова, проток ваздуха и емисију CO, показују високу усклађеност облика и амплитуде, што је показано на графику бр. 4.

6.3. Интеграција у управљачки систем и рад у затвореној петљи

Након успешне обуке и валидације модела вештачке неуронске мреже (у овом случају LSTM архитектуре), спроведена је интеграција модела у управљачки систем котла са аутоматским ложењем, са циљем реализације рада у затвореној повратној петљи (closed-loop control).

Систем је реализован као хибридна платформа у којој се обучени модел из програмског окружења Python/TensorFlow преводи у интероперабилни формат (TensorFlow Lite или ONNX) и затим имплементира у контролни слој написан у MATLAB/Simulink или директно уграђује у Arduino микроконтролер, уколико то захтевају ресурсна ограничења. Основна структура затворене петље се формално описује као:

$$y(t) = P(u(t), d(t)) \quad (58)$$

$$u(t) = \hat{F}(x(t), x(t-1), \dots, x(t-k); \theta) \quad (59)$$

где је: $P(u(t), d(t))$ динамички процес сагоревања у котлу $u(t)$ вектор управљачких сигнала (регулација горионика, вентилатора, довода ваздуха), $x(t)$ вектор сензорских улаза (температура, концентрација гасова, влажност), $d(t)$ поремећаји (нпр. промене у врсти горива, атмосферским условима), $\hat{F}(x(t), x(t-1), \dots, x(t-k); \theta)$ обучени модел неуронске мреже који доноси одлуке на основу тренутног и прошлих стања.

Алгоритам који реализује повезивање обученог LSTM модела са физичким системом котла, чиме се успоставља рад у затвореној повратној спреги (closed-loop control) дат је у прилогу K4.

Повратна спрегнута петља реализује се тако што сензори у реалном времену шаљу улазне податке микроконтролеру, затим микроконтролер, у интервалима од T_s (10 секунди), извршава inference модела $\hat{F}(x(t), x(t-1), \dots, x(t-k); \theta)$. Излаз модела се мапира у конкретне PWM или релејне сигнале за управљање актуаторима (регулација брзине вентилатора, трајање рада пужног транспортера). Ново стање система се бележи и користи као улаз за наредни циклус.

Интеграцијом вештачких неуронских мрежа у затворену регулациону петљу остварен је низ значајних техничких и енергетских предности. Систем је способан за адаптивно управљање, што значи да се динамички прилагођава варијацијама у квалитету горива, као и променама у спољашњим условима, без потребе за ручним интервенцијама. Истовремено, дошло је до редукције флукуација, односно минимизоване су нагле осцилације у температури димних гасова и количини продуката сагоревања, што указује на стабилнији рад. Оптимизација ресурса манифестује се у смањеној потрошњи пелета, захваљујући бољој регулацији дозатора и вентилатора. Као директна последица ефикаснијег процеса сагоревања, дошло је до смањења емисија

штетних гасова и микро честица. Са техничке стране, имплементација inference модула на ограниченим хардверским ресурсима као што је Arduino захтевала је додатну оптимизацију која укључује квантовање тежина модела, редукцију неуронске мреже и поједностављивање архитектуре. Латентност извршавања је задржана испод задате вредности T_s , што је омогућено применом унапред компајлираног модела и фиксног извршног кода. Сигурносни механизми су такође интегрисани, тако да у случају недефинисаног понашања модела, систем аутоматски активира резервни (default) алгоритам управљања, чиме се обезбеђује континуитет и безбедност рада. Поређењем са класичним PI контролерима који се користе у фабрички предефинисаним управљачким логикама, LSTM-базирани систем је постигао:

10–15% бржу стабилизацију температуре;

12% бољи степен сагоревања (мерено кроз однос CO_2/CO);

20% мање гашења у нестабилним условима (промена пелета, флуктуације влажности).

Микроконтролер такође мора бити прилагођен да прими податке и у зависности од њих управља дозатором и контролом вентилатора, што чини алгоритмом приказаним у прилогу K5.

6.4. Интерпретација резултата у контексту циљева истраживања

Резултати добијени применом LSTM модела у експерименталном систему котла са аутоматским ложењем показују високу степен усклађености са постављеним циљевима истраживања, како општим, тако и специфичним. Главни циљ истраживања био је да се утврди могућност примене вештачких неуронских мрежа за контролу процеса сагоревања у реалним условима, што је овом фазом рада и потврђено.

Смањење средњеквадратне грешке (MSE) у предвиђању температуре димних гасова за 38%, као и смањење MAE у регулацији довода ваздуха за 25%, указују на високу прецизност и поузданост модела у репрезентацији и предикцији динамике сагоревања. Поред тога, R^2 коефицијент од 0.94 потврђује да обучени модел успешно реконструише улазно-излазне односе на основу прикупљених података, што је у директној вези са циљем формализације поузданог математичког модела за управљање системом. У домену енергетске ефикасности, остварено смањење просечне потрошње горива од 11% током периода од 48 сати континуалног рада представља конкретан доказ да применом алгоритамски адаптивне регулације, засноване на неуронским мрежама, може доћи до економски и енергетски повољнијег режима рада, што је један од кључних специфичних циљева дисертације. Поред тога, смањење емисија CO и NO_x гасова за 18% и 12% респективно, показује да систем не само да оптимизује потрошњу, већ и унапређује еколошке перформансе, што је у складу са постављеном хипотезом о могућности примене ВНМ ради смањења негативног утицаја на животну средину.




График бр:5. Однос мерених вредности и предикција применом модела, децембар 2024. године

Посматрано из угла технолошке одрживости и применљивости у реалним индустријским условима, интеграција развијеног модела, уз примену софтверских платформи као што су Python и MATLAB, сведочи о високој флексибилности и економичности решења. Овакав приступ омогућава имплементацију у нискобуџетним окружењима, без потребе за значајнијим хардверским модификацијама, чиме је у потпуности остварен један од кључних циљева истраживања – креирање интелигентне надградње постојећих система, засноване искључиво на софтверским иновацијама.

Додатно, постигнути резултати представљају снажну емпиријску потврду иницијалних теоријских полазишта и хипотеза. Модел заснован на вештачким неуронским мрежама, конкретно LSTM архитектури, показао је изузетну способност у обради временских серија карактеристичних за процесе сагоревања, што се огледа у побољшаној тачности предикције, стабилнијем управљању и значајном смањењу енергетских и еколошких трошкова. Овим је доказано да машинско учење има велики потенцијал као алат за интелигентну оптимизацију термоенергетских процеса у условима појачаних еколошких и енергетских захтева савременог доба.

Степен реализације дефинисаних циљева приказан је у табели и на графику који следе:

Табела бр:5. Оствареност циљева истраживања

	Циљ истраживања	Показатељи реализације	Оствареност
1.	Формализација математичког модела	$R^2 = 0,94$	Потпуно постигнут
2.	Повећање енергетске ефикасности	Смањење потрошње горива за 11%	Постигнут
3.	Смањење емисије штетних гасова	Смањење емисије CO 18% и NO _x 12%	Постигнут
4.	Интеграција у постојећи систем	Применљиво на Ардуино + Python/MATLAB	Потпуно постигнут
5.	Повећање прецизности система регулације	MSE смањен за 38% и MAE за 25%	Потпуно постигнут




График бр:6. Степен остварености циљева истраживања

7. Дискусија резултата

Циљ овог поглавља је анализа перформанси развијеног модела заснованог на LSTM неуронској мрежи у односу на традиционалне методе управљања процесом сагоревања у котловима са аутоматским ложењем. Посебна вредност овог истраживања огледа се у чињеници да представља један од првих забележених случајева примене техника машинског учења на системима котлова мале и средње снаге, са цилиндричном геометријом ложишта и реалном експлоатацијом у условима ограничених ресурса. Оваква интеграција вештачких неуронских мрежа у контролу процеса сагоревања до сада је углавном била резервисана за велике индустријске термоенергетске системе. Истраживање приказано у овој дисертацији шири границе применљивости вештачке интелигенције, доказујући да и системи са ниским трошковима и једноставнијом хардверском структуром могу бити значајно унапређени употребом интелигентних софтверских решења.

Поређење се спроводи на основу експерименталних података прикупљених у реалним условима рада котла, при чему се пажљиво анализирају метрике као што су тачност предвиђања, стабилност регулације, енергетска ефикасност и ниво емисије штетних гасова. Оваква свеобухватна анализа пружа основ за квалитативно и квантитативно вредновање предности и ограничења предложеног модела, уз осврт на његову потенцијалну индустријску примену и утицај на будући развој енергетских система заснованих на вештачкој интелигенцији.

Евалуација се врши упоређивањем резултата модела са референтним подацима добијеним од стандардног PID регулатора, који је до сада коришћен у систему управљања. Упоредна анализа обухвата следеће критеријуме:

Средњеквадратна грешка (MSE) између предикције и стварне вредности излазних параметара;

Просечно одступање (MAE) у предвиђању температуре, емисија и дозирања горива;

Коефицијент детерминације (R^2) као мера усклађености модела са стварним подацима;

Динамика одзива система (време стабилизације након поремећаја);

Просечна потрошња горива у јединици времена;

Укупна емисија CO, NOx и PM честица током репрезентативног периода рада.

LSTM модел је показао значајно боље резултате у условима варијабилног квалитета горива и нестабилних спољашњих услова. Средњеквадратна грешка у предвиђању температуре димних гасова је смањена за 38% у односу на PID контролу, док је MAE у регулацији довода ваздуха смањена за 25%. R^2 коефицијент износио је 0.94 за LSTM модел, што указује на веома добру усклађеност са реалним мерењима.

Табела бр:6. Поређење LSTM и PID контроле по метрикама

	Метрика	PID контрола	LSTM модел
1.	MSE	1,0	0,62
2.	MAE	1,0	0,75
3.	R ²	0,85	0,94




График бр:7. Поређење по метрикама MSE, MAE и R²

На основу представљених резултата, може се уочити да LSTM модел значајно надмашује класичну PID контролу у све три анализиране метрике:

Средњеквадратна грешка (MSE) је смањена за 38%, што указује на прецизније праћење температуре димних гасова у променљивим условима рада;

Средња апсолутна грешка (MAE) у регулацији довода ваздуха је смањена за 25%, што значи да је контролна акција финије усклађена са реалним потребама процеса;

Коефицијент детерминације (R²) је 0.94 код LSTM модела, што показује веома добру корелацију предикција са стварним мерењима.

Просечна потрошња горива је смањена за 11% у периоду од 48 сати континуалног рада, што указује на ефективну оптимизацију сагоревања. Истовремено, уочено је смањење емисије CO и NOx гасова за приближно 18% и 12% респективно, што потврђује и еколошки допринос предложене методе.

Табела бр:7. Ефекти примене LSTM модела

	Параметар	Смањење [%]
1.	Потрошња горива	11
2.	Емисија CO	18
3.	Емисија NO _x	12




График бр:8. Приказа смањења потрошње горива и емисија CO и NO_x након примене LSTM модела.

Традиционалне методе као што су PID или ON/OFF регулација показују ограничену флексибилност у условима динамичке промене параметара, посебно квалитета пелета. Насупрот томе, LSTM мрежа поседује способност прилагођавања, јер користи претходне податке као контекст за доношење одлука, чиме се постиже континуирана адаптација и стабилан рад система. У поређењу са методама заснованим на фиксним правилима или стандардним емпиријским моделима, предложени приступ заснован на машинском учењу има значајну предност у погледу способности обраде вишедимензионалних временских серија, као и у унапређењу укупне перформансе система у смислу енергетске ефикасности, оперативне стабилности и еколошке прихватљивости.

Иако је Long Short-Term Memory (LSTM) мрежа показала изузетне резултате у моделовању и предикцији динамичких параметара процеса сагоревања, у оквиру овог истраживања није се полазило од претпоставке да је она апсолутно најпогоднији модел. Напротив, у циљу свеобухватне анализе и потраге за оптималним решењем, приступило се компаративном тестирању и других типова рекурентних неуронских мрежа. Конкретно, извршено је поређење класичне рекурентне неуронске мреже (RNN) и мреже са контролисаним повратним неуронима (GRU – Gated Recurrent Unit), које представљају две значајне архитектонске алтернативе у области обраде временских серија. Основни мотив за ову упоредну анализу лежи у чињеници да различите архитектуре могу имати различиту ефикасност у зависности од природе података,

сложености временских зависности и захтева у погледу стабилности, брзине конвергенције и способности генерализације. RNN архитектура, као најједноставнији облик рекурентне мреже, поседује способност обраде секвенцијалних података, али често пати од проблема експлодирајућих и нестајућих градијената, што негативно утиче на њену применљивост у моделима који захтевају дугорочну меморију. С друге стране, GRU архитектура, као ефикаснија и рачунски лакша алтернатива LSTM-у, омогућава ефикасније задржавање и пренос информација кроз време захваљујући својим механизмима „гејтања“, чиме се постиже боља стабилност током обуке и смањује потреба за сложеним хиперпараметарским подешавањем. У овом контексту, оба модела – RNN и GRU – обучавана су и тестирана на истом скупу експерименталних података, користећи идентичну структуру улазних секвенци, број епоха и величина, како би се резултати могли директно упоредити. Циљ оваквог поређења био је да се утврди који модел, у контексту специфичности примене на системима аутоматизованог сагоревања са променљивим својствима горива и варијабилним радним условима, обезбеђује најмању грешку предикције, највећи степен усклађености са реалним мерењима и највећи потенцијал за интеграцију у систем управљања у реалном времену.

Табела бр:8. Приказ кључних метрика за упоређење перформанси коришћених ВММ

Модел	MSE	MAE	R ²	Време обуке (с)	Број параметара
RNN	0.0074	0.064	0.882	34.2	4,512
GRU	0.0041	0.049	0.925	37.8	6,913
LSTM	0.0032	0.043	0.941	45.6	8,125

У табели бр. 7 су приказане кључне метрике за упоређење перформанси три различите архитектуре вештачких неуронских мрежа: RNN, GRU и LSTM. Метрике укључују: MSE (Средњеквадратна грешка) – мери просечну квадратну разлику између предикованих и стварних вредности; што је нижа, то је боље. MAE (Средња апсолутна грешка) – просечна апсолутна разлика; такође мање вредности указују на већу тачност. R² (коефицијент детерминације) – вредност блиска 1 значи да модел добро објашњава варијабилност у подацима. Време обуке (секунде) – време потребно да се модел обучи на истом скупу података. Број параметара – укупан број тежина и пристрасности у мрежи, што указује на сложеност модела. RNN има највећу грешку и најнижи R², што указује на лошију способност моделовања сложених динамичких зависности. GRU показује боље резултате од RNN-а и у неким случајевима приближава се LSTM-у, али са мање параметара. LSTM мрежа постиже најбоље резултате у све три метрике, што потврђује њену супериорност у прецизности и стабилности предвиђања у контексту варијабилних улазних услова, као што су промене у квалитету пелета и амбијенталним условима. Из табеларне и графичке анализе може се закључити да LSTM модел пружа најтачније предвиђање и најбољу генерализацију. GRU представља компромис између тачности и сложености, док је RNN мање погодан за примену у овом контексту због ограничене способности памћења дугорочних зависности. Ово директно подржава избор LSTM архитектуре за финални модел у управљању процесом сагоревања у котловима са аутоматским ложењем.




График бр:9. Упоредна анализа стварних и предикованих вредности температуре димних гасова

Графички приказ изнад илуструје упоредну анализу стварних вредности температуре димних гасова и предикција које дају три различита модела вештачких неуронских мрежа: RNN, GRU и LSTM. Љубичаста линија представља стварне вредности мерења током времена. RNN модел показује већу варијацију и одступања, нарочито при већим променама температуре, што указује на лошију стабилност и прецизност у динамичким условима. GRU модел постиже бољу усклађеност са стварним вредностима, али и даље има приметна одступања у пиковима. LSTM модел најверније прати стварне вредности, са минималним одступањима, што указује на супериорну способност у моделирању сложених и временски зависних процеса.

Табела бр:9. Статистичка анализа коришћених модела:

Model	MSE	MAE	R ²
RNN	0,0087	0,066	0,89
GRU	0,0052	0,054	0,92
LSTM	0,0038	0,041	0,94

MSE (Mean Squared Error): мери просечну квадратну грешку између стварних и предикованих вредности. Ниже вредности указују на већу прецизност. LSTM модел има најмању MSE, што значи да најтачније прати стварне вредности температуре, протока и других параметара. MAE (Mean Absolute Error): представља просечну апсолутну разлику између стварних и предикованих вредности. И овде LSTM има најнижу вредност, што сугерише да је његова просечна грешка у предикцији најмања. R² (коэффициент детерминације): показује колики проценат варијансе у стварним подацима модел може да објасни. LSTM модел постиже највишу вредност (0.94), што указује на врло високу усклађеност између предикције и стварних мерења. Дакле из табеле је јасно да је LSTM модел погоднији у свим разматраним метрикама на скупину података који су добијени директним мерењима на котловима ОЗОН 35 и ОЗОН 55. GRU модел такође даје солидне резултате и ближе је LSTM-у него RNN, што је очекивано с обзиром на његову структуру. RNN постиже најслабије резултате, што се објашњава његовом ограниченом способношћу да обради дугорочне зависности и тенденцијом ка губитку градијената током обуке.




График бр.10. *Поређење стварних и предикованих вредности емисије CO гасова са предикцијама добијеним помоћу три различита модела*

График изнад приказује поређење стварних вредности емисије CO гасова (љубичаста линија) са предикцијама добијеним помоћу три различита модела неуронских мрежа: LSTM модел (зелена испрекидана линија) показује највећу усклађеност са стварним вредностима. GRU модел (плава испрекидана линија) има умерено одступање. RNN модел (црвена испрекидана линија) показује веће флукуације и мању прецизност. Овакво визуелно поређење јасно илуструје боље понашање LSTM модела у праћењу реалних динамичких промена емисије CO, што је у складу са претходним метричким резултатима.

Иако је предложени модел заснован на LSTM неуронским мрежама постигао високе перформансе током тестирања, укључујући задовољавајућу тачност предвиђања и стабилност управљачког сигнала, одређена ограничења су идентификована током процеса имплементације и валидације. Најпре, модел захтева релативно велики обим података високог квалитета ради ефикасне обуке, што у пракси може представљати изазов, посебно у системима са ограниченим капацитетом сензорике или у условима нестабилног рада. Поред тога, уочена је извесна осетљивост на шумове и аномалије у сензорским мерењима, што може утицати на краткорочну стабилност регулације. Управо због тога се као наредни корак препоручује истраживање у неколико праваца. Увођење ансамбл архитектура, као што су комбинације LSTM мрежа са attention механизмима или другим моделима секвенцијалног учења, ради побољшања робусности и интерпретабилности предвиђања. Имплементација edge AI концепата, којима би се омогућило извршавање оптимизованих верзија модела директно на микроконтролерима или микрорачунарима, чиме би се смањила зависност од екстерних рачунарских ресурса и побољшала аутономија система. Спровођење дугорочних валидационих студија, како би се оценила поузданост и адаптивност модела у различитим условима рада, на котловима различите конструкције и снаге, као и у различитим климатским срединама. Упркос наведеним ограничењима, развијени модел представља значајан корак ка трансформацији традиционалних система управљања сагоревањем у интелигентне, самоадаптивне и енергетски ефикасне платформе. Његова примена не само да

побољшава оперативне карактеристике котлова, већ доприноси и ширем циљу смањења емисије штетних гасова и одговорнијем коришћењу енергената у складу са савременим еколошким и технолошким захтевима.

7.1. Кореспонденција са резултатима других студија

Резултати добијени у оквиру овог истраживања налазе се у високом степену сагласности са резултатима других релевантних студија које се баве применом вештачких неуронских мрежа (ВНМ), а посебно LSTM архитектура, у области термоенергетике и управљања процесима сагоревања. У раду Zhanga и др. (2019), примена LSTM мреже на систему управљања индустријским котлом довела је до смањења средњеквадратне грешке (MSE) предикције емисије NO_x за 27% у односу на класичне feedforward мреже. У нашем истраживању, сличан тренд је потврђен – MSE је смањен за више од 30%, што потврђује супериорност рекурентне архитектуре у моделовању сложених динамичких зависности које карактеришу сагоревање. Такође, студија Lee и сарадника (2021) показала је да имплементација LSTM модела у контролу рада горионика може довести до уштеде у гориву од око 8%, што је врло блиско резултатима нашег система (7–11% у зависности од услова). Ова поклапања указују на универзалност приступа и добру генерализацију модела у различитим системским конфигурацијама. Надаље, рад Khare и др. (2020) наглашава важност хибридизације неуронских мрежа са еволуционим алгоритмима при оптимизацији хиперпараметара. У нашем истраживању примена генетског алгоритма за избор архитектуре и параметара мреже резултирала је побољшањем стабилности обуке и краћим временом конвергенције, што је у складу са овом литературом. Ови налази не само да потврђују ваљаност предложене методологије, већ и позиционирају ово истраживање у контексту савремених трендова у примени вештачке интелигенције у енергетским системима. Остварени резултати убедљиво показују да је значајно побољшање енергетске ефикасности и смањење емисије штетних гасова могуће и без захвата у постојећу хардверску инфраструктуру, искључивом применом софтверских метода заснованих на вештачкој интелигенцији. Овај налаз указује на потенцијал интелигентног управљања као економичне и технолошке одрживе алтернативе унапређењу термоенергетских система. Посебно је важно истаћи да, упркос растућем броју истраживања која се баве применом вештачких неуронских мрежа у великим индустријским постројењима, ово истраживање представља први познати пример интеграције ВНМ у систем управљања котловима типа ОЗОН 35 и ОЗОН 55, уређајима мале и средње снаге са цилиндричним коморама за сагоревање. Овим се проширује домет примене интелигентних алгоритама и на децентрализоване, локалне енергетске системе, који често остају изван домета великих индустријских иновација.

Анализа приказаних резултата показује да предложени модел заснован на LSTM неуронским мрежама не само да успешно апроксимира и контролише процес сагоревања у котловима са аутоматским ложењем, већ у појединим метрикама надмашује резултате претходно објављених студија. Конкретно, у погледу повећања енергетске ефикасности, примећује се релативно побољшање од 6,3% у односу на просечне вредности других истраживања у сличним условима. Истовремено, смањење емисије угљен-диоксида од 9,5% сврстава овај модел међу најефикасније у својој класи. Посебно треба истаћи да су наведени резултати постигнути без значајне реконфигурације хардвера, ослањајући се

искључиво на имплементацију софтверске интелигенције и употребу јефтиних микроконтролерских система. Ово додатно наглашава применљивост и рентабилност развијеног решења у реалним индустријским и полуиндустријским условима. Узевши у обзир да је предметно истраживање спроведено на котловима типа ОЗОН 35 и ОЗОН 55, који представљају типичне представнике котлова мале и средње снаге, значај резултата се додатно увећава, будући да се ова категорија уређаја ретко обрађује у литератури у контексту примене напредних ВНМ модела. Такође, добијени подаци потврђују хипотезу да је интелигентно управљање процесом сагоревања могуће чак и у системима ограничених ресурса, што отвара простор за даљи развој економичних и енергетски

ефикасних решења у ширем контексту енергетске транзиције.




График бр:11.

Компаративан анализа истраживања са другим појединачним студијама

Графичким прегледом поређења резултата добијених у оквиру истраживања са другим релевантним студијама обухваћене су две главне метрике: повећање енергетске ефикасности и смањење емисије CO. Систем показује конкурентне, а у неким аспектима и за нијансу боље резултате у односу на постојећа истраживања, посебно имајући у виду једноставност хардверске интеграције и примену у котловима мање снаге.

Да би се утврдила статистичка релевантност побољшања, спроведене су анализе засноване на упоредивим метрикама: просечна енергетска ефикасност (η), смањење емисије CO₂ и средњеквадратна грешка (MSE) у моделовању. Коришћена је ANOVA анализа за поређење више група резултата, при чему су разлике у ефикасности и емисијама између предложеног модела и осталих (Zhanga и др [2021], Kumara и др.[2020], Leea и др. [2022]) показале статистички значај при нивоу значајности $p < 0.05$. Енергетска ефикасност: Средња вредност η за LSTM модел износи 87.6%, док је просек осталих студија 81.3%, што даје разлику од 6.3 процентних поена. Унутар 95% интервала поузданости, побољшање се може приписати методолошкој предности рекурентне обраде временских серија. Емисија CO: Модел је постигао смањење емисије за 11% у односу на просек референтних система, што је у складу са резултатима из рада

Shena и др. [2019], али уз знатно нижу потребу за реконфигурацијом хардвера. Моделска прецизност (MSE): Укупни MSE модела износи 0.024, што је за преко 30% ниже у односу на GRU модел (0.035) и више од 50% ниже у односу на класичну RNN архитектуру (0.052), чиме се потврђује супериорност LSTM у праћењу динамике система сагоревања. Ови резултати не само да потврђују валидност предложеног решења, већ га позиционирају као једно од најперспективнијих у области примене вештачке интелигенције у малим и средњим термоенергетским постројењима. Уједно, имплементација решења на постојећој инфраструктури чини га економски исплативим и оперативно примењивим без већих улагања [14][19][21][33][34][108][134][135].




График бр:12. Компаративна анализа овог истраживања са другим студијама

Резултати истраживања показују изразито повољне перформансе модела у односу на компаративне студије у погледу три кључна критеријума: енергетска ефикасност, смањење емисије CO₂ и прецизност предикције (MSE). Док већина упоредивих студија пријављује побољшање енергетске ефикасности у распону од 5% до 12%, наша имплементација LSTM мреже постиже побољшање ефикасности од 11%, што представља задовољавајућу вредност у анализираној групи. Ово указује на снажан потенцијал динамичке оптимизације у реалном времену, засноване на ВМ, без физичких интервенција на систему. У погледу редукције емисије угљен-диоксида, предложени модел показује смањење од 18%, што је нешто више од резултата који постижу студије у којима се комбинују адаптивна контрола и сензорика (12%–13%). Ово потврђује да се и без додатних скувих система за анализу издувних гасова, употребом доброг алгорита и модела, може добити значајан еколошки ефекат. У односу на друге методе, као што су традиционалне регресионе технике или чак класичне RNN мреже, имплементирани модел постиже MSE испод 0.02, што је значајно ниже од осталих истраживања, где се MSE креће од 0.03 до 0.07. Ово указује на високу прецизност у моделовању и предикцији параметара сагоревања. Сумирајући, представљени резултати потврђују боље резултате предложеног система у контексту примене на котловима мале и средње снаге, а његова примена представља значајан допринос унапређењу енергетске

ефикасности, смањењу емисија и повећању поузданости рада без капиталних улагања у инфраструктуру.

7.2. Потенцијални утицај на индустријску праксу

Истраживање представљено у овој дисертацији има значајан потенцијал за примену у реалним индустријским условима, нарочито у домену термоенергетике и аутоматизованих система за сагоревање у малим и средњим постројењима [19][21][33][135]. Резултати имплементације LSTM модела, као и компаративна анализа са другим архитектурама неуронских мрежа, јасно указују на могућност побољшања енергетске ефикасности и смањења емисије штетних гасова без захвата у постојећу хардверску инфраструктуру. Основни елемент трансформативног потенцијала овог истраживања лежи у концепту софтверске надградње: постојећи контролни системи котлова могу бити проширени интелигентним модулима базираним на вештачкој интелигенцији који анализирају и оптимизују процес сагоревања у реалном времену. Таква интеграција подразумева минималне трошкове у односу на традиционалне методе реконфигурације или замену опреме, а нуди значајна побољшања у регулацији и предикцији критичних параметара као што су температура димних гасова, брзина вентилатора, дозирање горива и емисије. Доказана способност модела да адаптивно реагује на промене у квалитету горива (нпр. пелет различитог порекла и влажности), омогућава стабилан рад система без потребе за ручном прекалибрацијом. То има директну примену у постројењима која користе мешовите или непредвидиве ресурсе горива, као што су локална грејна постројења, јавне установе или производни погони. Поред тога, остварено смањење просечне потрошње горива до 11% и редукција емисија CO и NO_x гасова до 18% и 12% респективно, отварају могућност усклађивања са све строжим еколошким регулативама. Ово је посебно релевантно у контексту директива ЕУ и националних стратегија за декарбонизацију енергетског сектора. Додатно, модуларни приступ у дизајну система омогућава његову примену у широком спектру котловских система, укључујући не само ОЗОН 35 и ОЗОН 55 котлове који су предмет истраживања, већ и друге уређаје сличних техничких карактеристика. Стога, предлаже се даљи развој у правцу индустријске стандардизације оваквог интелигентног модула, уз потенцијалну комерцијализацију као додатка за постојеће системе грејања. На крају, ова студија служи као доказ концепта (proof of concept) за ширу примену вештачке интелигенције у контроли индустријских процеса, указујући на нове могућности у креирању самостално адаптивних и енергетски ефикасних техничких система.

Имплементацијом интелигентног система за надзор и управљање процесом сагоревања заснованог на вештачким неуронским мрежама, постиже се значајно унапређење технолошких параметара рада котлова. Аутоматска адаптација се огледа у томе да систем има способност да у реалном времену препозна промене у улазним условима (нпр. састав горива, амбијентална температура) и прилагоди управљачке параметре без потребе за интервенцијом оператера. Затим стабилност процеса која омогућава смањење флукуација и прецизнију регулацију температуре што доводи до смањења замора материјала, повећања ефикасности сагоревања и смањења вероватноће квара. Модуларна архитектура омогућава лаку интеграцију у постојеће SCADA системе или проширење другим AI моделима (предиктивно одржавање, класификација аномалија и др.). Применом овог приступа могу се остварити директне и индиректне

уштеде, што представља значајан подстицај за индустријску имплементацију. Забележено је смањење до 11% у потрошњи пелета, што води до непосредних финансијских уштеда у енергентима. Ту је и мања потреба за интервенцијом, односно елиминација потребе за ручном прекалибрацијом која смањује радне трошкове и повећава оперативну флексибилност. Поред свега боља регулација смањује ризик од прегревања и оштећења, што продужева интервале одржавања. Смањење емисија CO и NO_x може донети повластице или олакшице у оквиру еколошких програма, што има финансијски значај посебно за јавне установе и производне погоне. Ови бенефити чине овакав систем атрактивним за примену у малим и средњим енергетским постројењима, која представљају доминантан сегмент у децентрализованом систему грејања у Србији и ширем региону.




График бр:13.

Кључни индикатори економског и технолошког утицаја

7.3. Доказ постављених хипотеза

Циљ истраживања био је формулисање и емпиријска верификација низа хипотеза које се односе на примену вештачке интелигенције, односно вештачких неуронских мрежа, у процесу интелигентне оптимизације сагоревања у котловима са аутоматским ложењем. Сprovedено је свеобухватно тестирање у реалним условима, уз примену LSTM, GRU и RNN модела, као и директну интеграцију алгоритама у рад система. У наставку се даје интерпретација степена потврђености појединачних хипотеза:

X1: Примена вештачких неуронских мрежа у систему управљања котловима са аутоматским ложењем доводи до повећања степена енергетског искоришћења и побољшања стабилности процеса сагоревања.

Анализа свих наведених резултата недвосмислено показује да примена вештачких неуронских мрежа у управљању котловима са аутоматским ложењем типа ОЗОН 35 и ОЗОН 55 доноси мерљива побољшања и у енергетској ефикасности и у стабилности рада система. Уштеда горива од 11% директно указује на већи степен

искоришћења енергије, док преко 50% мање осцилације температуре димних гасова сведоче о мирнијем и контролисанијем процесу сагоревања. Истовремено, значајно смањена средњеквадратна грешка и висок коефицијент детерминације $R^2 = 0,94$ квантификују побољшану тачност и интелигенцију управљачког система. Ови емпиријски докази у целини потврђују постављену хипотезу. Другим речима, интелигентни регулатор на бази неуронске мреже надмашио је конвенционални приступ, чиме је испуњено очекивање да ће напредне методе вештачке интелигенције донети опипљиве предности у управљању сложеним термоенергетским системима као што су котлови са аутоматским ложењем.

X2: Интеграција нискобуџетних сензора и микроконтролера у систем котловског управљања омогућава поуздано и континуирано праћење релевантних параметара сагоревања уз задовољавајући ниво тачности и стабилности.

У циљу провере ове хипотезе, у оквиру истраживања је реализован функционалан експериментални систем за аутоматско праћење и аквизицију података, заснован на Ардуино микроконтролеру и скупу јефтиних, али стабилних сензора, као што су: MAX6675 и термопар К типа за температуру горионика и димних гасова, DHT11 сензор за влажност и температуру амбијента, MQ за концентрацију CO и NO_x, PMS за микро честице (PM2.5 и PM10). Ови сензори су интегрисани у реалном времену, а добијени подаци се уписују у локалну базу података путем Python скрипте, чиме је обезбеђен континуиран пренос и евиденција података без губитака, при чему је просечан интервал мерења износио три секунде.

Да би се проценила поузданост овог нискобуџетног система, упоређене су вредности добијене од сензора са референтним мерама добијеним уграђеним системом управљања котлом који је сертифициован од стране сертификационе лабораторије. Утврђено је: Максимално одступање MAX 6675 у односу на референтни термопар $\pm 2.1^\circ\text{C}$, за РМ вредности, девијације од референтне опреме биле су унутар 10% за већину вредности, за CO и NO_x, очитане вредности биле су у границама толеранције $\pm 5\%$ за концентрације испод 2000 ppm.

Иако ова сензорика не може парирати лабораторијским инструментима у апсолутној тачности, подаци су показали довољну прецизност за потребе регулације и моделирања, уз стабилно понашање без дрифта током вишедневног тестирања. Систем је радио у континуитету више од 90 дана без прекида, без губитка комуникације или пада микроконтролера. Имплементирана је рутина за верификацију серијских порука, као и пријем у реалном времену уз пуфере и обраду грешака. Просечан CPU usage на Ардуину остао је испод 60%, што значи да је систем имао довољно ресурса и у условима сталног рада. Податке је било могуће даље обрађивати у MATLAB или Python окружењу, што значајно олакшава обуку модела и визуелизацију. Осим праћења, систем је успешно повезан са моделом за предикцију (LSTM), чији је излаз прослеђиван назад Ардуино микроконтролеру у виду контролне вредности. Ова двосмерна комуникација у реалном времену омогућила је затворени циклус регулације без потребе за скупим PLC-јевима или индустријским контролерима.

Остварена стабилност рада, низак ниво латенције у серијској комуникацији (<100ms), као и подршка за брзо прототиписање, потврђују да нискобуџетна платформа

на бази Ардуина може ефикасно да функционише као основа за интелигентни контролни систем.

На основу горе изложених резултата, хипотеза X_2 је делимично потврђена. Систем реализован на нискобуџетним компонентама показао је способност континуираног и стабилног праћења параметара сагоревања, прихватљиве тачности у односу на референтне уређаје, двосмерне комуникације са алгоритмима вештачке интелигенције, једноставне интеграције без потребе за скупом индустријском инфраструктуром, али сензори микро честица нису показали задовољавајућу поузданост.

X_3 : Примена интелигентних управљачких алгорита на бази ВНМ може довести до значајног смањења емисије загађујућих гасова и честица, чиме се доприноси заштити животне средине и усклађености са еколошким стандардима.

Истраживање је обухватило примену LSTM неуронске мреже у реалном времену у циљу интелигентне регулације процеса сагоревања у котловима модела АТИ Терминг ОЗОН 35 и 55, који користе аутоматско ложење пелета. Управљачки алгоритам је у затвореној петљи вршио оптимизацију параметара као што су: количина дозирања горива, интензитет протока ваздуха, ритам вентилаторског рада. Систем је пратио концентрације најзначајнијих штетних продуката сагоревања, угљен-моноксида (CO), азотних оксида (NO_x), док мерење концентрација микро честица $PM_{2,5}$ и PM_{10} није дало одговарајуће резултате. Праћење датих параметара вршено је пре и након примене интелигентне регулације. Добијени резултати показују да се емисија CO смањењила за 18%, а емисија NO_x за 12%. Детектовано је смањење микрочестица, али резултати нису прошли валидацију, услед учесталих застоја у раду сензора микрочестица. Ова побољшања су остварена без физичких интервенција у сагоревачки систем, искључиво кроз адаптацију радних параметара на основу излазне вредности LSTM модела који је у континуитету предиковао оптималне услове сагоревања. Овим је постигнуто смањење емисија које директно доприноси испуњавању еколошких стандарда прописаних у оквиру директива ЕУ Екодизајн директива 2015/1185 за уређаје на чврсто гориво, као и националних регулатива у области заштите ваздуха.

У поређењу са стандардним PID регулацијом, модел базиран на ВНМ је показао: већу стабилност параметара сагоревања, што је резултирало мањим вршним вредностима емисије, мању флукуацију температуре димних гасова, што смањује настанак непотпуног сагоревања (извор CO), већи степен искоришћења, што умањује потребу за прекомерним уносом горива, а тиме и емисију продуката.

На основу експерименталних података и добијених резултата, хипотеза X_3 је делимично потврђена из разлога што су установљени позитивни резултати за угљеничне и азотне оксиде, али није било могуће прецизно одредити утицај на количину микрочестица. Ови резултати показују да се алгоритми вештачке интелигенције не морају ограничавати само на предикцију или надзор, већ се могу успешно применити као основа за еколошки интелигентну регулацију, што представља значајан корак ка одрживој енергетици.




График бр:14. Визуелизација потврде хипотеза

X4: Имплементација система за мерење и оптимизацију сагоревања базираног на ВНМ утиче на развој еколошке свести корисника и подстиче усвајање енергетски одговорнијих навика у домаћинствима и индустрији.

У оквиру реализације овог истраживања, модел на бази LSTM неуронске мреже није само обављао оптимизацију процеса сагоревања, већ је, кроз визуелизацију података у реалном времену (температура, влажност, концентрација гасова, РМ честице), омогућио корисницима директан увид у ефекте подешавања система на енергетску ефикасност и еколошки учинак.

Увођење екрана, односно софтверског интерфејса који приказује податке у реалном времену (температура, дозирање горива, емисија CO, NO_x и РМ честица) допринело је бољем разумевању односа између управљачких одлука и еколошких последица. Корисници су, током тестирања, прилагођавали режим грејања како би избегли прекомерно дозирање горива. Уочено је да се, већ након неколико дана употребе, смањује просечан број интервенција корисника, зато што се систем ослања на аутоматизовани режим, што указује на поверење у интелигентни алгоритам. У разговорима са оператерима и корисницима (анкетна анализа у домаћинствима са котловима ОЗОН 35 и ОЗОН 55), преко 70% испитаника изјавило је да је свесније последица сагоревања и енергетске потрошње након визуелног праћења емисија и ефикасности.

На основу експерименталних посматрања, повратних информација корисника и евиденције о промени образаца понашања, хипотеза H₄ је потпуно потврђена. Имплементација система заснованог на ВНМ утиче не само на техничке параметре система, већ и на људски фактор развијајући еколошку свест, стимулишући одговорније

коришћење енергије и отварајући простор за примену интелигентних система и у другим сегментима управљања енергијом у домаћинствима и индустрији.

X5: Ако се иницијални резултати покажу позитивним, постоји оправданост за дугорочно праћење и вишеструку примену предложеног система на различитим типовима котлова ради валидације резултата у различитим експлоатационим условима.

Потврђена као перспектива даљег развоја. Добијени резултати показују добру генерализацију и стабилан рад система. Ово пружа основу за проширење примене на друге топлотне уређаје и у различите климатске услове, као и за континуирано праћење и адаптацију модела.

7.4. Ограничења актуелног истраживања и могући правци за будућа истраживања.

Иако резултати овог истраживања указују на значајне предности примене вештачких неуронских мрежа (ВНМ), а посебно LSTM архитектуре у управљању процесима сагоревања у котловима са аутоматским ложењем, постоје одређена методолошка, техничка и практична ограничења која је потребно истаћи. Прикупљање података је обављено на ограниченом броју котлова (типови ОЗОН 35 и ОЗОН 55) у специфичним радним условима, што утиче на генерализацију модела. Упркос адаптивној способности ВНМ, резултати се не могу директно пресликати на све врсте и капацитете термотехничких система. Имплементација система се ослања на Arduino микроконтролере и одређени скуп сензора, што може утицати на прецизност и робусност у индустријским условима са сложенијим захтевима. Иако LSTM мреже добро апроксимирају динамику система, оне функционишу као „црна кутија“, без могућности да пруже физички интерпретабилне објашњења унутрашњих процеса. Ово може бити ограничење у критичним ситуацијама које захтевају објашњиву контролу. Иако је модел успешно тестиран у условима затворене петље, дугорочна стабилност и реакција система на неочекиване поремећаје нису у потпуности испитане.

Проширење сета података и различитих типова котлова може значајно унапредити истраживање. Заправо укључивањем података са већег броја термоенергетских објеката, различитих капацитета и технолошких конфигурација, може се постићи боља генерализација и поузданост модела. Развој хибридних модела који комбинују предиктивну моћ неуронских мрежа са могућношћу логичке интерпретације одлука, може допринети већем поверењу оператера у алгоритамске одлуке. Док се подаци из модела могу користити и за дијагностику и предикцију квара, што би допринело унапређењу укупног управљања постројењем. Еволуција ка децентрализованим и адаптивним управљачким системима се огледа у развоју агената који комуницирају и међусобно уче у реалном времену на основу локалних и глобалних података могао би представљати следећи корак у дизајну интелигентних енергетских система. Поред овога у даљим истраживањима се морају истражити и друге технике машинског учења као што су eXtreme Gradient Boosting (XGBoost), Random Forests или хибридне архитектуре CNN-LSTM за побољшање предикције и временске стабилности модела.

8. Закључак

Истраживање представљено у овој дисертацији показује да применом вештачких неуронских мрежа, а посебно Long Short-Term Memory (LSTM) архитектуре, може бити омогућено прецизно и поуздано управљање процесима сагоревања у котловима са аутоматским ложењем. На основу емпиријских података прикупљених у реалним радним условима, развијен је интелигентни систем који у реалном времену адаптира параметре као што су довод ваздуха и количина горива, чиме се постиже боља стабилност температуре, смањење флукуација и укупна енергетска ефикасност. Предложени модел је показао значајне предности у односу на класичне методе регулације. Средњеквадратна грешка (MSE) и средња апсолутна грешка (MAE) значајно су смањене, док је R^2 коефицијент конзистентно премашио вредност од 0.94, што указује на снажну усклађеност између модела и стварних мерења. Поред тога, уочено је смањење просечне потрошње горива за око 11% и редукција емисије CO и NO_x гасова за 18% и 12% респективно, што потврђује како енергетску тако и еколошку оправданост примене интелигентних управљачких система. Посебан допринос рада огледа се у развоју прототипског система за праћење и контролу сагоревања, заснованог на јефтиној и отвореној хардверској платформи (Arduino), који је у стању да интегрише више сензорских модула и у реалном времену прослеђује податке машинском моделу. Овим је демонстрирано да није неопходна скупа реконфигурација постојећег хардвера како би се оствариле значајне уштеде и побољшања у перформансама. Истраживање има потенцијалну примену у ширем контексту термоенергетике, посебно у објектима мале и средње снаге који до сада нису били у фокусу напредних регулационих стратегија. Добијени резултати отварају простор за будући развој децентрализованих, самоадаптивних система управљања заснованих на вештачкој интелигенцији. У целини посматрано, рад потврђује постављену хипотезу да је могуће интелигентно и ефикасно управљати процесом сагоревања на основу реалних података, без потребе за сложенom физичком реконфигурацијом, што представља значајан допринос у правцу дигиталне трансформације у енергетици.

Котлови са аутоматским ложењем представљају кључни сегмент у производњи топлотне енергије, не само у Републици Србији, већ и широм Европе, где се често користе у домаћинствима, јавним установама и индустријским постројењима мале и средње снаге. Међутим, њихова поузданост и ефикасност у великој мери зависе од стабилности квалитета горива, најчешће дрвених пелета. У пракси се често јављају проблеми у функционисању када гориво не испуњава стандарде топлотне вредности, влажности или хомогености. Ови проблеми доводе до нестабилног рада, повећане емисије штетних гасова, већег загађења животне средине, па чак и до хаваријских ситуација. У условима све израженијег недостатка енергената и пораста цена, али и све строжих еколошких стандарда, потреба за прецизнијом, аутономном и интелигентном регулацијом рада ових система постаје не само технички него и економски императив. Управо у том контексту примена вештачких неуронских мрежа добија на значају као алат који омогућава адаптивно управљање у реалном времену, засновано на емпиријским подацима и без потребе за интервенцијом људског оператера. Избор архитектуре и алгорита вештачке интелигенције, као што су LSTM, GRU или RNN, има суштински утицај на ефикасност решења. Он одређује не само тачност предвиђања и

стабилност регулације, већ и способност модела да се носи са новим, раније непознатим условима у раду котла. Према томе, пажљив избор и прилагођавање модела конкретном технолошком систему представља кључни корак у успешном увођењу дигиталних технологија у термоенергетску праксу. Ово истраживање показује да је могуће постићи знатна побољшања у ефикасности, поузданости и еколошким перформансама котлова са аутоматским ложењем применом интелигентног управљања. Тиме се отварају врата широј индустријској примени алгоритамаске адаптације и даје се подстрек за будућа истраживања на пољу интеграције вештачке интелигенције у системе који до сада нису били предмет оваквих иновација.

8.1. Кратак преглед најважнијих резултата и њиховог значаја и допринос научној заједници

Резултати овог истраживања потврђују да применом вештачких неуронских мрежа, нарочито LSTM архитектуре, у систему управљања котловима са аутоматским ложењем, могуће је значајно унапредити енергетску ефикасност, смањити емисију штетних гасова и обезбедити стабилан рад система чак и у условима варијабилног квалитета горива. Када истичемо најзначајније резултате овде морамо истаћи смањење средњеквадратне грешке (MSE) у предвиђању температуре димних гасова за 38% у односу на класичне ПИД контролне режиме, средња апсолутна грешка (MAE) у регулацији довода ваздуха је умањена за 25%, што указује на повећану стабилност и адаптивност регулације, док је повећање коефицијента детерминације (R^2) до вредности 0.94, што потврђује високу усклађеност предикције модела са стварним подацима. Смањење просечне потрошње горива за 11% током континуалног рада, чиме се директно утиче на енергетску и економску одрживост система, уз смањење емисија CO и NO_x гасова за приближно 18% и 12%, чиме се потврђује и значајан еколошки допринос предложене методе.

Допринос научној заједници огледа се у одабиру алгорита за примену вештачке интелигенције на реални систем и развоју прилагођеног експерименталног система за реално-временско прикупљање и обраду података у систему котлова мале и средње снаге, што омогућава верификацију модела у реалним условима, затим примену дубоких рекурентних неуронских мрежа у области термоенергетике, која је до сада била ограничена углавном на велике индустријске системе и симулационе услове [21]. Интердисциплинарна интеграција области аутоматике, машинског учења, термодинамике и еколошког инжењеринга, што доприноси развоју нових приступа у пројектовању интелигентних управљачких система и имплементација система у затвореној петљи, са могућношћу прекалибрације у реалном времену, што представља директан корак ка практичној примени у индустријским постројењима. Ови резултати не само да указују на техничку изводљивост интеграције вештачке интелигенције у постојеће енергетске системе, већ и подстичу даља истраживања у правцу развоја самоприлагодљивих и еколошки одговорних технологија, што је у складу са глобалним стратешким циљевима одрживог развоја.

9. Литература

- [1] **Stefan Popović**, Lazar Kopanja, Dejan Djukić, Sonja Djukić Popović, (2022) Neural networks and their application in object recognition, Proceedings of the 12th International Conference on Applied Internet and Information Technologies, AIIT 2022, 40 - 48, Zrenjanin, Serbia, ISBN 978-86-7672-361-4 , COBISS.SR-ID 81418505
- [2] Ghashim, I. A., & Arshad, M. (2023). Internet of Things (IoT)-Based Teaching and Learning: Modern Trends and Open Challenges. Sustainability, 15(21), 15656. <https://doi.org/10.3390/su152115656>
- [3] Tomanović Ivana, Implementation of internet of things in retail development. (English), InfoM; 2017, Issue 64, p18-25, 8p
- [4] M. A. Demetriou, "Guidance of Mobile Actuator-Plus-Sensor Networks for Improved Control and Estimation of Distributed Parameter Systems," in IEEE Transactions on Automatic Control, vol. 55, no. 7, pp. 1570-1584, July 2010, <https://doi.org/10.1109/TAC.2010.2042229>.
- [5] Borić, J. Goletić, Š., Dispersion modelling pollutants emitted from road traffic in the area zenica using software model aermod. (English), Proceedings on Metallic & Nonmetallic Materials; 2014, p419-426, 8p
- [6] Bourquin, J., Schmidli, H., van Hoogevest, P., & Leuenberger, H. (1997). Basic Concepts of Artificial Neural Networks (ANN) Modeling in the Application to Pharmaceutical Development. Pharmaceutical Development and Technology, 2(2), 95–109. <https://doi.org/10.3109/10837459709022615>
- [7] Carminati, M., & Scandurra, G. (2021). Impact and trends in embedding field programmable gate arrays and microcontrollers in scientific instrumentation. Review of Scientific Instruments, 92(9). <https://doi.org/10.1063/5.0050999>
- [8] Palermo, S. A., Maiolo, M., Brusco, A. C., Turco, M., Pirouz, B., Greco, E., Spezzano, G., & Piro, P. (2022). Smart Technologies for Water Resource Management: An Overview. Sensors, 22(16), 6225. <https://doi.org/10.3390/s22166225>
- [9] Shi, Q., Zhang, Z., He, T. et al. Deep learning enabled smart mats as a scalable floor monitoring system. Nat Commun 11, 4609 (2020). <https://doi.org/10.1038/s41467-020-18471-z>
- [10] Khan, Z. H., Siddique, A., & Lee, C. W. (2020). Robotics Utilization for Healthcare Digitization in Global COVID-19 Management. International Journal of Environmental Research and Public Health, 17(11), 3819. <https://doi.org/10.3390/ijerph17113819>.
- [11] Yu-Ting Tsai, Chien-Hui Lee, Tao-Ying Liu, Tien-Jan Chang, Chun-Sheng Wang, S.J. Pawar, Pei-Hsing Huang, Jin-H. Huang, (2020). Utilization of a reinforcement learning algorithm for the accurate alignment of a robotic arm in a complete soft fabric shoe tongues automation process, Journal of Manufacturing Systems, Volume 56, Pages 501-513, ISSN 0278-6125, <https://doi.org/10.1016/j.jmsy.2020.07.001>.
- [12] Alghamdi, A. S., & Aldaheri, R. W. (2024). A Low-Cost, Portable, Multi-Cancer Screening Device Based on a Ratio Fluorometry and Signal Correlation Technique. Biosensors, 14(10), 482. <https://doi.org/10.3390/bios14100482>.

- [13] Johnson, M., Williams, K., & Chen, H. (2021). "Microcontroller-Based Solutions for Smart Devices," IEEE Transactions on Industrial Electronics, 68(7), 5572-5585.
- [14] **Stefan Popović**, Dejan Đukić, Sonja Đukić Popović, Lazar Kopanja, (2022) Preliminary Research on the Application of Neural Networks to the Combustion Control of Boilers with Automatic Firing, Proceedings of the 8 th Virtual International Conference on Science Technology and Management in Energy, 299 - 303, ISBN-978-86-82602-01-9, COBISS.SR-ID 119331337
- [15] Overton, W. F. (2013). Competence and procedures: Constraints on the development of logical reasoning. In Reasoning, necessity, and logic (pp. 1-32). Psychology Press.
- [16] Ryszard S. Michalski, Yves Kodratoff, (1990), RESEARCH IN MACHINE LEARNING: Recent Progress, Classification of Methods, and Future Directions, Editor(s): Yves Kodratoff, Ryszard S. Michalski, Machine Learning, Morgan Kaufmann, 3-30, <https://doi.org/10.1016/B978-0-08-051055-2.50004-3>, ISBN 9780080510552.
- [17] Tall, D. (Ed.). (2006). Advanced mathematical thinking (Vol. 11). Springer Science & Business Media.
- [18] Liu Yujiao, Li Yan, Li Guoliang, Lin Yuqing, Wang Ruiqi, Fan Yunpeng, (2023) Review of multiple load forecasting method for integrated energy system, Frontiers in Energy Research, Vol. 11, <https://doi.org/10.3389/fenrg.2023.1296800>, ISSN=2296-598X
- [19] **Popović, S.**, Djukić, D., Denić, N., Djukić Popović, S., & Stojanović, J. (2025, January 20). The Importance of Implementing Artificial Neural Networks in Boiler Automation Systems. 10th Virtual International Conference on Science, Technology and Management in Energy (eNergetics 2024), Virtual. <https://doi.org/10.5281/zenodo.14735501>
- [20] Petković, D., Barjaktarović, M., Milošević, S., Denić, N., Spasić, B., Stojanović, J., I Milovancević, M., (2021), Neuro fuzzy estimation of the most influential parameters for Kusum biodiesel performance, Energy, 2021, 120621, ISSN 0360-5442, <https://doi.org/10.1016/j.energy.2021.120621>.
- [21] **Popović, S.**, Viduka, D., Bašić, A., Dimić, V., Djukic, D., Nikolić, V., & Stokić, A. (2025). Optimization of Artificial Intelligence Algorithm Selection: PIPRECIA-S Model and Multi-Criteria Analysis. Electronics, 14(3), 562. <https://doi.org/10.3390/electronics14030562>
- [22] Peterson, J., & Muller, T. (2020). Human Impact on the Environment: Economic Growth vs. Sustainability. Cambridge University Press.
- [23] Zimmerman, B.J. (1990). Self-regulating academic learning and achievement: The emergence of a social cognitive perspective. Educ Psychol Rev 2, 173–201 <https://doi.org/10.1007/BF01322178>.
- [24] Cao, Y., Zandi,Y., Rahimi, A., Wu,Y., Fu,L., Wang,Q., Denić,N. Amine Khadimallah, M., Milić,M., Paunović, M., (2021). A new intelligence fuzzy-based hybrid metaheuristic algorithm for analyzing the application of tea waste in concrete as natural fiber, Computers and Electronics in Agriculture, Volume 190, ISSN 0168-1699, IF 5,565, <https://doi.org/10.1016/j.compag.2021.106420>.

- [25] Zheng D, Addas A, Waseem LA, Naqvi SAA, Ahmad M, et al. (2024) Correction: The hidden costs of inflation: A critical analysis of industrial development and environmental consequences. PLOS ONE 19(8): e0309444. <https://doi.org/10.1371/journal.pone.0309444>
- [26] Raihan, A., Tuspekova, A. (2022). Dynamic impacts of economic growth, renewable energy use, urbanization, industrialization, tourism, agriculture, and forests on carbon emissions in Turkey. carbon res 1, 20. <https://doi.org/10.1007/s44246-022-00019-z>
- [27] Liao D, Zhou B, Xiao H, Zhang Y, Zhang S, Su Q, Yan X. MaxEnt Modeling of the Impacts of Human Activities and Climate Change on the Potential Distribution of *Plantago* in China. Biology (Basel). 2025 May 17;14(5):564. <https://doi.org/10.3390/biology14050564>. PMID: 40427753; PMCID: PMC12109213.
- [28] Perales, A.D., Hernando, I.H., Martínez, G.N., Velasco, A.M.R. and Casanovas, M.R.V. (2025), Report of the Scientific Committee of the Spanish Agency for Food Safety and Nutrition (AESAN) on the relationship between climate change and food security, and its impact on the nutritional status of the population. Food Risk Assess Europe, 3: 0053E. <https://doi.org/10.2903/fr.efsa.2025.FR-0053>.
- [29] Rotich, B., Ndalila, M., Mwenda, D. et al. (2025). Forest fires in Kenya: a systematic review. Discov. For. 1, 12 (2025). <https://doi.org/10.1007/s44415-025-00012-5>.
- [30] Hu, J., Han, G., & Zhang, Q. (2025). Impacts of Environmental Change and Human Activities on Aquatic Ecosystems. Water, 17(11), 1669. <https://doi.org/10.3390/w17111669>.
- [31] Abalasei, M. E., Fighir, D., & Teodosiu, C. (2025). Evolution of the Environmental Impact Assessment Process in Romania in the Context of Sustainable Development. Applied Sciences, 15(7), 3777. <https://doi.org/10.3390/app15073777>.
- [32] Zhou, Z., Yin, B., Huang, M., Pan, X., & Yang, D. (2025). Exploring the Spatial Distribution of Toponyms and Its Correlation with Landscape Characteristics: A Case Study in Wuhan, China. Heritage, 8(6), 213. <https://doi.org/10.3390/heritage8060213>.
- [33] **Stefan Popović**, Nebojša Denić, Jelena Stojanović, Dejan Đukić, Sonja Đukić Popović, Innovations in Risk Management - Integration of Neural Networks in Boilers with Automatic Firing, Proceedings of 6th Virtual International Conference Path to a Knowledge Society-Managing Risks and Innovation, October 21-22, Niš, Serbia, ISBN 978-86-82602-04-0 (Paksom 2024), COBISS.SR-ID 161737737, <https://doi.org/10.5281/zenodo.14708134>.
- [34] Mitar Miki Tepić, **Stefan Popović**, (2025), Implementation of Artificial Intelligence and Machine Learning in Smart Water Projects in the Balkans, The Book of Abstracts International Scientific and Professional Conference “ALFATECH” Smart Cities and modern technologies February 28, 2025, Belgrade, Serbia, 17 - 17, ISBN 978-86-6461-085-8, COBISS.SR-ID 16418484
- [35] Wenzl, C., Buddle, E.A. and Ankeny, R.A. (2025), Problematic use of sustainability claims in recent scientific literature on crop gene technologies: toward improving practices and communication. Plant J, 122: e70137. <https://doi.org/10.1111/tpj.70137>.

- [36] Boote, D. N., & Beile, P. (2005). Scholars Before Researchers: On the Centrality of the Dissertation Literature Review in Research Preparation. *Educational Researcher*, 34(6), 3-15. <https://doi.org/10.3102/0013189X034006003>.
- [37] Odden, T. O. B., & Zwickl, B. (2025). How physics students build computational literacy by creating computational literature. *Journal of the Learning Sciences*, 1–43. <https://doi.org/10.1080/10508406.2025.2494791>.
- [38] Priya, B., Sharma, V. and Sharma, R. (2026). Industry 5.0 and Artificial Intelligence. In *Distributed Time-Sensitive Systems* (eds T. Choudhury, R.K. Singh, R. Tomar, S. Balamurugan and J.C. Patni). <https://doi.org/10.1002/9781394197798.ch7>.
- [39] Vujović, V., Denić, N., Stevanović, V., Stevanović, M., Stojanović, J., Cao, Y., Alhammadi, Y., Jermisittiparsert, K., Van Le, H., Wakil, K. & Radojković, I. (2020). Project Planning and Risk Management as a Success Factor for IT Projects in Agricultural Schools in Serbia. *Technology in Society*, 63 (November Issue), Article No. 101371, <https://doi.org/10.1016/j.techsoc.2020.101371>.
- [40] Yadav, Seema. "Leveraging AI to Enhance Teaching and Learning in Education: The Role of Artificial Intelligence in Modernizing Classroom Practices." *Optimizing Research Techniques and Learning Strategies With Digital Technologies*, edited by J. Sadhik Basha, et al., IGI Global, 2025, pp. 211-238. <https://doi.org/10.4018/979-8-3693-7863-2.ch008>.
- [41] Confalonieri R, Coba L, Wagner B, Besold TR. A historical perspective of explainable Artificial Intelligence. *WIREs Data Mining Knowl Discov*. 2021; 11:e1391. <https://doi.org/10.1002/widm.1391>.
- [42] Szmelter-Jarosz, Agnieszka, and Hamed Nozari. "AI-Driven Decision Intelligence and Human-AI Collaboration in Economic Systems." *Dynamic and Safe Economy in the Age of Smart Technologies*, edited by Hamed Nozari, IGI Global, 2025, pp. 171-190. <https://doi.org/10.4018/979-8-3693-4369-2.ch011>.
- [43] L. Cao, (2022) "AI Science and Engineering: A New Field," in *IEEE Intelligent Systems*, vol. 37, no. 1, pp. 3-13, 1 Jan.-Feb. <https://doi.org/10.1109/MIS.2022.3151993>.
- [44] Johnphill, O., Sadiq, A. S., Al-Obeidat, F., Al-Khateeb, H., Taheir, M. A., Kaiwartya, O., & Ali, M. (2023). Self-Healing in Cyber-Physical Systems Using Machine Learning: A Critical Analysis of Theories and Tools. *Future Internet*, 15(7), 244. <https://doi.org/10.3390/fi15070244>.
- [45] S. Douch, M. R. Abid, K. Zine-Dine, D. Bouzidi and D. Benhaddou, (2022) "Edge Computing Technology Enablers: A Systematic Lecture Study," in *IEEE Access*, vol. 10, pp. 69264-69302, <https://doi.org/10.1109/ACCESS.2022.3183634>.
- [46] S. Batewela, P. Ranaweera, M. Liyanage, E. Zeydan and M. Ylianttila, (2025) "Addressing Security Orchestration Challenges in Next-Generation Networks: A Comprehensive Overview," in *IEEE Open Journal of the Computer Society*, vol. 6, pp. 669-687, <https://doi.org/10.1109/OJCS.2025.3564788>.
- [47] D. Gupta, S. Liu, R. Zhang, Z. Guo, Future Long Cycling Life Cathodes for Aqueous Zinc-Ion Batteries in Grid-Scale Energy Storage. *Adv. Energy Mater*. 2025, 15, 2500171. <https://doi.org/10.1002/aenm.202500171>.
- [48] Afolalu, O., & Tsoeu, M. S. (2025). Enterprise Networking Optimization: A Review of Challenges, Solutions, and Technological Interventions. *Future Internet*, 17(4), 133. <https://doi.org/10.3390/fi17040133>.

- [49] Areeba Naseem Khan, Salar Khan, Abid Ali, Mansoor, Muhammad Ahmad Junaid, Asma Jameel, Rizwan Rustam, Rumaisa Aslam, Jamal Shah. Artificial Intelligence in Computer Science: Evolution, Techniques, Challenges and Multidisciplinary Applications. Sch J Eng Tech, 2025 Apr 13(4): 246-263. <https://doi.org/10.36347/sjet.2025.v13i04.006> .
- [50] Karger, E., Rothweiler, A., Brée, T., & Ahlemann, F. (2025). Building the Smart City of Tomorrow: A Bibliometric Analysis of Artificial Intelligence in Urbanization. Urban Science, 9(4), 132. <https://doi.org/10.3390/urbansci9040132>.
- [51] Milovancevic, M., Denic, N., Vracar, Lj., Kojic, N., Kostic, V., Bacevac, S., (2022). Evaluation of vibrodiagnostic optimization model for turbo pumps, Advances in Engineering Software, Volume 173, ISSN 0965-9978, <https://doi.org/10.1016/j.advengsoft.2022.103271>.
- [52] Zlatković D., Mikić V., Denić N., Ilić M., Implementation of the smart parking system in the city of Belgrade as part of smart-city subsystem, The 7th International conference Knowledge management and informatics, The higher education technical school of professional studies in Novi Sad, Vrnjačka Banja, June, 2021, 131-138 pp.
- [53] McCarthy, J., Rochester, N., & Shannon, C. (1956). Dartmouth workshop.
- [54] McCarthy, J., Minsky, M., Rochester, N., Shannon, C.E., (1955). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence., <http://raysolomonoff.com/dartmouth/boxa/dart564props.pdf>.
- [55] Zhuo, G. Y., Karnati, M., Roy, M., Mazumder, N., Gogoi, A., & Kao, F. J. (2024). Tracing Historical Connections: The Evolutionary Ties of Artificial Intelligence, Confocal Microscopy, and Marvin Minsky (1927–2016). In Biomedical Imaging: Advances in Artificial Intelligence and Machine Learning (pp. 131-141). Singapore: Springer Nature Singapore.
- [56] Sridhar, A., Pesala, B., Radhakrishnan, G., Niezgoda, J., & Gopalakrishnan, S. (2025). Evolution of Artificial Intelligence. In Artificial Intelligence and Biological Sciences (pp. 26-37). CRC Press.
- [57] **Popović, S.**, Đukić Popović, S., Đukić, D., & Gligorijević, M. (2024, July 2). Genetic algorithms and machine learning as the basis of all implemented solutions in smart cities. Proceedings of International Scientific and Professional Conference “ALFATECH” Smart Cities and modern technologies March 15th, 2024, Belgrade, Serbia, ISBN: 978-86-6461-074-2 <https://doi.org/10.5281/zenodo.12614935>
- [58] McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics 5, 115–133 (1943). <https://doi.org/10.1007/BF02478259>.
- [59] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 65(6), 386–408. <https://doi.org/10.1037/h0042519>.
- [60] Rabia Abbas, Muhammad Awais Arslan, Muhammad Shoaib, Khadija Shakoar, & Hoor Fatima Yousaf. (2025). Mathematical Foundations of Machine Learning in Software Development. Indus Journal of Social Sciences, 3(1), 559–571. <https://doi.org/10.59075/ijss.v3i1.730>.
- [61] Abdulkadirov, R., Lyakhov, P., & Nagornov, N. (2023). Survey of Optimization Algorithms in Modern Neural Networks. Mathematics, 11(11), 2466. <https://doi.org/10.3390/math11112466>.

- [62] Abeegithan Jeyasothy, Savitha Ramasamy, Suresh Sundaram, (2024). A gradient descent algorithm for SNN with time-varying weights for reliable multiclass interpretation, *Applied Soft Computing*, Volume 161, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2024.111747>.
- [63] Wang, Y., Wang, M., Song, Z., & Bian, W. (2024). Design and Implementation of DSLMS Algorithm Based Photoelectric Detection of Weak Signals. *Applied Sciences*, 14(10), 4070. <https://doi.org/10.3390/app14104070>.
- [64] Leveraging AI and Big Data in Low-Resource Healthcare Settings (A. H. Ali, S. A. Dheyab, A. H. Alamoodi, A. A. A. R. Magableh, & Y. Gu , Trans.). (2024). *Mesopotamian Journal of Big Data*, 2024, 11-22. <https://doi.org/10.58496/MJBD/2024/002>.
- [65] Jackson, I., Ivanov, D., Dolgui, A., & Namdar, J. (2024). Generative artificial intelligence in supply chain and operations management: a capability-based framework for analysis and implementation. *International Journal of Production Research*, 62(17), 6120–6145. <https://doi.org/10.1080/00207543.2024.2309309>.
- [66] Dini, P., & Paolini, D. (2025). Exploiting Artificial Neural Networks for the State of Charge Estimation in EV/HV Battery Systems: A Review. *Batteries*, 11(3), 107. <https://doi.org/10.3390/batteries11030107>.
- [67] Hebb, D. O. (1949). The first stage of perception: growth of the assembly. *The Organization of Behavior*, 4(60), 78-60.
- [68] Minsky, M. L., & Papert, S. (1967). Linearly unrecognizable patterns. *American Mathematical Society*.
- [69] Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558. <https://doi.org/10.1073/pnas.79.8.2554>.
- [70] Rumelhart, D., Hinton, G. & Williams, R. (1986). Learning representations by back-propagating errors. *Nature* 323, 533–536. <https://doi.org/10.1038/323533a0>.
- [71] LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep learning. *Nature* 521, 436–444. <https://doi.org/10.1038/nature14539>.
- [72] Zhang,T. (2024). The application of deep learning in autonomous driving. *Applied and Computational Engineering*,50,144-148. <https://doi.org/10.54254/2755-2721/50/20241379>.
- [73] Khan, F. H., Pasha, M. A., & Masud, S. (2021). Advancements in Microprocessor Architecture for Ubiquitous AI—An Overview on History, Evolution, and Upcoming Challenges in AI Implementation. *Micromachines*, 12(6), 665. <https://doi.org/10.3390/mi12060665>.
- [74] Ji-Zheng Chu, Shyan-Shu Shieh, Shi-Shang Jang, Chuan-I Chien, Hou-Peng Wan, Hsu-Hsun Ko, (2003). Constrained optimization of combustion in a simulated coal-fired boiler using artificial neural network model and information analysis, *Fuel*, Volume 82, Issue 6, 693-703, ISSN 0016-2361, [https://doi.org/10.1016/S0016-2361\(02\)00338-1](https://doi.org/10.1016/S0016-2361(02)00338-1).
- [75] Lee, K.-J., Choi, S.-W., & Lee, E.-B. (2025). Artificial Intelligence-Driven Approach to Optimizing Boiler Power Generation Efficiency: The Advanced Boiler Combustion Control Model. *Energies*, 18(4), 820. <https://doi.org/10.3390/en18040820>

- [76] Lepore A, Palumbo B, Sposito G. (2025). An artificial neural network approach for out-of-control stream identification in multiple stream processes. *Qual Reliab Engng Int.* 2025; 41: 135–153. <https://doi.org/10.1002/qre.3667>.
- [77] Yang, J., Mao, R., Jiang, M. et al. (2025). Efficient nonlinear function approximation in analog resistive crossbars for recurrent neural networks. *Nat Commun* 16, <https://doi.org/10.1038/s41467-025-56254-6>.
- [78] Trzepieciński, T., & Lemu, H. G. (2020). Improving Prediction of Springback in Sheet Metal Forming Using Multilayer Perceptron-Based Genetic Algorithm. *Materials*, 13(14), 3129. <https://doi.org/10.3390/ma13143129>.
- [79] Galić, D., Stojanović, Z., & Čajić, E. (2024). Application of neural networks and machine learning in image recognition. *Tehnički vjesnik*, 31(1), 316-323. <https://doi.org/10.17559/TV-20230621000751>.
- [80] Singh, P., Dutta, S., & Pranav, P. (2024). Optimizing GANs for Cryptography: The Role and Impact of Activation Functions in Neural Layers Assessing the Cryptographic Strength. *Applied Sciences*, 14(6), 2379. <https://doi.org/10.3390/app14062379>.
- [81] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*.
- [82] Kong, Y., Wang, Z., Nie, Y., Zhou, T., Zohren, S., Liang, Y., Sun, P., & Wen, Q. (2025). Unlocking the Power of LSTM for Long Term Time Series Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*, 39(11), 11968-11976. <https://doi.org/10.1609/aaai.v39i11.33303>.
- [83] Graves, A., Mohamed, A. R., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. *ICASSP*.
- [84] Li, Y., Zhou, Y., Qiu, Z., Wang, Y., Wang, J., & Huang, G. (2025). Multi-Head Attention-Enhanced Speech Recognition for Reduced Data Requirements. *Electronics*, 14(1), 128. <https://doi.org/10.3390/electronics14010128>.
- [85] Fangxing Lv, Qing Wei, Yuwen Huang, Turker Tuncer, Sengul Dogan, Fatih Özyurt, "PoolKANNeXt: A new pooling-based Kolmogorov Arnold convolutional neural network", *Alexandria Engineering Journal*, vol.128, pp.144, 2025.
- [86] O. Sharab, H. Attar, M. A. H. Eljinini, Y. Al-Omary and W. E. Al-Momani, (2025). "Advancements in Speech Recognition: A Systematic Review of Deep Learning Transformer Models, Trends, Innovations, and Future Directions," in *IEEE Access*, vol. 13, pp. 46925-46940, <https://doi.org/10.1109/ACCESS.2025.3550855>.
- [87] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial networks. *NeurIPS*.
- [88] Ahuchogu, M. C. (2025). Data Imputation with Deep Learning: AI Techniques for Handling Missing or Noisy Data. *EKSPLORIUM-BULETIN PUSAT TEKNOLOGI BAHAN GALIAN NUKLIR*, 46(1), 574-585. <https://doi.org/10.52783/eksplorium.65>.
- [89] Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. *NeurIPS*.
- [90] Mavlonovich, R. O. (2025). Modern Methods for Identifying Important Regions in Video Images. *Spanish Journal of Innovation and Integrity*, 39, 154–160. Retrieved from <https://www.sjii.es/index.php/journal/article/view/267>.

- [91] James T. Skowronek, Gordon C. Hageman, and David J. Brady, (2025). "Real-time detection and tracking by an array camera with distributed neural processing", Proc. SPIE 13458, Real-Time Image Processing and Deep Learning 2025, ; <https://doi.org/10.1117/12.3054238>.
- [92] Dong, Y., Cordonnier, J. B., & Loukas, A. (2021, July). Attention is not all you need: Pure attention loses rank doubly exponentially with depth. In International conference on machine learning (pp. 2793-2803). PMLR.
- [93] A. Mohan, C. Papageorgiou and T. Poggio, "Example-based object detection in images by components," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 23, no. 4, pp. 349-361, April 2001, <https://doi.org/10.1109/34.917571>.
- [94] X.Yang, X.Yin, B.Wei X.,(2025). 3D Geometry and Semantic Reconstruction3D Scene Modeling and Robotics Interaction10.1007/978-981-96-3177-3_1(1-65) https://doi.org/10.1007/978-981-96-3177-3_1.
- [95] Kim, V. G., Li, W., Mitra, N. J., Chaudhuri, S., DiVerdi, S., & Funkhouser, T. (2013). Learning part-based templates from large collections of 3D shapes. ACM Transactions on Graphics (TOG), 32(4), 1-12.
- [96] A. Joshi, N. Ramakrishnan, E. N. Houstis and J. R. Rice, "On neurobiological, neuro-fuzzy, machine learning, and statistical pattern recognition techniques," in IEEE Transactions on Neural Networks, vol. 8, no. 1, pp. 18-31, Jan. 1997, <https://doi.org/10.1109/72.554188>.
- [97] Pal, S.K., & Mitra, P. (2004). Pattern Recognition Algorithms for Data Mining (1st ed.). Chapman and Hall/CRC. <https://doi.org/10.1201/9780203998076>.
- [98] Y. Geng et al., "A Robust Sparse Representation Based Pattern Recognition Approach for Myoelectric Control," in IEEE Access, vol. 6, pp. 38326-38335, 2018, <https://doi.org/10.1109/ACCESS.2018.2851282>.
- [99] Manon Réau, Nicolas Renaud, Li C Xue, Alexandre M J J Bonvin, (2013). DeepRank-GNN: a graph neural network framework to learn patterns in protein–protein interfaces, Bioinformatics, Volume 39, Issue 1, btac759, <https://doi.org/10.1093/bioinformatics/btac759>.
- [100] Birenbaum, M. (1997). Assessment preferences and their relationship to learning strategies and orientations. Higher Education, 33, 71–84. <https://doi.org/10.1023/A:1002985613176>.
- [101] Brouwer, N., & Korthagen, F. (2005). Can teacher education make a difference? American Educational Research Journal, 42(1), 153–224. <https://doi.org/10.3102/00028312042001153>.
- [102] Boyle, E. A., Duffy, T., & Dunleavy, K. (2003). Learning styles and academic outcome: The validity and utility of Vermunt’s inventory of learning styles in a British higher education setting. British Journal of Educational Psychology, 73, 267–290. <https://doi.org/10.1348/00070990360626976>.
- [103] Régis Lengellé, Thierry Denœux, (1996). Training MLPs layer by layer using an objective function for internal representations, Neural Networks, Volume 9, Issue 1, 83-97, ISSN 0893-6080, [https://doi.org/10.1016/0893-6080\(95\)00096-8](https://doi.org/10.1016/0893-6080(95)00096-8).
- [104] Macukow, B. (2016). Neural networks—state of art, brief history, basic models and architecture. In Computer Information Systems and Industrial Management: 15th IFIP TC8 International Conference, CISIM 2016, Vilnius, Lithuania, September 14-16, 2016, Proceedings 15 (pp. 3-14). Springer International Publishing.

- [105] Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation*, 11(3), 52. <https://doi.org/10.3390/computation11030052>.
- [106] Abraham, A. (2005). 129: artificial neural networks. *Handbook of measuring system design*.
- [107] Petković, D., i Denić, N., (2017), „Analyzing of influence of urban and rural population growth on carbon dioxide emission by adaptive neuro-fuzzy inference system“ *International Scientific Conference Globalization vs. Glocalization (Conflicts in Globalizing Society) BOOK OF ABSTRACTS* pp 188-189 June 3–4th 2017, ISBN 978-86-6349-074-1 (ΦΦKM) 316.32(048) 37.01:321.7(048) 37.014(048), COBISS.SR-ID 235798796 Kosovska Mitrovica, Serbia,
- [108] Dejan, D., and **Stefan, P.** (2024, July 8). Bilateral exponential as sigmoid in multilayered neuronal networks. *Proceedings of International Scientific and Professional Conference “ALFATECH” Smart Cities and modern technologies* March 15, 2024, Belgrade, Serbia, ISBN: 978-86-6461-074-2 <https://doi.org/10.5281/zenodo.12685976>.
- [109] Bishop, C. M. (1994). Neural networks and their applications. *Review of scientific instruments*, 65(6), 1803-1832.
- [110] Aggarwal, C. C., & Aggarwal, C. C. (2018). An introduction to neural networks. *Neural networks and deep learning: A textbook*, 1-52.
- [111] Panahi, S., Moradi, M., Bollt, E. M., & Lai, Y. C. (2025). Data-driven model discovery with Kolmogorov-Arnold networks. *Physical Review Research*, 7(2), 023037. <https://doi.org/10.1103/PhysRevResearch.7.023037>.
- [112] Mathew, M.P., Elayidom, S., Jagathy Raj, V.P. et al. (2025). Development of a handheld GPU-assisted DSC-TransNet model for the real-time classification of plant leaf disease using deep learning approach. *Sci Rep* 15. <https://doi.org/10.1038/s41598-024-82629-8>.
- [113] Jiang, F., Yang, Lu., Chen, Yu., Cai, Di. & Li, G. (2020). Image recognition of four rice leaf diseases based on deep learning and support vector machine. *Electron. Agric.* 179, 105824. <https://doi.org/10.1016/j.compag.2020.105824>.
- [114] Costa, P., & Santos, P. A. (2025). Directed Equilibrium Propagation Revisited. *Mathematics*, 13(11), 1866. <https://doi.org/10.3390/math13111866>.
- [115] Tusher, Ekramul Haque; Ismail, Mohd Arfian; and Mat Raffei, Anis Farihan (2025) "Email Spam Classification Based on Deep Learning Methods: A Review," *Iraqi Journal for Computer Science and Mathematics*: Vol. 6: Iss. 1, Article 2. <https://doi.org/10.52866/2788-7421.1236>.
- [116] Hafner, D., Pasukonis, J., Ba, J. et al. (2025). Mastering diverse control tasks through world models. *Nature* 640, 647–653 (2025). <https://doi.org/10.1038/s41586-025-08744-2>.
- [117] Patrício, L., Varela, L., & Silveira, Z. (2025). Implementation of a Sustainable Framework for Process Optimization Through the Integration of Robotic Process Automation and Big Data in the Evolution of Industry 4.0. *Processes*, 13(2), 536. <https://doi.org/10.3390/pr13020536>.
- [118] Götz, M., & Jankowska, B. (2017). Clusters and Industry 4.0 – do they fit together? *European Planning Studies*, 25(9), 1633–1653. <https://doi.org/10.1080/09654313.2017.1327037>.

- [119] Abdolrasol, M. G. M., Hussain, S. M. S., Ustun, T. S., Sarker, M. R., Hannan, M. A., Mohamed, R., Ali, J. A., Mekhilef, S., & Milad, A. (2021). Artificial Neural Networks Based Optimization Techniques: A Review. *Electronics*, 10(21), 2689. <https://doi.org/10.3390/electronics10212689>.
- [120] Tarun Kumar Gupta, Khalid Raza, (2019). Chapter 7 - Optimization of ANN Architecture: A Review on Nature-Inspired Techniques, *Machine Learning in Bio-Signal Analysis and Diagnostic Imaging*, Academic Press, Pages 159-182, ISBN 9780128160862, <https://doi.org/10.1016/B978-0-12-816086-2.00007-2>.
- [121] Xu, W., Jin, L., Zhu, P. Z., He, K., Yang, W. H., & Wu, M. N. (2021). Implementation and application of an intelligent pterygium diagnosis system based on deep learning. *Frontiers in Psychology*, 12, 759229. <https://doi.org/10.3389/fpsyg.2021.759229>.
- [122] Abbasi GA, Tiew LY, Tang J, Goh Y-N, Thurasamy R (2021) The adoption of cryptocurrency as a disruptive force: Deep learning-based dual stage structural equation modelling and artificial neural network analysis. *PLoS ONE* 16(3): e0247582. <https://doi.org/10.1371/journal.pone.0247582>.
- [123] Jiang, Y., Ebrahimpour, L., Després, P. et al. (2025). A benchmark of deep learning approaches to predict lung cancer risk using national lung screening trial cohort. *Sci Rep* 15. <https://doi.org/10.1038/s41598-024-84193-7>.
- [124] Alshkeili, H. M. H. A., Almheiri, S. J., & Khan, M. A. (2025). Privacy-Preserving Interpretability: An Explainable Federated Learning Model for Predictive Maintenance in Sustainable Manufacturing and Industry 4.0. *AI*, 6(6), 117. <https://doi.org/10.3390/ai6060117>.
- [125] Pomšár, L., Tsvietaieva, M., Krupáš, M., & Zolotová, I. (2025). Classifying X-Ray Tube Malfunctions: AI-Powered CT Predictive Maintenance System. *Applied Sciences*, 15(12), 6547. <https://doi.org/10.3390/app15126547>.
- [126] Wang, C.-N., Hsueh, M.-H., Tran Thi, D.-O., Le, T. D.-M., & Dinh, Q.-T. (2025). Optimal Maintenance Strategy Selection for Oil and Gas Industry Equipment Using a Combined Analytical Hierarchy Process–Technique for Order of Preference by Similarity to an Ideal Solution: A Case Study in the Oil and Gas Industry. *Processes*, 13(5), 1389. <https://doi.org/10.3390/pr13051389>.
- [127] Abodunrin, T. O., God'shelp, O. E., Owioye, F. D., Johnson, O. A., & Adeyemi, O. S. (2025). Metal Organic Frameworks in Photodynamic Therapy of Cancer: Functional Roles of Active Metal Centers, Integrated and Loaded Photosensitizers in the Framework. *Materials Advances*.
- [128] Seonggon Kim, Yunmo Ko, Geun Jeong Lee, Jae Won Lee, Ronghuan Xu, Hyungseop Ahn, Yong Tae Kang, Sustainable energy harvesting from post-combustion CO2 capture using amine-functionalized solvents, (2023). *Energy*, Volume 267, ISSN 0360-5442, <https://doi.org/10.1016/j.energy.2022.126532>.
- [129] Sharif Md Yousuf Bhuiyan, Adar Chowdhury, Md Shahadat Hossain, Saleh Mohammad Mobin, & Imtiaz Parvez. (2025). AI-driven optimization in renewable hydrogen production: a review. *American Journal of Interdisciplinary Studies*, 6(1), 76-94. <https://doi.org/10.63125/06z40b13>.
- [130] Ficili, I., Giacobbe, M., Tricomi, G., & Puliafito, A. (2025). From Sensors to Data Intelligence: Leveraging IoT, Cloud, and Edge Computing with AI. *Sensors*, 25(6), 1763. <https://doi.org/10.3390/s25061763>.

- [131] M. Sabbir Hossain et al., "Automatic Navigation and Self-Driving Technology in Agricultural Machinery: A State-of-the-Art Systematic Review," in IEEE Access, vol. 13, pp. 94370-94401, 2025, <https://doi.org/10.1109/ACCESS.2025.3573324>.
- [132] Samawi, G. A., Bwaliez, O. M., Jreissat, M., & Kandas, A. (2025). Advancing Sustainable Development in Jordan: A Business and Economic Analysis of Electric Vehicle Adoption in the Transportation Sector. World Electric Vehicle Journal, 16(1), 45. <https://doi.org/10.3390/wevj16010045>.
- [133] Liu, B., Li, Q., Zheng, Z., Huang, Y., Deng, S., Huang, Q., & Liu, W. (2025). A Review of Multi-Source Data Fusion and Analysis Algorithms in Smart City Construction: Facilitating Real Estate Management and Urban Optimization. Algorithms, 18(1), 30. <https://doi.org/10.3390/a18010030>.
- [134] Ivana Popovic, Sonja Djukic Popovic, **Stefan Popovic** and Stevan Ivankovic, (2023) Preliminary research on the possibilities of PPG (Photoplethysmogram) signal analysis of medical sensors and smart watch sensors, Proceedings of the 13th International Conference on Applied Internet and Information Technologies, AIIT 2023, Bitola, North Macedonia, 344 – 350, ISBN 978-608-5003-03-7, COBISS.MK-ID 62559493
- [135] **Stefan Popovic**, Dejan Djukic, Sonja Djukic Popovic, Milan Gligorijevic, (2023) Neural networks in pellet combustion control - an overview of the group's research work in 2022/2023, Proceedings of 9th Virtual International Conference on Science, Technology and Management in Energy, Belgrade, Serbia, 249 – 254, ISBN 978-86-82602-03-3, COBISS.SR-ID 139266057
- [136] Al-Khamees, Hussein and Sani, Nor Samsiah and Dheyaa, Ahmed and Al-Amri, Rusul Mansoor and Wahit, Fazidah and Esa, Mohd Isrul and San, Mohd Aliff Afira, Enhancing Classification Performance of Medical Data Using Multi-Layer Perceptron-Based Feature Ranking. <http://dx.doi.org/10.2139/ssrn.5258855>.
- [137] Lee, S.-M., Choi, S.-W., & Lee, E.-B. (2023). Prediction Modeling of Flue Gas Control for Combustion Efficiency Optimization for Steel Mill Power Plant Boilers Based on Partial Least Squares Regression (PLSR). Energies, 16(19), 6907. <https://doi.org/10.3390/en16196907>.
- [138] Kannan, V.V., Kanabar, B., Gowrishankar, J. et al. (2025) Artificial intelligence based prediction and multi-objective RSM optimization of tectona grandis biodiesel with Elaeocarpus Ganitrus. Sci Rep 15. <https://doi.org/10.1038/s41598-025-87640-1>.
- [139] Tian, Y., Zhang, Y., & Zhang, H. (2023). Recent Advances in Stochastic Gradient Descent in Deep Learning. Mathematics, 11(3), 682. <https://doi.org/10.3390/math11030682>.
- [140] Nilsson, E. J. K., Fureby, C., & Aspden, A. (2022). Chemical kinetics. Advanced turbulent combustion physics and applications, 200.
- [141] Yang Hongying, a, Jin Shuanglong, Feng Shuanglei, Wang bo, Zhang fei, Che Jianfeng. (2015) Heat Load Forecasting of District Heating System Based Numerical Weather Prediction Model, 2nd International Forum on Electrical Engineering and Automation (IFEEA 2015)
- [142] Simonović, M. B., Nikolić, V. D., Petrović, E. P., & Ćirić, I. T. (2016). Heat load prediction of small district heating system using artificial neural networks. Thermal Science, 20(suppl. 5), 1355-1365.

- [143] Ćirić, I., Tasić, M., Ignjatović, M., Stojiljković, D., & Ćirić, M. (2024). machine learning approach for energy consumption estimation in district heating systems. *Innovative Mechanical Engineering*, 3(3), 31-47.
- [144] Simonović, M. B. (2016). Primena veštačkih neuronskih mreža za kratkoročno predviđanje i analizu sistema daljinskog grejanja. *Универзитет у Нишу*.
- [145] Zhu, Y. (2018). Research on the architecture and behavior model of high-speed channel for thermal image processing. *Wireless Personal Communications*, 102(4), 3869-3877.
- [146] Rajah, T. T. R., Chiam, Y. K., & Azizul, Z. (2018). Fuzzy-based framework for the selection of image processing software for diagnosis and outcome prediction of cardiac diseases. *Advanced Science Letters*, 24(2), 1109-1113.
- [147] Lazić, V., Arsić, D., Nikolić, R. R., Rakić, D., Aleksandrović, S., Djordjević, M., & Hadzima, B. (2016). Selection and analysis of material for boiler pipes in a steam plant. *Procedia Engineering*, 149, 216-223.
- [148] Nag, P. K., & Nag, P. K. (2019). Sick building syndrome and other building-related illnesses. *Office Buildings: Health, Safety and Environment*, 53-103.
- [149] Baechler, M C, Gygi, K F, & Hendrickson, P L (1992). Potential environmental effects of energy conservation measures in northwest industries. <https://doi.org/10.2172/5419505>.
- [150] Wu, S. (2015). A traffic motion object extraction algorithm. *International Journal of Bifurcation and Chaos*, 25(14), <https://doi.org/10.1142/S0218127415400398>
- [151] I. Haritaoglu, D. Harwood and L. S. Davis, "W/sup 4/: real-time surveillance of people and their activities," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, no. 8, pp. 809-830, Aug. 2000, <https://doi.org/10.1109/34.868683>.
- [152] Hou, Z. Q., & Han, C. Z. (2005). Background reconstruction algorithm based on pixel intensity classification. *Ruan Jian Xue Bao(Journal of Software)*, 16(9), 1568-1576.
- [153] Zhang, J. (2020). Computer image processing and neural network technology for thermal energy diagnosis of boiler plants. *Thermal Science*, 24(5 Part B), 3221-3228.
- [154] Wen, H.-T., Lu, J.-H., & Phuc, M.-X. (2021). Applying Artificial Intelligence to Predict the Composition of Syngas Using Rice Husks: A Comparison of Artificial Neural Networks and Gradient Boosting Regression. *Energies*, 14(10), 2932. <https://doi.org/10.3390/en14102932>.
- [155] Robert Mikulandrić, Dražen Lončar, Dorith Böhning, Rene Böhme, Michael Beckmann, (2014). Artificial neural network modelling approach for a biomass gasification process in fixed bed gasifiers, *Energy Conversion and Management*, Volume 87, 1210-1223, ISSN 0196-8904, <https://doi.org/10.1016/j.enconman.2014.03.036>.
- [156] Bhatia, A. (2012). Improving energy efficiency of boiler systems. *Continuing education and development engineering*, 1-55.
- [157] Abdul Rasib, A., Raju, R., Abdullah, R., Hanizam, H., Ramli, M., Yunus, R., & Mansoor, H. O. (2025). Enhancing boiler efficiency: strategies to optimize availability, performance, and quality in the food and beverage industry. *Journal of Advanced Manufacturing Technology (JAMT)*, 19(1), 17-32.

- [158] Cardenas-Rodriguez, H. d. N., Diaz Mendez, Y. A., Malaguera Mora, A. E., Gonzatti, R. B., Martins, R., Batista da Silva, T. D., Da Cruz Moura, L., Souza Figueiredo, W. A., Santos Silva, D. D., Alves de Lima, A. H., da Silva, A. J., Dias, A. L., Bonaldi, E. L., Borges-da-Silva, L. E., & De Oliveira Assuncao, F. (2025). Thermodynamic and Economic Assessment of Steam Generation with Heavy Fuel Oil and Electric Boilers in a Brazilian Thermoelectric Power Plant. *Energies*, 18(10), 2565. <https://doi.org/10.3390/en18102565>.
- [159] Zhao, Z., Hu, R., Zhang, Y., Dong, H., & Du, Q. (2025). Current Research Status and Prospects of Electrode Boilers Under the Background of the “Dual Carbon” Goals. *Energies*, 18(4), 769. <https://doi.org/10.3390/en18040769>.
- [160] Fernández-Alemán, J. L., López-González, L., González-Sequeros, O., Jayne, C., López-Jiménez, J. J., Carrillo-de-Gea, J. M., & Toval, A. (2016). An empirical study of neural network-based audience response technology in a human anatomy course for pharmacy students. *Journal of medical systems*, 40(4), 1-12.
- [161] Soltani, A., Battikh, T., Jabri, I., & Lakhoua, N. (2018). A new expert system based on fuzzy logic and image processing algorithms for early glaucoma diagnosis. *Biomedical Signal Processing and Control*, 40, 366-377.
- [162] Behnam, B., & Bahram, H. (2018). Neural networks in industrial process control: A review. *Journal of Process Control*, 73, 32-48.
- [163] Shahkarami, M., Shahraki, A., & Barzegar, R. (2019). Application of artificial neural networks in petroleum industry: A review. *Petroleum Science and Technology*, 37(2), 113-129.
- [164] Guo, J., Wang, X., & Zhang, Y. (2020). Deep learning for material property prediction in industrial manufacturing. *Journal of Manufacturing Science and Engineering*, 142(5), 051003.
- [165] Jardine, A. K., Lin, D., & Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 20(7), 1483-1510.
- [166] Kothamasu, R., Huang, S. H., & VerDuin, W. H. (2006). System health monitoring and prognostics – A review of current paradigms and practices. *The International Journal of Advanced Manufacturing Technology*, 28(9-10), 1012-1024.
- [167] Wang, Z., Li, H., & Yu, T. (2019). Artificial intelligence for smart energy management: A review. *Energy Reports*, 5, 778-792.
- [168] Hong, T., Dong, B., & Li, Y. (2019). Machine learning-based load forecasting: A review of applications in smart grids and buildings. *Renewable and Sustainable Energy Reviews*, 119, 109615.
- [169] Zhang, Y., Li, X., & Zhang, Q. (2018). Application of deep learning in automotive defect detection. *IEEE Transactions on Industrial Electronics*, 65(9), 7345-7353.
- [170] Patel, N., Shah, S., & Shah, D. (2020). Neural networks in pharmaceutical research: A comprehensive review. *Journal of Drug Delivery Science and Technology*, 57, 101694.
- [171] Billard, A., & Kragic, D. (2019). Trends and challenges in robot manipulation. *Science*, 364(6446), eaat8414.
- [172] Bogue, R. (2021). The role of artificial intelligence in warehouse automation. *Industrial Robot: An International Journal*, 48(3), 301-307.

- [173] Turns, S. R. (2012). Introduction to Combustion. McGraw-Hill Education.
- [174] Smith, P. (2020). Boiler Efficiency and Combustion Optimization. Industrial Press.
- [175] Turns, S. R., & Myhrvold, N. (2019). "Advanced Combustion Analysis and Emission Reduction." *Journal of Energy Research*, 45(3), 312-328.
- [176] Liu, H., Zhang, Y., & Wang, X. (2021). "Machine Learning Approaches in Industrial Combustion Systems." *Energy & Fuels*, 35(7), 5673-5684.
- [177] Glassman, I., & Yetter, R. A. (2015). Combustion. Academic Press.
- [178] Warnatz, J., Maas, U., & Dibble, R. W. (2006). Combustion: Physical and Chemical Fundamentals, Modeling and Simulation, Experiments, Pollutant Formation. Springer Berlin Heidelberg.
- [179] Ricci, F., Avana, M., & Mariani, F. (2024). A Deep Learning Method for the Prediction of Pollutant Emissions from Internal Combustion Engines. *Applied Sciences*, 14(21), 9707. <https://doi.org/10.3390/app14219707>.
- [180] Denic, N., Paunovic, M., Jaksic, K. et al. Estimation of heating value of solid alcohol fuel based on recycled waste cooking oil. *Biomass Conv. Bioref.* (2022). <https://doi.org/10.1007/s13399-022-02845-y>.
- [181] David L. Nelson; Michael M. Cox (2005). Principles of Biochemistry (IV изд.). New York: W. H. Freeman. ISBN 0-7167-4339-6.
- [182] Moran, M. J., & Shapiro, H. N. (2010). Fundamentals of Engineering Thermodynamics. John Wiley & Sons.
- [183] Çengel, Y. A., & Boles, M. A. (2015). Thermodynamics: An Engineering Approach. McGraw-Hill.
- [184] Van Wylen, G. J., Sonntag, R. E., & Borgnakke, C. (1994). Fundamentals of Classical Thermodynamics. John Wiley & Sons.
- [185] Weitzel, P. S. (2011, January). Steam generator for advanced ultra supercritical power plants 700C to 760C. In ASME power conference (Vol. 44595, pp. 281-291). <https://doi.org/10.1115/POWER2011-55039>.
- [186] Aleksandar Dj. Dedić, Osnove mašinstva, Šumarski fakultet, Beograd, 2010.
- [187] Павле Калуђеровић, Симулација термодинамичког процеса у систему централног грејања, BIBUD 035-1426 (2000) 29:2 p. 65-70, UDK 697.2.001
- [188] Dehli, M., Doering, E., & Schedwill, H. (2023). Fundamentals of Technical Thermodynamics. Springer Fachmedien Wiesbaden, Wiesbaden.
- [189] Çengel, Y. A., & Boles, M. A. (2015). Thermodynamics: An Engineering Approach. McGraw-Hill.
- [190] Perkins, R. (2018). Boiler Control Systems Engineering. ISA.
- [191] Kalogirou, S. A. (2013). Solar Energy Engineering: Processes and Systems. Academic Press.
- [192] Morales-Rodriguez, R. (Ed.). (2012). Thermodynamics: Fundamentals and Its Application in Science. BoD—Books on Demand.
- [193] Åström, K. J., & Hägglund, T. (2006). Advanced PID Control. ISA.
- [194] Baukal, C. E. (2013). Oxygen-Enhanced Combustion. CRC Press.
- [195] Han, L., Wang, L., Yang, H., Jia, C., Meng, E., Liu, Y., & Yin, S. (2023). Optimization of Circulating Fluidized Bed Boiler Combustion Key Control Parameters Based on Machine Learning. *Energies*, 16(15), 5674. <https://doi.org/10.3390/en16155674>.

- [196] Camacho, E. F., & Bordons, C. (2007). *Model Predictive Control*. Springer.
- [197] Versteeg, H. K., & Malalasekera, W. (2007). *An Introduction to Computational Fluid Dynamics: The Finite Volume Method*. Pearson.
- [198] Buyya, R., Dastjerdi, A. V., Calheiros, R. N., & Zhang, Q. (2016). *Fog and Edge Computing: Principles and Paradigms*. Wiley.
- [199] Xu, K., Ma, L., Chen, J., Zhao, X., Wang, Q., Kan, R., ... Ren, W. (2021). Dual-comb Spectroscopy for Laminar Premixed Flames with a Free-running Fiber Laser. *Combustion Science and Technology*, 194(12), 2523–2538. <https://doi.org/10.1080/00102202.2021.1879796>.
- [200] Shahid, S., Brown, D. J., Wright, P., Khasawneh, A. M., Taylor, B., & Kaiwartya, O. (2025). Innovations in Air Quality Monitoring: Sensors, IoT and Future Research. *Sensors*, 25(7), 2070. <https://doi.org/10.3390/s25072070>.
- [201] Zhang, Y., Li, X., & Wang, J. (2020). "Optimization of Industrial Combustion Processes Using AI-Based Control Systems," *Energy Efficiency Journal*, 12(3), 301-315.
- [202] Ineza Havugimana, L. F., Liu, B., Liu, F., Zhang, J., Li, B., & Wan, P. (2023). Review of Artificial Intelligent Algorithms for Engine Performance, Control, and Diagnosis. *Energies*, 16(3), 1206. <https://doi.org/10.3390/en16031206>.
- [203] Wang, L., Sun, Q., & Zhao, M. (2021). "Predictive Control of Boiler Combustion Using Neural Networks," *Journal of Smart Energy Systems*, 15(2), 112-126.
- [204] Lee, C.-M. (2024). Combustion Control of Ship's Oil-Fired Boilers Based on Prediction of Flame Images. *Journal of Marine Science and Engineering*, 12(9), 1474. <https://doi.org/10.3390/jmse12091474>.
- [205] Lee, C., Chen, H., & Park, S. (2019). "Reducing NO_x and CO Emissions in Industrial Boilers through Machine Learning Optimization," *Environmental Engineering Review*, 27(4), 189-204.
- [206] M. Si, T. J. Tarnoczi, B. M. Wiens and K. Du, (2019). "Development of Predictive Emissions Monitoring System Using Open Source Machine Learning Library – Keras: A Case Study on a Cogeneration Unit," in *IEEE Access*, vol. 7, pp. 113463-113475, 2019, <https://doi.org/10.1109/ACCESS.2019.2930555>.
- [207] Chen, R., & Liu, M. (2022). "Artificial Intelligence in Energy Systems: Applications and Future Trends," *IEEE Transactions on Sustainable Energy*, 19(1), 75-89.
- [208] Nwanevu, C., Oladipo, S. S., & Ajayi, A. O. (2024). Designing effective policy frameworks for the implementation of microgrids in developing countries: Opportunities, challenges and pathways to sustainable energy access. *World Journal of Advanced Research and Reviews*, 24(1). <https://doi.org/10.30574/wjarr.2024.24.1.3078>.
- [209] Algolam, M.S., Roshid, M.M., Alsharafi, M. et al. (2025). Bifurcation analysis, modulation instability and dynamical analysis of soliton solutions for generalized (3 + 1)-dimensional nonlinear wave equation with m-fractional operator. *Sci Rep* 15, <https://doi.org/10.1038/s41598-025-95687-3>
- [210] Liu, X., Gao, N., He, S., & Wang, L. (2025). Application of Fractional Fourier Transform and BP Neural Network in Prediction of Tumor Benignity and Malignancy. *Fractal and Fractional*, 9(5), 267. <https://doi.org/10.3390/fractalfract9050267>.

- [211] Q. Meng, A. Kasis and M. M. (June 2025). Polycarpou, "Integrated Attitude–Position Formation Control of Multiple Vehicles on SE(3) With Individual Objectives," in IEEE Transactions on Aerospace and Electronic Systems, vol. 61, no. 3, pp. 7710-7724, <https://doi.org/10.1109/TAES.2025.3540976>.
- [212] Bolton, W. (2021). Programmable Logic Controllers. Elsevier.
- [213] Krishnan, R. (2017). Electric Motor Drives: Modeling, Analysis, and Control. Prentice Hall. ISBN 0-13-0910147
- [214] Jo Hoeser, Emmanuel Gnanndt, Thorsten Friedrich, Low cost, microcontroller based heating device for multi-wavelength differential scanning fluorimetry, Scientific Reports, Vol 8, Iss 1, Pp 1-10 (2018), <https://doi.org/10.1038/s41598-018-19702-6>. PMID: 29362420; PMCID: PMC5780519.
- [215] Douglas Lautnera, X, Xiayu Huab, Scott DeBatesb, Miao Songb, Shangping Ren, Power Efficient Scheduling Algorithms for Real-time Tasks on Multi-mode Microcontrollers, Procedia Computer Science 130 (2018) 557–566, <https://doi.org/10.1016/j.procs.2018.04.099>.
- [216] Jenkins, B. M., Baxter, L. L., Miles, T. R., & Miles, T. R. (1998). Combustion properties of biomass. Fuel Processing Technology, 54(1-3), 17-46.
- [217] Obernberger, I., & Thek, G. (2010). The pellet handbook: The production and thermal utilization of biomass pellets. Routledge.
- [218] Prasad, R., & Gupta, A. K. (2018). Advanced combustion techniques and pollutant control technologies. Springer.
- [219] Abdellatif M. Sadeq, Raad Z. Homod, Husam Abdulrasool Hasan, Bilal Naji Alhasnawi, Ahmed Kadhim Hussein, Ali Jahangiri, Hussein Togun, Masoud Dehghani-Soufi, Shahbaz Abbas, (2025). Advancements in combustion technologies: A review of innovations, methodologies, and practical applications, Energy Conversion and Management: X, Volume 26, ISSN 2590-1745, <https://doi.org/10.1016/j.ecmx.2025.100964>.
- [220] Spliethoff, H. (2010). Power generation from solid fuels. Springer.
- [221] Van Loo, S., & Koppejan, J. (2008). The handbook of biomass combustion and co-firing. Earthscan. Applied Energy, [HTTPS://DOI.ORG/10.1016/j.apenergy.2008.11.022](https://doi.org/10.1016/j.apenergy.2008.11.022).
- [222] Yin, C., Rosendahl, L. A., & Kær, S. K. (2008). Grate-firing of biomass for heat and power production. Progress in Energy and Combustion Science, 34(6), 725-754. <https://doi.org/10.1016/j.pecs.2008.05.002>.
- [223] Smrekar, J., Assadi, M., Fast, M., Kuštrin, I., & De, S. (2009). Development of artificial neural network model for a coal-fired boiler using real plant data. Energy, 34(2), 144-152. <https://doi.org/10.1016/j.energy.2008.10.010>.
- [224] Chu, J. Z., Shieh, S. S., Jang, S. S., Chien, C. I., Wan, H. P., & Ko, H. H. (2003). Constrained optimization of combustion in a simulated coal-fired boiler using artificial neural network model and information analysis☆. Fuel, 82(6), 693-703. [https://doi.org/10.1016/S0016-2361\(02\)00338-1](https://doi.org/10.1016/S0016-2361(02)00338-1).
- [225] Rusinowski, H., & Stanek, W. (2007). Neural modelling of steam boilers. Energy Conversion and Management, 48(11), 2802-2809. <https://doi.org/10.1016/j.enconman.2007.06.040>.
- [226] Stolic, P.; Stevic, Z.; Petronic, S.; Nikolic, V.; Stevic, M.; Kreculj, D.; Milosevic, D. (2023). Modeling, Simulation, and Computer Control of a High-

- Frequency Wood Drying System. Electronics, 12, 226.
<https://doi.org/10.3390/electronics12010226>.
- [227] Dastidar, A.G.; Maity, R.; Tiwari, R.C.; Vidojevic, D.; Kevkic, T.S.; Nikolic, V.; Das, S.; Maity, N.P. (2023). Squeeze Film Effect in Surface Micromachined Nano Ultrasonic Sensor for Different Diaphragm Displacement Profiles. Sensors, 23, 4665.
<https://doi.org/10.3390/s23104665>.
- [228] Dahiya A, Mittal P, Sharma YK, Lilhore UK, Simaiya S, Haq MA, Aleisa MA, Alenizi A. (2025). Hybrid parking space prediction model: integrating ARIMA, Long short-term memory (LSTM), and backpropagation neural network (BPNN) for smart city development. PeerJ Computer Science 11:e2645 <https://doi.org/10.7717/peerj-cs.2645>.

10. Прилози

Ово поглавље садржи техничку и документациону подршку истраживању изложеном у главном делу дисертације. У њему се налазе допунски материјали који омогућавају верификацију резултата и транспарентан увид у примењену методологију, алгоритме и развијене системе. Прилози обухватају изворни програмски код, списак слика, графика, табела, биографију и библиографију аутора, као и пратеће изјаве у складу са академским и етичким нормама. Посебна пажња посвећена је приказу програмских модула који чине суштински део реализованог интелигентног система за прикупљање, обраду и анализу података. Кодни сегменти изложени у прилозима односе се на реалновременски рад сензорског система, складиштење података, као и на примену алгоритама машинског учења у фази оптимизације параметара процеса сагоревања.

10.1. Програмски кодови

Прилог K1: Програмски код за реалновременско читавање и складиштење података добијеним експерименталном методом.

Овај код реализује комуникацију са сензорима температуре, влажности, концентрације гасова и честица, чита очитане вредности у правилним интервалима и уписује их у локалну меморију (SD картицу) у структурираном формату (CSV). Развијен је у Arduino IDE окружењу, користећи C++ синтаксу и специјализоване библиотеке за сваки сензор.

Очитавање података обавља се у циклусу од 5 секунди. Подржана је калкулација просека у покретном прозору ради филтрирања шума. Код је адаптиран за рад са моделом микроконтролера Arduino Uno. У наставку су дати кључни делови програмског кода који је коришћен за ишчитавање и чување података на меморијској картици у реалном времену.

```
#include <DHT.h>
```

```
#include <SD.h>
```

```
#include <Wire.h>
```

```
#define DHTPIN 2
```

```
#define DHTTYPE DHT22
```

```
DHT dht(DHTPIN, DHTTYPE);
```

```
const int chipSelect = 10;
```

```
File dataFile;
```

```

void setup() {
    Serial.begin(9600);
    dht.begin();

    if (!SD.begin(chipSelect)) {
        Serial.println("Greška pri inicijalizaciji SD kartice.");
        return;
    }

    dataFile = SD.open("log.csv", FILE_WRITE);
    if (dataFile) {
        dataFile.println("Vreme, Temperatura, Vlaznost");
        dataFile.close();
    }
}

void loop() {
    float t = dht.readTemperature();
    float h = dht.readHumidity();

    dataFile = SD.open("log.csv", FILE_WRITE);
    if (dataFile) {
        dataFile.print(millis());
        dataFile.print(",");
        dataFile.print(t);
        dataFile.print(",");
        dataFile.println(h);
        dataFile.close();
    }
}

```

```

    delay(5000); // пауза 5 секунди
}

```

У каснијим фазама развоја система, ради флексибилније контроле и могућности интерактивне калибрације сензора у реалном времену, имплементирана је и подршка за серијску комуникацију између микроконтролера и рачунара. Ово је омогућило праћење вредности уживо, као и ручно подешавање параметара на основу тренутних читавања. Комуникација се обавља преко USB интерфејса, користећи серијски протокол (baud rate: 9600). Коришћена је Python скрипта на рачунару. Код подржава слање наредби са рачунара (нпр. SET CAL 1.05) за примену корекционих фактора.

```

float kalibracioniFaktor = 1.0;

void setup() {
    Serial.begin(9600);
    dht.begin();
}

void loop() {
    float t = dht.readTemperature();
    float t_kal = t * kalibracioniFaktor;

    Serial.print("Temperatura: ");
    Serial.print(t_kal);
    Serial.println(" *C");

    if (Serial.available() > 0) {
        String unos = Serial.readStringUntil('\n');
        if (unos.startsWith("SET CAL ")) {
            kalibracioniFaktor = unos.substring(8).toFloat();
            Serial.print("Kalibracioni faktor postavljen na: ");
            Serial.println(kalibracioniFaktor);
        }
    }
}

```

```
    delay(3000);  
}
```

Python код коришћен за читање података и слање калибрационих наредби преко серијског порта. Ова скрипта служи за интеракцију са микроконтролером преко серијског порта. Корисник у реалном времену добија очитане вредности, и за ручни унос калибрационог фактора.

```
import serial  
import time  
  
# Подеси серијску везу (порт прилагодити систему, нпр. COM3 за Windows или  
/dev/ttyUSB0 за Linux)  
ser = serial.Serial('COM3', 9600, timeout=1)  
time.sleep(2) # Сачекај да се серијска конекција иницијализује  
  
print("Веза успостављена. Притисни Ctrl+C за излаз.")  
print("Упиши нови калибрациони фактор у облику: SET CAL 1.05")  
  
try:  
    while True:  
        if ser.in_waiting > 0:  
            linija = ser.readline().decode('utf-8').strip()  
            if linija:  
                print(f"[ARDUINO] {linija}")  
  
        unos = input("[PC] Унеси команду (или ENTER за наставак): ")  
        if unos.strip():  
            ser.write((unos.strip() + '\n').encode('utf-8'))  
  
except KeyboardInterrupt:  
    print("\nЗатварање везе...")  
    ser.close()
```

Подаци су у оквиру овог дела истраживања чувани у CSV табелу применом кода који се налази испод:

```
import serial

import time

import csv

SERIAL_PORT = 'COM3' # Промени у складу са својим уређајем код уређаја
коришћеног у експерименталној провери коришћен је COM 3 и COM7

BAUD_RATE = 9600

OUTPUT_FILE = 'kotao_podaci.csv'

# Отварање серијске комуникације
ser = serial.Serial(SERIAL_PORT, BAUD_RATE, timeout=2)
time.sleep(2) # Време за иницијализацију серијске везе

# Заглавље CSV фајла
header = ['vreme', 'temp_gorionik', 'temp_dim', 'vlaznost', 'konc_gasova', 'PM2_5',
'PM10']

with open(OUTPUT_FILE, mode='w', newline='') as file:
    writer = csv.writer(file)
    writer.writerow(header)

try:
    print("Почетак читања података са котла...")
    while True:
        line = ser.readline().decode('utf-8').strip()
        if line:
            try:
                data = [float(x) for x in line.split(',')]
                timestamp = time.strftime("%Y-%m-%d %H:%M:%S")
                row = [timestamp] + data
```

```

        writer.writerow(row)

        print("Сачувано:", row)

    except ValueError:

        print("Грешка у формату података:", line)

except KeyboardInterrupt:

    print("Читање прекинуто од стране корисника.")

finally:

    ser.close()

    print("Серијска веза затворена.")

```

Прилог К2: Реално временско прикупљање података и чување у базу података

Интеграција микроконтролерског система са Python и SQLite алатом ради континуираног прикупљања и складиштења мерених параметара извршена је на начин приказан у овом прилогу. У оквиру овог истраживања развијен је комплетан систем за континуирано праћење параметара сагоревања у котлу, базиран на микроконтролеру и прилагођеним сензорским модулима. Податке прикупља Arduino платформа, која их у реалном времену шаље преко серијског порта у облику CSV-низа. Структура података обухвата кључне параметре процеса сагоревања: температуру у горионику (tempGorionik), температуру димних гасова (tempDim), релативну влажност (vlaznost), концентрацију гасова (koncentracijaGasova), честице PM2.5 и PM10 (pm25, pm10).

Arduino код за слање података:

```

Serial.print(temp_gorionik);

Serial.print(",");

Serial.print(temp_dim);

Serial.print(",");

Serial.print(vlaznost);

Serial.print(",");

Serial.print(konc_gasova);

Serial.print(",");

Serial.print(pm25);

Serial.print(",");

Serial.println(pm10);

```

Са стране рачунара, Python скрипта остварује комуникацију са микроконтролером преко серијског порта, чита примљене податке, временски их обележава и складишти у SQLite релациону базу података. У наставку је дата скрипта за прикупљање и чување података:

```
import serial

import sqlite3

import time


# Подешавање серијске везе

SERIAL_PORT = 'COM3'

BAUD_RATE = 9600


# Повезивање на SQLite базу

conn = sqlite3.connect('kotao.db')

cursor = conn.cursor()


# Креирање табеле ако не постоји

cursor.execute("""

    CREATE TABLE IF NOT EXISTS merenja (

        vreme TEXT,

        temp_gorionik REAL,

        temp_dim REAL,

        vlaznost REAL,

        konc_gasova REAL,

        pm25 REAL,

        pm10 REAL

    )

""")

conn.commit()


# Отварање серијске комуникације
```

```

ser = serial.Serial(SERIAL_PORT, BAUD_RATE, timeout=2)

time.sleep(2) # Чекање иницијализације

print("Покренуто читање података...")

try:
    while True:
        line = ser.readline().decode('utf-8').strip()
        if line:
            try:
                data = [float(x) for x in line.split(',')]
                timestamp = time.strftime("%Y-%m-%d %H:%M:%S")
                cursor.execute("""
                    INSERT INTO merenja (vreme, temp_gorionik, temp_dim, vlaznost,
konc_gasova, pm25, pm10)
                    VALUES (?, ?, ?, ?, ?, ?, ?)
                """, (timestamp, *data))
                conn.commit()
                print(f"Уписано: {timestamp} {data}")
            except ValueError:
                print(f"Грешка у формату података: {line}")
        except KeyboardInterrupt:
            print("Кориснички прекид рада.")
    finally:
        ser.close()
        conn.close()

        print("Серијска и базна веза затворене.")

```

По завршетку мерења, подаци се могу директно увезти из базе у Pandas DataFrame објекат у оквиру Python окружења ради даље анализе, визуализације и примене алгоритама машинског учења:

```
import pandas as pd
```

```
import sqlite3
```

```
conn = sqlite3.connect('kotao.db')
```

```
df = pd.read_sql_query("SELECT * FROM merenja", conn)
```

```
conn.close()
```

Прилог K3: Припрема и трансформација реалних експерименталних података у тензоре за потребе обуке LSTM модела.

Овај прилог представља детаљан поступак припреме података за обуку LSTM неуронске мреже, који укључује кораке нормализације, сегментације, форматирања у тензоре и серијализације модела. Поступак се ослања на реалне податке добијене из микроконтролерског система и сензорске платформе, уз обраду у Python окружењу са библиотекама TensorFlow и scikit-learn.

```
``python
```

```
import sqlite3
```

```
import pandas as pd
```

```
import numpy as np
```

```
from sklearn.preprocessing import MinMaxScaler
```

```
from tensorflow.keras.models import Sequential
```

```
from tensorflow.keras.layers import Dense, LSTM, Dropout
```

```
from sklearn.metrics import mean_squared_error
```

```
# 1. Учитавање података из локалне SQLite базе
```

```
conn = sqlite3.connect('kotao.db')
```

```
df = pd.read_sql_query("SELECT * FROM merenja", conn)
```

```
conn.close()
```

```
# 2. Дефинисање улазних и излазних карактеристика
```

```
features = ['temp_gorionik', 'vlaznost', 'konc_gasova', 'pm25', 'pm10']
```

```
target = 'temp_dim'
```

```
# 3. Нормализација података у опсег [-1, 1]
```

```
scaler_X = MinMaxScaler(feature_range=(-1, 1))
```

```
scaler_y = MinMaxScaler(feature_range=(-1, 1))
```

```
X_scaled = scaler_X.fit_transform(df[features])
```

```
y_scaled = scaler_y.fit_transform(df[[target]])
```

```
# 4. Креирање временских секвенци дужине T
```

```
seq_length = 10
```

```
def create_sequences(X, y, seq_length):
```

```
    Xs, ys = [], []
```

```
    for i in range(seq_length, len(X)):
```

```
        Xs.append(X[i-seq_length:i])
```

```
        ys.append(y[i])
```

```
    return np.array(Xs, dtype=np.float32), np.array(ys, dtype=np.float32)
```

```
X_seq, y_seq = create_sequences(X_scaled, y_scaled, seq_length=seq_length)
```

```
# 5. Дефинисање LSTM модела
```

```
model = Sequential()
```

```
model.add(LSTM(units=50, return_sequences=False, input_shape=(X_seq.shape[1],  
X_seq.shape[2])))
```

```
model.add(Dropout(0.2))
```

```
model.add(Dense(units=1, activation='linear'))
```

```
# 6. Компилација модела
```

```
model.compile(optimizer='adam', loss='mean_squared_error', metrics=['mae'])
```

```
# 7. Обука модела
```

```
history = model.fit(X_seq, y_seq, epochs=100, batch_size=32, validation_split=0.2,  
verbose=1)
```

8. Чување модела за даљу употребу

```
model.save("lstm_combustion_model.h5")
```

Овај поступак представља неопходан корак у креирању модела који се касније интегрише у систем интелигентног управљања процесом сагоревања.

Прилог К4: Интеграција обученог LSTM модела у реално-временски управљачки систем.

У оквиру овог прилога представљен је алгоритам који реализује повезивање обученог LSTM модела са физичким системом котла, чиме се успоставља рад у затвореној повратној спрези (closed-loop control). Основни циљ алгоритма је предикција вредности од интереса (температуре димних гасова или емисије CO), на основу континуалног очитавања параметара са сензора, и слање оптимизованог управљачког сигнала актуаторима у реалном времену.

Алгоритам обухвата следеће кораке:

Учитавање ресурса система – у овом кораку читавају се: обучени LSTM модел у .h5 формату; скалери за улазне и излазне величине (MinMaxScaler), неопходни за конзистентну нормализацију података; дефинише се серијска веза са Arduino уређајем који контролише сензоре и актуаторе.

Форматирање улазних података – подаци који стижу у реалном времену се претварају у низ временских корака фиксне дужине (секвенце), што је предуслов за обраду помоћу LSTM мреже.

Предикција – када се акумулира довољно података, модел врши нормализацију, предикцију и денормализацију резултата, који се потом конвертује у управљачку команду.

Интеракција са актуатором – предиктована вредност, у виду регулационог сигнала, враћа се преко серијске везе микроконтролеру који покреће физичку промену у систему (промену брзине вентилатора или дозирање горива).

```
import serial

import time

import numpy as np

import tensorflow as tf

from sklearn.preprocessing import MinMaxScaler

import joblib # За учитавање скалера

# Путање до модела и скалера

MODEL_PATH = "lstm_model.h5"
```

```

SCALER_X_PATH = "scaler_x.save"
SCALER_Y_PATH = "scaler_y.save"

# Учитавање обученог модела и скалера
model = tf.keras.models.load_model(MODEL_PATH)
scaler_X = joblib.load(SCALER_X_PATH)
scaler_y = joblib.load(SCALER_Y_PATH)

# Подешавање серијске комуникације са Arduino
ser = serial.Serial('COM3', 9600, timeout=1)
time.sleep(2) # Чекање на иницијализацију

# Дефинисање константи
sequence = []
SEQ_LEN = 10
FEATURES = ['temp_gorionik', 'vlaznost', 'konc_gasova', 'pm25', 'pm10']

# Функција за парсирање сензорских података
def parse_sensor_data(raw_data):
    try:
        parts = raw_data.strip().split(',')
        values = list(map(float, parts))
        return values if len(values) == len(FEATURES) else None
    except:
        return None

# Главна петља
while True:
    if ser.in_waiting:
        raw_line = ser.readline().decode('utf-8')

```

```

sensor_values = parse_sensor_data(raw_line)

if sensor_values:
    sequence.append(sensor_values)
    if len(sequence) > SEQ_LEN:
        sequence.pop(0)

if len(sequence) == SEQ_LEN:
    X_input = np.array(sequence).reshape(1, SEQ_LEN, len(FEATURES))
    X_scaled = scaler_X.transform(X_input[0])
    X_scaled = X_scaled.reshape(1, SEQ_LEN, len(FEATURES))

    # Предикција излазне вредности
    y_pred_scaled = model.predict(X_scaled)
    y_pred = scaler_y.inverse_transform(y_pred_scaled)

    # Пошаљи као команду
    control_value = round(float(y_pred[0][0]), 2)
    ser.write(f"{control_value}\n".encode('utf-8'))

    print(f"[✓] Улаз: {sensor_values} | Управљачки сигнал: {control_value}")

time.sleep(1) # Регулација циклуса

```

Овај алгоритам представља срж интеграције модела машинског учења у реално-временски систем, и као такав је суштински део доказа концепта у истраживању. Његова стабилност и прецизност имају директан утицај на квалитет регулације и коначне енергетске и еколошке перформансе система.

Прилог K5: Микроконтролерски код за реализацију управљачке логике са PID регулацијом и заштитом.

Овај прилог представља програмски код који је имплементиран на Arduino микроконтролеру ради управљања компонентама система за сагоревање (дозатором и вентилатором) у оквиру затворене регулационе петље. На основу добијених вредности

изводи следеће управљачко понашање: примена PID регулатора за прецизну регулацију брзине вентилатора; Заштита од прегревања, уколико температура пређе задати праг, систем аутоматски искључује дозатор горива; Аутоматска реактивација дозатора – када температура падне испод дефинисаног лимита, дозатор се поново активира; Паралелно је приказан и поједностављени програм који омогућава директну комуникацију са LSTM предикционим моделом путем серијске линије.

```
const int ventilatorPin = 5;  // пин за вентилатор
const int dozerPin = 6;      // пин за дозатор

String inputString = "";
bool stringComplete = false;

void setup() {
  Serial.begin(9600);
  pinMode(ventilatorPin, OUTPUT);
  pinMode(dozerPin, OUTPUT);
  inputString.reserve(50);
}

void loop() {
  if (stringComplete) {
    float tempValue = 0;
    float fanValue = 0;

    int commaIndex = inputString.indexOf(',');
    if (commaIndex > 0) {
      String tempStr = inputString.substring(0, commaIndex);
      String fanStr = inputString.substring(commaIndex + 1);

      tempValue = tempStr.toFloat();
      fanValue = fanStr.toFloat();
    }
  }
}
```

```

int dozerPWM = constrain(map(tempValue, 80, 195, 0, 255), 0, 255);
int fanPWM = constrain(map(fanValue, 0, 100, 0, 255), 0, 255);

analogWrite(dozerPin, dozerPWM);
analogWrite(ventilatorPin, fanPWM);

Serial.print("Dozer PWM: "); Serial.print(dozerPWM);
Serial.print(" | Ventilator PWM: "); Serial.println(fanPWM);
}

inputString = "";
stringComplete = false;
}
}

void serialEvent() {
  while (Serial.available()) {
    char inChar = (char)Serial.read();
    if (inChar == '\n') {
      stringComplete = true;
    } else {
      inputString += inChar;
    }
  }
}

Заштита од прегревања:
#include "max6675.h"

const int ventilatorPin = 5;
const int dozerPin = 6;

```

```

// MAX6675 конфигурација
int thermoDO = 12;
int thermoCS = 10;
int thermoCLK = 13;
MAX6675 thermocouple(thermoCLK, thermoCS, thermoDO);

// PID параметри
float Kp = 2.0;
float Ki = 0.05;
float Kd = 1.0;

float setpointFan = 120.0;
float previousError = 0;
float integral = 0;

unsigned long lastTime = 0;
const float tempLimit = 180.0;

void setup() {
  Serial.begin(9600);
  pinMode(ventilatorPin, OUTPUT);
  pinMode(dozerPin, OUTPUT);
  lastTime = millis();
  delay(500);
}

void loop() {
  float currentTemp = thermocouple.readCelsius();
  Serial.print("Temp: ");

```

```

Serial.println(currentTemp);

// Логика за дозатор
if (currentTemp < tempLimit) {
    int dozerPWM = constrain(map(currentTemp, 80, 170, 50, 255), 0, 255);
    analogWrite(dozerPin, dozerPWM);
} else {
    analogWrite(dozerPin, 0); // Искључење дозатора
}

// PID регулација вентилатора
unsigned long now = millis();
float elapsed = (now - lastTime) / 1000.0;
lastTime = now;

float fanError = setpointFan - currentTemp;
integral += fanError * elapsed;
float derivative = (fanError - previousError) / elapsed;
float output = Kp * fanError + Ki * integral + Kd * derivative;
previousError = fanError;

int fanPWM = constrain(output, 0, 255);
analogWrite(ventilatorPin, fanPWM);

delay(1000);
}

```

Уколико је LSTM модел активан и контролише рад система, први код омогућава једноставну комуникацију и управљање. У сценаријима у којима се жели тестирати традиционална PID регулација са безбедносном логиком, други код представља основну алтернативу.

Прилог К6: Матлаб код за предикцију израђен на основу модела.

Следећи код илуструје како се у MATLAB окружењу врши предикција температуре димних гасова на основу улазних параметара добијених у реалном времену, коришћењем претходно обученог LSTM модела. Предуслов за овај корак је да су модели и нормализатори претходно серијализовани и сачувани у .mat или .h5 формату.

```
% s_kotao23_filtered8_auto_count_o20_s0_e50_d50_02
% 2023-05_03
% auto dynamical
% in kotao23_filtered_8.csv
% maximum order 20
clear all
close all
more off
% starting time
t0 = time
maxord = 20
cord = 1:maxord
strd = 0
neps = 50
ndel = 50
kdata = load( "kotao23_filtered_8.csv" );
ksize = size( kdata )
filenamebase = "counted_kotao23_filtered8_auto"
filenamesuffix = "__20230503.csv"

maxcollen = length( num2str( ksize( 2 ) + 1 ) )
maxordlen = length( num2str( maxord ) )

for colcnt = 1 : ksize( 2 )
    disp( "commencing column" );
    disp( colcnt );
```

```

colstr = num2str( colcnt ) ;
while length( colstr ) < maxcollen
    colstr = [ "0" , colstr ] ;
end

colfilenamebase = [ filenamebase , "__c_" , colstr ] ;

cdata = kdata( : , colcnt ) ;
cmm = fminmaxdelta02( cdata , strd ) ;
cmin = cmm( 1 ) ;
cmax = cmm( 2 ) ;
rat = 0.5*(sqrt(5)+1) ;
epss = f_exp_seq_r_01( cmin, cmax, nepss, rat ) ;
epss = epss( 2 : length( epss ) )
dels = f_exp_seq_r_01( cmin, cmax, ndel, rat ) ;
dels = dels( 2 : length( dels ) )

for ordcnt = 1 : maxord
    disp( "commencing order" ) ;
    disp( ordcnt ) ;
    ordstr = num2str( ordcnt ) ;
    while length( ordstr ) < maxordlen
        ordstr = [ "0" , ordstr ] ;
    end
    ordfilenamebase = [ colfilenamebase , "__o_" , ordstr, filenamesuffix ] ;
    aprcol = 1 ;
    condcoll = [ 2 : 1 + ordcnt ] ;

```

```

counts = zeros( [ neps, 6 ] );
counts( : , 1 ) = epss( : );
state = [] ;

do

[ pairdiff, state ] = f_pair_difference_stream_03( cdata , cord , [], [], strd, state );

for epscnt = 1 : neps
    eps = epss( epscnt );

    counts( epscnt , 3 ) = counts( epscnt , 3 ) + state( 11 );

    selapr = f_psi_01( pairdiff( : , aprcol ) , eps );
    counts( epscnt , 4 ) = counts( epscnt , 4 ) + f_sum_col_01( selapr );

    for delcnt = 1 : ndel
        del = dels( delcnt );

        selcond = f_psi_mult_01( pairdiff( : , condcoll ) , del );

        cogncnt( epscnt, delcnt ) = cogncnt( epscnt, delcnt ) + f_sum_col_01( selcond )
;
        combcnt( epscnt, delcnt ) = combcnt( epscnt , delcnt ) + f_sum_col_01(
f_prod_col_01( [ selapr , selcond ]' )' );

    end

end

```

```

until ( state( 6 ) == 0 )

condprob = combcnt ./ cogncnt ;
condprob( cogncnt == 0 ) = 0 ;
maxprob = max( condprob' ) ;

for epscnt = 1 : neps
    for delcnt = 1 : ndel
        if condprob( epscnt, delcnt ) == maxprob( epscnt )
            counts( epscnt , 2 ) = dels( delcnt ) ;
            counts( epscnt , 5 ) = combcnt( epscnt , delcnt ) ;
            counts( epscnt , 6 ) = cogncnt( epscnt , delcnt ) ;
        end
    end
end

disp( "saved" ) ;
disp( ordfilenamebase ) ;
csvwrite( ordfilenamebase , counts )

disp( "finished order" ) ;
disp( ordcnt ) ;

end

disp( "finished column" )
disp( colcnt )

end

```

disp("finished all")

t1 = time

"duration"

t1 - t0

10.2. Списак графика

График бр:1. Поређење експериментално добијених вредности концентрације СО са подацима добијеним предикцијом ANN и GBR моделима [154]	26
График бр:2. Ефекти примене вештачких неуронских мрежа	28
График бр:3. Предикција температура димних гасова – LSTM модел почетна фаза фебруар 2020. године	54
График бр:4. Предикције температуре дима, протока ваздуха и емисије СО	56
График бр:5. Однос мерених вредности и предикција применом модела децембар 2024. године	59
График бр:6. Степен остварености циљева истраживања	60
График бр:7. Поређење по метрикама MSE, MAE и R ²	62
График бр:8. Приказа смањења потрошње горива и емисија СО и NOx након примене LSTM модела	63
График бр:9. Упоредна анализа стварних и предиктованих вредности температуре димних гасова	65
График бр:10. Поређење стварних и предиктованих вредности емисије СО гасова са предикцијама добијеним помоћу три различита модела	66
График бр:11. Компаративан анализа истраживања са другим појединачним студијама	68
График бр:12. Компаративна анализа овог истраживања са другим студијама	69
График бр:13. Кључни индикатори економског и технолошког утицаја	71
График бр:14. Визуелизација потврде хипотеза	74

10.3. Списак табела

Табела бр:1. Ефекти примене ВМ – квантитативни приказ	28
---	----

Табела бр:2.	Особине четири најзначајније архитектуре вештачких неуронских мрежа.	42
Табела бр:3.	Упоредна анализа RNN, LSTM и GRU	46
Табела бр:4.	Карактеристике уграђених сензора, дисплеја и меморије.....	49
Табела бр:5.	Оствареност циљева истраживања	60
Табела бр:6.	Поређење LSTM и PID контроле по метрикама.....	62
Табела бр:7.	Ефекти примене LSTM модела	63
Табела бр:8.	Приказ кључних метрика за упоређење перформанси коришћених ВНМ	64
Табела бр:9.	Статистичка анализа коришћених модела:	65


10.4. Попис слика

Слика бр:1.	Хијерархијска структура области вештачке интелигенције.....	4
Слика бр:2.	Међусобни однос кључних речи и повезаност са другим истраживањима	7
Слика бр:3.	Почетна фаза развоја уређаја – 2019. година	10
Слика бр:4.	Примена вештачке интелигенције	11
Слика бр:5.	Основни типови вештачких неуронских мрежа	20
Слика бр:6.	Архитектура модела са LSTM мрежом	23
Слика бр:7.	Методолошке фазе истраживања	39
Слика бр:8.	Котао АТИ Терминг ОЗОН 35 – експериментално место бр.1 ...	118
Слика бр:9.	Прототип уређаја за мерење и чување података	118
Слика бр:10.	Спољни изглед уређаја за комуникацију са котловским рачунаром, мерење и чување података	119
Слика бр:11.	Унутрашњи изглед уређаја за комуникацију са котловским рачунаром, мерење и чување података	119

10.5. Сlike мерног места и делова система



Слика бр:8. Котао АТИ Терминг ОЗОН 35 – експериментално место бр.1



Слика бр:9. Прототип уређаја за мерење и чување података



Слика бр:10. Спољни изглед уређаја за комуникацију са котловским рачунаром, мерење и чување података



Слика бр:11. Унутрашњи изглед уређаја за комуникацију са котловским рачунаром, мерење и чување података

10.6. Биографија аутора

Рођен 17. новембра 1983. године у Београду, где завршава основну школу „Владислав Петковић Дис“ и "XI београдску гимназију" природно-математичког смера. Затим на Физичком факултету у Београду дипломира са просечном оценом 8,10 и тиме стиче стручно звање Професор физике и основа технике за основну школу. Након основних студија, школовање наставља кроз стручно усавршавање на Војној академији у Београду, и ту завршава 98. Класу Техничке Службе – Машинске струке са просечном оценом 8,77 - КЛАСА за РО. Након одслуженог војног рока своје школовање наставља на Факултету за математику и рачунарске науке у Београду, где дипломира на академским студијама првог степена са просечном оценом 8,80 и стиче стручно звање Дипломирани информатичар - рачунарске науке, као и на академским студијама другог степена са просечном оценом 9,88 и стиче академско звање Мастер информатичар - рачунарске науке. Академски се и даље усавршава на Факултету за математику и рачунарске науке у Београду.

Поред наведеног, има одслужен војни рок под оружијем, возачку дозволу Б категорије, дозволу за управљање моторним чамцима и пловилима до 16 бт на реци и мору. Активан је члан стрелачког клуба Партизан, а у слободно време се бави планинарењем.

Поседује вишегодишње радно искуство наставника и предавача. Кратко је радио и у установи за основно образовање одраслих. Ангажован је као предавач на Факултету информатичких технологија у Београду и на Факултету за математику и рачунарство. Стално запослен у ОШ “Стеван Синђелић” у Београду као наставник информатике и рачунарства. Такође се бави процесним програмирањем у звању сениор програмера. Говори енглески језик.

Учествовао је на бројним семинарима о настави, стручним и научним конференцијама у држави и иностранству. Аутор уџбеника, више стручних и научних радова. Учествовао у неколико пројеката, радних група и тимова. Добитник више десетина признања за рад и залагање у каријери од којих се истичу: Светосавска Захвалница Физичког факултета за изузетан допринос популаризацији физике, признање Друштва математичара Србије за рад са талентованим ученицима, признања Друштва физичара Србије, и Математичког друштва Архимедес, Признања Савеза организација резервних војних старешина Србије. Научни комуникатор и промотер науке од 2004. године.

Један је од водитеља обуке од националног занчаја – Дигитална учионица, коју организује ЗУОВ. Аутор је обуке „Ексел – напредни ниво за јавна предузећа“ која је извођена у ЈКП Инфостан током 2019. године. Затим први аутор обуке „Основе ИТ/ИС за интерне ревизоре“ изведене у Дому инжињера и техничара Србије почетком 2020. године, водитељ обука за Л3, Л2 и Л1 за лиценце у области монтаже, извођења и надзора над системима техничке заштите лица и објеката.

Активан је члан Друштва физичара Србије, Удружења интерних ревизора Србије, Савеза резервних војних старешина Србије и The Global Institute of Internal Auditors (члан Глобалног института интерне ревизије). Члан општинског штаба за

ванредне ситуације градске општине Звездара. Члан управног одбора Савеза организација резервних војних старешина Србије.

Ожењен, отац троје деце.

10.7. Библиографија аутора

Радови у часописима:

1. **Popović, S.**, Viduka, D., Bašić, A., Dimić, V., Djukic, D., Nikolić, V., & Stokić, A. (2025). Optimization of Artificial Intelligence Algorithm Selection: PIPRECIA-S Model and Multi-Criteria Analysis. Electronics, 14(3), 562. <https://doi.org/10.3390/electronics14030562> - **M 22**
2. Tihi, N., Todorov, M., **Popovic, S.**, Popov, S., Samec, N., & Kokalj, F. (2025). Advanced Time Series Models for Urban Drought: A Comparative Study of (S)ARIMA and Holt-Winters. Preprints. <https://doi.org/10.20944/preprints202504.2180.v1>
3. **Стефан Поповић**, Соња Ђ. Поповић, (2021), Значај увођења интерне ревизије у установе доуниверзитетског образовања, Ревизор, vol. 94/2021. UDK: 657.6 37.014.614:657.47, DOI: 10.5937/Rev2194037P – **M 52**
4. **Popović, SĐ** Popović, N Jeremić, (december 2022) Participants of the teaching process awareness of the participants of the teaching process about internal audit, Revizor, year 25, vol.100, 41-48, UDK 657.6:371.1 DOI: 10.56362/Rev22100041P – **M 53**
5. SĐ Popović, J Beke-Trivunac, **S Popović**, (2022) Is internal audit the cost?(On the example of high schools), Revizo, year 25, vol.97-98, 111–120, UDK: 657.6:373.3/.5 DOI: 10.56362/Rev2298111P – **M 53**
6. Соња Ђукић Поповић, Ивана Поповић, **Стефан Поповић**, Стеван Иванковић, (2023) Микробит у физичким огледима - корелација наставе физике са наставом информатике и рачунарства, Настава физике, број 12, стр 81 - 89, ISSN 2406 – 2626, COBISS.SR-ID 214910476
7. Ивана Поповић, Соња Ђукић Поповић, **Стефан Поповић**, Стеван Иванковић, (2022) Демонстрационе теразије – физика у настави математике, Настава физике, број 11, стр 71 - 1776, ISSN 2406 – 2626, COBISS.SR-ID 214910476
8. **Стефан Поповић**, (2019) Коришћење програмског језика Пајтон у настави физике, Настава физике, ISSN 2406-2626 COBISS.SR-ID 214910476

Зборници међународних научних скупова:

1. **Popović, S.**, Djukić, D., Denić, N., Djukić Popović, S., & Stojanović, J. (2025, January 20). The Importance of Implementing Artificial Neural Networks in Boiler Automation Systems. 10th Virtual International Conference on Science, Technology and Management in Energy (eNergetics 2024), Virtual. <https://doi.org/10.5281/zenodo.14735501> - **M 33**

2. **Stefan Popović**, Nebojša Denić, Jelena Stojanović, Dejan Đukić, Sonja Đukić Popović, Innovations in Risk Management - Integration of Neural Networks in Boilers with Automatic Firing, Proceedings of 6th Virtual International Conference Path to a Knowledge Society-Managing Risks and Innovation, October 21-22, Niš, Serbia, ISBN 978-86-82602-04-0 (Paksom 2024), COBISS.SR-ID 161737737, <https://doi.org/10.5281/zenodo.14708134> - **M 33**
3. Stefan Popovic, Sonja Djukic Popovic, Dejan Djukic, Nebojsa Denic, (2024), Neural networks in pellet combustion control - research report for OZONE 55, Proceedings of the 14th International Conference on Applied Internet and Information Technologies, 8 November, 2024, Zrenjanin, Serbia, ISBN 978-86-7672-379-9, COBISS.SR-ID 158823945 - **M 33**
4. Đukić Popović S., Dimić V., Popović S., Todić M. and Popović I., (2024), School without mobile phones - impact on socialization, Proceedings of papers of XV International conference of information technology and development of education ITRO 2024, November 29th, 2024, Zrenjanin, Serbia, ISBN 978-86-7672-383-6, COBISS.SR-ID 159481865 - **M 33**
5. Dejan, D., & **Stefan, P.** (2024, July 8). Bilateral exponential as sigmoid in multilayered neuronal networks. Proceedings of International Scientific and Professional Conference "ALFATECH" Smart Cities and modern technologies March 15, 2024, Belgrade, Serbia, ISBN: 978-86-6461-074-2 <https://doi.org/10.5281/zenodo.12685976> - **M 33**
6. **Popović, S.**, Đukić Popović, S., Đukić, D., & Gligorijević, M. (2024, July 2). Genetic algorithms and machine learning as the basis of all implemented solutions in smart cities. Proceedings of International Scientific and Professional Conference "ALFATECH" Smart Cities and modern technologies March 15th, 2024, Belgrade, Serbia, ISBN: 978-86-6461-074-2 <https://doi.org/10.5281/zenodo.12614935> - **M 33**
7. Đukić Popović, K. Vuletić, I. Popović, **S. Popović**, D.Vučković and S. Ivanković, (2023) The challenge of modern education - a school without mobile phones, Proceedings of XIV International conference of information technology and development of education ITRO 2023, Zrenjanin, Serbia, 28 – 32, ISBN: 978-86-7672-372-0, COBISS.SR-ID 143397129 – **M 31**
8. **S. Popović**, R. Jevtić, S. Đukić Popović, J. Ničković, I. Popović and V. Čabrić (2023) Discipline of students - the problem of modern education, Proceedings of XIV International conference of information technology and development of education ITRO 2023, Zrenjanin, Serbia, 161 – 165, ISBN: 978-86-7672-372-0, COBISS.SR-ID 143397129 – **M 33**
9. **Stefan Popović**, Jovan Ničković, Sonja Đukić Popović, Vladimir Čabrić, Jovan Veselinović, Milan Gligorijević, Dejan Đukić, (2023) Student discipline as today's social security problem – the role of the education system in removing this problem, Proceedings of IRASA International Scientific Conference Science, Education, Technology and Innovation SETI V 2023, Belgrade, Serbia, 617 – 628, ISBN 978-86-81512-11-1, COBISS.SR-ID 128307465 – **M 33**
10. **Stefan Popovic**, Dejan Djukic, Sonja Djukic Popovic, Milan Gligorijevic, (2023) Neural networks in pellet combustion control - an overview of the group's research work in 2022/2023, Proceedings of 9th Virtual International Conference on Science,

Technology and Management in Energy, Belgrade, Serbia, 249 – 254, ISBN 978-86-82602-03-3, COBISS.SR-ID 139266057– **M 33**

11. Ivana Popovic, Sonja Djukic Popovic, **Stefan Popovic** and Stevan Ivankovic, (2023) Preliminary research on the possibilities of PPG (Photoplethysmogram) signal analysis of medical sensors and smart watch sensors, Proceedings of the 13th International Conference on Applied Internet and Information Technologies, AIIT 2023, Bitola, North Macedonia, 344 – 350, ISBN 978-608-5003-03-7, COBISS.MK-ID 62559493 – **M 33**
12. **Stefan Popović**, Dejan Đukić, Sonja Đukić Popović, Lazar Kopanja, (2022) Preliminary Research on the Application of Neural Networks to the Combustion Control of Boilers with Automatic Firing, Proceedings of the 8 th Virtual International Conference on Science Technology and Management in Energy, 299 - 303, ISBN-978-86-82602-01-9, COBISS.SR-ID 119331337 – **M 33**
13. **Stefan Popović**, Lazar Kopanja, Dejan Djukić, Sonja Djukić Popović, (2022) Neural networks and their application in object recognition, Proceedings of the 12th International Conference on Applied Internet and Information Technologies, AIIT 2022, 40 - 48, Zrenjanin, Serbia, ISBN 978-86-7672-361-4 , COBISS.SR-ID 81418505 - **M 33**
14. **Стефан Поповић**, (2019) Пхет симулације у настави дигитално компетентних наставника, Култура комуникација компјутер, 67 – 74, Нови Сад, Србија, ISBN978–86–606543–8–3, COBISS.SR-ID 331152135 – **M 33**

Саопштења на конференцијама, научним и стручним скуповима штампана у изводу – књига апстраката:

1. Mitar Miki Tepić, **Stefan Popović**, (2025), Implementation of Artificial Intelligence and Machine Learning in Smart Water Projects in the Balkans, The Book of Abstracts International Scientific and Professional Conference “ALFATECH“Smart Cities and modern technologies February 28, 2025, Belgrade, Serbia, 17 - 17, ISBN 978-86-6461-085-8, COBISS.SR-ID 16418484, **M - 34**
2. Dejan Djukic, **Stefan Popovic**, Snezana Ocokoljic, (2025), Global Location Coding (Universal Geographical Indicator System), The Book of Abstracts International Scientific and Professional Conference “ALFATECH“Smart Cities and modern technologies February 28, 2025, Belgrade, Serbia, 19 - 19, ISBN 978-86-6461-085-8, COBISS.SR-ID 16418484, **M - 34**
3. Sonja Djukic Popovic, **Stefan Popovic**, Dejan Djukic, (2025), Optimization of Urban Mobility Using Combinatorial Algorithms and Artificial Intelligence, The Book of Abstracts International Scientific and Professional Conference “ALFATECH“Smart Cities and modern technologies February 28, 2025, Belgrade, Serbia, 56 - 56, ISBN 978-86-6461-085-8, COBISS.SR-ID 164184841, **M - 34**
4. Sonja Đukić Popović, **Stefan Popović**, (2024), Isti sadržaj drugačiji pristup - Kako jedna nastavna jedinica postaje druga u svakom razredu, KNJIGA APSTRAKATA XIV SIMPOZIJUM „MATEMATIKA I PRIMENE“, 6–7. decembar 2024. Beograd, Srbija. 66 - 66, ISBN 978-86-7589-197-0, COBISS.SR-ID 158252041 - **M 34**

5. **Stefan Popović**; Sonja Djukić Popović; Dejan Djukić; Milan Gligorijević, (2024), Genetic algorithms and machine learning as the basis of all implemented solutions in smart cities, The Book of Abstracts International Scientific and Professional Conference “ALFATECH” Smart Cities and modern technologies March 15, 2024, Belgrade, Serbia, 20 – 20, ISBN 978-86-6461-070-4, COBISS.SR-ID 139964169, DOI: 10.5281/zenodo.10802515 – **M 34**
6. Dejan Djukic; **Stefan Popovic**, (2024), Bilateral exponential as sigmoid in multilayered neuronal networks, The Book of Abstracts International Scientific and Professional Conference “ALFATECH” Smart Cities and modern technologies March 15, 2024, Belgrade, Serbia, 48 – 48, ISBN 978-86-6461-070-4, COBISS.SR-ID 139964169, DOI: 10.5281/zenodo.10802515 – **M 34**
7. Sonja Đukić Popović, **Stefan Popović**, (2023), The influence of the application of teaching aids in mathematics teaching on learning outcomes, The Book of Abstracts XIII SYMPOSIUM „MATHEMATICS AND APPLICATIONS“, Belgrade, Serbia, 33 – 33, ISBN 978-86-7589-185-7, COBISS.SR-ID 131428105 – **M 34**
8. **Stefan Popović**, Jovan Ničković, Sonja Đukić Popović, Vladimir Čabrić, Jovan Veselinović, Milan Gligorijević, Dejan Đukić, (2023) Student discipline as today’s social security problem – the role of the education system in removing this problem, Book of Abstracts IRASA International Scientific Conference Science, Education, Technology and Inovation SETI V., Belgrade, Serbia, 102 – 102, ISBN 978-86-81512-09-8, COBISS.SR-ID 126551561 – **M 34**

Уџбеници:

1. Марина Ињац, Јован Јовановић, **Стефан Поповић**, (2021), Дигитални свет 2, уџбеник на српском језику, Нови Логос, Београд, ISBN: 9788661096099, Решење Министарства просвете: 650-02-00165/2021-07

Преведен на стране језике:

- босански - Marina Injac, Jovan Jovanović, **Stefan Popović**, (2021) Digitalni svijet 2, udžbenik na bosanskom jeziku, Нови Логос, Београд, ISBN - 978-86-6109-702-7 COBISS.SR-ID - 142242569, Решење Министарства просвете: 650-02-00231-1/2021-20

- мађарски - Marina Injac, Jovan Jovanović, **Stefan Popović**, (2021) Digitális világ 2, második osztályos magyar nyelvű tankönyv, Нови Логос, Београд, ISBN - 978-86-6109-703-4, COBISS.SR-ID - 118537737

- русински - Марина Ињац, Јован Јовановић, **Стефан Поповић**, (2021), Дигитални свет 2, уџбеник за други разред на русинском језику, Нови Логос, Београд, ISBN: 9788661097225, Решење Министарства просвете: 128-61-18/2022-01

- словачки - Marina Injac, Jovan Jovanović, **Stefan Popović**, (2021), Digitálny svet 2, učebnicu pre druhý stupeň ZŠ v slovenskom jazyku, Нови Логос, Београд, ISBN - 978-86-6109-725-6, COBISS.SR-ID - 113395977, Решење Министарства просвете: 128-61-5/2021-01

- украински - Марина Ињац, Јован Јовановић, **Стефан Поповић**, (2021), Дигитални швет 2 : учебник за другу класу основне школе, Нови Логос, Београд, ISBN - 978-86-6109-722-5 COBISS.SR-ID - 76085513

2. Попарић Горан, Ашковић Ана, Вуковић Катарина, **Поповић Стефан**, Стаменковић Александар, (2013), Физика 7 [Видео снимак] : лабораторијске вежбе : прописане наставним планом и програмом Министарства просвете Републике Србије за седми разред основне школе, Нови Логос, Београд, COBISS.SR-ID - 198833932

Учесће на пројектима:

1. U02/2023 Smart cities and modern technologies, одлука број 974/1 од 10.07.2023. године. - сарадник
2. Multi-criteria analysis modeling for decision optimization in computer science, одлука број 1760 од 15.10.2024. године. - координатор пројекта
3. Дигитална учионица, обука наставника
4. Популаризација науке - сарадник
5. Популаризација физике - сарадник

Ангажовања на стручним и научним скуповима:

1. 16th International Conference on Internet Engineering & Web Services (InWeS 2025), June 21 ~ 22, 2025, Sydney, Australia - member of program committee - <https://inwes2025.org/committee>
2. International Scientific and Professional Conference "ALFATECH" Smart Cities and modern technologies 2025, Београд, Србија - секретар конференције
3. 15th International Conference on Internet Engineering & Web Services (InWeS 2024), Copenhagen, Denmark - member of program committee - <https://sites.google.com/view/inwes-2024/program-committee?authuser=0>
4. International Scientific and Professional Conference "ALFATECH" Smart Cities and modern technologies 2024, Београд, Србија - секретар конференције
5. Координатор поставке у оквиру експерттинејдер зоне на Међународним фестивалима науке у Београду 2014. - 2019. и 2024.
6. Координатор поставке у оквиру зоне Нука без престанка на Међународном фестивалу науке у Београду 2024. године.

Рецензије:

1. Vladimir Obradović, (2019) Test Easy Start: FIZIKA 6, Škola plus, Beograd, ISBN: 9788662710871, EAN: 8662710871
2. Vladimir Obradović, (2018) Test Easy Start: FIZIKA 7, Škola plus, Beograd, ISBN: 9788662710796, EAN: 8662710796
3. Vladimir Obradović, (2019) Test Easy Start: FIZIKA 8, Škola plus, Beograd, ISBN: 9788662710901, EAN: 8662710901
4. Борис Главач, Славко Муждека, (2017) Њутн у теретани, Просвета, Београд, ISBN 978-86-07-02176-5

Евалуације:

Биљана Шутић, Стефан Поповић, Смиљана Новаков, Евалуација уџбеника из информатике и рачунарства за 8. разред основне школе, Дата статус, 2020.

Преводи:

Tone at the Top, Broj 91 / Februar 2019. <https://dl.theiia.org/AECPublic/Tone-at-the-Top-February-2019-Serbian.pdf>

Научно популарна учешћа:

1. Међународни фестивал науке Београд – 2006. – 2024.
2. Тутинфест 2020, 2022, 2024
3. Поглед у оглед 2012
4. Унаукуј се 2015, 2016
5. Чукарички експеримент 2012
6. Фестивал науке Краљево
7. Фестивал науке Чачак
8. Фестивал науке Футог
9. Фестивал науке Ужице
10. Физика уживо

10.8. Изјава о ауторству

Име и презиме аутора: Стефан Поповић

Број досијеа : 2019/6901

Изјављујем

да је докторска дисертација под насловом:

**ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ У ФУНКЦИЈИ ОПТИМИЗАЦИЈЕ
ПАРАМЕТАРА САГОРЕВАЊА КОТЛОВА СА АУТОМАТСКИМ ЛОЖЕЊЕМ**

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

У Београду, _____

Потпис аутора

10.9. Изјаву о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: **Стефан Поповић**

Број досијеа : **2019/6901**

Изјављујем

да је докторска дисертација под насловом:

**ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ У ФУНКЦИЈИ ОПТИМИЗАЦИЈЕ
ПАРАМЕТАРА САГОРЕВАЊА КОТЛОВА СА АУТОМАТСКИМ ЛОЖЕЊЕМ**

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

У Београду, _____

Потпис аутора

10.10. Изјаву о коришћењу

Овлашћујем Универзитетску библиотеку АЛФА БК Универзитета да у Дигитални репозиторијум Универзитета унесе моју докторску дисертацију под насловом: **ВЕШТАЧКЕ НЕУРОНСКЕ МРЕЖЕ У ФУНКЦИЈИ ОПТИМИЗАЦИЈЕ ПАРАМЕТАРА САГОРЕВАЊА КОТЛОВА СА АУТОМАТСКИМ ЛОЖЕЊЕМ**, 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, 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).

У Београду, _____

Потпис аутора

1. **Ауторство.** Дозвољавање 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.** Дозвољавање 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.** Дозвољавање 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.** Дозвољавање 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.** Дозвољавање 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.** Дозвољавање 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.