

УНИВЕРЗИТЕТ У БЕОГРАДУ
ЕЛЕКТРОТЕХНИЧКИ ФАКУЛТЕТ

Александар С. Стојковић

**ПРЕДВИЂАЊЕ ИНДУСТРИЈСКЕ ПРОИЗВОДЊЕ
ПРИМЕНОМ МОДЕЛА МАШИНСКОГ УЧЕЊА
ОПТИМИЗОВАНИХ МЕТАХЕУРИСТИКАМА**

докторска дисертација

Београд, 2026.

UNIVERSITY OF BELGRADE
SCHOOL OF ELECTRICAL ENGINEERING

Aleksandar S. Stojković

**INDUSTRIAL PRODUCTION FORECASTING
USING MACHINE LEARNING MODELS
OPTIMIZED WITH METAHEURISTICS**

Doctoral Dissertation

Belgrade, 2026.

Ментор

др Бошко Николић, редовни професор, Универзитет у Београду – Електротехнички факултет

Чланови комисије

- др Милош Цветановић, ванредни професор, Универзитет у Београду – Електротехнички факултет
- др Зоран Шеварац, редовни професор, Универзитет у Београду – Факултет организационих наука
- др Горан Квашчев, редовни професор, Универзитет у Београду – Електротехнички факултет
- др Милета Жарковић, ванредни професор, Универзитет у Београду – Електротехнички факултет
- др Владимир Јоцовић, доцент, Универзитет у Београду – Електротехнички факултет

Датум одбране

Захвалност

Ономе који „даје мудрост” и из чијих уста „долази знање и разум” (Приче Соломунове 2:6).

Проф. др Бошку Николићу и проф. др Небојши Бачанину, на одличној сарадњи и помоћи током овог истраживања.

Мом оцу, др Слободану Стојковићу, који ме је од малих ногу усмерио ка науци. Радовао би се овоме, иако докторирам код „глупих жицара”.

Мојој мајци Зорки. Волим Те, мама.

Божидару, Милани и Дарији. Ви сте оно најлепше у мом животу.

Јасмини, зато што ме је трпела толике године.

Др Валентини Тимченко, зато што ми није дозволила да одустанем.

Гордану Конечном, на свесрдној помоћи око прикупљања података.

Уни Кисић и др Бориславу Ђорђевићу, на искреној подршци.

Ирини Стефановић, на мотивацији за избор теме, и зато што ме је, кроз честа самоиспитивања, чинила бољим човеком.

Јелени, жени које нема. Тебе чувам за крај. Хвала Ти што си бар накратко престала да будеш имагинарна. (Ипак, молим мало дуже следећи пут.) Захваљујући Теби, „усред зиме сам најзад открио да у себи носим непобедиво лето”. Због Тебе сам ту где јесам.

Наслов докторске дисертације

Предвиђање индустријске производње применом модела машинског учења оптимизованих метахеуристикама

Сажетак

Ограничена доступност и природна неодрживост фосилних горива довели су до раста интересовања за обновљиве изворе енергије. Међутим, потребни су напори да се енергија из обновљивих извора потпуније укључи у дистрибутивне мреже. Пошто је поузданост кључна за производњу енергије, зависност соларних електрана од метеоролошких услова представља изазов за одржавање конзистентне производње. Зато је прецизно предвиђање фотонапонске производње неопходно за ефикасно управљање мрежом и учешће на тржишту енергије. Модели машинског учења представљају перспективно решење због своје способности да обрађују велике скупове података и хватају сложене обрасце унутар података.

Ово истраживање бави се применом техника метахеуристичке оптимизације за побољшање модела заснованих на LSTM мрежама са и без пажње за предвиђање фотонапонске производње. Предложена је модификована метода метахеуристичке оптимизације заснована на алгоритму оптимизације роја честица, да би се побољшала оптимизација хиперпараметара. Спроведене су симулације на подацима из стварног света, уз упоредну анализу са неколико познатих метахеуристичких. Коришћен је јавно доступан скуп података који се састоји од мерења из две фотонапонске електране у Индији. Осим тога, креиран је и коришћен додатни скуп података прикупљен из фотонапонске електране на крову Института „Михајло Пупин” у Београду.

Ово истраживање попуњава празнину у посматраној области; наиме, према прегледу литературе, LSTM модели мале тежине нису довољно испитани за проблем предвиђања фотонапонске производње. Најбољи креирани модели постигли су вредности nMSE од само 0,001812 до 0,007662 за коришћене скупове података. То показује значајан потенцијал предложеног решења за примене у стварном свету. Применљивост најбољих модела потврђена је и помоћу минијатурног машинског учења.

Кључне речи

Обновљива енергија, соларна енергија, прогнозирање, метахеуристике, оптимизација роја честица, LSTM

Научна област

Рачунарска техника и информатика

Ужа научна област

Вештачка интелигенција

Doctoral dissertation title

Industrial production forecasting using machine learning models optimized with metaheuristics

Abstract

Limited availability and natural unsustainability of fossil fuel sources have led to a surge in interest in renewable energy sources. However, efforts are required to fully integrate renewable energy into distribution networks. Since reliability is crucial for energy production, the dependence of solar power plants on weather conditions poses a challenge to maintaining consistent production. Consequently, accurate forecasting of photovoltaic production is essential for efficient grid management and energy market participation. Machine learning models are a promising solution due to their ability to process large datasets and capture complex patterns in data.

This research deals with the application of metaheuristic optimization techniques to improve models based on LSTM networks with and without attention for predicting photovoltaic generation. A modified metaheuristic optimization method based on the particle swarm optimization algorithm is proposed to improve hyperparameter optimization. Simulations were conducted on real-world data, with comparative analysis with several well-known metaheuristics. A publicly available dataset consisting of measurements from two power plants in India was used. In addition, a supplementary dataset collected from a rooftop photovoltaic power plant at the Institute “Mihailo Pupin” in Belgrade was created and used.

This research fills a gap in the field, since, according to a literature review, lightweight LSTM models are not sufficiently tested for the problem of photovoltaic generation forecasting. The best of the produced models achieved nMSE values of only 0.001812 to 0.007662 for the used datasets. This demonstrates the significant potential of the proposed approach for real-world applications. The applicability of the best-performing models was also validated using TinyML.

Keywords

Renewable energy, solar energy, forecasting, metaheuristics, particle swarm optimization, LSTM

Scientific field

Computer engineering and information technology

Scientific subfield

Artificial intelligence

Садржај

1	Увод.....	1
2	Теоријске основе	10
2.1	Фотонапонска технологија.....	10
2.1.1	Сунчево зрачење	11
2.1.2	Фотоелектрични ефекат	13
2.1.3	Понашање фотонапонских модула.....	14
2.1.4	Предвиђање фотонапонске производње	16
2.2	Метрике за оцењивање модела	17
2.2.1	Коефицијент детерминације (R^2).....	17
2.2.2	Средња квадратна грешка (MSE) и корен средње квадратне грешке (RMSE)	18
2.2.3	Друге метрике.....	19
2.3	Регресиони модели.....	19
2.3.1	Линеарна регресија	19
2.3.2	Полиномска регресија	20
2.4	Машинско учење.....	21
2.4.1	Врсте примена машинског учења.....	22
2.4.2	Врсте машинског учења	22
2.5	Неуронске мреже	24
2.5.1	Биолошки неурон	25
2.5.2	Општа структура вештачке неуронске мреже.....	26
2.5.3	Вештачки неурон	26
2.5.4	Функције активације.....	28
2.5.5	Процес обуке	31
2.5.5.1	Функција губитка.....	31
2.5.5.2	Оптимизатори	31
2.5.5.2.1	Градијентни спуст	32
2.5.5.2.2	Оптимизатор заснован на моментуму	33
2.5.5.2.3	Адаптивна процена момената	33
2.5.5.2.4	Алтернативни оптимизатори.....	34
2.5.5.3	Пропагација уназад.....	35
2.5.6	Врсте вештачких неуронских мрежа.....	36
2.5.6.1	Мреже са прослеђивањем унапред	36
2.5.6.2	Рекурентне неуронске мреже	36
2.5.6.2.1	Стандардне рекурентне неуронске мреже	36
2.5.6.2.2	Мреже дугог краткорочног памћења – LSTM	38
2.5.6.3	Конволутивне мреже	39

2.5.7	Припрема података и креирање модела.....	40
2.6	Метахеуристичка оптимизација	44
2.7	Истраживачка анализа података.....	44
2.7.1	Расподела фреквенција.....	45
2.7.2	Корелација	47
2.7.3	Мултиколинеарност.....	47
2.7.4	Квартили	48
2.7.5	Релевантност и статистичка значајност.....	48
3	Преглед стања у области	50
3.1	Критеријуми за избор	50
3.2	Кратки резимеи	51
3.3	Резултати анализа	56
3.3.1	Категорије радова.....	56
3.3.2	Методe прогнозирања.....	57
3.3.3	Врсте прогнозирања у погледу одређености резултата	60
3.3.4	Обухвати прогноза.....	61
3.3.5	Количине података.....	61
3.3.6	Временске резолуције података.....	63
3.3.7	Хоризонти прогнозе.....	64
3.3.8	Врсте улазних података.....	67
3.3.9	Предобрада	70
3.3.10	Вршне снаге.....	71
3.3.11	Избор улазних обележја	71
3.3.12	Оптимизација хиперпараметара	74
3.3.13	Метрике.....	76
3.3.14	Најбоље тачности.....	79
3.3.15	Величине неуронских мрежа	81
3.3.16	Функције активације.....	83
3.3.17	Оптимизатори.....	85
3.3.18	Функције губитка.....	86
3.3.19	Програмски језици	87
3.4	Закључци.....	89
4	Предложено решење	92
4.1	Модификовани метахеуристички алгоритам	92
4.1.1	Оригинални PSO алгоритам.....	92
4.1.2	Предложени измењени PSO алгоритам	94
4.2	Скупови података.....	97
4.2.1	Јавно доступан скуп података из Индије.....	97

4.2.2	Нови скуп података.....	98
4.3	Истраживачка анализа података.....	99
4.3.1	Приказ вредности података.....	99
4.3.2	Анализа нормалности података.....	101
4.3.3	Анализа корелације.....	102
4.3.4	Анализа мултиколинеарности.....	104
4.3.4.1	Анализа мултиколинеарности за први скуп података – електрана 1.....	104
4.3.4.2	Анализа мултиколинеарности за први скуп података – електрана 2.....	106
4.3.4.3	Анализа мултиколинеарности за други скуп података.....	107
4.3.5	Анализа помоћу линеарне регресије.....	109
4.3.6	Квартилна анализа.....	111
4.3.6.1	Квартилна анализа за први скуп података – електрана 1.....	112
4.3.6.2	Квартилна анализа за први скуп података – електрана 2.....	115
4.3.6.3	Квартилна анализа за други скуп података.....	118
4.4	Предобрада података.....	120
4.5	Поставке симулација.....	125
5	Резултати симулација.....	128
5.1	Први скуп података – електрана 1.....	128
5.1.1	Први скуп података – електрана 1 – LSTM модели.....	128
5.1.2	Први скуп података – електрана 1 – LSTM-АТТ модели.....	133
5.2	Први скуп података – електрана 2.....	137
5.2.1	Први скуп података – електрана 2 – LSTM модели.....	137
5.2.2	Први скуп података – електрана 2 – LSTM-АТТ модели.....	142
5.3	Други скуп података.....	147
5.3.1	Други скуп података – LSTM модели.....	147
5.3.2	Други скуп података – LSTM-АТТ модели.....	152
5.4	Примена помоћу TinyML-а.....	155
6	Закључак.....	158
	Литература.....	161
Прилог А	Примери кода.....	174
А.1	Имплементација LSTM мреже у програмском језику Python.....	174
А.2	Имплементација LSTM-АТТ мреже у програмском језику Python.....	179

Списак слика

СЛ. 1: Глобална потрошња енергије по изворима.....	3
СЛ. 2: Удео електричне енергије произведене из соларне у укупно произведеној електричној енергији, по континентима одн. регионима, у процентима	4
СЛ. 3: Укупан капацитет соларних електрана у Србији, у GW.....	5
СЛ. 4: Призор из фотонапонске електране „Топаз” која се налази у Калифорнији.....	10
СЛ. 5: Спектар сунчевог зрачења.....	11
СЛ. 6: Биланс енергије сунчевог зрачења на Земљи	12
СЛ. 7: Глобална хоризонтална ирадијација	13
СЛ. 8: Фотоелектрична карактеристика соларне ћелије	14
СЛ. 9: Соларне ћелије, модули, панели и низови	14
СЛ. 10: Зависност струје и напона у фотонапонском систему од ирадијансе	15
СЛ. 11: Зависност струје и напона у фотонапонском систему од температуре модула	15
СЛ. 12: Тренд најважнијих параметара у фотонапонском систему током дана	15
СЛ. 13: Тренд напона и струје у фотонапонском систему током дана.....	16
СЛ. 14: Врсте примена машинског учења	22
СЛ. 15: Шема учења под надзором	23
СЛ. 16: Шема учења без надзора.....	23
СЛ. 17: Шема учења поткрепљивањем.....	24
СЛ. 18: Основне компоненте биолошког неурона.....	25
СЛ. 19: Пример типичне вишеслојне вештачке неуронске мреже.....	26
СЛ. 20: Модел вештачког неурона.....	27
СЛ. 21: Алтернативни модел вештачког неурона.....	27
СЛ. 22: Логистичка функција	28
СЛ. 23: Функција \tanh	29
СЛ. 24: Функција ReLU.....	30
СЛ. 25: Функција ReLU са цурењем	30
СЛ. 26: Оптимизатори засновани на алгоритмима градијентног спуста	33
СЛ. 27: Мрежа са прослеђивањем унапред.....	36
СЛ. 28: Рекурентна неуронска мрежа са повратним везама у истом слоју.....	37
СЛ. 29: Рекурентна неуронска мрежа са повратним везама ка претходном слоју	37
СЛ. 30: „Размотана” рекурентна неуронска мрежа	37
СЛ. 31: Модул који се понавља у стандардној рекурентној неуронској мрежи садржи један елемент .	37
СЛ. 32: Ћелија LSTM мреже.....	38
СЛ. 33: Конволутивна мрежа.....	39
СЛ. 34: Дијаграм тока креирања модела вођеног подацима.....	40
СЛ. 35: Криве учења за модел који нема довољан капацитет	41
СЛ. 36: Криве учења за модел који захтева још обуке.....	42
СЛ. 37: Криве учења за претерано прилагођен модел	42
СЛ. 38: Криве учења за добро прилагођен модел.....	42
СЛ. 39: Криве учења у случају нерепрезентативног подскупа за обуку	43
СЛ. 40: Криве учења у случају нерепрезентативног подскупа за валидацију	43
СЛ. 41: Криве учења у случају када је подскуп за валидацију једноставније предвидети.....	43
СЛ. 42: Симетричност криве расподеле фреквенција.....	46

СЛ. 43: Сплљоштеност криве расподеле фреквенција.....	46
СЛ. 44: Функције густине вероватноће Студентове t-расподеле за разне вредности v	48
СЛ. 45: Категорије прегледаних радова	56
СЛ. 46: Методе прогнозирања у прегледаним радовима	59
СЛ. 47: Број записа по скупу података у прегледаним радовима	62
СЛ. 48: Временске резолуције улазних података у прегледаним радовима	63
СЛ. 49: Максимални хоризонти прогнозе изражени у временским јединицама	65
СЛ. 50: Врсте улазних података у прегледаним радовима	67
СЛ. 51: Методе селекције улазних обележја у прегледаним радовима.....	74
СЛ. 52: Методе оптимизације хиперпараметара у прегледаним радовима.....	75
СЛ. 53: Метрике за детерминистичко предвиђање у прегледаним радовима	77
СЛ. 54: Расподела вредности $nRMSE$ у прегледаним радовима	80
СЛ. 55: Расподела вредности $nMAE$ у прегледаним радовима	81
СЛ. 56: Расподела вредности R^2 у прегледаним радовима	81
СЛ. 57: Функције активације у прегледаним радовима	84
СЛ. 58: Оптимизатори у прегледаним радовима	85
СЛ. 59: Функције губитка у прегледаним радовима	87
СЛ. 60: Програмски језици у прегледаним радовима	88
СЛ. 61: Механизам генетског укрштања	95
СЛ. 62: Механизам генетске мутације.....	96
СЛ. 63: Исечак из сирових података за други скуп.....	98
СЛ. 64: Просечне АС снаге и ирадијансе по данима за први скуп података – електрана 1	99
СЛ. 65: Просечне АС снаге и ирадијансе по данима за први скуп података – електрана 2	100
СЛ. 66: Просечне АС снаге и ирадијансе по седмицама за други скуп података	100
СЛ. 67: Просечне температуре ваздуха и модула по данима за први скуп података – електрана 1	100
СЛ. 68: Просечне температуре ваздуха и модула по данима за први скуп података – електрана 2	101
СЛ. 69: Просечне температуре ваздуха и модула по седмицама за други скуп података	101
СЛ. 70: Топлотна мапа корелација за први скуп података – електрана 1, у току предобраде	103
СЛ. 71: Топлотна мапа корелација за први скуп података – електрана 2, у току предобраде	103
СЛ. 72: Топлотна мапа корелација за други скуп података, у току предобраде	104
СЛ. 73: Кутијасте дијаграми за електрану 1 из првог скупа података (сви записи)	112
СЛ. 74: Кутијасте дијаграми за електрану 1 из првог скупа података (само током дана)	114
СЛ. 75: Кутијасте дијаграми за електрану 2 из првог скупа података (сви записи)	115
СЛ. 76: Просечне АС снаге по сатима за електрану 2 из првог скупа података.....	116
СЛ. 77: Кутијасте дијаграми за електрану 2 из првог скупа података (само током дана)	117
СЛ. 78: Кутијасте дијаграми за други скуп података (сви записи).....	118
СЛ. 79: Кутијасте дијаграми за други скуп података (само током дана).....	120
СЛ. 80: Топлотна мапа корелација за први скуп података – електрана 1, након предобраде.....	123
СЛ. 81: Топлотна мапа корелација за први скуп података – електрана 2, након предобраде.....	123
СЛ. 82: Топлотна мапа корелација за други скуп података, након предобраде	124
СЛ. 83: Дијаграм тока оквира за обуку и тестирање модела.....	126
СЛ. 84: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података	129
СЛ. 85: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података	131

Сл. 111: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM модела за други скуп података	148
Сл. 112: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM модела за други скуп података.....	150
Сл. 113: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM модела за други скуп података.....	150
Сл. 114: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM модела за други скуп података	150
Сл. 115: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM модела за други скуп података	151
Сл. 116: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM модела за други скуп података.....	151
Сл. 117: Најбоља предвиђања за 1, 2 и 3 корака унапред методом LSTM-DGPSO за други скуп података	151
Сл. 118: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM-ATT модела за други скуп података	153
Сл. 119: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM-ATT модела за други скуп података	153
Сл. 120: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM-ATT модела за други скуп података.....	155
Сл. 121: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM-ATT модела за други скуп података	155

Списак табела

ТАБ. 1: Глобална потрошња енергије по изворима (само за обновљиве изворе) у TWh.....	3
ТАБ. 2: Удео електричне енергије произведене из соларне у укупно произведеној електричној енергији, по континентима одн. регионима, у процентима.....	4
ТАБ. 3: Соларни капацитети и њихово коришћење у Србији и окружењу, у 2022. години.....	5
ТАБ. 4: Производња електричне енергије у Србији по изворима, у процентима.....	6
ТАБ. 5: Типичне функције активације за скривене слојеве.....	30
ТАБ. 6: Типичне функције активације за излазни слој.....	30
ТАБ. 7: Потребан број цитирања.....	50
ТАБ. 8: Категорије прегледаних радова.....	56
ТАБ. 9: Методе прогнозирања у прегледаним радовима.....	58
ТАБ. 10: Методе прогнозирања које су произвеле nRMSE < 2%.....	60
ТАБ. 11: Врсте предвиђања по одређености резултата у прегледаним радовима.....	60
ТАБ. 12: Обухвати прогноза у прегледаним радовима.....	61
ТАБ. 13: Број записа по скупу података у прегледаним радовима.....	61
ТАБ. 14: Статистички подаци о величинама скупова података по методама прогнозирања.....	62
ТАБ. 15: Временске резолуције улазних података у прегледаним радовима.....	63
ТАБ. 16: Класификација прогноза по хоризонту.....	64
ТАБ. 17: Максимални хоризонти прогнозе изражени у временским јединицама.....	65
ТАБ. 18: Максимални хоризонти прогнозе изражени бројем корака унапред.....	65
ТАБ. 19: Укључени хоризонти прогнозе изражени у временским јединицама.....	66
ТАБ. 20: Методе прогнозирања коришћене за 96 или више корака унапред у више од једног рада.....	66
ТАБ. 21: Врсте улазних података у прегледаним радовима.....	68
ТАБ. 22: Вршне снаге фотонапонских електрана коришћених у прегледаним радовима.....	71
ТАБ. 23: Методе селекције улазних обележја у прегледаним радовима.....	73
ТАБ. 24: Методе селекције улазних обележја које су произвеле nRMSE < 2%.....	74
ТАБ. 25: Методе оптимизације хиперпараметара у прегледаним радовима.....	75
ТАБ. 26: Методе оптимизације хиперпараметара које су произвеле nRMSE < 2%.....	76
ТАБ. 27: Метрике за детерминистичко предвиђање у прегледаним радовима.....	76
ТАБ. 28: Промена метрика за различите хоризонте прогнозе у [25].....	79
ТАБ. 29: Промена метрика за различите хоризонте прогнозе у [39].....	79
ТАБ. 30: Промена метрика за различита годишња доба у [32].....	80
ТАБ. 31: Промена метрика за различита годишња доба у [36].....	80
ТАБ. 32: Статистике о броју скривених слојева и ћелија у прегледаним радовима.....	82
ТАБ. 33: Оптималне величине MLP мрежа за моделе оптимизоване помоћу MAE и MSE.....	83
ТАБ. 34: Функције активације у прегледаним радовима.....	84
ТАБ. 35: Оптимизатори у прегледаним радовима.....	85
ТАБ. 36: Функције губитка у прегледаним радовима.....	87
ТАБ. 37: Програмски језици у прегледаним радовима.....	88
ТАБ. 38: Најважнији Python пакети у прегледаним радовима.....	88
ТАБ. 39: Вредности коефицијената асиметричности и спљоштености за први скуп података.....	102
ТАБ. 40: Вредности коефицијената асиметричности и спљоштености за други скуп података.....	102
ТАБ. 41: Вредности фактора инфлације варијансе у почетној итерацији (први скуп података – електрана 1).....	104

ТАБ. 42: Вредности фактора инфлације варијансе након изостављања променљиве MODULE_TEMPERATURE (први скуп података – електрана 1).....	105
ТАБ. 43: Вредности фактора инфлације варијансе након изостављања променљиве AMBIENT_TEMPERATURE (први скуп података – електрана 1).....	105
ТАБ. 44: Вредности фактора инфлације варијансе након изостављања променљиве AC_POWER_PREV (први скуп података – електрана 1).....	105
ТАБ. 45: Вредности фактора инфлације варијансе у почетној итерацији (први скуп података – електрана 2).....	106
ТАБ. 46: Вредности фактора инфлације варијансе након изостављања променљиве MODULE_TEMPERATURE (први скуп података – електрана 2).....	106
ТАБ. 47: Вредности фактора инфлације варијансе након изостављања променљиве AMBIENT_TEMPERATURE (први скуп података – електрана 2).....	106
ТАБ. 48: Вредности фактора инфлације варијансе након изостављања променљиве AC_POWER_PREV (први скуп података – електрана 2).....	107
ТАБ. 49: Вредности фактора инфлације варијансе у почетној итерацији (други скуп података).....	107
ТАБ. 50: Вредности фактора инфлације варијансе након изостављања променљиве MODULE_TEMPERATURE (други скуп података).....	107
ТАБ. 51: Вредности фактора инфлације варијансе након изостављања променљиве AC_POWER_PREV (други скуп података).....	108
ТАБ. 52: Вредности фактора инфлације варијансе након изостављања променљиве WIND_DIRECTION (други скуп података).....	108
ТАБ. 53: Вредности фактора инфлације варијансе након изостављања променљиве AMBIENT_TEMPERATURE (други скуп података).....	108
ТАБ. 54: Комплетни статистички резултати регресије помоћу модела OLS, за електрану 1 из првог скупа података, у првој итерацији.....	109
ТАБ. 55: Најважнији статистички резултати регресије помоћу модела OLS за електрану 1 из првог скупа података.....	110
ТАБ. 56: Најважнији статистички резултати регресије помоћу модела OLS за електрану 2 из првог скупа података.....	110
ТАБ. 57: Најважнији статистички резултати регресије помоћу модела OLS за други скуп података .	111
ТАБ. 58: Број одступајућих вредности за електрану 1 из првог скупа података (сви записи).....	112
ТАБ. 59: Укупна AC снага по интервалима за електрану 1 из првог скупа података.....	113
ТАБ. 60: Статистички описи најважнијих променљивих у електрани 1 из првог скупа података (само током дана).....	113
ТАБ. 61: Број одступајућих вредности за електрану 1 из првог скупа података (само током дана)	114
ТАБ. 62: Број одступајућих вредности за електрану 2 из првог скупа података (сви записи).....	115
ТАБ. 63: Укупна AC снага по интервалима за електрану 2 из првог скупа података.....	116
ТАБ. 64: Статистички описи најважнијих променљивих у електрани 2 из првог скупа података (само током дана).....	117
ТАБ. 65: Број одступајућих вредности за електрану 2 из првог скупа података (само током дана)	117
ТАБ. 66: Број одступајућих вредности за други скуп података (сви записи)	118
ТАБ. 67: Укупна AC снага по интервалима за други скуп података	119
ТАБ. 68: Статистички описи најважнијих променљивих у другом скупу података (само током дана).....	119
ТАБ. 69: Број одступајућих вредности за други скуп података (само током дана).....	120
ТАБ. 70: Статистички описи најважнијих променљивих у првом скупу података, електрана 1	122
ТАБ. 71: Статистички описи најважнијих променљивих у првом скупу података, електрана 2	122
ТАБ. 72: Статистички описи најважнијих променљивих у другом скупу података	122
ТАБ. 73: Вредности коефицијената корелације са циљним атрибутом за први скуп података, након предобrade.....	124

ТАБ. 74: Вредности коефицијената корелације са циљним атрибутом за други скуп података, након предобраде.....	124
ТАБ. 75: Скуп хиперпараметара који се оптимизују.....	125
ТАБ. 76: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	129
ТАБ. 77: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	129
ТАБ. 78: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	130
ТАБ. 79: Најбољи одабрани LSTM хиперпараметри за експерименте са електраном 1 из првог скупа података.....	130
ТАБ. 80: Статистике функције циља за LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	133
ТАБ. 81: Све метрике за најбоље LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	134
ТАБ. 82: Детаљне метрике за најбоље LSTM-АТТ моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података.....	135
ТАБ. 83: Најбољи одабрани LSTM-АТТ хиперпараметри за експерименте са електраном 1 из првог скупа података.....	135
ТАБ. 84: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	138
ТАБ. 85: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	138
ТАБ. 86: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	139
ТАБ. 87: Најбољи одабрани LSTM хиперпараметри за експерименте са електраном 2 из првог скупа података.....	139
ТАБ. 88: Статистике функције циља за LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	143
ТАБ. 89: Све метрике за најбоље LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	143
ТАБ. 90: Детаљне метрике за најбоље LSTM-АТТ моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података.....	144
ТАБ. 91: Најбољи одабрани LSTM-АТТ хиперпараметри за експерименте са електраном 2 из првог скупа података.....	144
ТАБ. 92: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	148
ТАБ. 93: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	148
ТАБ. 94: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	149
ТАБ. 95: Најбољи одабрани LSTM хиперпараметри за експерименте са другим скупом података.....	149
ТАБ. 96: Статистике функције циља за LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	152
ТАБ. 97: Све метрике за најбоље LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	153
ТАБ. 98: Детаљне метрике за најбоље LSTM-АТТ моделе при предвиђањима за 1, 2 и 3 корака унапред за други скуп података.....	154
ТАБ. 99: Најбољи одабрани LSTM-АТТ хиперпараметри за експерименте са другим скупом података.....	154

1 Увод

У савременом индустријском окружењу, предвиђање производних капацитета представља кључни изазов који може значајно утицати на оперативну ефикасност и профитабилност предузећа. У оквиру ове тезе истражује се могућност примене модела машинског учења у комбинацији са оптимизованим метахеуристичким приступима за унапређење тачности предикција индустријске производње. Различите технике машинског учења, као што су регресиони модели, стабла одлучивања и неуронске мреже, могу се синергијски повезати са метахеуристикама, као што су генетски алгоритми и оптимизација роја честица, за оптимизацију хиперпараметара модела и избор функција. Резултати експеримената показују да комбинација тих приступа омогућава постизање значајно боље прецизности у предикцијама у поређењу са традиционалним методама. Тиме се пружа свеобухватан оквир за имплементацију напредних техника у предвиђању индустријске производње, с потенцијалом да унапреди стратегије доношења одлука у индустрији.

Скоро свака грана индустрије може имати користи од примене модела машинског учења. На пример, у тешкој индустрији могуће је вршити предвиђање одржавања и кварова (енгл. *smart maintenance*). У фабрикама са комплексним производним линијама (нпр. у металургији, хемијској индустрији, производњи цемента, електранама...), помоћу алгоритама машинског учења могу се анализирати сензорски подаци са опреме. Као унапређење процеса, модели оптимизовани метахеуристикама могу да помогну у предвиђању отказа, чиме се смањују трошкови ванредног одржавања и губици у производњи.

Велика могућност примене постоји и у фармацеутској индустрији у процесима оптимизације рада и производње. На основу историјских података и трендова болести могуће је вршити предвиђање потребне производње лекова и помоћних средстава. И у овом случају, модели оптимизовани метахеуристикама могу да помогну у проналажењу најбољих параметара за производњу активних супстанци, чиме се повећава ефикасност и смањује потрошња скупих сировина.

Као добар пример важности предвиђања производње могу послужити и фотонапонски (ФН, енгл. *photovoltaic – PV*) системи и електране, и том примеру посвећена је нарочита пажња у овом истраживању. Глобална потражња за чистом енергијом стално расте, а развој фотонапонске технологије омогућава боље коришћење соларне енергије. Фотонапонске електране представљају најважније подручје примене те технологије. Заједно са ветрогенераторима, фотонапонска технологија омогућила је многим домаћинствима и организацијама да производе сопствену електричну енергију, и тиме су многи потрошачи постали купци-произвођачи (енгл. *prosumer*). То је довело до суштинских промена у концептима електроенергетских мрежа, чинећи паметне мреже неопходним.

Развој фотонапонске технологије омогућава човечанству да користи више енергије коју наша планета добија од Сунца. Луминозност (излазна снага) Сунца, тј. укупна количина енергије коју Сунце ослобађа сваке секунде, износи око $3,86 \times 10^{26}$ W. Пошто се та енергија равномерно зрачи у свим правцима, наша планета пресеће само њен мајушни део, али то нам и даље дарује огромних $1,75 \times 10^{17}$ W бесплатне и обновљиве енергије [51].

Општа потражња за чистом енергијом, мотивисана очигледном потребом за смањењем емисије гасова стаклене баште, довела је до наглог повећања инсталираног капацитета фотонапонских система са око 1 GW у 2000. години на преко 1 TW у 2022. години [52], са јасном тенденцијом даљег раста. По предвиђањима, до краја 2025. године глобални капацитет фотонапонских система требало је да достигне 3 TW, што је скоро троструко више за само 3

године [53]. ЕУ, на пример, жели да производи најмање 42,5% своје енергије из обновљивих извора до 2030. године, али тежи да достигне 45% [54]. То је двоструко више од 21,8%, колики је био удео обновљивих извора у потрошњи енергије ЕУ у 2021. години [55]. Процењује се да би до 2050. године 86% глобалне електричне енергије могло бити из обновљивих извора [56].

Главни проблем у вези са добијањем електричне из соларне енергије је променљивост количине генерисане енергије. Излазна снага фотонапонског система динамички се мења током времена због променљивости фактора околине. Производња фотонапонске енергије у великој мери зависи од сунчевог зрачења, тј. количине енергије примљене од Сунца по јединици површине, али и други метеоролошки фактори попут температуре ваздуха имају одређени утицај [72]. Сунчево зрачење зависи пре свега од атмосферских услова и облачности. Природна променљивост расположиве сунчеве светлости и других метеоролошких параметара током дана и године доводи до променљивости генерисане фотонапонске енергије.

Количина генерисане енергије зависи и од других фактора, попут оперативног стања инвертора и модула. Пошто фотонапонске ћелије производе једносмерну струју, фотонапонске електране садрже инверторе који претварају једносмерну струју у наизменичну за јавну употребу. Лоше стање ћелија (запрљаност, неправилан угао, дефекти итд.) и/или инвертора може драстично смањити жељени излаз. Очигледно је да бројни фактори утичу на производњу фотонапонске енергије и стога компликују њено прогнозирање [73], [74].

Нестабилност количине генерисане фотонапонске енергије представља значајан изазов за стабилност и поузданост електродистрибутивне мреже. Варијације улаза у мрежу узрокују флукуације напона и/или фреквенције и друге проблеме са квалитетом електричне енергије, као и неусклађеност понуде и потражње [66]. Способност прецизног и благовременог предвиђања производње фотонапонске енергије постала је кључна за функционисање електроенергетске мреже у многим земљама, зато што омогућава системима паметних мрежа и оператерима да проактивно контролишу инхерентну променљивост соларне енергије тако да ефикасно уравнотеже производњу и потрошњу, тј. понуду и потражњу енергије, и тиме одрже стабилност мреже [67], [68].

Предвиђање производње електричне енергије у фотонапонском систему помаже не само у одржавању система, већ и у бољем коришћењу енергетских ресурса. Та оптимизација омогућава се и предвиђањем када и у ком периоду ће се више тражити од система, и то такође помаже у креирању политике рационализације енергије. Уз адекватну прогнозу може се проценити нпр. када ће бити потребно улагати у дистрибутивну мрежу [148], [149].

Квалитет прогноза производње фотонапонске енергије веома је битан и за власнике фотонапонских електрана, зато што им омогућава да буду конкурентнији на тржишту енергије. У тржишним условима, споменути проблеми директно утичу на репутацију произвођача у погледу поузданости и њихов потенцијал лицитирања [69]. Према [31], побољшање тачности прогнозирања производње фотонапонске енергије од само 1% доводи до значајних економских користи због смањења казни и могућности постизања бољих цена на тржишту. Стога, прецизно предвиђање не само што побољшава поузданост мреже, већ и олакшава жељени пораст удела фотонапонских извора као улаза у мрежу [70], [71].


Од произвођача се на тржишту најчешће очекује да достављају прогнозе за један дан унапред. Хоризонти краћи од једног дана корисни су за оператере мреже, због тога што омогућавају боље управљање резервама снаге и оптимално ангажовање ресурса. Дужи хоризонти потребни су за оперативно планирање рада, заказивање одржавања и планирање капацитета.

Коришћење фотонапонске технологије за генерисање електричне енергије постало је популарно последњих година, углавном захваљујући подстицајима влада развијених земаља и растућој потражњи за чистим изворима енергије. Штавише, фотонапонски панели су технолошки еволуирали, омогућавајући веће перформансе и поузданост. Фотонапонски

системи одликују се флексибилношћу, која омогућава да се инсталирају на различите начине и у различитим просторима [146], [147].

ТАБ. 1: Глобална потрошња енергије по изворима (само за обновљиве изворе) у TWh (извор података: [126])

Година	Биогорива	Соларна енергија	Ветар	Хидроелектране	Остали обновљиви извори енергије
2010	699,7631	94,1262	961,4860	9520,602	1173,9039
2011	735,3815	181,1018	1215,6783	9635,082	1232,3865
2012	762,4717	278,3655	1454,6062	9985,715	1334,9750
2013	828,6506	377,7236	1732,0238	10324,202	1442,0590
2014	878,8694	534,4008	1912,3210	10535,740	1560,9077
2015	912,9778	689,3456	2238,8726	10447,261	1688,6459
2016	953,7291	879,1791	2575,6694	10746,731	1714,8402
2017	974,0694	1185,5515	3037,9270	10834,706	1826,1881
2018	1049,8936	1523,3044	3358,8267	11084,954	1973,9960
2019	1124,6016	1858,9540	3744,7256	11185,189	2072,3691
2020	1073,7583	2243,8350	4186,1810	11448,027	2182,6973
2021	1142,8717	2771,8290	4851,5940	11222,360	2335,3115
2022	1199,2067	3448,2373	5487,6000	11299,816	2413,8076
% раста	71,37%	3563,42%	470,74%	18,69%	105,62%



СЛ. 1: Глобална потрошња енергије по изворима (прилагођено из [126])


Та популаризација може се уочити на графикону на сл. 1, а нарочито у ТАБ. 1 [126]. Графикон приказује глобалну потрошњу енергије по изворима од 1800. до 2022., а табела садржи подскуп података са графикона – само обновљиве изворе енергије, и то од 2010. до 2022. Године 2010. соларна енергија била је убедљиво најмање заступљена међу свим изворима енергије, са потрошњом од свега 94,1 TWh, а само деценију касније већ је била заступљенија од биогорива и осталих обновљивих извора енергије. Нарочито је импресиван проценат раста употребе соларне енергије од 2010. до 2022., приказан у последњем реду табеле, који је убедљиво највећи међу свим изворима енергије.

У константном порасту у читавом свету је и удео електричне енергије произведене из соларне у укупно произведеној електричној енергији (ТАБ. 2 и СЛ. 2) [152]. Око 2000. године тај удео

био је приближно једнак нули, док је 2022. на глобалном нивоу износио 4,59%. У томе предњачи Аустралија и Океанија са уделом од 11,97% у 2022. години и израженим трендом наглог раста удела. Цела Европа нешто је боља од глобалног просека захваљујући Европској унији, која је била глобални лидер до 2018., али крива за целу Европу мења се исто као и крива за ЕУ, што показује да европске земље ван ЕУ још увек само кваре просек.

ТАБ. 2: Удео електричне енергије произведене из соларне у укупно произведеној електричној енергији, по континентима одн. регионима, у процентима (извор података: [152])

Година	Африка	Азија	Цела Европа	Само ЕУ	Латинска Америка	САД и Канада	Аустралија и Океанија	Цео свет
2000	0	0,01	0	0	0	0,01	0,02	0,01
2001	0	0,01	0	0,01	0	0,01	0,02	0,01
2002	0	0,02	0,01	0,01	0	0,01	0,02	0,01
2003	0	0,02	0,01	0,01	0	0,01	0,02	0,01
2004	0	0,03	0,01	0,02	0	0,01	0,02	0,02
2005	0	0,03	0,03	0,05	0	0,01	0,03	0,02
2006	0,01	0,03	0,05	0,09	0	0,01	0,03	0,03
2007	0	0,04	0,08	0,13	0	0,01	0,04	0,04
2008	0,01	0,04	0,15	0,25	0	0,02	0,05	0,06
2009	0,01	0,05	0,29	0,51	0	0,02	0,10	0,10
2010	0,03	0,07	0,46	0,80	0,01	0,03	0,32	0,15
2011	0,08	0,11	0,95	1,64	0,01	0,05	0,66	0,29
2012	0,13	0,16	1,42	2,43	0,03	0,11	0,80	0,43
2013	0,10	0,29	1,71	2,90	0,05	0,22	1,28	0,57
2014	0,24	0,56	1,98	3,31	0,09	0,65	1,66	0,83
2015	0,46	0,86	2,18	3,49	0,20	0,88	2,05	1,07
2016	0,62	1,23	2,24	3,48	0,32	1,24	2,44	1,33
2017	0,86	1,83	2,42	3,67	0,54	1,71	2,92	1,75
2018	1,01	2,41	2,67	3,91	0,98	2,00	3,97	2,18
2019	1,30	2,93	2,99	4,33	1,73	2,30	5,82	2,64
2020	1,79	3,44	3,61	5,26	2,55	2,87	7,60	3,20
2021	2,02	4,02	3,86	5,67	3,35	3,53	9,83	3,75
2022	2,41	4,85	4,97	7,59	4,26	4,27	11,97	4,59




СЛ. 2: Удео електричне енергије произведене из соларне у укупно произведеној електричној енергији, по континентима одн. регионима, у процентима (извор података: [152])

Број сати сунчевог зрачења у току године на територији Србије износи између 1500 и 2200, што је више него у већини европских земаља. Просечна енергија сунчевог зрачења износи од 1200 kWh/m² годишње у северозападној Србији до 1550 kWh/m² годишње у југоисточној Србији, док у централном делу Србије износи око 1400 kWh/m² годишње. У јануару, просек је од 1,1 kWh/m² дневно на северу до 1,7 kWh/m² дневно на југу, а у јулу од 5,9 до 6,6 kWh/m² дневно [179].

Укупан капацитет соларних електрана у Србији, по подацима из [152], 2010. године био је око 0,01 GW (тј. 10 MW), а 2022. износио је око 0,14 GW (тј. 140 MW). Тренд раста у том периоду приказан је на сл. 3. По инсталираном соларном капацитету, Србија је 2022. године била на деоби 90. места од 210 држава или територија за које постоје подаци. У окружењу предњачи Грчка која је те године била на 23. месту, док је најмање соларних капацитета у Црној Гори и на тзв. Косову, који су били на деоби 133. места (ТАБ. 3).

ТАБ. 3: Соларни капацитети и њихово коришћење у Србији и окружењу, у 2022. години (извор података: [152])

Земља или територија	Капацитет соларних електрана (GW)	Место на свету по капацитету соларних електрана	Пораст капацитета 2021-2022		Електрична енергија произведена из соларне (TWh)	Пораст производње 2021-2022		Удео соларне укупно произведене електричне енергије (%)	Место на свету по искоришћености соларних капацитета
			GW	%		TWh	%		
Албанија	0,03	126	0,01	50,00	0,04	0	0	0,57	62
Аустрија	3,55	28	0,77	27,70	3,79	1,01	36,33	5,90	93
Босна и Херцеговина	0,11	95	0,05	83,33	0,14	0,07	100,00	0,85	71
Бугарска	1,95	35	0,68	53,54	2,09	0,62	42,18	4,16	91
Грчка	5,56	23	1,28	29,91	7,14	1,89	36,00	13,83	70
тзв. Косово	0,02	133	0,01	100,00	0,02	0	0	0,29	97
Мађарска	2,99	31	0,02	0,67	4,73	0,93	24,47	13,23	41
Румунија	1,41	41	0,02	1,44	1,99	0,29	17,06	3,64	54
Северна Македонија	0,08	108	0	0	0,03	0	0	0,52	155
Словенија	0,63	51	0,17	36,96	0,65	0,20	44,44	4,87	96
Србија	0,14	90	0,09	180,00	0,01	0	0	0,03	157
Хрватска	0,18	86	0,04	28,57	0,15	0	0	1,05	127
Црна Гора	0,02	133	0,02		0	0		0	



Сл. 3: Укупан капацитет соларних електрана у Србији, у GW (извор података: [152])

Међутим, ако су тачни подаци о производњи електричне из соларне енергије у Србији наведени у [152], по искоришћености соларних капацитета (тј. односу произведене електричне енергије и капацитета) Србија је међу најлошијима у свету! Тачније, 2022. била је на 157. месту од 166 земаља у којима постоје соларни капацитети од бар 10 MW! Самим тим, удео

електричне енергије произведене из соларне у укупно произведеној електричној енергији у Србији још увек је симболичан.

ТАБ. 4: Производња електричне енергије у Србији по изворима, у процентима
(извор података: [152])

Година	Биогорива	Угаљ	Гас	Хидро- електране	Остала фосилна горива	Соларна енергија	Ветар
2000	0	66,00	1,20	31,84	0,95	0	0
2001	0	65,65	1,50	31,89	0,96	0	0
2002	0	66,82	1,48	30,95	0,74	0	0
2003	0	71,33	1,56	26,33	0,78	0	0
2004	0	68,29	1,80	29,50	0,40	0	0
2005	0	64,09	0,88	32,98	2,06	0	0
2006	0	68,57	0,33	30,06	1,04	0	0
2007	0	69,96	1,18	27,47	1,40	0	0
2008	0	71,39	1,10	27,05	0,45	0	0
2009	0	70,09	0,44	29,08	0,39	0	0
2010	0	65,67	0,87	32,99	0,47	0	0
2011	0	74,40	1,30	23,94	0,36	0	0
2012	0,03	71,50	1,30	26,92	0,24	0	0
2013	0,05	71,89	0,75	27,21	0,10	0	0
2014	0,06	64,97	0,68	34,12	0,15	0,03	0
2015	0,05	70,93	0,57	28,15	0,26	0,03	0
2016	0,08	69,24	0,97	29,28	0,33	0,03	0,08
2017	0,22	71,44	1,48	26,32	0,38	0,03	0,13
2018	0,27	66,86	1,60	30,44	0,40	0,03	0,40
2019	0,37	68,03	1,78	27,13	0,27	0,03	2,39
2020	0,50	69,72	1,34	25,69	0,13	0,03	2,58
2021	0,65	62,18	2,80	31,34	0,18	0,03	2,83
2022	0,64	65,70	4,98	26,04	0	0,03	2,61
2023	0,59	60,04	4,06	32,90	0	0,03	2,40

У ТАБ. 4 приказан је процентуални удео појединих извора у укупној производњи електричне енергије у Србији. Константно се око две трећине електричне енергије производи из угља и нешто мање од једне трећине у хидроелектранама, са мањим варијацијама из године у годину. Добро је што је порасла производња електричне енергије из природног гаса и што је престала производња из осталих фосилних горива, тј. нафте и њених деривата. Међутим, очигледна је стагнација у уделу обновљивих извора енергије. Након почетног замаха, производња из енергије ветра стагнира на око 2,5%, из биогорива на око 0,6%, а производња из соларне енергије, по тим подацима, константно је на симболичних 0,03% [152].

У тренутку писања овог дела текста, [152] садржи податке закључно са 2022., а за поједине категорије 2023. годином. У априлу 2023. отворена је, у том тренутку, највећа соларна електрана у Србији од 9,9 MW у околини Лапова [153]. Међутим, у околини Куле гради се агросоларни парк (што подразумева производњу електричне из соларне енергије упоредо са производњом пољопривредних култура) капацитета чак 660 MW, што би по подацима са почетка 2024. била највећа соларна електрана у Европи [155]! У Србији су у изградњи још неке соларне електране. Дакле, очекује се да се капацитет соларних електрана, производња електричне из соларне енергије, као и удео електричне енергије произведене из соларне у укупно генерисаној електричној енергији у Србији драстично повећају у наредном периоду.

Што се тиче малих произвођача електричне из соларне енергије, тзв. прозјумера или купаца-произвођача, пад цена соларних панела из године у годину учинио је да мале соларне електране постану економски исплативе и врате укупно почетно улагање након 4 до 12 година, зависно од капацитета. С обзиром на очекивани животни век соларне електране од 25 година, јасно је да ће она годинама доносити битну уштеду. Почетком 2025. у Србији је било око 5000 прозјумера, а укупан капацитет њихових панела био је око 93 MW [156]. Зашто нема још више прозјумера и панела, нарочито међу домаћинствима? Држава је донедавно била прилично рестриктивна према прозјумерима: нису имали могућност да продају вишкове, наплаћивало им се „држање” вишкова предатих ЕДС-у, тј. то што се из њихове перспективе ЕДС понашао као виртуелна батерија, а вишкови које не искористе до датума поравнања су пропадали.

Наиме, због недовољне техничке опремљености и застареле једносмерне архитектуре мреже, повратна снага коју генеришу прозјумери представља озбиљан технички изазов за ЕДС. Долази до локалних скокова напона, неискористивих вишкова енергије, као и преоптерећења трансформатора који нису предвиђени за повратну струју. Проблем је у недостатку „паметне мреже” (тј. напредних система за аутоматизовано управљање производњом и потрошњом у реалном времену), „паментних бројила” (тј. информација о локалном стању нисконапонске мреже у реалном времену), као и батеријских система за складиштење вишкова.

Очекује се да недавне измене закона које уводе концепт активног купца поправе ситуацију. Тај концепт мотивише а делом и обавезује активне купце да инсталирају сопствене батеријске системе. Уводи се и најављивање испоручене количине енергије, као и пенали ако се испоручи мање, али и више него што је најављено. Тиме се активни купци мотивишу да користе системе за прецизно прогнозирање и да преузму део одговорности за стабилност система. Активни купци имају могућност продаје вишкова по тржишним ценама, а може им се плаћати и смањивање производње приликом преоптерећења (тзв. услуге флексибилности). Уводи се и концепт агрегатора – посредника између ЕДС-а и већег броја малих активних купаца [157].

У неким државама већ дуже време постоје таква решења, а на прозјумере се гледа као на сараднике у обезбеђивању стабилности система. На пример, у Колумбији прозјумери имају могућност да са електродистрибуцијом уговоре количину енергије за коју гарантују да ће је редовно испоручивати у електродистрибутивну мрежу. Уколико испуњавају то обећање, осим цене произведене електричне енергије исплаћује им се и додатна накнада за поузданост [177], зато што доприносе стабилности електроенергетског система. Због тога је суштински важна поуздана прогноза, на основу које прозјумери могу да планирају продају вишкова, или резерву за периоде у којима је произведена количина енергије мања од њихових потреба.

Као што је већ истакнуто, предвиђање производње електричне енергије у фотонапонском систему представља компликован задатак с обзиром на зависност те производње од бројних параметара, као што су интензитет зрачења, температура ваздуха, друге метеоролошке променљиве, годишње доба, стање разних компоненти система, итд. Технике машинског учења постале су препоручени начин решавања комплексних проблема са великим скуповима података [136]. Стога, употреба машинског учења у комбинацији са великим скуповима података постаје интересантно решење за проблеме процене временских серија ради добијања задовољавајућих прогноза у енергетским системима [141]. Област машинског учења пружа разне методе за предвиђање (процену временских серија) и доношење одлука на основу историје датог сигнала или система.

Предмет овог истраживања је примена модела машинског учења (МУ) за предвиђање индустријске производње, са посебним освртом на производњу електричне енергије у фотонапонским електранама, као и модификовани метахеуристички алгоритам за оптимизацију прогнозирања. Технологије машинског учења доказале су своју ефикасност у решавању различитих сложених проблема на које утиче низ фактора [4], [75], [76]. Једна од типичних примена модела машинског учења су проблеми предвиђања, а то обухвата и посматрани проблем. Међутим, модели машинског учења ограничени су тиме што захтевају

фино подешавање својих хиперпараметара за сваки појединачни проблем, као што је објашњено теоремом о непостојању бесплатног ручка (енгл. *no free lunch theorem*) [77].

Избор оптималних вредности хиперпараметара од суштинске је важности за квалитет решења добијених моделима машинског учења. С обзиром на већи број хиперпараметара, њихова оптимизација представља NP-тежак задатак оптимизације, који се не исплати решавати традиционалним детерминистичким техникама. Метакхеуристички алгоритми нашли су се у фокусу истраживања последњих година зато што се истичу у решавању таквих задатака захваљујући својој стохастичкој природи. Они су у стању да постигну довољно добра решења за проблеме које је немогуће или непрактично представити и решити експлицитним, детерминистичким алгоритмима [58], [78], [79], уз разуман утрошак рачунарских ресурса и времена. Метакхеуристике су често инспирисане колективном интелигенцијом живих бића (тзв. интелигенцијом ројева, нпр. мрава, пчела и сл.) и другим процесима у природи.

Главни циљ овог истраживања је реализација модела машинског учења за прецизну прогнозу индустријске производње, при чему се хиперпараметри модела оптимизују помоћу метакхеуристичких алгоритама. За валидацију успешности предложеног модела користе се скупови података са фотонапонских електрана, и то метеоролошки подаци прикупљени одговарајућим сензорима, као и подаци о генерисаној електричној енергији. Детаљан преглед стања у области прогнозирања фотонапонске производње, извршен у склопу овог истраживања, између осталог је показао да оптимизацији хиперпараметара помоћу метакхеуристика није посвећено довољно пажње у тој области.

Додатни циљ овог истраживања је модификација неког од постојећих метакхеуристичких алгоритама у циљу постизања боље и ефикасније оптимизације. Осим те нове, модификоване верзије метакхеуристике, користи се и неколико постојећих метакхеуристика, а резултати добијени применом свих тих алгоритама упоређени су помоћу разних метрика. Такође је извршена припрема новог скупа података са фотонапонске електране, који је у самом истраживању коришћен упоредо са јавно доступним скупом података.

У овом истраживању предлаже се употреба мрежа дугог краткорочног памћења (енгл. *Long Short-Term Memory – LSTM*) [122] за прогнозирање снаге фотонапонског система. Пошто LSTM мреже такође захтевају подешавање својих хиперпараметара, за решавање тог задатка предложена је измењена имплементација алгоритма оптимизације роја честица (енгл. *Particle Swarm Optimization – PSO*) [80]. PSO је изабран као основа за нови алгоритам зато што је то позната метакхеуристика која постоји дуже време и коришћена је у широком спектру практичних проблема уз веома обећавајуће резултате [59], [81], [82], [83]. Дизајнирани су модели мале тежине оптимизовани за перформансе и тачност прогнозирања, који могу да раде на исплативим уграђеним (енгл. *embedded*) TinyML платформама, побољшавајући оперативну ефикасност и интеграцију прогнозирања и производње фотонапонске енергије.

Значај овог истраживања је у унапређењу метода прецизног прогнозирања индустријске производње. Развијене нове методе могу да се примене у пракси за допринос побољшању стабилности електроенергетских мрежа, у сврху оптимизације производње фотонапонских електрана, планирања капацитета батеријских система и сл. Нова, побољшана метакхеуристика може бити коришћена у другим сличним истраживањима, али и у свакој другој области у којој се могу применити методе машинског учења. Нови скуп података може бити коришћен за друга слична истраживања у вези са фотонапонским електранама.

Ово истраживање покушава да попуни празнине у постојећој литератури о посматраној области у два аспекта. Најпре, у литератури је уочена недовољна примена метакхеуристика за оптимизацију хиперпараметара при прогнозирању фотонапонске производње. Такође, према прегледу савремене литературе, LSTM модели мале тежине нису довољно испитани за посматрани проблем. Осим тога, део употребљених података није коришћен ни у једном претходном истраживању.

Главно питање којим се бави ово истраживање гласи: да ли је могуће направити метахеуристички алгоритам за оптимизацију хиперпараметара модела машинског учења за прогнозу фотонапонске производње који би унапредио прецизност постојећих метода?

Научни доприноси овог истраживања могу се сумирати на следећи начин:

- Преглед и анализа постојећих модела машинског учења за прогнозирање индустријске производње, а посебно у вези са производњом електричне енергије у фотонапонским електранама.
- Креирање новог скупа података на основу сирових података из индустријске производње, који може бити коришћен и у другим сличним истраживањима.
- Анализа неких од постојећих метахеуристичких алгоритама који се користе за оптимизацију хиперпараметара модела машинског учења.
- Креирање новог, модификованог метахеуристичког алгоритма за оптимизацију хиперпараметара модела машинског учења, који ће довести до бољих резултата и бољих перформанси у решавању посматраног проблема. Нови алгоритам може бити коришћен и у другим областима у којима се примењује машинско учење.
- Унапређење решавања посматраног проблема помоћу модела машинског учења, уз оптимизацију хиперпараметара помоћу разних постојећих и новог метахеуристичког алгоритма и компаративну анализу резултата различитих алгоритама.

Остатак ове тезе организован је на следећи начин. Поглавље 2 садржи теоријске основе. Поглавље 3 даје преглед стања у области прогнозирања фотонапонске производње. Поглавље 4 представља предложену методологију и модификовани алгоритам оптимизације, а затим скупове података и поставке коришћене за спровођење симулација којим је тај алгоритам верификован. Поглавље 5 представља резултате спроведених симулација. Поглавље 6 даје кратке завршне напомене и разматра ограничења овог истраживања, као и потенцијална будућа истраживања.

2 Теоријске основе

У овом поглављу сабране су основне информације о разним областима које су у вези са овим истраживањем: фотонапонском технологијом, метрикама за оцењивање модела, регресионим моделима, машинским учењем, неуронским мрежама, метахеуристичком оптимизацијом, као и истраживачком анализом података.

2.1 Фотонапонска технологија

Производња електричне енергије из сунчевог зрачења могућа је захваљујући фотонапонској технологији, у којој соларни панели, састављени од фотонапонских ћелија, претварају енергију сунчеве светлости у електричну, на основу фотоелектричног ефекта. Будући да зависи од сунчевог зрачења, фотонапонска технологија као извор енергије суочава се са посебним ограничењима. Најпре, производња се прекида током ноћи и у периодима дана када нема довољно сунчевог зрачења. Затим, производња веома зависи од метеоролошких фактора, а јављају се и ситуације сенчења, када облаци или околни објекти блокирају пролаз сунчеве светлости. Упркос таквим ограничењима, једноставност инсталирања система, уважавање имовине на којој је систем инсталиран, брзи повраћај високих почетних улагања и мали утицај на животну средину оправдавају коришћење те технологије. Поред тога, интермитентност фотонапонске енергије може се превазићи применом батеријских система за складиштење произведене енергије. На Сл. 4 приказан је типичан изглед фотонапонског постројења.



Сл. 4: Призор из фотонапонске електране „Топаз” која се налази у Калифорнији [223]


Фотонапонска технологија врши директну конверзију енергије фотона сунчеве светлости у електричну енергију, и тиме омогућава употребу једног од најкористиљивијих обновљивих извора енергије. Главни недостаци те технологије су неизвесност и дисконтинуитет производње, као и за већину обновљивих извора енергије. Чинилац који доноси највише сметњи је облачност, зато што доводи до пада производње електричне енергије, делом због пада сунчевог зрачења, а делом због ограничења соларних панела [197]. С обзиром на такве

проблеме, фотонапонска електрана можда неће моћи да производи електричну енергију непрекидно током целог дана, а то ограничава фактор капацитета (енергија стварно произведена током неког периода, нпр. године, подељена са теоретском енергијом при пуној називној снази непрекидно током истог периода). Штавише, крива производње блиско прати криву сунчевог зрачења.

У наставку овог одељка описане су специфичности сунчевог зрачења, фотоелектрични ефекат, понашање фотонапонских модула, као и неки начини за оквирно предвиђање фотонапонске производње.

2.1.1 Сунчево зрачење

Сунце добија енергију из процеса нуклеарне фузије, при чему се водоник претвара у хелијум, захваљујући реакцији која се зове *протон-протонски ланац*. Та реакција ослобађа невероватну количину енергије која омогућава живот на овој планети обезбеђујући енергију сваком живом бићу. Луминозност, тј. укупна снага зрачења Сунца износи око $3,86 \times 10^{26}$ W. Произведена енергија напушта Сунце као израчена (радијативна) компонента, а мали део је у облику материје (соларни ветар). Регистровани спектар електромагнетног зрачења Сунца приближно је једнак зрачењу црног тела исте температуре, која на површини Сунца износи око 5777 K [224]. Најважнији део соларног спектра је видљива светлост. Када зрачење стигне до површине Земље, одвија се неколико процеса који смањују његов стварни интензитет и мењају спектар који доспева до земље [204].



Сл. 5: Спектар сунчевог зрачења (прилагођено из [224])


На сл. 5 жутом бојом приказан је соларни спектар пре него што стигне у атмосферу, а црвеном спектар измерен на земљи [201], [224]. Главни механизми који утичу на те промене спектра описани су у наставку.

- **Апсорпција** се јавља када фотон удари у честицу. Тај судар доводи до преноса енергије са фотона и долази до промене унутрашње енергије честице. Тај процес одвија се и на самом Сунцу и доводи до формирања тзв. Фраунхоферових линија у Сунчевом спектру (тј. црних линија на одређеним таласним дужинама), због хемијског састава Сунца. Молекули који апсорбују зрачење у Земљиној атмосфери приказани су на слици љубичастом бојом; то су углавном озон (O_3), водена пара и угљен-диоксид. Око 23% долазне енергије зрачења Сунца апсорбује се у атмосфери [202], [230].

- **Расејање** (енгл. *scattering*) представља физички процес при ком се зрачење преусмерава у разним правцима приликом сударања са честицама и молекулима; приликом расејања, електрон погођен фотоном не задржава енергију коју је примио, већ одмах ослобађа нови фотон исте енергије у другом правцу [203]. Део расуте светлости шири се по атмосфери, али део се рефлектује од атмосфере и услед тога губи у свемиру. Око 22% зрачења Сунца

рефлектује се од атмосфере, и још око 7% од тла [202], [230]. Главне врсте расејања су Рејлијево и Мијево.

– *Рејлијево расејање* (енгл. *Rayleigh scattering*) [225] представља расејање електромагнетног зрачења приликом сударања са честицама које су мање од његове таласне дужине. То је процес одговоран за плаву боју неба, пошто плава светлост има најмању таласну дужину и зато се највише расејава [226], [227], [228]. Такође и за црвенкасту боју Сунца на хоризонту, пошто светлост тада мора да прође дужи пут кроз атмосферу и бива више расејана, остављајући црвену (која има највећу таласну дужину и зато се најмање расејава) као главну боју Сунца.



Сл. 6: Биланс енергије сунчевог зрачења на Земљи [230]

– *Мијево расејање* (енгл. *Mie scattering*) [229] јавља се када су честице сличних димензија или веће од таласне дужине зрачења. За разлику од Рејлијевог расејања, приликом Мијевог расејања све боје у видљивом делу спектра расејавају се скоро подједнако. Мијево расејање одговорно је за белу боју облака, зато што се облаци састоје од капљица воде које изазивају тај процес.


Због наведених процеса, енергија зрачења Сунца доступна на површини Земље зависи од дебљине атмосфере, тј. дужине путање зрачења кроз атмосферу (то је тзв. коефицијент ваздушне масе, енгл. *air mass*). Поред тога, постоји зависност од географске локације, надморске висине, доба дана, годишњег доба и индекса ведрога неба. На ово последње утиче пре свега облачност. Облаци имају пресудан утицај на количину светлости доступну на нивоу тла, због свих горе наведених процеса. Остали чиниоци који доприносе губитку енергије зрачења су присуство распршених честица (аеросола), загађеност и влажност. Биланс енергије сунчевог зрачења на Земљи приказан је на Сл. 6.

Интензитет сунчевог зрачења често се изражава помоћу ирадијансе (енгл. *irradiance*), која се дефинише као густина флукса, тј. снага зрачења Сунца по јединици површине, и изражава се у W/m^2 [231]. Зрачење на површини Земље састоји се од три компоненте, а то су директно зрачење или зрачење снопа (енгл. *beam radiation* – G_b), дифузно зрачење (G_d) и рефлектовано зрачење (G_r). Укупно зрачење на површини Земље представља збир те три компоненте:

$$G = G_b + G_d + G_r \quad (1)$$

На Сл. 7 приказана је глобална хоризонтална ирадијација (енгл. *irradiation*), тј. упадна енергија по јединици хоризонталне површине доступна на површини Земље.

Још један чинилац који треба узети у обзир је угао директног упадног зрачења у односу на површину од интереса. Количина енергије зрачења која доспева на површину сразмерна је синусу тог угла. Дакле, у оптималном случају тај угао треба да буде што ближи 90° , тј. површина треба да буде постављена управно у односу на сунчеве зраке.



Сл. 7: Глобална хоризонтална ирадијација [232]

2.1.2 Фотоелектрични ефекат

Фотоелектрични ефекат је физички феномен који омогућава рад соларних ћелија. Када фотон са одговарајућом количином енергије удари у електрон, тај електрон одваја се од свог атома, тј. валентни електрон (електрон у последњем електронском омотачу атома) постаје слободан. Соларна ћелија садржи полупроводне PN спојеве. Слободни електрони бивају привучени на N страну споја, а шупљине (носиоци позитивног набоја) на P страну. Тиме се ствара електрични потенцијал и омогућава електрична струја [233].

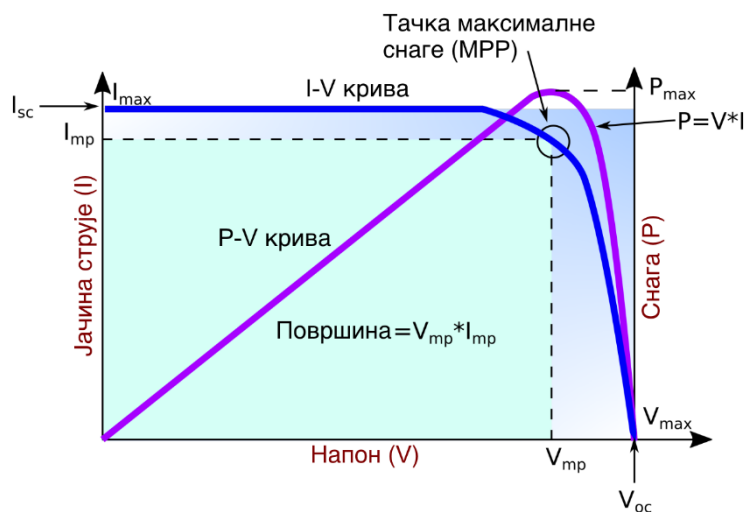
Да би се јавио фотоелектрични ефекат, енергија фотона мора бити већа од енергије потребне да се валентни електрон ослободи. С обзиром на то што је енергија фотона сразмерна његовој фреквенцији, соларна ћелија не може да искористи цео спектар зрачења Сунца, зато што инфрацрвена светлост нема довољно енергије да доведе до ослобађања електрона. Да би се то превазишло, постоје соларне ћелије са додатним слојевима који повећавају искоришћење енергије инфрацрвеног и ултраљубичастог зрачења [200].

Све три претходно описане компоненте сунчевог зрачења стварају фотоелектрични ефекат. Највећи део настаје директним зрачењем, али и дифузно и рефлектовано зрачење могу дати важан допринос. Дифузно зрачење преовлађује у облачним условима, док рефлектовано зависи од рефлективних карактеристика околине која окружује соларну ћелију. С друге стране, не апсорбују се сви фотони који стигну до соларне ћелије; у свим њеним слојевима, део фотона се рефлектује.


Количина произведене електричне енергије директно зависи од количине сунчевог зрачења које стиже до соларне ћелије, тј. директно је пропорционална ирадијанси. На Сл. 8 приказана је фотоелектрична карактеристика соларне ћелије, тј. зависност струје од напона (тзв. I-V крива) и снаге од напона (тзв. P-V крива) [198], [234]. При томе су:

- I_{max} – максимална струја,
- I_{SC} – струја кратког споја (енгл. *Short Circuit* – SC),
- I_{mp} – струја у тачки максималне снаге (енгл. *Maximum Power Point* – MPP),
- V_{max} – максимални напон,

- V_{OC} – напон отвореног кола (енгл. *Open Circuit* – OC),
- V_{mp} – напон у тачки максималне снаге,
- P_{max} – максимална снага.



Сл. 8: Фотоелектрична карактеристика соларне ћелије (прилагођено из [234])



Сл. 9: Соларне ћелије, модули, панели и низови (прилагођено из [235])

Фотонапонски систем састоји се од већег броја ћелија повезаних у модуле. Модули се спајају у панеле, а панели у низове (енгл. *string*, Сл. 9). Редним везивањем елемената повећава се напон, а паралелним јачина струје. У оквиру модула најчешће се користи и редно и паралелно везивање. Панели у низу најчешће су спојени редно, а низови паралелно.

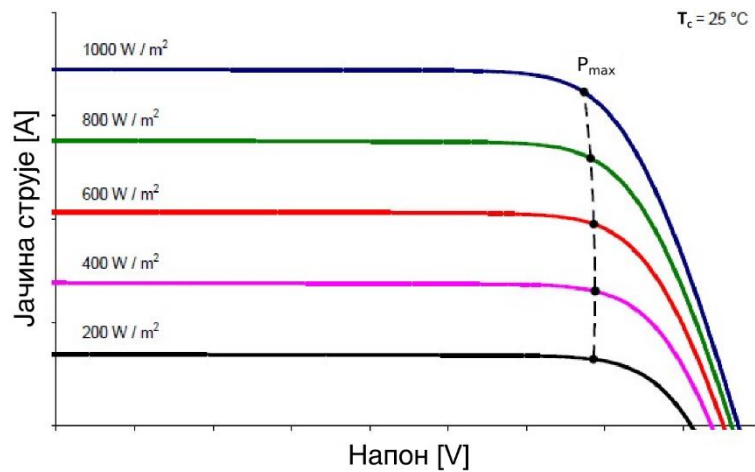
2.1.3 Понашање фотонапонских модула

Електрична снага коју производе фотонапонски системи повезана је са ирадијансом и са температуром амбијента (која утиче на температуру модула), али и са електричним оптерећењем прикљученим на постројење. У фотонапонским системима користе се алгоритми и уређаји за тражење тачке максималне снаге (енгл. *Maximum Power Point Tracker* – MPPT) да би се пронашла тачка у фотонапонској карактеристици где струја и напон омогућавају производњу максималне могуће снаге у датим условима околине [199], [236].

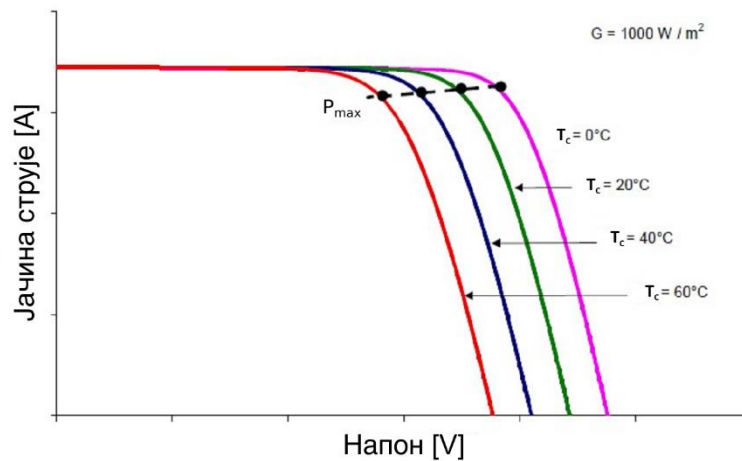
На сл. 10 приказано је да са смањивањем ирадијансе вредност произведене струје опада пропорционално док напон остаје скоро константан. С друге стране, како температура модула расте, напон се смањује (Сл. 11), а самим тим и произведена снага опада. При томе су:

- T_c – температура модула,

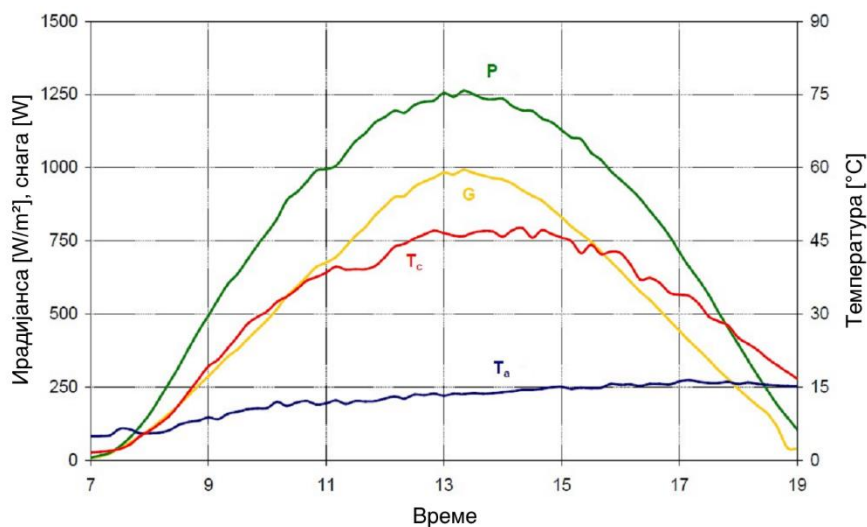
- P_{max} – максимална снага,
- G – ирадијанса.



Сл. 10: Зависност струје и напона у фотонапонском систему од ирадијансе (прилагођено из [199])

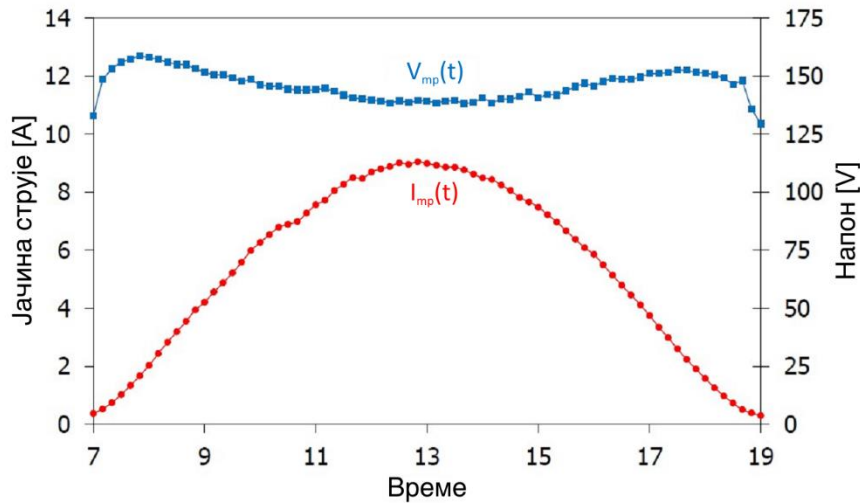


Сл. 11: Зависност струје и напона у фотонапонском систему од температуре модула (прилагођено из [199])



Сл. 12: Тренд најважнијих параметара у фотонапонском систему током дана (прилагођено из [199])

На сл. 12 приказани су трендови најважнијих карактеристика фотонапонског система током дана, при чему је T_a температура амбијента. Јасно је видљива зависност произведене снаге и температуре модула од ирадијансе. Мењање произведеног напона и струје током дана приказано је на сл. 13. При томе су I_{mp} и V_{mp} струја и напон у тачки максималне снаге, респективно. С обзиром на то што се снага процењује на основу тренутних вредности напона и струје, треба приметити да на струју највише утиче ирадијанса, а на напон температура модула.



сл. 13: Тренд напона и струје у фотонапонском систему током дана (прилагођено из [199])

2.1.4 Предвиђање фотонапонске производње

За оквирну процену перформанси фотонапонских система могу се користити поједностављени физички модели засновани на релативно једноставним математичким једначинама, као што је једначина (2), која омогућава процењивање излазне снаге фотонапонског модула (или ћелије) [199].

$$P_m(G, T_c) = P_M(STC) \cdot G \cdot (1 + \lambda_{pm} \cdot \Delta T_c) \quad (2)$$

При томе су:

- P_m – излазна снага модула,
- G – ирадијанса,
- T_c – температура модула,
- $P_M(STC)$ – називна снага модула при стандардним условима испитивања (енгл. *Standard Test Conditions* – STC), тј. при температури модула T_{cSTC} (најчешће 25°C) и ирадијанси G_{STC} (најчешће 1000 W/m^2),
- λ_{pm} – топлотни коефицијент максималне снаге,
- ΔT_c – разлика између температуре модула и T_{cSTC} .

Ако се као променљиве користе само метеоролошки подаци, температура модула може се проценити на основу ирадијансе и температуре амбијента помоћу једначине (3) [235].

$$T_c = T_a + \frac{NOCT - 20^\circ\text{C}}{800 \frac{\text{W}}{\text{m}^2}} G \quad (3)$$

При томе су:

- T_c – температура модула,
- T_a – температура ваздуха,
- $NOCT$ – номинална радна температура модула (енгл. *Nominal Operating Cell Temperature*), тј. температура модула при ирадијанси 800 W/m^2 , температури амбијента 20°C , брзини ветра 1 m/s и нагибу модула 45° [237], и
- G – ирадијанса.

Коришћење физичких модела у пракси није тако једноставно, због тога што се поред ирадијансе морају узети у обзир и температура модула и електрични параметри. Наведене поједностављене једначине не дају довољно добре процене у свим ситуацијама. Већина физичких модела много зависи од тренутних оперативних услова фотонапонског система, метеоролошких параметара и карактеристика окружења на локацији на којој се систем налази (нпр. осенчење од стране околних објеката), што се не може унапред предвидети већ захтева додатне прилагођене процене.

Међутим, излазна снага фотонапонског система такође се може предвидети статистичким методама и методама машинског учења (ML). Различите статистичке и ML методе користе се за прогнозирање рада фотонапонског система, као нпр. линеарне регресије, машине вектора подршке (енгл. *Support Vector Machine – SVM*), ауторегресивни покретни просеци (енгл. *AutoRegressive Moving Average – ARMA*), регресиона стабла (енгл. *Regression Trees*), неуронске мреже, итд. У сваком случају, и за те методе неопходно је имати одговарајућу количину историјских података, нпр. измерене вредности ирадијансе.

Осим укупне ирадијансе, могле би бити од интереса и вредности три њене претходно описане компоненте засебно. Нпр. вредности директне и рефлектоване ирадијансе потребне су да би се ухватиле варијације облачности током одређеног периода. Други параметри које би требало пратити су произведена струја и напон, спољна температура, итд. На основу историјских података који омогућавају обуку модела, могу се користити методе засноване на машинском учењу. Након обуке модела, могуће је на основу временске прогнозе предвидети са задовољавајућом прецизношћу излазну снагу модула за кратке и дуже временске периоде [190].

2.2 Метрике за оцењивање модела

Постоје разне функције које се користе за процену да ли је модел био успешан у предвиђању података, укључујући коефицијент детерминације (R^2), средњу квадратну грешку (MSE) и корен средње квадратне грешке (RMSE). У овом одељку описано је неколико најчешћих метрика, а додатне информације могу се наћи у одељцима 3.3.13 и 3.3.14. Описи тих функција дати су пре описа самих модела зато што се неке од њих користе при оптимизацији модела.

2.2.1 Коефицијент детерминације (R^2)

Коефицијент детерминације (R^2) показује који проценат варијансе излазних података је објашњен моделом, тј. за који део података је модел дао тачно предвиђање. Нема димензију. Тај коефицијент такође показује колико је креирани модел бољи у односу на тривијалан основни модел који увек враћа средњу вредност стварних података, зато што је за тај модел коефицијент детерминације једнак нули.

Вредност коефицијента детерминације најчешће је у опсегу од 0 до 1, а негативна вредност тог коефицијента показује да је модел лошији од основног. На пример, коефицијент детерминације једнак 0,87 значи да је модел успешно предвидео 87% варијансе излазних података. Тај коефицијент једнак је 1 за „савршен” модел, тј. модел који је за све податке дао тачно предвиђање.

Коефицијент детерминације може се израчунати помоћу једначине (4), где су y_i стварне (измерене) вредности, \hat{y}_i предвиђене (прогнозиране) вредности, \bar{y} средња вредност (аритметичка средина стварних вредности), а n број узорака. Сума у бројиоцу назива се сума квадрата остатака (енгл. *residual sum of squares* – SS_{res}), а у имениоцу укупна сума квадрата (енгл. *total sum of squares* – SS_{tot}).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{SS_{res}}{SS_{tot}} \quad (4)$$

У неким случајевима коефицијент детерминације једнак је квадрату Пирсоновог коефицијента корелације између уочених и прогнозираних вредности излазне променљиве, или између улазне и излазне променљиве. То не треба мешати са коефицијентом корелације између две улазне променљиве.

Проблем са коефицијентом детерминације је што се никад не смањује ако се нова променљива дода у модел, чак и ако је та променљива ирелевантна за прогнозирање излазних података. Зато се понекад користи прилагођени коефицијент детерминације (енгл. *adjusted R^2* , тј. R_{adj}^2), дизајниран тако да се смањује при додавању ирелевантних променљивих. Прилагођени коефицијент детерминације увек је мањи или једнак R^2 , и може се израчунати помоћу једначине (5).

$$R_{adj}^2 = 1 - \frac{SS_{res}/df_{res}}{SS_{tot}/df_{tot}} = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad (5)$$

У тој једначини, $df_{res} = n - p - 1$ назива се број степени слободе остатака (тј. број вредности које се могу слободно мењати у процени варијансе популације у односу на прогнозиране вредности), $df_{tot} = n - 1$ је укупан број степени слободе (тј. број вредности које се могу слободно мењати у процени варијансе популације у односу на средњу вредност), n је број узорака (тј. укупан број опсервација у скупу података) а p број независних променљивих у моделу [145], [165], [166].

2.2.2 Средња квадратна грешка (MSE) и корен средње квадратне грешке (RMSE)

Средња квадратна грешка (енгл. *Mean Square Error* – MSE) и корен средње квадратне грешке (енгл. *Root Mean Square Error* – RMSE) спадају у најчешће метрике и користе се за мерење тачности модела примењених у разноврсним областима, од метеорологије до превиђања индустријске производње [118], [190]. Употреба тих метрика прикладна је у случајевима када је расподела грешака слична нормалној (Гаусовој) расподели. Што је нижа вредност тих метрика, то је предвиђање модела боље.

MSE представља средњу вредност квадрата разлика између измерених и прогнозираних вредности, према једначини (6). RMSE представља корен из MSE, да би метрика имала исту димензију као мерена величина, и дата је у једначини (7).

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (6)$$

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (7)$$

У пракси, поређење модела помоћу MSE или RMSE доводи до истог резултата, пошто вредност која минимизује неку функцију такође минимизује њен квадратни корен [119].

2.2.3 Друге метрике

Следеће метрике такође се релативно често користе: средња апсолутна грешка (енгл. *Mean Absolute Error* – MAE, једначина (8)), средња апсолутна процентуална грешка (енгл. *Mean Absolute Percentage Error* – MAPE, једначина (9)), као и средња грешка пристрасности (енгл. *Mean Bias Error* – MBE, једначина (10)). У овом истраживању коришћен је и индекс слагања (енгл. *Index of Agreement* – IoA) [114], представљен једначином (11).

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (9)$$

$$\text{MBE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i) \quad (10)$$

$$\text{IoA} = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (|y_i - \bar{y}| + |y_i - \hat{y}_i|)^2} \quad (11)$$

У наведеним једначинама, y_i и \hat{y}_i одговарају стварним и прогнозираним вредностима i -тог узорка, респективно, \bar{y} је средња вредност, док n представља број узорака.

2.3 Регресиони модели

Регресиони модели, поред тога што се и сами користе за прогнозирање на основу серија података, представљају једну од математичких основа за вештачке неуронске мреже. Стога је у овом одељку описана најпре линеарна, а затим и полиномска регресија.

2.3.1 Линеарна регресија

Линеарна регресија је статистички модел који користи тзв. линеарну хипотезу за уопштenu процену серије података, тј. претпоставља да је однос улаза и излаза линеаран. За ту процену, модел линеарне регресије рачуна пондерисани збир улазних вредности (тзв. линеарну комбинацију), према једначини (12). При томе је $\hat{y}^{(i)}$ предвиђена вредност i -тог узорка, n је број улазних атрибута (n одређује димензију улазног простора), $x_j^{(i)}$ је j -ти улазни атрибут i -тог узорка, w_j је j -ти угаони коефицијент (тежина) модела, а b представља линеарни коефицијент модела (тзв. отклон, енгл. *bias*) [119], [151].

$$\hat{y}^{(i)} = b + w_1 x_1^{(i)} + w_2 x_2^{(i)} + \dots + w_n x_n^{(i)} \quad (12)$$

$$\hat{y}^{(i)} = w_0 + [w_1 \dots w_n] \cdot \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}^{(i)} = b + \mathbf{w}^T \mathbf{x}^{(i)} \quad (13)$$

Једначина (13) даје векторску нотацију линеарне регресије. При томе је $b = w_0$, $\mathbf{w}^T = [w_1 \dots w_n]$ и $\mathbf{x}^{(i)T} = [x_1 \dots x_n]^{(i)}$, а T у експоненту означава транспоновани вектор или матрицу.

Једначина (13) може се поједноставити додавањем константне улазне вредности $x_0 = 1$. Тада се улазни атрибути могу представити као $\mathbf{x}^{(i)T} = [1 \ x_1 \dots x_n]^{(i)}$, а тежине модела као $\mathbf{w}^T = [w_0 \ w_1 \dots w_n]$. Захваљујући томе, једначина (13) може се претворити у једначину (14):

$$\hat{y}^{(i)} = \mathbf{w}^T \mathbf{x}^{(i)} \quad (14)$$

Функција трошка $J(\mathbf{w})$ приказана је у једначини (15); у том примеру, као функција трошка користи се средња квадратна грешка (MSE) између предвиђених вредности $\hat{y}^{(i)}$ и стварних вредности $y^{(i)}$. Минимизовањем функције трошка могу се израчунати оптималне вредности тежина. При томе m представља број инстанци, тј. укупан број узорака у скупу за обуку.

$$J(\mathbf{w}) = \frac{1}{m} \sum_{i=1}^m (\hat{y}^{(i)} - y^{(i)})^2 = \frac{1}{m} \sum_{i=1}^m (\mathbf{w}^T \mathbf{x}^{(i)} - y^{(i)})^2 \quad (15)$$

Да би се израчунала вредност \mathbf{w} која минимизује функцију трошка $J(\mathbf{w})$, означена са \mathbf{w}_{opt} , потребно је пронаћи нулту вредност извода функције трошка: $\frac{\partial J(\mathbf{w})}{\partial w_j} = 0$. Та процедура

позната је као метод најмањих квадрата (енгл. *ordinary least squares* – обични најмањи квадрати), а њено решење представљено је једначином (16), која се назива нормална једначина [119]. Та једначина пружа одличне резултате за малу количину података, пошто инверзија матрица у једначини (означена са -1 у експоненту) захтева велику рачунарску снагу.

$$\mathbf{w}_{\text{opt}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} \quad (16)$$

При томе је \mathbf{X} матрица улазних података, тј. матрица која садржи вредности свих атрибута за све инстанце улазних података, а \mathbf{y} матрица излазних података, која садржи све инстанце излазних података у скупу за обуку.

За линеарну регресију која користи само једну улазну променљиву (просту линеарну регресију), излаз је једноставна права линија, док се за линеарну регресију која користи више улазних променљивих (вишеструку линеарну регресију) добија хиперраван у n -димензионалном простору података, где је n број улазних променљивих [120].

2.3.2 Полиномска регресија

У већини посматраних проблема не може се линеарном релацијом описати нелинеарни однос улаза и излаза. Линеарна регресија уз коришћење полиномски трансформисаних атрибута може бити добар избор у таквим ситуацијама. Основна идеја тог приступа је да се било која крива може апроксимирати помоћу основних функција (као што је нпр. полином), све док се не пронађе одговарајућа основна функција која на задовољавајући начин карактерише криву

података од интереса. Избор добрих атрибута или трансформација атрибута је проблем инжењеринга обележја (енгл. *feature engineering*), који у великој мери зависи од истраживачке анализе података.

Полиномска регресија је посебан случај линеарне регресије са више променљивих. При томе се свака улазна променљива трансформише полиномом степена p , као што је приказано у једначини (17).

$$\varphi(x, p) = \begin{bmatrix} 1 & x_1 & x_1^2 & \dots & x_1^p \\ 1 & x_2 & x_2^2 & \dots & x_2^p \\ 1 & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^p \end{bmatrix} = \begin{bmatrix} \varphi_1(x, p) \\ \varphi_2(x, p) \\ \vdots \\ \varphi_n(x, p) \end{bmatrix} \quad (17)$$

Улазни атрибути могу се уопштено представити као $x_j = \varphi_j(x, p)$. Сходно томе, полиномска регресија (линеарна регресија са трансформацијом атрибута полиномом степена p) описана је једначином (18).

$$\hat{y} = w_1\varphi_1(x, p) + w_2\varphi_2(x, p) + \dots + w_n\varphi_n(x, p) \quad (18)$$

Чак и ако садржи нелинеарне чланове, модел полиномске регресије и даље се сматра линеарним моделом, пошто је линеаран у односу на тежине \mathbf{w} с обзиром на њихове одговарајуће базне функције $\varphi_j(x, p)$ [124].

2.4 Машинско учење

Вештачка интелигенција (енгл. *Artificial Intelligence* – AI) као научна област формално постоји од 1956. године. Током наредних деценија постала је популарна у покушајима решавања разних проблема, нпр. кроз експертске системе, који су на основу логичких правила покушавали да репродукују доношење одлука професионалаца у одређеним областима знања. Међутим, шира практична примена вештачке интелигенције почела је тек када су побољшања перформанси рачунарских система и хардвера за дигиталну обраду сигнала омогућила да се теоријска достигнућа спроводе у пракси. Отприлике од 2010. године почиње период њеног наглог развоја и широке распрострањености, а решавање све сложенијих проблема коришћењем вештачке интелигенције постало је уобичајено [136], [180].

Напредак технологија за прикупљање, складиштење и обраду података, као и пораст броја радника обучених за коришћење дигиталних технологија (иако још увек недовољан), омогућили су компанијама да усвоје вештачку интелигенцију за примену у различитим секторима свог пословања.

Машинско учење (енгл. *Machine Learning* – ML) је грана вештачке интелигенције која тренутно представља главни правац истраживања у тој области и све више се примењује у индустрији. По општој дефиницији, ако се перформансе програма побољшавају при извршавању неког задатка, каже се да програм учи на основу искуства стеченог извршавањем тог задатка. Неке од бројних примена машинског учења су нпр. препознавање нежељене електронске поште (енгл. *spam e-mail*), генерисање аутоматских титлова у видео снимцима на YouTube-у, препознавање лица и/или гласа, разврставање слика, итд. [136].

Машинско учење инспирисано је механизмима учења живог бића, где стечена искуства воде до знања. У класичном програмирању унапред се дефинишу поступци, тј. алгоритми или правила, и на основу улазних података програм који ради по задатом поступку као резултате

даје решења. Уместо тога, у машинском учењу, на основу улазних података програм као резултате даје поступке помоћу којих се из тих података добијају конкретна решења.


Штавише, машина не мора бити програмирана за конкретан проблем, већ мора бити обучена улазним подацима. Обука је срце машинског учења. Делимично се заснива на статистичким методама, али је вођена подацима. При машинском учењу најчешће се барата са огромном количином података који су типично хетерогени. Зато је веома важна припрема података, која се састоји од три главне фазе: прикупљања, организовања и чишћења података. Тек након процеса припреме, подаци се могу употребити за машинско учење [181].

У наставку овог одељка описане су врсте примена машинског учења, као и основне врсте машинског учења.

2.4.1 Врсте примена машинског учења

Примене машинског учења могу се у грубим цртама поделити на три главне врсте: класификацију, груписање и регресију (сл. 14) [206].

Класификација се врши када нове елементе треба придружити већ постојећим групама. Алгоритми који се најчешће користе за такве примене су стабла одлучивања (енгл. *Decision Trees* – DT), вештачке неуронске мреже (енгл. *Artificial Neural Networks* – ANN) и k -најближих суседа (енгл. *k-Nearest Neighbors* – kNN).



Сл. 14: Врсте примена машинског учења (прилагођено из [206])


Груписање (енгл. *clustering*) се може применити када се подаци могу поделити и груписати према својим атрибутима. За разлику од класификације, класе нису унапред задате, али програм мора да буде у стању да идентификује да ли су подаци слични једни другима и на крају их групише заједно. Најкоришћенији алгоритми за такве примене су груписање k -средњих вредности (енгл. *k-Means Clustering*), груписање са померањем средње вредности (енгл. *Mean-Shift Clustering*) и агломеративно хијерархијско груписање (енгл. *Agglomerative Hierarchical Clustering*).

Регресија се заснива на одређивању функција (на слици представљених линијама) које најбоље одговарају улазним подацима, тј. најбоље их описују. Може да ради са једноставним или вишеструким моделима, који имају више од једног обележја, и са линеарним или нелинеарним моделима. За такве примене, неки од најважнијих алгоритама су регресија стабла одлучивања (енгл. *Decision Tree Regression*), регресија случајне шуме (енгл. *Random Forest Regression*) и вештачке неуронске мреже.

2.4.2 Врсте машинског учења


Две главне врсте машинског учења су надгледано и ненадгледано учење, а треба истаћи и учење поткрепљивањем.

Надгледано учење или учење под надзором (енгл. *supervised learning*, сл. 15) [184] типично се користи за предиктивне активности. То су активности код којих на основу улазних атрибута треба предвидети циљне атрибуте; на пример, треба предвидети износ рачуна за енергију за наредних неколико месеци, на основу историје потрошње енергије у стану. У ту врсту спада и примена машинског учења на проблем који се истражује у овом раду, тј. предвиђање производње електричне енергије у фотонапонском систему. Та врста учења углавном се користи за проблеме класификације и регресије.



сл. 15: Шема учења под надзором (прилагођено из [184])

Процес се састоји од две фазе, *обуке* и *предвиђања*. Обука представља најважнији део процеса, зато што је то фаза у којој се модел креира и обучава скупом података. Улаз у фази обуке је такозвани *скуп података за обуку* (енгл. *training dataset*), који се састоји од улазних и излазних података. Након што је модел добро обучен, може се применити фаза предвиђања, у којој се нови скуп улазних података уноси у модел, који на основу тих података даје жељени излаз. На пример, та врста учења користи се за препознавање слика: велика количина слика уноси се у програм са објашњењем шта свака од њих значи, а након што је модел обучен, може нове слике које су у вези са оним које је „видео” током обуке да класификује према претходно дефинисаним особинама. Друге могуће примене су нпр. предвиђање цене акција на тржишту, метеоролошка предвиђања, итд.




сл. 16: Шема учења без надзора (прилагођено из [184])

Ненадгледано учење или учење без надзора (енгл. *unsupervised learning*, сл. 16) [184] типично се користи за дескриптивне активности, тј. активности код којих програм открива односе и шаблоне у неозначеним подацима, покушава да их групише и сл., и тиме описује те податке

на нове начине. Дакле, обично се примењује за проблеме груписања, када постоје подаци који нису означени, а треба их груписати. На програму је да „разуме” образац који стоји иза података, тако да је људска интервенција, у том случају, ограничена. Неки од примера су откривање превара са кредитним картицама или нежељене е-поште, примене у анализи друштвених мрежа, класификација купаца у маркетингу и сл. [137], [138].

Још један пример примене је препознавање болести, попут тумора, при чему се неозначене слике шаљу моделу а он сам учи да ли, на пример, особа може имати рак плућа. Тај тип учења назива се полунадгледано учење (енгл. *semi-supervised learning*) и представља мешавину учења без надзора и учења са надзором. Полунадгледано учење захтева означавање дела података, што помаже програму да пронађе образац неозначених података.

Учење поткрепљивањем или учење уз подстицај (енгл. *reinforcement learning*, сл. 17) [184] слично је учењу без надзора по томе што необрађени подаци нису означени, али процес је другачији. Помоћу петље, тј. повратне спреге, агент је вођен повратним информацијама од окружења у ком се налази. Те повратне информације су позитивне или негативне, на основу система евалуације. Та врста учења углавном се користи за регресију, нпр. у роботички, аутомобилима без возача и сл.



сл. 17: Шема учења поткрепљивањем (прилагођено из [184])

2.5 Неуронске мреже

Концепт вештачке неуронске мреже, као што се може закључити из имена, потиче од архитектуре и функционисања неуронске мреже људског мозга. Људски мозак изузетно је компликован и представља огромну неуронску мрежу – процењује се да у људском мозгу постоји око 85 милијарди неурона [115], [182]. Сваки неурон повезан је са хиљадама других неурона преко веза званих синапсе, тако да постоје милиони милијарди веза.

Вештачке неуронске мреже покушавају да опонашају људски мозак; оне нису алгоритми који су ограничени на обављање одређених задатака, као што је нпр. играње шаха, извођење математичких прорачуна или аутоматизација неке мануелне активности. Тачно је да људски мозак може да обавља и такве активности. Међутим, примера ради, када се видео-игрица игра по први пут, мозак препознаје шта треба да се уради путем покушаја и грешака, препознаје обрасце, учи да лик треба нпр. да скочи у одређено време и сл. Тиме стиче знање које резултира решењем, а то је да се игрица игра на начин који је неопходан за успешан завршетак.

Слично мозгу, вештачка неуронска мрежа заснива се на улазима на основу којих стиче знање. Обликујући информације тежинама, развија се аутономно, учи да игра игру самостално, да прави предвиђања према обрасцима и математичким прорачунима, класификује објекте, препознаје обрасце на сликама, између осталих примена.

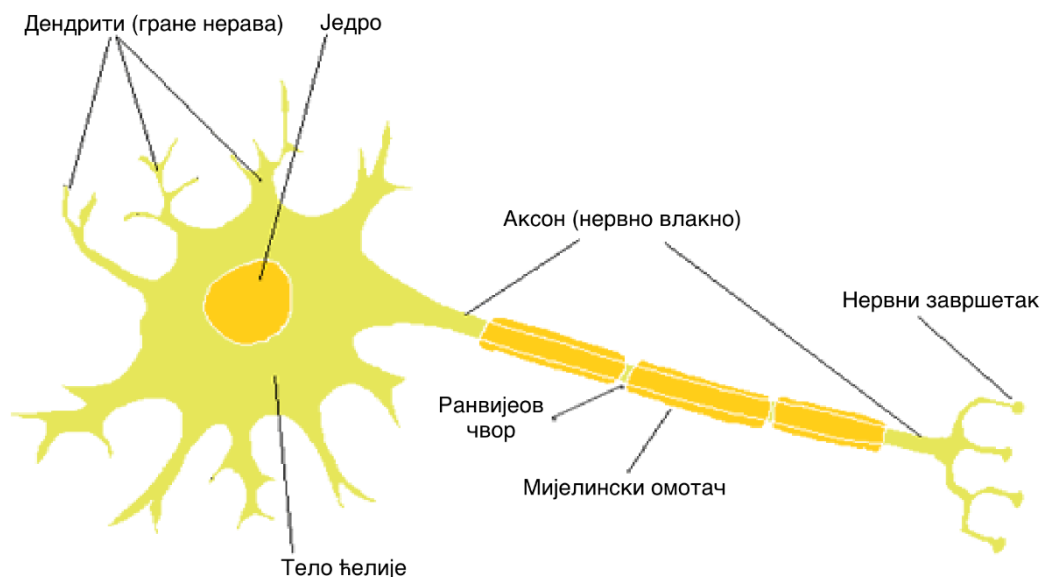
Неуронске мреже покушавају да имитирају пренос информација који се догађа у људском мозгу приликом обављања одређених задатака. Ради тога, везе између неурона које постоје у мозгу апроксимирају се моделима неуронских мрежа, чувајући информације и учећи из њих. По једној дефиницији, неуронска мрежа је масовно паралелно дистрибуирани процесор састављен од једноставних процесних јединица, које имају способност да складиште експериментално знање и учине га доступним за употребу. Неуронска мрежа подсећа на мозак у два аспекта: мрежа стиче знање из свог окружења кроз процес учења, и јачине веза између неурона (познате као синаптичке тежине) користе се за складиштење стеченог знања.

Добро дизајнирана неуронска мрежа има велики капацитет генерализације. Другим речима, могу се добити задовољавајући резултати и када мрежа ради са подацима који нису „виђени” у фази обуке, тј. када се улазни подаци разликују од оних помоћу којих је неуронска мрежа обучавана, што најчешће јесте случај [121].

Занимљиво је најпре укратко описати како функционише нервна ћелија у живом организму, тј. биолошки неурон, пре описа опште структуре вештачке неуронске мреже и функционисања вештачког неурона. Затим су описане специфичности вештачких неуронских мрежа: функције активације, процес обуке, основне врсте вештачких неуронских мрежа, као и процес припреме података и креирања модела.

2.5.1 Биолошки неурон

Неурони врше обраду информација у нервном систему. Трајање неуронских догађаја у мозгу је реда величине милисекунди, што значи да су биолошки неурони око 5 до 6 редова величине спорији од силицијумских логичких капија, којима је за комуникацију потребно време реда величине наносекунди [121]. Мању брзину биолошких неурона компензује огроман број веза између њих.



Сл. 18: Основне компоненте биолошког неурона (прилагођено из [127])


Основни делови типичног неурона приказани су на сл. 18. Централни део неурона назива се тело ћелије, сома или перикарион, а из њега излази неколико веза налик танким цевима – аксон и дендрити. Аксон је дужи од дендрита и представља линију за пренос података – кроз аксон се нервни импулси спроводе од тела ћелије до следећег неурона. Аксон је на крају разгранат, завршава се тзв. аксонским терминалима. Дендрити су много мањи од аксона, њихова основна улога је да примају стимулусе и спроводе их до тела ћелије. Нервни завршеци су мала проширења у облику чворића на крајевима неурона. Нервни завршеци формирају синапсе, тј. везе са суседним неуронима [115], [127].

Комуникација између неурона одвија се кроз синапсе, које служе за преношење информација другим неуронима, а по начину преношења информација могу бити електричне или хемијске. Синапсе најчешће представљају везе аксона једног неурона са дендритима другог, мада се могу формирати и између аксона и тела ћелије, два аксона, а понекад чак и два дендрита. Информације из синапси обрађују се у телу ћелије и преносе следећем неурону дуж аксона (трансмисионе линије). Већина синапси у људском мозгу су хемијске. Хемијске синапсе у великој већини случајева су једносмерне, а све електричне синапсе су двосмерне [115], [127].

2.5.2 Општа структура вештачке неуронске мреже

Вештачка неуронска мрежа састављена је од извесног броја неурона, који су међусобно повезани синаптичким везама којима су додељене тежине. Тежине могу да попримају позитивне или негативне вредности које се прилагођавају током процеса учења, кодирајући тиме знање које мрежа стиче, и утичући на тачност резултата добијених коришћењем неуронске мреже [121], [139].

Неурони у мрежи распоређени су у слојеве. Постоје различите врсте слојева за различите примене. Најчешће, сваки неурон повезан је са свим неуронима у суседним слојевима. Типична вишеслојна вештачка неуронска мрежа (сл. 19) састоји се од улазног слоја, излазног слоја и неколико међуслојева, који се називају скривени слојеви. Улазни сигнали (атрибути) доводе се на пријемне јединице (сензоре, улазне чворове) у улазном слоју. Улазни подаци могу бити представљени вектором или матрицом. Излази пријемних јединица повезани су са неуронима у првом скривеном слоју, итд. То може бити поновљено више пута, тј. може бити онолико скривених слојева колико је потребно [121].




Сл. 19: Пример типичне вишеслојне вештачке неуронске мреже [121]

Коначно, постоји излазни слој који може бити састављен од једног или више неурона, у зависности од потребног броја излазних вредности. Нпр. ако се мрежа користи за проблем предвиђања једне вредности, излазни слој састоји се од само једног неурона, чији излаз ће бити предвиђена вредност [119], [121]. Сваки неурон у слоју ступа у интеракцију са суседним неуронима преко синапси и јединица које извршавају функције преноса и активације [187].

2.5.3 Вештачки неурон

Вештачки неурон не може да понови сложеност правог неурона; међутим, он је у математичком смислу најближи симулацији процеса учења. На сл. 20 приказан је типичан модел вештачког неурона. Сабирни чвор (енгл. *summing junction*) израчунава функцију преноса (енгл. *transfer function*), тј. сабира улазне сигнале (x_j) помножене синаптичким тежинама веза (w_{kj} , од енгл. *weight*), као и отклон (b_k , од енгл. *bias*). Тежина или тежински

коэффициент показује важност одређене везе, а самим тим и важност одговарајућег обележја. Према томе, ниска вредност или нулта вредност тежине значи да је одређено обележје мање важно или неважно. Отклон или пристрасност је коэффициент који омогућава модификовање, тј. повећавање или смањивање функције преноса у циљу брже конвергенције [121], [207], [208].




Сл. 20: Модел вештачког неурона [121]

Општи облик функције преноса дат је у једначини (19). На резултат функције преноса (v_k) примењује се функција активације φ , што је приказано у једначини (20). Функција активације игра кључну улогу у вештачкој неуронској мрежи, зато што потенцијално уводи нелинеарност у мрежу и тиме омогућава неуронским мрежама да моделирају сложене нелинеарне обрасце који се не могу приказати једноставним моделима [123], [191]. Уједно може ограничавати амплитуду излазног сигнала неурона.

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \tag{19}$$

$$y_k = \varphi(v_k) \tag{20}$$

При томе је m укупан број улаза, а k ознака неурона. Једначина (19) може се поједноставити по узору на поједностављену нотацију модела линеарне регресије дату у једначини (14). У том циљу, додаје се нова синапса са индексом 0, чији је тежински коэффициент једнак отклону ($w_{k0} = b_k$), а одговарајући улаз је 1 ($x_0 = 1$). Тада се модел неурона може представити једначинама (21) и (20) и приказати на Сл. 21 [121].



Сл. 21: Алтернативни модел вештачког неурона [121]

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (21)$$


2.5.4 Функције активације

Функције активације одређују да ли неурон треба да се активира (и тако сачува његова вредност) или не, у складу са одговарајућим тежинама, тј. значајем за модел. Постоје разне функције активације, које се могу поделити у неколико врста. У овом одељку описано је неколико најчешћих, а додатни детаљи могу се наћи у одељку 3.3.16.

Најједноставнија функција активације је линеарна активација код које су улаз и излаз једнаки. То захтева најниже могуће рачунске трошкове у поређењу са нелинеарним функцијама, али би ограничило способност модела да се генерализује што је више могуће. У наставку су описане најчешће функције активације.

Сигмоидна функција је, уопштено говорећи, свака математичка функција чији је графикон у облику тзв. сигмоидне криве, тј. искошеног латиничног слова S [209]. У контексту вештачких неуронских мрежа, под тим називом најчешће се подразумева тзв. логистичка функција, представљена једначином (22) и приказана на сл. 22 [180].

$$\text{logistic}(x) = \frac{1}{1 + e^{-x}} \quad (22)$$



сл. 22: Логистичка функција (прилагођено из [180])

Општи облик логистичке функције, дат у једначини (23), садржи и параметар a који одређује нагиб функције. Што је већа вредност тог параметра, то је стрмији нагиб криве у околини нуле [121].


$$\text{logistic}(x) = \frac{1}{1 + e^{-ax}} \quad (23)$$

Сигмоидне функције су униформно растуће и одликују се равнотежом између линеарног и нелинеарног понашања. Важно је напоменути да су сигмоидне функције диференцијабилне. Та особина веома је важна за теорију неуронских мрежа, зато што омогућава прилагођавање тежина синапси коришћењем парцијалних деривација.

Логистичка функција традиционално је била најчешћа функција активације, али у новије време користи се мање него у прошлости. Опсег вредности резултата те функције је $(0, 1)$, тј. за мале вредности улаза логистичка функција враћа вредности близу 0, а за велике вредности резултат је близу 1 [183]. Међутим, за мале или велике вредности улаза то узрокује проблем који се назива *нестајући градијент* (енгл. *vanishing gradient*). Због тог проблема модел више не може да учи или постаје веома спор, са високим рачунским трошковима.

Функција \tanh (хиперболички тангенс) представљена је једначином (24) и приказана на сл. 23.

$$\tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (24)$$



сл. 23: Функција \tanh (прилагођено из [180])

Опсег вредности резултата је $(-1, 1)$. Функција \tanh такође спада у групу сигмоидних функција, тј. даје криву у облику латиничног слова S. Стога, она има исте недостатке као логистичка функција, али и предност што олакшава моделирање улаза са великим негативним или позитивним вредностима.

Функција softmax, позната и као нормализована експоненцијална функција, претвара нумерички низ у дистрибуцију вероватноћа [61]. Представља генерализацију описане логистичке функције за више димензија. За разлику од свих осталих функција споменутих у овом одељку, softmax је мултиваријантна функција – она узима вектор улаза и враћа вектор вероватноћа, при чему су вредности резултата нормализоване у опсег $(0, 1)$ и збир свих вредности износи 1. Функција softmax представљена је једначином (25). На сваки елемент улазног низа примењује се експоненцијална функција, и дели збиром свих тих експонената.

$$\text{softmax}(x) = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}} \quad (25)$$

При томе су:

- x – улазни низ,
- K – број елемената низа x ,
- $i = 1..K$ – индекс тренутног елемента низа x .


Резултати те функције пропорционални су експонентима улаза, тако да се на основу резултата може вршити класификација улазних вредности. Зато се та функција пре свега користи за проблеме класификације, и то углавном за излазни слој, као што је наведено у ТАБ. 6.

Функција ReLU (енгл. *Rectified Linear Unit* – исправљена линеарна јединица) ради слично сигмоидној функцији, али са бољим перформансама. Функција је представљена једначином (26) и приказана на сл. 24 [180].

$$\text{ReLU}(x) = \max(0, x) = \begin{cases} x, & \text{за } x > 0 \\ 0, & \text{за } x \leq 0 \end{cases} \quad (26)$$

ReLU је данас најчешће коришћена функција активације. Излаз је у опсегу $[0, \infty)$, и има знатно мањи рачунски трошак од претходно описаних функција. С друге стране, код те функције


јавља се проблем под називом „умирући ReLU” (енгл. *Dying ReLU*) при ком, за улазе који су негативни или близу нуле, модел не може да учи.



Сл. 24: Функција ReLU [180]

Функција ReLU са цурењем (енгл. *Leaky ReLU*) представља варијанту функције ReLU такву да за $x < 0$, уместо константне вредности 0, даје линију са малим константним нагибом α . Примера ради, подразумевана вредност константе α у Python библиотеци Keras износи 0,3 [183]. Том модификацијом избегнут је проблем „умирући ReLU”. Резултати могу бити у опсегу $(-\infty, +\infty)$. Функција је представљена једначином (27) и приказана на сл. 25 [180].

$$\text{Leaky_ReLU}(x) = \begin{cases} x, & \text{за } x > 0 \\ \alpha x, & \text{за } x \leq 0 \end{cases} \quad (27)$$



Сл. 25: Функција ReLU са цурењем [180]

ТАБ. 5: Типичне функције активације за скривене слојеве (прилагођено из [185])

Врста вештачке неуронске мреже	Функција активације
Вишеслојни перцептрон (енгл. <i>MultiLayer Perceptron</i>)	ReLU
Конволутивна НМ (енгл. <i>Convolutional NN</i>)	ReLU
Рекурентна НМ (енгл. <i>Recurrent NN</i>)	logistic, tanh

ТАБ. 6: Типичне функције активације за излазни слој (прилагођено из [185])

Врста примене	Функција активације	
Регресија	linear	
Класификација	Бинарна	logistic
	Са више класа (енгл. <i>Multiclass</i>)	softmax
	Са више ознака (енгл. <i>Multilabel</i>)	logistic

Избор најбоље функције активације за скривени слој зависи од врсте мреже која се користи, док избор за излазни слој зависи од врсте примене [185]. На основу тога, јасно је да се обично не користи иста функција активације за све слојеве вештачке неуронске мреже. Функције

активације које се најчешће користе за скривене слојеве у неким врстама вештачких неуронских мрежа наведене су у ТАБ. 5, а за излазни слој у ТАБ. 6.

2.5.5 Процес обуке

Главни концепт вештачке неуронске мреже је да процес учења води ка проналажењу најбољих коефицијената мреже, тј. тежина и одклона, за одређени проблем. Тај процес назива се обука. Током обуке израчунавају се губици, а затим се минимизују помоћу метода за оптимизацију [188].

2.5.5.1 Функција губитка

Сврха функције губитка (енгл. *loss function*) је израчунавање губитака $C(W)$ које модел треба да минимизује током процеса обуке [183]. Најважније функције губитка су [186]:

- **Пробабилистичке:**

- *Бинарна унакрсна ентропија* (енгл. *binary crossentropy*) користи се за бинарну класификацију, тј. класификацију код које постоје само две излазне класе.

- *Категоричка унакрсна ентропија* (енгл. *categorical crossentropy*) прилагођена је за класификацију у више класа. Број неурона у излазном слоју мора бити једнак броју класа.

- **Регресијске:**

- *Средња квадратна грешка* (енгл. *Mean Square Error – MSE*, једначина (6)) израчунава се као збир квадрата разлика између циљних (тј. стварних) и прогнозираних вредности. Ефикаснија је при проналажењу решења у поређењу са другим функцијама грешке, али и осетљивија на изузетке (тј. на вредности које се разликују од већине других, енгл. *outliers*).

- *Средња апсолутна грешка* (енгл. *Mean Absolute Error – MAE*, једначина (8)) представља збир апсолутних разлика између циљних и прогнозираних вредности. У односу на MSE, отпорнија је на изузетке, али мање ефикасна у проналажењу решења.

- *Средња апсолутна процентуална грешка* (енгл. *Mean Absolute Percentage Error – MAPE*, једначина (9)) представља процентуални однос између апсолутне грешке и циљних вредности. Изражавајући грешку у процентима, омогућава упоређивање различитих модела за различите примене. Међутим, у случају да су циљне вредности блиске или једнаке нули, не може се користити.

Додатне информације у вези са функцијама губитка могу се пронаћи у одељку 3.3.18.

2.5.5.2 Оптимизатори

Након израчунавања грешака помоћу функције губитка, оне се морају минимизовати помоћу метода за оптимизацију. Функције активације неурона типично су нелинеарне и диференцијабилне. Ако би се на сваки неурон примењивала инверзија матрице да би се минимизовала грешка по методи најмањих квадрата, тј. решавала једначина (16) позната као нормална једначина, било би неизводљиво спровести обуку, зато што би то захтевало много рачунске обраде. Поред тога, када је функција активације нелинеарна, простор грешака више није квадратан. Стога, оптимално детерминистичко решење представљено нормалном једначином постаје веома тешко пронаћи.

Из тих разлога, у неуронској мрежи грешка се типично минимизује помоћу методе градијентног спуста или неке од изведених метода. Те методе су итеративне и представљају апроксимације оптималног решења. Модел најпре коефицијентима додељује случајне вредности изабране према типу слоја [183], а затим је задатак оптимизатора да пронађе у ком правцу модел треба да се креће да би се достигао минимум губитака [192]. У свакој итерацији

оптимизатор ажурира коефицијенте (тежине и отклоне) вештачке неуронске мреже помоћу технике пропагације уназад, у потрази за глобалним минимумом функције грешке [119], [121]. Најважнији алгоритми за оптимизацију описани су у наставку, а додатне информације о таквим алгоритмима дате су у одељку 3.3.17.

2.5.5.2.1 Градијентни спуст

Градијентни спуст (енгл. *Gradient Descent* – GD) представља алгоритам оптимизације који је најједноставнији за имплементацију и први измишљен, средином 19. века. Преко првог извода функције могуће је једноставно пронаћи минималне и максималне вредности, зато што је у тим тачкама први извод једнак нули. Исти принцип може се применити за функције више променљивих. Градијент је генерализација извода за функције више променљивих; то је вектор чије су компоненте парцијални изводи по појединачним променљивим. На крају циклуса (тј. епохе) израчунава се градијент за цео скуп података, а затим ажурирају коефицијенти вештачке неуронске мреже. Тај алгоритам веома споро конвергира и захтева високе рачунске трошкове [192]. Функционисање тог алгоритма представљено је једначином (28). Исказано речима, с обзиром на то што је циљ да градијент буде једнак нули, треба направити мали корак насупрот градијенту [210].

$$W = W - \alpha \nabla C(W; x, y) \quad (28)$$

При томе су:

- W – стање модела, тј. скуп коефицијената вештачке неуронске мреже,
- α – корак, тј. стопа учења (енгл. *learning rate*),
- C – функција грешке,
- $\nabla C(W; x, y)$ – градијент функције грешке,
- x, y – скуп података за обуку, сачињен од улазних и излазних података.

Стохастички градијентни спуст (енгл. *Stochastic Gradient Descent* – SGD): уместо да израчунава функцију грешке на основу целог скупа података, тај алгоритам је израчунава за једну случајно (стохастички) изабрану опсервацију из скупа података за обуку, и на основу тога ажурира коефицијенте вештачке неуронске мреже. То има за последицу сталне промене коефицијената и велике флукуације при проналажењу минимума, као што се може видети на сл. 26. Достиже конвергенцију много брже и захтева знатно мање рачунских ресурса него GD. С обзиром на велике флукуације, постиже нешто лошије резултате него GD, али најчешће довољно добре [192]. Функционисање тог алгоритма представљено је једначином (29) [211], [212].

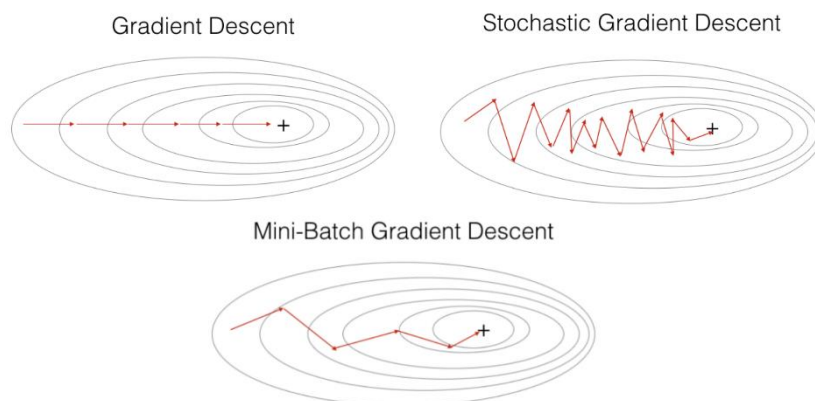
$$W = W - \alpha \nabla C(W; x_i, y_i) \quad (29)$$

При томе је $\{x_i, y_i\}$ опсервација изабрана за обуку (тј. један ред из скупа података за обуку).

Градијентни спуст по малим групама (енгл. *Mini-Batch Gradient Descent* – MBGD) представља комбинацију два претходна алгоритма: коефицијенти се ажурирају након израчунавања функције грешке за случајно изабрану групу података (енгл. *batch*). На тај начин остварују се предности оба претходна алгоритма а избегавају њихови недостаци. И даље има случајну компоненту која доводи до осцилација, али оне су знатно мање него код SGD-а. Осим тога, величина групе може се прилагодити конкретном проблему [192]. Функционисање тог алгоритма представљено је једначином (30), у којој B_i представља изабрану групу података.

$$W = W - \alpha \nabla C(W; B_i) \quad (30)$$

Начин функционисања оптимизатора заснованих на алгоритмима градијентног спуста приказан је на сл. 26.



Сл. 26: Оптимизатори засновани на алгоритмима градијентног спуста [180]

2.5.5.2.2 Оптимизатор заснован на моментуму

Оптимизатор заснован на моментуму представља допуну алгоритма градијентног спуста са циљем да се убрза обука, тј. кретање модела у повољном правцу, уз смањење осцилација. Концепт тог оптимизатора описан је једначином (31), а коефицијенти мреже ажурирају се према једначини (32).

$$V_t = \gamma V_{t-1} + \alpha \nabla C(W) \tag{31}$$

$$W = W - V_t \tag{32}$$

При томе су:

- t – итерација,
- V_t – промена коефицијената у датој итерацији,
- γ – моментум.

Као што се може видети из једначина, узимају се у обзир тренутна и претходна итерација, а утицај промене из претходне итерације одређен је хиперпараметром названим моментум или замах. Вредности тог хиперпараметра су у опсегу $[0, 1]$. Типична вредност моментума је око 0,9. Ако је моментум 0, тај алгоритам претвара се у градијентни спуст [213].

2.5.5.2.3 Адаптивна процена момената

Адаптивна процена момената (енгл. *ADaptive Moment estimation* – Adam, пише се као име а не као скраћеница) [62] такође се заснива на градијентном спусту, али користи први (\hat{m}_t) и други (\hat{v}_t) момент градијента у циљу брже конвергенције и бољих резултата. Први момент неке функције је њена средња вредност, а као други користи се нецентрирана варијанса [214]. Стопе учења су прилагодљиве (адаптивне) и индивидуалне, тј. разликују се за различите параметре. Учење се убрзава у регионима удаљеним од минимума а успорава у близини минимума. Израчунавање процена момената представљено је једначинама (33)-(35).

$$g_t = \nabla C(W) \tag{33}$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{34}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{35}$$

При томе су:

- t – итерација,

- g_t – вектор градијената функције грешке,
- β_1 и β_2 – експоненцијалне стопе опадања (енгл. *decay rates*) процена момената,
- m_t – вектор процена првих момената градијената,
- v_t – вектор процена нецентрираних других момената градијената.

Затим се израчунавају кориговане процене момената, једначинама (36) и (37):

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (36)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (37)$$

При томе су:

- \hat{m}_t – вектор коригованих процена првих момената градијената,
- \hat{v}_t – вектор коригованих процена нецентрираних других момената градијената.

Ажурирање коефицијената вештачке неуронске мреже представљено је једначином (38).

$$W_t = W_{t-1} - \frac{\alpha}{\sqrt{\hat{v}_t} + \varepsilon} \hat{m}_t \quad (38)$$

При томе су:

- α – корак, тј. стопа учења,
- ε – корекција варијансе.

Вектори процена момената иницијално, тј. за $t = 0$, попуњени су нулама. Хиперпараметри β_1 и β_2 могу бити у опсегу $[0, 1)$. Аутори тог алгоритма предложили су следеће вредности хиперпараметара: $\alpha = 0,001$, $\beta_1 = 0,9$, $\beta_2 = 0,999$, $\varepsilon = 10^{-8}$. Основна функција хиперпараметра ε је нумеричка стабилност, тј. избегавање могућности дељења нулом; међутим, у неким проблемима бољи резултати постижу се коришћењем знатно већих вредности тог хиперпараметра [215], [216]. Преглед вредности тих хиперпараметара предложених у разним изворима наведен је у [217].

Једначине (36)-(38) могу се заменити једначинама (39) и (40), што доприноси ефикасности.

$$\alpha_t = \alpha \frac{\sqrt{1 - \beta_2^t}}{1 - \beta_1^t} \quad (39)$$

$$W_t = W_{t-1} - \frac{\alpha_t}{\sqrt{v_t} + \hat{\varepsilon}} m_t \quad (40)$$

При томе су:

- α_t – адаптивни корак,
- $\hat{\varepsilon}$ – додатна корекција варијансе.

2.5.5.2.4 Алтернативни оптимизатори

Сви претходно описани алгоритми за оптимизацију заснивају се на градијентном спусту, и због тога захтевају да циљна функција буде диференцијабилна, конвексна и непрекидна

(континуирана) у целом домену решења. С обзиром на то што та својства често нису позната унапред, користе се и други алгоритми за оптимизацију, као на пример метахеуристички алгоритми [205]. Ти алгоритми описани су у засебном одељку 2.6, због тога што се у машинском учењу могу примењивати не само за оптимизацију коефицијената мреже, већ и за решавање других проблема, као што је нпр. оптимизација хиперпараметара.

2.5.5.3 Пропагација уназад

Процедура којом је вештачка неуронска мрежа у стању да обезбеди излазе на основу улаза, помоћу тежина и отклона, назива се пропагација унапред (енгл. *forward propagation*) јер информације путују од улазних ка излазним слојевима модела. На крају тог процеса генерише се скаларна цена $C(W)$. Уместо тога, алгоритам пропагације уназад (енгл. *backpropagation*) омогућава враћање те информације о скаларној цени, израчунавајући извод функције губитка у односу на коефицијенте вештачке неуронске мреже [188]. Тај алгоритам представљен је 1986. године у [135], и захваљујући њему, постало је могуће успешно обучити вештачке неуронске мреже. Алгоритам израчунава вредности коефицијената модела помоћу методе итеративног градијентног спуста, описане једначином (41). Једначина (42) представља опис те методе у матричној нотацији, а једначина (43) разраду матричне нотације под претпоставком да се MSE користи као функција грешке.

$$w_{i,j}^{[t]} = w_{i,j}^{[t-1]} - \alpha \frac{\partial C}{\partial w_{i,j}} \quad (41)$$

$$\mathbf{w}^{[t]} = \mathbf{w}^{[t-1]} - \alpha \frac{\partial C}{\partial \mathbf{w}} \quad (42)$$

$$\mathbf{w}^{[t]} = \mathbf{w}^{[t-1]} - \alpha \frac{2}{m} \mathbf{X}^T (\mathbf{X} \mathbf{w}^{[t-1]} - \mathbf{y}) \quad (43)$$

При томе су $\mathbf{w}^{[t]}$ и $\mathbf{w}^{[t-1]}$ матрице коефицијената модела (тежина и отклона) у тренуцима t и $t-1$, респективно, $w_{i,j}$ су појединачни коефицијенти, α представља стопу учења модела, m је број инстанци, а \mathbf{X} и \mathbf{y} матрице улазних и излазних података, респективно, као што је описано уз једначине (15) и (16) [119].

Градијент показује колико се неки параметар мора променити (у позитивном или негативном смеру) да би се минимизовала функција од интереса. Међутим, нумеричко израчунавање градијента може захтевати превелике рачунске трошкове, а функција циља (тј. функција трошка добијена из функције губитка) зависи од више променљивих. Да би се превазишао тај проблем, примењује се Лајбницево правило ланца за израчунавање градијента композитне функције трошка. Градијент се рачуна за један по један слој, и то од излаза уназад ка улазу, разрешавањем већ познатих извода [218]. На основу тако израчунатог градијента, оптимизатор добија информацију како да ажурира коефицијенте да би се приближио жељеном излазу [193].

Алгоритам пропагације уназад прилагођава тежине веза између неурона у сваком слоју мреже. У том процесу најпре се врши прогноза (пролаз унапред) и израчунава се грешка. Затим се врши повратни пролаз, у ком се кроз парцијалне изводе израчунава колико свака веза у једном по једном слоју доприноси грешци. Израчунава се допринос сваке везе грешци почев од излазног слоја, затим слоја који му претходи, итд. све до улазног слоја. На крају, тежине се прилагођавају у правцу минимизовања грешке на основу једначине (41), чиме се извршава један корак у методи градијентног спуста [119]. У пракси, имплементације помоћу библиотека као што је TensorFlow омогућавају израчунавање тежина помоћу матричних операција, на основу једначине (42), коришћењем савременог хардвера за обраду тензора.


2.5.6 Врсте вештачких неуронских мрежа

Постоји неколико типова вештачких неуронских мрежа, који се пре свега разликују по архитектури. Архитектура дефинише врсте и број неурона који се користе, као и број слојева и начин на који су међусобно повезани. Од архитектуре зависе начини на које се информације обрађују и памте [121].

Главна предност вештачких неуронских мрежа је могућност извођења нелинеарних трансформација преко активационе функције, зато што се на тај начин генерише више дискриминативних атрибута за дати проблем. Аналогно полиномској регресији, вештачке неуронске мреже такође користе трансформације атрибута, али такве трансформације изводе комбинацијом нелинеарних излаза из сваког слоја мреже.

2.5.6.1 Мреже са прослеђивањем унапред

Вештачке неуронске мреже са прослеђивањем унапред (енгл. *feedforward ANN*, сл. 27) [189] су најједноставније и прве које су коришћене. Подаци се простиру кроз мрежу само у једном смеру, унапред, улазећи у улазни слој и излазећи из излазног. Улазни слој означен је наранџастим круговима, излазни црвеним, а зелени представљају скривене ћелије. Сваки неурон повезан је са свим неуронима у суседним слојевима. Мрежа са прослеђивањем унапред са једним или више скривених слојева назива се вишеслојни перцептрон (енгл. *MultiLayer Perceptron* – MLP).



Сл. 27: Мрежа са прослеђивањем унапред [189]

2.5.6.2 Рекурентне неуронске мреже


У овом одељку најпре су описане стандардне рекурентне неуронске мреже, а затим мреже дугог краткорочног памћења, као нарочито заступљена подврста.

2.5.6.2.1 Стандардне рекурентне неуронске мреже


За разлику од мрежа са прослеђивањем унапред, код којих подаци теку једносмерно, од улазног до излазног слоја, у рекурентним неуронским мрежама (енгл. *Recurrent Neural Network* – RNN) постоје и повратне спреге. Помоћу тих спрега, излаз неурона може се спровести на улаз неурона у истом (сл. 28) [189] или неком од претходних слојева (сл. 29) [178], носећи повратне информације. Другим речима, неурони су повезани рекурзивно, стварајући циклусе. То значи да мрежа постаје много сложенија и са значајним повећањем броја веза, а информације за неурон пружају и претходни слој и нпр. сам неурон. Према томе, улази у неурон зависе од тежина и отклона не само претходног слоја, већ и претходног временског корака. Та особина омогућава рекурентним неуронским мрежама да обрађују секвенце података променљиве дужине, и зато се користе нпр. у проблемима временских серија и у симулацији нелинеарних динамичких система [121], [139], [140]. Временски корак представља количину кашњења у рекурентној мрежи, а тиме и број претходних посматрања потребан за предвиђање следећег.

У рекурентним неуронским мрежама, неурони примају не само улазне информације, већ и претходно прогнозиране информације; дакле, предвиђања која су већ направљена утичу на тренутна предвиђања [116]. То је важна особина људског мозга: људи не размишљају сваки пут испочетка, „од нуле” – свака мисао обликована је знањем стеченим кроз прошла искуства [125]. Рекурентна неуронска мрежа може се замислити као низ, тј. ланац који се састоји од


неколико копија исте неуронске мреже (сл. 30), где свака копија преноси генерисану информацију до следеће. На тај начин, мрежа наставља да разматра претходна предвиђања при генерисању будућих предвиђања. При томе је веома важан временски редослед информација.




сл. 28: Рекурентна неуронска мрежа са повратним везама у истом слоју [189]



сл. 29: Рекурентна неуронска мрежа са повратним везама ка претходном слоју [178]



сл. 30: „Размотана” рекурентна неуронска мрежа [125]



сл. 31: Модул који се понавља у стандардној рекурентној неуронској мрежи садржи један елемент [125]


На сл. 31 [125] детаљније је приказано функционисање стандардне рекурентне неуронске мреже. Неуронска мрежа у тренутку t прима улазну информацију (x_t). Та информација пролази кроз слој неурона којима је функција активације нпр. хиперболички тангенс (\tanh), што резултира тренутним излазом (h_t) који може бити у опсегу од -1 до 1 (захваљујући хиперболичком тангенсу). Међутим, поред примања улазних информација, слој неурона такође прима предвиђања мреже у прошлости (h_{t-1}), и преноси тренутно предвиђање у будући тренутак ($t+1$). Оно ће бити обрађено заједно са будућим улазним подацима (x_{t+1}), што ће

резултирати будућим излазом (h_{t+1}). Дакле, у слоју у тренутку t , улазни подаци (x_t) повезани су са информацијама прогнозираним у тренутку $t-1$ (h_{t-1}), тако да чине улазни вектор $[h_{t-1}, x_t]$.

Међутим, стандардна рекурентна неуронска мрежа има потешкоћа при решавању проблема са дуготрајним зависностима, код којих су потребне информације из даље прошлости у односу на тренутак у ком се траже. Да би се решио тај проблем, може се користити неуронска мрежа дугог краткорочног памћења.

2.5.6.2.2 Мреже дугог краткорочног памћења – LSTM

Неуронска мрежа дугог краткорочног памћења (енгл. *Long Short-Term Memory* – LSTM), први пут представљена у [122] а касније побољшана од стране неколико истраживачких група, представља варијанту и унапређење RNN архитектуре. LSTM мреже карактерише препознатљива структура ћелије приказана на сл. 32 [219]. LSTM је створена за моделирање дуготрајних зависности [125]. Занимљива особина LSTM мреже је да може селективно заборављати и памтити информације. У обичној рекурентној мрежи, ћелија која се понавља је једноставна и састоји се од једног елемента. За разлику од тога, у LSTM мрежи ћелија која се понавља састоји се од неколико елемената организованих у три тзв. капије, које олакшавају динамичко складиштење информација. Свака LSTM ћелија садржи улазну капију (енгл. *input gate* – i_t), капију за заборављање (енгл. *forget gate* – f_t) и излазну капију (енгл. *output gate* – o_t), где t представља тренутни временски корак. Те капије управљају стањем меморије ћелије (C_t).



Сл. 32: Ћелија LSTM мреже [219]

Прва фаза при обради улаза у ћелију LSTM мреже укључује одређивање који део претходно запамћених информација ће бити заборављен. Претходна предвиђања и нове информације обрађују се помоћу сигмоидне (тј. логистичке) функције, као што је приказано у једначини (44). Вредност те функције је у опсегу (0, 1) и служи као критеријум за одређивање да ли одређену информацију треба сачувати или заборавити.

$$f_t = \sigma(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f) \quad (44)$$

При томе је x_t улазни низ у временском кораку t , h_{t-1} излазни низ из претходног корака, а b_f вектор отклона капије за заборављање. Матрице тежина означене су са $W_{f,x}$ и $W_{f,h}$.

У другој фази одређује се које информације ће бити сачуване, тј. додате стању ћелије. Уз сигмоидну функцију, функција хиперболички тангенс користи се за нормализацију улазног низа у границама (-1, 1). Једначине (45) и (46) користе се за одређивање вредности \tilde{c}_t и вредности улазне капије i_t .

$$\tilde{c}_t = \tanh(W_{\tilde{c},x}x_t + W_{\tilde{c},h}h_{t-1} + b_{\tilde{c}}) \quad (45)$$

$$i_t = \sigma(W_{i,x}x_t + W_{i,h}h_{t-1} + b_i) \quad (46)$$

При томе $b_{\tilde{c}}$ и b_i означавају низове отклона, а $W_{\tilde{c},x}$, $W_{\tilde{c},h}$, $W_{i,x}$ и $W_{i,h}$ су матрице тежина. Након бирања вредности које ће бити заборављене и запамћене, у трећој фази одређује се стање C_t на

основу информација из прве две фазе и стања из претходног временског корака C_{t-1} , као што је представљено једначином (47):

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (47)$$

При томе симбол \times представља Адамаров (фр. *Hadamard*) производ, тј. производ по одговарајућим елементима. Први сабирак означава заборављање информација које су у првој фази изабране да се забораве, а други памћење информација које су у другој фази изабране да се запамте. У четвртој фази одређује се који део претходних предвиђања и улазних података ће постати нови излаз, тј. ново предвиђање. Помоћу сигмоидне и \tanh функције, на начин описан једначинама (48) и (49), израчунава се излазни резултат h_t , означен и као y_t .

$$o_t = \sigma(W_{o,x}x_t + W_{o,h}h_{t-1} + b_o) \quad (48)$$


$$h_t = o_t \times \tanh(C_t) \quad (49)$$

При томе је низ отклона за излазну капију означен са b_o , док су $W_{o,x}$ и $W_{o,h}$ матрице тежина. Нормализацијом помоћу функције \tanh спречава се да вредност излаза h_t буде превелика, зато што вредност стања ћелије C_t може бити знатно изван опсега $(-1, 1)$ [125].

Интеграција те три капије представља кључну снагу LSTM мрежа, зато што омогућава дугорочно складиштење података унутар мреже. Та могућност оспособљава LSTM мреже да ефикасно задрже и селективно ослобађају сегменте података повезане са претходним улазима. Те особине значајно побољшавају способност модела да обрађује секвенцијалне податке и открива fine односе унутар сложених низова података. LSTM може да моделира дуготрајне и кратке временске зависности, а показало се да је то својство кључно за предвиђање на основу временских серија.

2.5.6.3 Конволутивне мреже


Конволутивне мреже битно се разликују од претходне две врсте вештачких неуронских мрежа, а најчешће се користе за класификацију слика или звука. Специфичност те врсте мрежа проистиче из ћелија приказаних љубичастом бојом на сл. 33. Најпре, за разлику од претходне две врсте мрежа, ти неурони нису повезани са свим неуронима у претходном и следећем слоју, већ само са суседним неуронима. Њихов рад заснива се на математичкој операцији конволуције, тј. интегралу производа две функције након што се једна од њих преслика у односу на y -осу и помери [220]. Та операција у пракси се понаша као филтер који смањује број елемената у матрици компоненти слике. Смањивање се врши да би се олакшала обрада слике, и како информација пролази кроз слојеве, она се све више и више смањује. На крају, информације о класификацији одређују се помоћу класичне мреже са прослеђивањем унапред.



сл. 33: Конволутивна мрежа [189]

2.5.7 Припрема података и креирање модела

Дијаграм тока на сл. 34 [180] резимира комплетан поступак креирања модела на основу улазних података. Први блок, који се зове руковање подацима (енгл. *data handling*), састоји се од детаљне анализе података у циљу разумевања корисности одређених променљивих, као и решавања података који недостају или нису број (енгл. *Not a Number – NaN*).



сл. 34: Дијаграм тока креирања модела вођеног подацима [180]

Затим, знајући како функционише алгоритам оптимизације, важно је извршити скалирање обележја (енгл. *feature scaling*) прилагођавањем опсега сваког обележја. Без тога, са хетерогеним, различито дистрибуираним подацима, оптимизатор би правио велике осцилације у сваком кораку. Скалирањем обележја, међутим, те флукуације се смањују и потрага за минимумом функције трошка је побољшана. Најчешће методе за скалирање обележја су нормализација и стандардизација [194].

- *Нормализација* је представљена једначином (50) и скалира податке у опсег [0, 1] на основу минималне и максималне вредности посматраног обележја у скупу података.

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{50}$$

При томе су x_{min} и x_{max} минимална и максимална вредност посматраног обележја, респективно, x је вредност тог обележја у једној опсервацији, а x' нормализована вредност податка x .

• *Стандардизација* је представљена једначином (51) и мења дистрибуцију података тако да им средња вредност буде 0 а стандардна девијација 1. Опсег вредности података није ограничен [221].

$$x' = \frac{x - \bar{x}}{\sigma} \quad (51)$$

При томе су \bar{x} и σ средња вредност и стандардна девијација, респективно, а x' стандардизована вредност податка x .

Затим је важно извршити поделу скупа података на подскупе за обуку, валидацију и тестирање. Подскупови за обуку и валидацију користе се за изградњу модела вештачке неуронске мреже, а подскуп за тестирање приликом евалуације модела.

– *Подскуп за обуку* представља најважнији део скупа података. Као што му име каже, користи се за обуку вештачке неуронске мреже. Програм види ове податке и покушава да уклопи модел у сваком кораку.


– *Подскуп за валидацију* користи се током фазе обуке, за евалуацију модела у свакој итерацији. Неопходан је за фино подешавање архитектуре модела.

– *Подскуп за тестирање* служи за евалуацију модела након завршетка обуке и постављања коефицијената вештачке неуронске мреже, пошто програм не види те податке током обуке.


Сваки од подскупова затим се дели на улазе и излазе (означене нпр. са x и y , респективно), при чему су улази променљиве које модел користи за предвиђање излаза. Улази из подскупа за обуку уносе се у вештачку неуронску мрежу, а на основу прогнозе и излаза одређује се грешка, тј. резултат функције губитка. Захваљујући пропагацији уназад, информација о грешци враћа се кроз мрежу, ажурирајући вредности тежина и отклона у складу са изабраним оптимизатором.

Када се постигне конвергенција или се заврши задати број епоха, могу се креирати криве учења (енгл. *learning curves*), које показују да ли су коефицијенти мреже добро одабрани и да ли су у стању да генерализују проучавани проблем. Најважнији случајеви описани су у наставку [195], [196].


1. *Недовољна прилагођеност* (енгл. *underfit*) јавља се када модел не успева да се обучи на основу подскупа за обуку. Ако је модел превише једноставан у односу на сложеност проблема, губитак при обуци (енгл. *training loss*) остаје релативно велики и приближно је исти током целог процеса обуке (сл. 35), тј. обука не доводи до учења. Ако се обука модела заустави прерано, губитак при обуци стрмо се смањује до самог краја обуке (сл. 36).



Сл. 35: Криве учења за модел који нема довољан капацитет [196]




Сл. 36: Криве учења за модел који захтева још обуке [196]




Сл. 37: Криве учења за претерано прилагођен модел [196]

2. *Претерана прилагођеност* (енгл. *overfit*) јавља се када је модел превише обучен, нпр. научио је чак и статистички шум и случајне флукуације из подскупа за обуку. Другим речима, модел се превише специјализовао за подскуп за обуку и не може добро да генерализује проблем. У том случају, губитак при валидацији (енгл. *validation loss*) након неке тачке почиње да расте уместо да се смањује, а губитак при обуци не постиже стабилан (тј. приближно константан) ниво већ се лагано смањује до самог краја обуке (Сл. 37).


3. *Добра прилагођеност* (енгл. *good fit*) је циљ модела вештачке неуронске мреже; у том случају криве губитака при обуци и валидацији постижу стабилан ниво и на том нивоу се приближно поклапају (Сл. 38), што значи да је модел у стању да добро генерализује проблем.



Сл. 38: Криве учења за добро прилагођен модел [196]




Сл. 39: Криве учења у случају нерепрезентативног подскупа за обуку [196]



Сл. 40: Криве учења у случају нерепрезентативног подскупа за валидацију [196]

Такође се може догодити да коришћени подскупови података нису репрезентативни за проблем који се решава (нпр. неки од подскупова је премали). Ако подскуп за обуку није репрезентативан, крива за валидацију биће увек изнад криве за обуку, а крива за обуку наставиће лагано да пада до самог краја обуке (Сл. 39). Ако подскуп за валидацију није репрезентативан, крива за валидацију ће осциловати око стабилног нивоа (Сл. 40). Може се догодити и да подскуп за валидацију буде сувише лако предвидив у односу на подскуп за обуку (Сл. 41).



Сл. 41: Криве учења у случају када је подскуп за валидацију једноставније предвидети [196]

Методe за решавање проблема претеране прилагођености су:

- *Искључивање* (енгл. *dropout*) представља насумично одбацивање дела вредности добијених на излазу неког слоја. Тиме се успорава постизање конвергенције, али и избегава претерана

прилагођеност. Што се више изостављени део повећава, процес учења постаје хаотичнији и насумичнији. При томе се обично цели неурони привремено искључују.

- *Регуларизација* примењује казну која се додаје на функцију губитка. Та казна може се рачунати на основу збира апсолутних вредности коефицијената (тзв. L1 регуларизација или ласо регресија, енгл. *Lasso regression*), или на основу збира квадрата коефицијената (тзв. L2 регуларизација или гребенаста регресија, енгл. *Ridge regression*). Може се применити на тежине, отклоне или излазе слоја [222].

2.6 Метакхеуристичка оптимизација

Метакхеуристички оптимизатори су софистициране стохастичке методе оптимизације развијене за решавање сложених проблема код којих традиционалне детерминистичке технике нису практичне. Метакхеуристике не могу да гарантују проналажење апсолутно најбољег решења, али се одликују ефикасним кретањем кроз велике, вишедимензионалне домene претраживања и успешно проналазе решења блиска оптималним [85], [86]. Инспирисани природним појавама и биолошким системима, метакхеуристички приступи веома су „сналажљиви” и робусни, што их чини погодним за решавање чак и NP-тешких [84] проблема уз разумно коришћење рачунарских ресурса. Ти алгоритми налазе широку примену у различитим практичним областима као што су инжењерство, логистика, медицина, машинско учење и финансије, решавајући проблеме попут проналажења најбоље руте, расподеле расположивих ресурса и заказивања [87]. Неке од најпознатијих категорија метакхеуристике су генетски алгоритми и технике засноване на интелигенцији роја.

Методе интелигенције роја инспирисане су колективним понашањем примећеним код друштвених организама попут пчела, птица и риба. Ти алгоритми емулирају децентрализоване, самоорганизоване системе да би колаборативно решавали сложене проблеме. На пример, алгоритам оптимизације колоније мравца (енгл. *Ant Colony Optimization – ACO*) [88] реплицира понашање тих инсеката док проналазе најкраће путеве од своје колоније до извора хране, док PSO [80] моделира хармонизовано кретање јата птица. Наглашавајући комуникацију и свестраност, метакхеуристике интелигенције роја веома су ефикасне за решавање динамичких и нелинеарних проблема оптимизације. Тај основни концепт подстакао је развој бројних техника оптимизације. Још неке од добро познатих метода интелигенције роја су вештачка колонија пчела (енгл. *Artificial Bee Colony – ABC*) [91] и алгоритам свитаца (енгл. *Firefly Algorithm – FA*) [92]. У последњих неколико година појавили су се нови представници те категорије – алгоритам претраге гмизаваца (енгл. *Reptile Search Algorithm – RSA*) [94], оптимизација црвене лисице (енгл. *Red Fox Optimization – RFO*) [95], алгоритам оптимизације шимпанзи (енгл. *Chimp Optimization Algorithm – ChOA*) [111] и други. У ту категорију спада и $\sinh \cosh$ оптимизатор (SCHO) [93], који није инспирисан природом већ математичким особинама споменутих функција, али попут метода интелигенције роја користи популацију потенцијалних решења (тзв. агената).

Метакхеуристички алгоритми засновани на интелигенцији роја показали су се као веома ефикасни и прилагодљиви, истичући се у широком спектру проблема из стварног света. Успешне скорашње примене обухватају медицину [96], [97], анализу расположења [98], [99], [100] као и активности развоја и тестирања софтвера [101], [102]. Друге значајне области примене укључују рачунарство у облаку [59], [81], пољопривреду [103], [104], као и производњу и потрошњу енергије из обновљивих извора [105], [106].

2.7 Истраживачка анализа података

Са развојем алгоритама за машинско учење, унапређењем хардвера за дигиталну обраду сигнала и порастом капацитета за складиштење података, потреба за специјалистичким знањем о подацима у циљу решавања датог проблема постаје све више заменљива чисто

аутоматским системима. Такви системи типично су познати у литератури као системи црних кутија, у којима се може изоставити специјалистичко знање професионалца о подацима, све док је на располагању велика количина података и велика рачунарска моћ. Међутим, за области као што је инжењеринг, некоришћење специфичних знања из дате области није интересантно. Уместо једноставне замене човека машином као у системима црних кутија, алтернативно решење могао би да буде заједнички рад – употреба алгоритама за машинско учење уз критичку анализу података од стране специјалисте у датој области. У том контексту, таква критичка анализа спроводи се и дискутује у фази истраживачке анализе података.

Да би се стекло боље разумевање и извршила критичка анализа података доступних у скупу за обуку, валидацију и тестирање, истраживачка анализа података (енгл. *Exploratory Data Analysis* – EDA) представља фундаментални корак, али и један од најзахтевнијих. Одређују се излазне променљиве, обрађују недостајуће и одступајуће вредности (вредности које у великој мери одступају од просека, енгл. *outliers*) да би се проверило да ли постоји нека аномалија, проверава се правилност расподеле података, а и зависност између атрибута израчунавањем корелације. Поред тога, да би се добило боље разумевање података, могу се формулисати хипотезе које треба потврдити или одбацити. Ако је потребно, могу се креирати нове или трансформисати постојеће променљиве [117].

Истраживачка анализа података представља релативно нову област у статистици – први пут је описана 1977. године у [150]. У наставку, приказане су неке статистичке методе које се користе за истраживачку анализу података у овом истраживању.

2.7.1 Расподела фреквенција

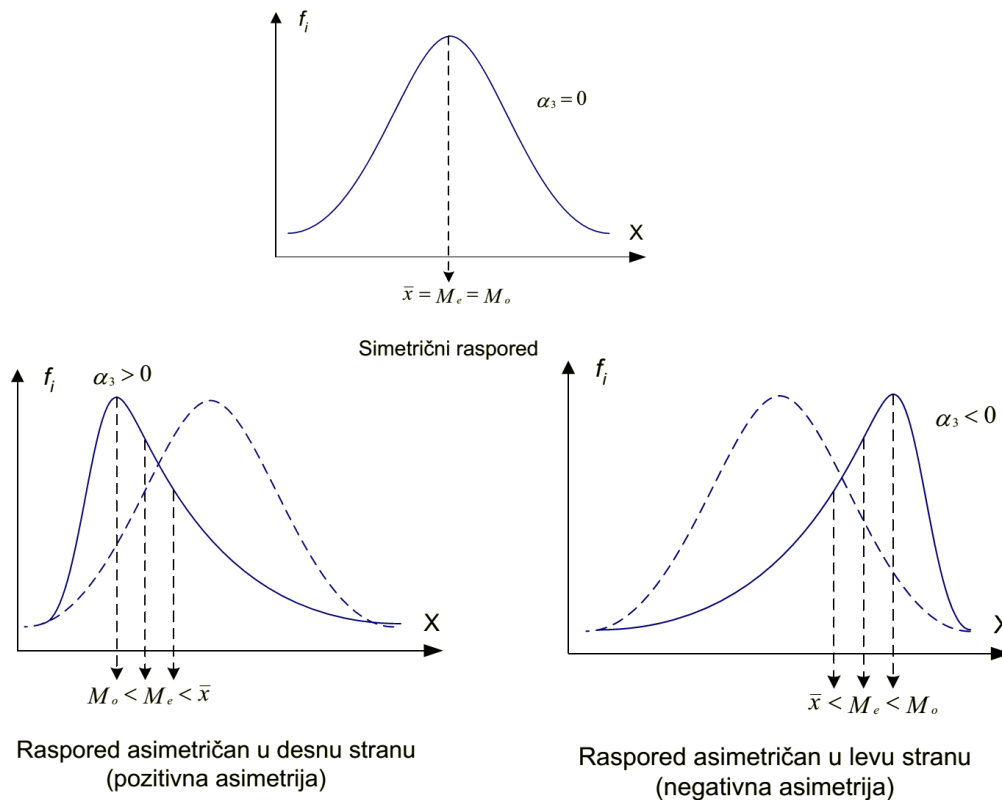
Провера расподеле (дистрибуције) фреквенција у скупу података, пре него што се они примене у моделу за машинско учење, изузетно је корисна за разумевање расподеле података и откривање образаца за сваки атрибут у узорку. Најчешћа симетрична расподела је Гаусова или нормална расподела, чија функција расподеле има облик звона, као на сл. 42 [128], [129]. Међутим, нису све симетричне расподеле Гаусове.

Асиметричност (енгл. *skewness*) и спљоштеност (енгл. *kurtosis*, од грч. *κυρτός* = закривљен, конвексан) често се користе као показатељи у којој мери расподела података одступа од нормалне. Један од начина да се израчуна коефицијент асиметричности (a_3 или A_3) дат је у једначини (52). При томе је \bar{x} средња вредност података, Mo представља модус (вредност са највећом апсолутном фреквенцијом у скупу података), а σ је стандардна девијација података у односу на средњу вредност. То је тзв. Пирсонов први коефицијент асиметричности [130], [131].

$$A_3 = \frac{\bar{x} - Mo}{\sigma} \quad (52)$$

Пирсонов коефицијент спљоштености K најчешће се израчунава као четврти стандардизовани момент, тј. четврти централни момент μ_4 нормализован четвртим степеном стандардне девијације σ . Од тако израчунатог коефицијента најчешће се одузима 3 и тиме се добија коефицијент спљоштености у односу на нормалну расподелу (Ke , енгл. *excess kurtosis*), као у једначини (53) [173]. У наставку, под „коефицијент спљоштености” мисли се на Ke .


$$Ke = \frac{\mu_4}{\sigma^4} - 3 \quad (53)$$



Сл. 42: Симетричност криве расподеле фреквенција [128]

На основу коефицијента спљоштености може се закључити колико у подацима има одступајућих вредности (енгл. *outliers*). Што је више одступајућих вредности, то крива расподеле фреквенција има израженије „репове” (зато што има више вредности које су далеко од просечних) и обрнуто. Расподеле за које је коефицијент спљоштености K_e приближно једнак нули називају се мезокуртичке (од грч. μέσος = просечан). У таквим расподелама број одступајућих вредности није ни нарочито велики ни нарочито мали.

Када је тај коефицијент мањи од нуле, такве расподеле називају се платикуртичке (од грч. πλατύς = широк). Крива такве расподеле фреквенција има мање репове, а у подацима има мање одступајућих вредности. Када је коефицијент спљоштености K_e већи од нуле, такве расподеле називају се лептокуртичке (од грч. λεπτός = танак). На кривој лептокуртичке расподеле репови су израженији, што указује на већи број одступајућих вредности (Сл. 43) [174].



Сл. 43: Сплљоштеност криве расподеле фреквенција [174]

За нормалну расподелу, вредности коефицијената асиметричности и спљоштености једнаке су нули [159]. Другим речима, нормална расподела је симетрична и мезокуртичка. Не постоји опште прихваћено правило које су прихватљиве вредности та два коефицијента. По [158],

расподела података не показује битнија одступања од нормалне расподеле ако је коефицијент асиметричности у опсегу $[-2, 2]$ а коефицијент спљоштености у опсегу $[-7, 7]$. По [160], прихватљиве вредности коефицијента асиметричности су у опсегу $[-3, 3]$, а коефицијента спљоштености у опсегу $[-10, 10]$; по [159], вредности изван тих опсега указују на проблеме са подацима.

2.7.2 Корелација

Коефицијент корелације (r) изражава степен везе (зависности) између две променљиве (x и y). Вредност тог коефицијента је у опсегу $[-1, 1]$. При томе, што је тај коефицијент ближи вредности 1 или -1 , то су променљиве у већој корелацији, односно већа је линеарна веза између њих. Пирсонов коефицијент корелације може се израчунати помоћу једначине (54). При томе су \bar{x} и \bar{y} средње вредности променљивих x и y , респективно, x_i и y_i вредности тих променљивих у појединачним узорцима, а n број узорака у скупу података [132], [133].

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (54)$$

2.7.3 Мултиколинеарност

Мултиколинеарност такође истражује зависност између улазних променљивих модела. Понекад није довољно испитати зависност само између парова улазних променљивих, као што то чини коефицијент корелације, зато што се може догодити да постоји зависност између три или више променљивих. У таквим ситуацијама каже се да постоји мултиколинеарност. Међусобно високо зависне променљиве су редундантне за процену вредности коју треба предвидети, тј. неке од њих (или чак све осим једне) могу се изоставити.

Један од начина да се открије мултиколинеарност је преко фактора инфлације варијансе (енгл. *Variance Inflation Factor* – VIF). Тај фактор може се израчунати помоћу једначине (55), при чему је R^2 коефицијент детерминације (описан у одељку 2.2.1). У случају прости линеарне регресије, тј. ако постоји само једна улазна и једна излазна променљива, уместо коефицијента детерминације користи се r^2 , тј. квадрат Пирсоновог коефицијента корелације [134], [142], [161].

$$\text{VIF} = \frac{1}{1 - R^2} \quad (55)$$

Фактор инфлације варијансе за неку улазну променљиву је мера пораста варијансе прогнозиране променљиве ако се та улазна променљива дода у регресију, и представља меру мултиколинеарности скупа података. Регресијом по методи најмањих квадрата, та улазна променљива (X_i) представља се као функција свих осталих улазних променљивих (једначина (56)), при чему је α_0 константа а ε грешка [162].

$$X_i = \alpha_0 + \alpha_1 X_1 + \dots + \alpha_{i-1} X_{i-1} + \alpha_{i+1} X_{i+1} + \dots + \alpha_n X_n + \varepsilon \quad (56)$$

Коефицијент детерминације рачуна се за ту једначину регресије, и затим се на основу њега рачуна фактор инфлације варијансе. Опште правило је да вредности тог фактора испод 4 (или по неким ауторима 5) показују ниску мултиколинеарност те улазне променљиве са осталим у скупу података, вредности између 4 (или 5) и 10 су прихватљиве али би их требало испитати, док вредности изнад 10 показују високу мултиколинеарност која захтева корекцију.

2.7.4 Квартили

Коришћењем теорије квартила у комбинацији са кутијастим (квантилним) дијаграмима (енгл. *box plots*) могу се једноставно идентификовати одступајуће вредности (енгл. *outliers*) у узорку података. Осим тога, квартили омогућавају боље разумевање расподеле података.

Квартили деле скуп података на 4 једнака дела: први квартал (Q_1) означава 25% најнижих вредности, медијана одн. други квартал (Q_2) централних 50% вредности, а трећи квартал (Q_3) представља 25% највиших вредности. Првом, другом и трећем квартилу одговарају перцентили P_{25} , P_{50} и P_{75} , респективно.

Разлика трећег и првог квартила ($Q_3 - Q_1$) назива се интерквартилна удаљеност (енгл. *Interquartile Range - IQR*). Та вредност може послужити као мера дисперзије података и пружа идеју о дисперзији централних вредности расподеле. Такође се може искористити за препознавање одступајућих вредности (енгл. *outliers*). Доња (енгл. *Lower Fence - LF*) и горња граница података (енгл. *Upper Fence - UF*) могу се дефинисати једначинама (57) и (58), респективно, а вредности које су изван тих граница сматрати за одступајуће [143], [144].


$$LF = Q_1 - 1.5 \cdot IQR \tag{57}$$

$$UF = Q_3 + 1.5 \cdot IQR \tag{58}$$

2.7.5 Релевантност и статистичка значајност

Студентов t -тест (енгл. *Student's t-test*) [169] представља статистички тест којим се проверава да ли је разлика између два скупа података статистички значајна, под претпоставком да подаци одговарају Студентовој t -расподели (енгл. *Student's t-distribution*) [168]. Та расподела је генерализација нормалне расподеле таква да њена функција густине вероватноће зависи од броја степени слободе ν (сл. 44).

Студентов t -тест заснива се на израчунавању тзв. t -вредности. Када је потребно упоредити две независне групе узорака, одговарајућа t -вредност може се израчунати на основу једначине (59). При томе су \bar{x}_1 и \bar{x}_2 средње вредности, σ_1 и σ_2 стандардне девијације, а n_1 и n_2 број опсервација (узорака) у првој и другој групи, респективно [172].



сл. 44: Функције густине вероватноће Студентове t -расподеле за разне вредности ν [168]

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\left(\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)}} \tag{59}$$

Ако се у моделу за предикцију израчунају t -вредности за једну по једну независну променљиву према циљној, оне показују предиктивни капацитет независних променљивих, тј. њихову релевантност за прогнозирање циљне променљиве. Већа t -вредност указује на већу релевантност одговарајуће променљиве (атрибута).

Тзв. p -вредности (латинично p) показују статистичку значајност (енгл. *statistical significance*) одговарајућих променљивих. Оне представљају вероватноћу да одговарајућа променљива НЕ доприноси прогнози циљне променљиве, тј. вероватноћу да је евентуални утицај те променљиве на прогнозу последица случајности. Анализа се врши поређењем p -вредности са тзв. нивоом значајности (енгл. *significance level*), који се обично обележава са α . Избор вредности α зависи од t -вредности, зато што се на основу њих одређују тзв. интервали сигурности (енгл. *confidence intervals*) за податке који задовољавају Студентову t -расподелу. У пракси, најчешће се бира вредност $\alpha = 0,05$ (тј. 5%, одн. 1 од 20 узорака).

Тзв. нулта хипотеза (енгл. *null hypothesis*) [170] представља претпоставку да НЕ постоји ефекат који се изучава, нпр. статистичка разлика између два скупа података, веза између две променљиве и сл. Алтернативна хипотеза је да постоји ефекат, разлика, веза и сл. Ако је $p \leq \alpha$, то је индикација да се нулта хипотеза може одбацити [171]. У случају испитивања утицаја једне променљиве на другу, ако је $p \leq \alpha$, то је добар показатељ да постоји статистичка веза између две променљиве, одн. да променљива на коју се односи конкретна p -вредност утиче на прогнозу циљне променљиве. И обрнуто, ако је $p > \alpha$, одговарајућа променљива највероватније нема битан утицај на прогнозу циљне променљиве. Статистичке значајности не треба користити као дефинитиван доказ, али свакако су један од показатеља утицаја одређене променљиве на модел.

3 Преглед стања у области

Ово поглавље садржи свеобухватан преглед актуелног стања у прогнозирању производње фотонапонске енергије, представљајући 50 најбољих радова одабраних по утврђеним критеријумима. Прегледани радови детаљно су анализирани у погледу више фактора који утичу на квалитет прогнозе, као што су методе прогнозирања, обухвати, временске резолуције, хоризонти, предобрада, избор улазних обележја, оптимизација хиперпараметара, метрике, величине неуронских мрежа, функције активације, оптимизатори, функције губитка итд. Представљени су и квантитативни и квалитативни аспекти резултата анализа, и наглашена су подручја која нису довољно обухваћена у прегледаним радовима.

Остатак овог поглавља организован је на следећи начин. Одељак 3.1 описује критеријуме и начин одабира радова за овај преглед. Одељак 3.2 садржи кратке резимее за већину радова. Одељак 3.3 представља резултате анализа прегледаних радова у односу на различите факторе. Одељак 3.4 закључује овај преглед.

3.1 Критеријуми за избор

Радови анализирани у овом прегледу одабрани су према следећим критеријумима:

- **Актуелност:** радови морају да представљају најсавременија достигнућа у посматраној области, тј. да укључују најновији напредак и трендове.
- **Репрезентативност:** научна заједница мора их препознати као најрепрезентативније и најутицајније у тој области.
- **Доступност:** радови морају бити јавно доступни да би утицали на најширу публику.

Имајући у виду те критеријуме, извршена је претрага на Google Scholar-у. Да би се задовољио критеријум актуелности, разматрају се само радови објављени 2020. године или новији. Критеријум репрезентативности и утицаја обезбеђен је не само редоследом у резултатима претраге, који се може незнатно мењати од претраге до претраге, већ првенствено бројем цитирања у другим научним публикацијама. Потребан број цитирања одређен је у односу на годину објављивања, као што је описано у ТАБ. 7; однос није строго линеаран, да би се омогућило укључивање новијих радова.

ТАБ. 7: Потребан број цитирања

Година објављивања	Минималан број цитирања
2020.	100
2021.	75
2022.	50
2023.	30
2024 и новије	10

Израз за претрагу био је: „allintitle: photovoltaic OR photovoltaics OR PV forecast OR forecasting -review”. Тражене године објављивања дефинисане су помоћу напредних опција претраге. Изабрано је првих 50 радова који задовољавају све критеријуме. Прегледни радови и радови који се не баве прогнозирањем производње фотонапонске снаге (већ само нпр. прогнозирањем ирадијансе или потрошње) изостављени су из овог прегледа. Референце од [1] до [50] одговарају прегледаним радовима, поређаним као у претрази.

3.2 Кратки резимеи

Овај одељак садржи кратке резимеи за већину прегледаних радова.

Аутори у [1], свесни изазова везаних за поређење резултата различитих истраживања, анализирају утицај различитих фактора на тачност прогнозе: временске резолуције улазних података, хоризонта прогнозе, количине података за обуку и тестирање и 4 методе машинског учења различитих класа – RF, SVR, LR и MLP. Такође испитују важност улазних обележја и њихов избор и упоређују брзине обуке и предвиђања. MLP је постигао најбољу тачност у 8 од 12 експеримената, али RF је остварио најбољи просечни RMSE, а LR је забележио најкраће време обуке. Један од њихових закључака је да квалитет података побољшава тачност више него квантитет.

Истраживање презентовано у [2] представља први корак ка циљу аутора да се створи регионални систем за фотонапонско прогнозирање, који прикупља податке из густе мреже фотонапонских електрана и тиме омогућава високу просторну и временску резолуцију прогноза. У прегледаном раду, представљен је модел заснован на LSTM мрежи за једну фотонапонску електрану.

Главна идеја у [3] је да метода прогнозирања не треба да се заснива искључиво на подацима, већ да укључује и неко знање из домена, тј. да буде прилагођена специфичном проблему који се решава. Аутори су класичној LSTM методи додали модуле који филтрирају немогуће и одступајуће податке и назвали своју методу LSTM ограничен физиком (енгл. *Physics-Constrained LSTM* – PC-LSTM). Њихова метода постигла је боље метрике од класичне LSTM методе у 9 од 10 експеримената. Такође испитују утицај количине података за обуку и примећују очигледно смањење тачности прогнозе за мање количине података.

У [4], упоређене су чак 24 различите методе, помоћу 3 скупа улазних обележја. Аутори тврде да избор обележја има већи утицај на тачност него избор модела. Укључивање углова Сунца у скупове обележја значајно побољшава прогнозе. KRR (енгл. *Kernel Ridge Regression*) и MLP постигли су најбољу тачност, али MLP се препоручује због изузетно дуге обуке KRR-а. LR је био најбржи, а и тачнији од тзв. напредних линеарних модела. Аутори такође наглашавају важност подешавања хиперпараметара. Препоручује се најмање једна година података за тренирање и валидацију модела, због годишње периодичности временских образаца.

Аутори у [5] представљају хибрид модела заснованог на физици, који се користи за прогнозирање трендова, и модела вођеног подацима, који се користи за фино прогнозирање на основу флукуација облачности. Хибрид садржи 3 TCN мреже – по једну у сваком од основних модела, и трећу која обједињује резултате тих модела. На тај начин, очекује се постизање добре тачности и за прогнозе до једног сата и за прогнозе од више сати унапред, зато што је модел заснован на физици бољи за дуже хоризонте, а модел вођен подацима за краће хоризонте. Користе се подаци са суседних локација, што је јефтиније од нпр. сателитских снимака. Развијена је метода анализе корелације заснована на сценаријима, која аутоматски идентификује суседне локације које највише доприносе.

У [6], представљен је наслагани ансамбл (енгл. *stacked ensemble*) састављен од 4 различите методе засноване на стаблима одлучивања (DT). Ансамбл је упоређен са појединачним методама и другим комбинацијама метода.

Регионално прогнозирање фотонапонске снаге главна је тема у [7], где је анализирано 6 различитих метода скалирања. Најбољи резултати добијају се коришћењем хибрида физичког модела и MLP-а. За разлику од прогноза за појединачне електране, када се ради о регионалним прогнозама, повећање хоризонта са 1 на 3 дана не утиче значајно на тачност прогноза, која више зависи од методе скалирања него од квалитета NWP података (енгл. *Numerical Weather Prediction* – нумеричка прогноза времена). Повећање квалитета NWP података од 50% довело је до повећања тачности прогнозе од само 20%; да би се то побољшало, мора се обратити

пажња на предобраду и накнадну обраду (енгл. *pre- and post-processing*). Повећање подручја за које се даје прогноза повећава тачност, због ефекта изглађивања прогнозе (енгл. *forecast smoothing effect*). Мора се направити компромис између додатних информација и сложености обуке да би се оптимизовале перформансе модела машинског учења.

Утицај недостајућих података на тачност прогнозе анализиран је у [8], а упоређене су 4 технике за руковање недостајућим подацима: брисање целог реда, линеарна импутација, kNN импутација и генеративна супарничка мрежа за импутацију (енгл. *Generative Adversarial Imputation Network – GAIN*). Хибрид CNN-а и GRU-а користи се као метода за прогнозирање. Такође се узима у обзир тип неба. За 10% недостајућих података, брисање производи најбоље прогнозе, за 20% GAIN, а за 30% kNN. У просеку, kNN је најбоља техника, али ниједна од њих није најбоља у свим ситуацијама и за све метрике.

Главна идеја у [9] је генерисање синтетичке прогнозе ирадијансе, засноване на историјским подацима о ирадијанси груписаним по сату у дану и дану у годишњем добу, и класификованим у 5 категорија помоћу алгоритма груписања *k*-средњих вредности (енгл. *k-means clustering*). Свака од тих 5 категорија одговара једној од 5 категорија у прогнози типа неба (од сунчаног до облачног). На тај начин, тачност прогноза фотонапонске снаге побољшана је за 33-44,6% у односу на прогнозе које користе само тип неба.

Аутори [11] користе CNN за анализу података из претходних дана, зато што је корелација између излазних снага у суседним данима у просеку 0,885. CNN је повезан са LSTM мрежом, која анализира претходне податке из дана за који се даје прогноза. Излази те две неуронске мреже спојени су помоћу пондерисаног збира (енгл. *weighted sum*).

У [12], статистичка завршна обрада помоћу линеарне регресије користи се за побољшање прогноза MLP мреже ублажавањем изобличења соларне ирадијансе.

Циљ рада [13] је истраживање могућности замене историјских NWP података, који могу бити скупи, измереним метеоролошким подацима у процесима обуке и тестирања модела.

Емпиријско и физичко моделирање различитих фотонапонских модула истражено је у [14]. Излазна снага 5 типова модула (моно-Si, поли-Si, a-Si, CIGS и CdTe) процењена је помоћу 3 модела: модела једноставне ефикасности (енгл. *simple efficiency model*), модела једноставне ефикасности са корекцијом температуре и модела са једном диодом. Последњи модел постигао је најбољу тачност у већини случајева.

У [15], ансамбл за нумеричко (NWP) предвиђање ирадијансе упарен је са ансамблом ланца физичких модела за пробабилистичко предвиђање снаге фотонапонског система. Приступ заснован на ансамблу у пробабилистичком предвиђању подразумева неколико извршавања модела са различитим почетним условима, након чега се нпр. израчунава просек свих сценарија. Такве прогнозе обично су тачније од детерминистичких, али потребно их је калибрисати поступком вођеним подацима (енгл. *data-driven*).

Аутори рада [16] упоредили су 3 статистичка модела, 5 неуронских мрежа и фази груписање методом *C*-средњих вредности (енгл. *Fuzzy C-Means Clustering – FCM*). Такође су испитали користан утицај уклањања одступајућих вредности (енгл. *outliers*) на тачност.

У [17], 5 метода машинског учења упоређено је помоћу чак 20 комбинација улазних обележја. Истраживање закључује да су MLP и RF генерално најприлагодљивије и најпоузданије методе за прогнозирање фотонапонске снаге. Не постоји скуп обележја који даје најбоље резултате са свим методама, зато што различите методе раде различито. Различита обележја делују као шум за различите методе; ипак, нека обележја појављују се у свим најбољим скуповима.

Предности хибридизације физичких и метода машинског учења истражене су у [18]. Аутор фаворизује поступак у 3 корака: 1) прогнозирање ирадијансе, 2) накнадна обрада прогнозе ирадијансе и 3) претварање ирадијансе у прогнозу фотонапонске снаге. Модел треба да садржи

што је могуће више знања из области. Упоређено је 8 хибридних модела, 4 чиста модела машинског учења са различитим улазним обележјима и 1 чист физички модел.

Фокус рада [19] је на методама објашњиве вештачке интелигенције (енгл. *eXplainable AI – XAI*): LIME, SHAP и ELI5. Прогнозирање снаге фотонапонских система помоћу RF-а служи као пример примене тих метода. Најбољу тачност постигао је SHAP, али његово време извршавања драстично је дуже у поређењу са друге две методе, а тачност тих метода такође је задовољавајућа.

Идеја у [20] је да се истовремено изврши импутација недостајућих података и пробабилитичко предвиђање помоћу рекурзивног LSTM (Rec-LSTM) модела. Захваљујући ауторегресивној структури модела, предвиђање за више корака унапред може се постићи рекурзивним извлачењем узорка из претходно прогнозиране пробабилитичке расподеле и његовим коришћењем као улаза у модел. Анализирају се случајеви са од 0 до 90% недостајућих података.

Аутори у [21] користе периодичност у подацима о снази фотонапонских система и разлажу их на компоненте ниских и високих фреквенција помоћу брзе Фуријеове трансформације (енгл. *Fast Fourier Transformation – FFT*). Ниске фреквенције одговарају редовном генерисању и показују тренд, док високе одговарају случајним флукуацијама. CNN се користи за предвиђање сваке фреквенције засебно, а пондерисани резултати састављају се у коначну прогнозу.

Сложени ансамбл описан је у [23], при чему су LSTM и MLP мреже употребљене као основни модели (енгл. *base learners*), док је XGBoost алгоритам примењен као метамодел (надређени модел, енгл. *meta-learner*). SHAP се користи за илустрацију утицаја сваког улазног обележја на резултат прогнозе.

Временска серија података о производњи фотонапонских система са више локација моделирана је у [25] графом у ком чворови представљају фотонапонске електране, сигнали су вредности снаге фотонапонских система, а везе су односи (тј. очекиване корелације) између постројења. Аутори предлажу два модела графовских неуронских мрежа: граф-конволуциони LSTM (GCLSTM) и граф-конволуциони трансформер (GCTrafo). Корелације између чворова уче се током обуке модела, заједно са тежинама и отклонима.

Резултат рада [26] је јавни скуп података који садржи слике и видео-записе неба у високој резолуцији током скоро 3 године, праћене одговарајућим умањеним (енгл. *downsampled*) сликама ниске резолуције и подацима о производњи фотонапонске снаге. CNN се користи за прогнозирање.

У [27], коришћено је и упоређено 5 техника изглађивања података током предобrade, а најмање грешке у предвиђању произвела је техника локално пондерисано изравнавање дијаграма расејања (енгл. *Locally Weighted Scatterplot Smoothing – LOWESS*). RF се примењује као омотачка метода (енгл. *wrapper method*) за избор улазних обележја, док се GRU комбинован са слојем RepeatVector и слојем TimeDistributed користи за предвиђање.

Сценаријско прогнозирање за 7 дана унапред истражује се у [28]. Темпорална резолуција података временске прогнозе побољшана је бикубичном интерполацијом, а затим коригована помоћу Vi-LSTM мреже. Аутори тврде да се тачност седмичне симулације фотонапонске снаге може побољшати правилном класификацијом мерења фотонапонске снаге с обзиром на метеоролошке услове. Класификовали су време током седмице у 6 категорија у зависности од броја сунчаних, облачних, кишних и снежних дана. Затим су тренирали засебне GRU-CNN мреже за сваку од категорија, при чему су GRU компоненте училе темпоралне, а CNN компоненте просторне карактеристике података о фотонапонској снази.

Утицаји улазних података на тачност прогнозе испитани су у [29]. Подаци могу бити организовани као структурни, временске серије или хибридни. LR и MLP модели упоређени су уз коришћење 6 различитих комбинација улазних података.

У [30], метахеуристика LFBAS (претрага антена буба са Левијевим летом, енгл. *Levy-Flight Beetle Antennae Search*) коришћена је за одабир историјских дана сличних дану прогнозе. Декомпозиција пакета таласића (енгл. *Wavelet Packet Decomposition – WPD*) разлаже оригиналне податке о снази фотонапонског система на 4 подсигнала. За сваки од подсигнала оптимизован је посебан GRU модел.

Подаци са сателитских снимака коришћени су у [31], комбиновани са подацима о снази и облацима из више постројења. Просторно-временска унакрсна корелација примењена је за избор суседа који највише доприноси прогнози, узимајући у обзир смер кретања облака. Линеарна екстраполација примењује се за предвиђање кретања облака.

У [32], упоређене су 3 варијанте CNN архитектуре: стандардни CNN, CNN са више глава и хибрид CNN-а и LSTM-а. Све 3 користе клизне прозоре (енгл. *sliding windows*).

Аутори рада [33] тврде да је то прво истраживање које користи временски фузиони трансформер (енгл. *Temporal Fusion Transformer – TFT*) за прогнозирање снаге фотонапонских система. TFT комбинује LSTM слојеве са интерпретабилним механизмима пажње заснованим на трансформеру са више глава, ради обухватања дугорочних зависности.

Чак 8 оптимизатора упоређено је у [34]. Аутори су одабрали Nadam као најбољи према својој методологији, али RMSProp и Adam дали су прилично сличне резултате, а Adamax и SGD такође задовољавајуће.

У [35], варијациони аутоенкодер (енгл. *Variational AutoEncoder – VAE*) упоређен је са низом других метода. Аутоенкодери уче како да компримују улазне податке уз задржавање најважнијих информација минимизовањем грешке реконструкције између декодираног и оригиналног улаза; они врше предвиђање путем смањења димензионалности. Варијациони аутоенкодери у стању су да реше проблем прекомерног прилагођавања (енгл. *overfitting*) у конвенционалним АЕ и да ефикасно обрађују различите врсте сложених података.

Аутори [37] креирали су хибрид GCN-а и информера. GCN се користи за издвајање обележја, при чему се узимају у обзир обележја суседних чворова. Информер се истиче у обухватању дугорочних зависности и генерисању предвиђања за више корака унапред. Матрица повезаности (енгл. *adjacency matrix*) у GCN-у генерише се на основу података из информеровог механизма пажње; зато је хибрид у стању да обухвати динамичке односе.

Економски аспекти прогнозирања за једну и више локација анализирани су у [38]. Аутори су дефинисали специфичну метрику названу економски приход (енгл. *Economic Revenue – ER*), која процењује економске последице грешака у прогнози; та метрика зависи од тржишне цене и казни. Упоредили су 12 различитих модела и њихов закључак је да избор оптималног модела зависи од постављеног циља. Ако је циљ тачна прогноза, RF и LSTM су најбољи; али ако је циљ профит, физички и LSTM су најбољи.

Идеја у [39] је да се направи ансамбл LSTM-а и информера да би се постигла добра тачност и за краткорочне и за средњорочне прогнозе, пошто је LSTM бољи за краткорочне, а информер за средњорочне прогнозе. Аутори користе слаб метамодел, LR, да би избегли прекомерно прилагођавање излазних резултата. Такође предлажу унакрсну валидацију временских серија, побољшање које решава потенцијални проблем у k -струкој унакрсној валидацији (енгл. *k-fold cross-validation*).

У [40], предложен је хибрид варијационе декомпозиције мода (енгл. *Variational Mode Decomposition – VMD*, тј. разлагања по модовима на основу варијација), метахеуристике оптимизације колоније мравца (енгл. *Ant Colony Optimization – ACO*) и две FitNet неуронске мреже. VMD се користи за декомпозицију високо флукутирајућих оригиналних података на

релативно стабилне компоненте. АСО метахеуристика није употребљена за оптимизацију хиперпараметара, већ као екстерни оптимизатор параметара модела.

Слике неба користе се у [41] и обрађују помоћу комбинације Vision Transformer-а (ViT), два GRU-а и MLP-а, укључујући и додатне CNN слојеве. Просторне карактеристике издвајају се помоћу CNN-а и ViT-а, а темпоралне карактеристике помоћу GRU-а. Историјски подаци о снази фотонапонских система и егзогени подаци обрађују се у одвојеним неуронским мрежама пре него што се споје за коначну прогнозу.

Хибрид NARXNN-а и LSTM-а користи се у [42] и за детерминистичко и за пробабилистичко предвиђање, и упоређен је са чак 25 других модела. NARXNN је употребљен за израчунавање вектора корекције грешке резидуала, а тај вектор служи као један од улаза у LSTM да би се смањила осетљивост мреже на темпоралне зависности.

У [43], временски променљива филтерско-емпиријска декомпозиција мода (енгл. *Time-Varying Filter-Empirical Mode Decomposition – TVF-EMD*) употребљена је за поделу података о фотонапонској снази у стабилније и константније подсерије. Као модел за прогнозирање користи се екстремна машина за учење (енгл. *Extreme Learning Machine – ELM*).

Аутори рада [44] креирали су хибрид временске конволуционе мреже (енгл. *Temporal Convolutional Network – TCN*), ефикасне мреже пажње канала (енгл. *Efficient Channel Attention Network – ECANet*) и GRU-а. TCN слојеви користе се за издвајање просторних обележја, а ECA модули убацују се у TCN блокове да би се побољшале њихове могућности обухватања обележја. GRU генерише коначну прогнозу.

Регионално прогнозирање истражено је у [45] помоћу динамичке конволуционе мреже усмерених графова (енгл. *Dynamic Directed Graph Convolution Network – DDGCN*), која је хибрид DGCN-а и LSTM-а са пажњом. Свака фотонапонска електрана представљена је чвором на графу, а историјски подаци о фотонапонској снази за електрану представљају обележје тог чвора. Због усмереног кретања облака, односи између електрана су асиметрични, тако да модел мора да обухвати асиметричну и динамичку просторно-временску корелацију између локација. За разлику од обичног GCN-а, DGCN може да обрађује усмерене графове. LSTM са пажњом конструише асиметрична суседства која се мењају током времена. Поред тога, електране су груписане у географске кластере поступком k -средњих вредности, и ти кластери користе се као виртуелне електране при прогнозирању.

У [46], Bi-LSTM, GRU и 1D-CNN упоређени су кроз 2 сценарија: са и без ноћних података. Скоро све метрике нешто су боље ако се употребљавају ноћни подаци.

Једини рад међу прегледаним који истражује трансфер учења (енгл. *Transfer Learning – TL*) је [47]. Трансфер учења може бити посебно користан за новоизграђене фотонапонске електране за које недостају историјски подаци. Аутори упоређују 6 метода за трансфер учења и предлажу нову методу машинског учења названу *Constrained LSTM (C-LSTM)*. Физичка ограничења извлаче се из претходног знања о домену помоћу kNN-а и укључују у обуку C-LSTM модела преко казненог дела функције губитка.

Аутори рада [48] истражују значај избора улазних обележја и предлажу додавање обележја израчунатих на основу физичког модела фотонапонског панела. Они упоређују 8 метода машинског учења помоћу 5 скупова обележја и закључују да укључивање егзогених података побољшава тачност. Такође сугеришу да избор обележја и избор модела имају велики утицај на резултате прогнозирања.

У [49], предложен је ансамбл који се састоји од 4 различита LSTM-а као основних модела и SVR-а као метамодела. Различити основни модели постижу најбоље метрике на свакој од 3 коришћене електране, али разлике између појединачних основних модела нису ни конзистентне ни значајне. С друге стране, ансамбл побољшава RMSE до 5% у поређењу са најбољим основним моделом.

Хибрид CNN-а и LSTM аутоенкодера предложен је у [50] и упоређен са 4 друге методе машинског учења. Резултати наглашавају побољшање тачности када се метеоролошки подаци користе поред историјских података о фотонапонској снази.

3.3 Резултати анализа


У овом одељку дати су резултати анализа прегледаних радова у односу на различите факторе.

3.3.1 Категорије радова

Прегледани радови могу се класификовати у 4 категорије, или главне врсте, приказане у ТАБ. 8 и на СЛ. 45. Више од половине, тј. 27 од 50 радова (54%), предлаже нову, побољшану методу машинског учења, креирану модификовањем постојећих метода и/или њиховим спајањем у хибридна решења.

ТАБ. 8: Категорије прегледаних радова

Категорија радова	Број радова	Радови
Побољшана метода машинског учења	27 (54%)	[3], [5], [6], [8], [11], [12], [18], [20], [21], [23], [24], [25], [27], [28], [30], [32], [37], [39], [40], [41], [42], [43], [44], [45], [47], [49], [50]
Метода машинског учења без модификација	11 (22%)	[2], [9], [13], [19], [22], [26], [29], [33], [34], [35], [36]
Поређење различитих метода машинског учења и других метода	10 (20%)	[1], [4], [7], [10], [16], [17], [31], [38], [46], [48]
Искључиво методе које нису машинско учење	2 (4%)	[14], [15]



СЛ. 45: Категорије прегледаних радова

Друга категорија садржи 11 радова (22%) који користе методе машинског учења без модификација. (Неке од примењених метода прилично су напредне, нпр. у [33] и [35], али такви радови ипак су уврштени у ту категорију зато што у њима није предложена никаква модификација методе познате од раније.) Међутим, радови у тој категорији теже постизању побољшања на друге начине, нпр. кроз бољи избор улазних обележја, предобраду и/или накнадну обраду података, оптимизацију хиперпараметара итд., или употребом методе машинског учења која раније није коришћена за прогнозирање снаге фотонапонских система.

Трећа категорија садржи 10 радова (20%) који се фокусирају на поређење различитих метода машинског учења међусобно и/или са методама које нису машинско учење. Та категорија садржи само радове који пореде методе на равноправној основи, а не радове који наглашавају

једну методу и упоређују је са другим ради провере перформанси – такви радови налазе се у осталим категоријама.

Прве три категорије садрже укупно 48 радова (96%) који користе машинско учење на различите начине, за разлику од само 2 рада (4%) у последњој категорији, који примењују искључиво решења која нису машинско учење. (Још 3 рада упоређују машинско учење са физичким методама или анализирају хибриде машинског учења и физичких метода, [7], [18] и [38], али пошто ти радови користе и машинско учење, наведени су у претходним категоријама.) Истраживачи посматране области фокусирани су на машинско учење до те мере да су конвенционалне методе маргинализоване. Физичке методе, некада доминантне за предвиђања фотонапонске снаге, данас су готово „изумрле” као самостална решења.

У описаној класификацији, физичке методе разликоване су од података заснованих на физици; типови улазних података у прегледаним радовима наведени су у посебном одељку. Пошто податке о нумеричком предвиђању времена (NWP) обично пружају спољне агенције, модели машинског учења који користе NWP у овом прегледу не третирају се као хибриди машинског учења и физичких метода. Само у једном од прегледаних радова аутори сами израчунавају NWP [7]. У сваком случају, са становишта машинског учења, NWP представља само податке. Те податке обично пружа неки спољни ентитет, а процес креирања NWP је „у облаку”, ирелевантан за примењену методу машинског учења. Физичким методама сматране су једино методе које у предложеним решењима пружају прогнозе само израчунавањем формула заснованих на физици.

Што се тиче последње категорије, оба рада баве се физичким методама. Један од њих истражује моделирање фотонапонских модула [14], а други индиректно предвиђање (прво ирадијансе а затим фотонапонске снаге) путем ланаца физичких модела [15].

3.3.2 Методе прогнозирања

ТАБ. 9 и СЛ. 46 сумирају методе машинског учења и друге методе прогнозирања које се користе у прегледаним радовима. Из радова који предлажу и/или наглашавају једну методу, наведена је само та метода, док остале методе прогнозирања које су употребљене за поређење нису наведене. С друге стране, када рад не наглашава једну методу, већ пружа поређење више метода на равноправној основи, наведене су све упоређене методе прогнозирања. Хибридне методе наведене су у више од једног реда у табели, нпр. CNN-LSTM уврштен је и у категорију „Модификовани или хибридни CNN” и у „Модификовани или хибридни LSTM”. Сходно томе, неколико радова појављује се у табели више пута – укупан број референци у табели је 125. Ради једноставности, методе наслаганог ансамбла са метамоделом и слична решења наведене су као хибриди.


Најчешће коришћена метода прогнозирања, како у основном облику, тако и као модификовано или хибридно решење, јесте дуго краткорочно памћење (енгл. *Long Short-Term Memory* – LSTM). То је сасвим очекивано када се има у виду способност LSTM-а да меморише дугорочне зависности, избегавајући проблем нестајућег градијента. Такве особине веома су пожељне када се ради са временским серијама. Наравно, LSTM није „свемогућ” – није погодан за све ситуације, све врсте улазних података, итд. Неки аутори известили су да LSTM није довео до побољшања у односу на једноставније методе, а у неким радовима чак је постигао најлошије резултате од свих упоређених метода [10], [17]. Вероватни узроци могли би бити неодговарајући подаци или субоптималне вредности хиперпараметара: као и све неуронске мреже, LSTM захтева пажљиву оптимизацију хиперпараметара.

Рекурентна јединица са капијама (енгл. *Gated Recurrent Unit* – GRU), будући да је нешто једноставнија и стога мање рачунски захтевна од LSTM-а, при чему задржава његове квалитете, може се сматрати за „звезду у успону”. Те две методе заједно чине рекурентне неуронске мреже (RNN) убедљиво најпопуларнијом групом метода прогнозирања.

ТАБ. 9: Методе прогнозирања у прегледаним радовима

Категорија метода	Број референци	Референце
LSTM	10	[2], [9], [10], [16], [17], [22], [34], [36], [38], [48]
Модификовани или хибридни LSTM	18	[3], [11], [16], [20], [23], [24], [25], [28], [32], [33], [39], [42], [45], [46], [47], [48], [49], [50]
GRU	1	[46]
Модификовани или хибридни GRU	6	[8], [27], [28], [30], [41], [44]
Укупно засноване на RNN-у	35 (28%)	
DT	3	[4], [10], [17]
RF	7	[1], [4], [10], [17], [19], [38], [48]
Модификовани или хибридни RF	1	[6]
GB	3	[4], [31], [38]
XGBoost	2	[4], [17]
Модификовани или хибридни XGBoost	2	[6], [23]
Укупно засноване на DT-у	18 (14,4%)	
CNN	4	[26], [32], [46], [48]
Модификовани или хибридни CNN	9	[8], [11], [21], [28], [32], [41], [48], [49], [50]
Модификовани или хибридни TCN	2	[5], [44]
Модификовани или хибридни GCN	3	[25], [37], [45]
Укупно засноване на конволуцији	18 (14,4%)	
MLP	9	[1], [4], [10], [13], [16], [17], [18], [29], [38]
Модификовани или хибридни MLP	6	[7], [12], [18], [23], [25], [41]
Укупно засноване на MLP-у	15 (12%)	
SVR	7 (5,6%)	[1], [4], [10], [31], [38], [48], [49]
LR	5 (4%)	[1], [4], [10], [29], [38]
Модификовани или хибридни трансформер	3	[25], [33], [41]
Модификовани или хибридни информер	2	[37], [39]
Укупно засноване на трансформеру	5 (4%)	
kNN	1	[4]
Модификовани или хибридни kNN	2	[7], [47]
Укупно засноване на kNN-у	3 (2,4%)	
Остале методе МУ	10 (8%)	[4], [6], [10], [16], [31], [35], [38], [40], [43], [48]

Категорија метода	Број референци	Референце
ARMA и њене варијанте	3	[16], [31], [38]
Остале статистичке	1	[7]
Укупно статистичке	4 (3,2%)	
Ланци физичких модела	3	[15], [18], [38]
Различити модели ФН модула	1	[14]
Детерминистички модели са повећавањем скале	1	[7]
Укупно физичке	5 (4%)	



Сл. 46: Методе прогнозирања у прегледаним радовима

Друго место деле методе засноване на стаблима одлучивања и методе засноване на конволуцији. Стабла одлучивања (енгл. *Decision Trees – DT*), нарочито случајна шума (енгл. *Random Forest – RF*) и екстремно појачавање градијента (енгл. *eXtreme Gradient Boosting – XGBoost*), представљају најпопуларнију групу метода прогнозирања изван велике породице разних неуронских мрежа. Бројни аутори (нпр. [1], [10], итд.) тврде да метода RF пружа тачне прогнозе и да је мање осетљива на лош квалитет или малу количину података. Једна од предности те методе је брзо тренирање, али пати од спорог прогнозирања.

Методе прогнозирања засноване на конволуцији, посебно конволуционе неуронске мреже (CNN), добро су познате из проблема обраде слика. Захваљујући коришћењу операције конволуције и слојева за сажимање (енгл. *pooling layers*), такве методе имају могућност да поједноставе податке уз задржавање најважнијих обележја. Посебно су корисне за обухватање просторних зависности, и зато се често примењују за прогнозе засноване на сликама. Штавише, неки аутори користе такве методе да обухвате зависности између суседних фотонапонских електрана, нпр. [5], [25].

Вишеслојни перцептрон (енгл. *MultiLayer Perceptron – MLP*), који неки аутори називају потпуно повезана неуронска мрежа (енгл. *Fully Connected NN – FCNN*) или чак, превише уопштено, вештачка неуронска мрежа (енгл. *Artificial NN – ANN*), представља другу најпопуларнију методу (иза LSTM-а) ако се узме у обзир само основни облик. Предности те методе су једноставност и мањи рачунарски захтеви него код већине других неуронских мрежа. У прегледаним радовима постоји неколико решења која садрже појединачне потпуно повезане слојеве (нпр. као излазни слој целог модела или његовог дела), али пошто се не ради о више слојева, такве методе нису рачунате као хибридни MLP.

Остале методе машинског учења које се појављују у већем броју радова су регресија вектора подршке (енгл. *Support Vector Regression – SVR*, 7 радова), линеарна регресија (енгл. *Linear*

Regression – LR, 5 радова), решења заснована на трансформеру (5 радова) и метода *k*-најближих суседа (енгл. *k-Nearest Neighbors – kNN*, 3 рада). Чак 10 метода прогнозирања јавља се у само по 1 раду у овом прегледу; такви радови наведени су у категорији „Остале методе машинског учења”.

Списак закључују укупно 4 рада који користе статистичке методе („варијанте ARMA” су ARIMA, SARIMA, SARIMAX и друге сличне методе) и укупно 5 радова који анализирају физичке методе, углавном ланце физичких модела.

У ТАБ. 10 приказан је резиме метода прогнозирања које су произвеле *nRMSE* мањи од 2% у прегледаним радовима. Ако се у раду користи више од једне методе, узима се у обзир само она која је постигла најбољи *nRMSE*. Као и у претходној табели, хибридне и ансамбл методе наведене су у више редова. Треба нагласити да су само две методе у табели у основном облику, тј. без модификације или хибридизације. Према тој анализи, LSTM, GRU и решења заснована на конволуцији обично дају најбољу тачност.

ТАБ. 10: Методе прогнозирања које су произвеле *nRMSE* < 2%

Категорија метода	Број референци	Референце
Модификовани или хибридни LSTM	5	[3], [11], [33], [42], [50]
Модификовани или хибридни GRU	3	[8], [30], [44]
Укупно засноване на RNN-у	8 (42,11%)	
Засноване на стаблима одлучивања	1 (5,26%)	[6]
CNN	1	[32]
Модификовани или хибридни CNN	4	[8], [11], [21], [50]
Модификовани или хибридни TCN	1	[44]
Укупно засноване на конволуцији	6 (31,58%)	
MLP	1 (5,26%)	[17]
Модификовани или хибридни трансформер	1 (5,26%)	[33]
Остале методе машинског учења	2 (10,53%)	[6], [40]

3.3.3 Врсте прогнозирања у погледу одређености резултата

Врсте предвиђања у погледу одређености резултата које се могу наћи у прегледаним радовима су детерминистичко, пробабилистичко (вероватносно) и сценаријско предвиђање. Код детерминистичког предвиђања (такође познатог као предвиђање једне тачке, једне вредности, најбоље претпоставке), предвиђа се само једна вредност („тачка”) по циљном тренутку. Код пробабилистичког предвиђања (такође познатог као дистрибутивно или ансамблско), уместо одређене вредности, прогноза се даје као расподела вероватноће циљне променљиве, у облику густине, квантила, интервала и сл.

У сценаријском прогнозирању, резултати прогнозе су вишеструки потенцијални будући исходи, тј. сценарији. Као што је приказано у ТАБ. 11, међу прегледаним радовима постоје 4 рада (8%) који анализирају пробабилистичко прогнозирање и 1 рад (2%) који користи сценаријско прогнозирање, тј. анализу сценарија. Тих 5 радова такође дају и резултате детерминистичког прогнозирања. Преосталих 45 радова (90%) примењује само детерминистичко прогнозирање.

ТАБ. 11: Врсте предвиђања по одређености резултата у прегледаним радовима

Врста предвиђања	Број радова	Радови
Пробабилистичко предвиђање	4 (8%)	[15], [20], [21], [42]
Сценаријско предвиђање	1 (2%)	[28]
Само детерминистичко предвиђање	45 (90%)	сви остали

3.3.4 Обухвати прогноза

Према обухватима датих прогноза, прегледани радови могу се класификовати као што је приказано у ТАБ. 12. Радови [14] и [17] дају прогнозе за један фотонапонски модул. Радови [25] и [38] баве се прогнозама за више локација, тј. заједничким прогнозама за групе географски блиских фотонапонских електрана; оба рада такође анализирају прогнозе за појединачне електране. Радови [7] и [45] дају прогнозе за целе регионе.

ТАБ. 12: Обухвати прогноза у прегледаним радовима

Обухват	Број радова	Радови
Модул	2 (4%)	[14], [17]
Група електрана	2 (4%)	[25], [38]
Регион	2 (4%)	[7], [45]
Једна електрана	44 (88%)	сви остали

Сви остали радови (44 рада, одн. 88%) анализирају прогнозе за појединачне локације, тј. за једну фотонапонску електрану. Неки радови користе податке из суседних електрана да би побољшали резултате [5], [31], али циљ је и даље једна локација – њихове прогнозе дате су за појединачне фотонапонске електране.


3.3.5 Количине података

За методе вођене подацима, као што и само име имплицира, квалитет и довољна количина података суштински су важни. Код малих скупова података постоји ризик да нису довољно репрезентативни, што доводи до недовољног обучавања модела, док велики скупови података захтевају више обраде. Ипак, број записа коришћених у прегледаним радовима варира од само 335 [1] до скоро 1,6 милиона [35]. Број скупова података и записа у њима одређен је узимајући у обзир обухват прогнозе, тј. да ли се прогноза даје за модул, једну електрану, групу електрана или регион. Нпр. ако рад даје прогнозе за 5 појединачних фотонапонских електрана и користи заједнички скуп података са по 10 000 записа за сваку од тих електрана, у овој анализи то се броји као један скуп података са 10 000 записа, иако их заправо има 50 000. Међутим, ако би тај рад давао само збирну прогнозу за свих 5 електрана, број записа у том скупу података у овој анализи био би 50 000.

Анализира се број записа након предобраде, зато што је то број записа који се користи за обуку и тестирање модела. За неке радове, број записа емпиријски је процењен, првенствено због уклањања ноћних записа. Број записа по скупу података дат је у ТАБ. 13 и на сл. 47. Од 50 прегледаних радова, 5 користи скупове података са мање од 2 000 записа: [1], [6], [8], [27] и [34]. Скоро половина анализираних скупова података садржи између 10 000 и 49 999 записа. Просечан број записа у коришћеним скуповима података износи 104 431, али медијана је много мања – 32 160.

ТАБ. 13: Број записа по скупу података у прегледаним радовима

Број записа	Број скупова података	Процент
мање од 2 000	5	8%
2 000 до 9 999	8	13%
10 000 до 49 999	30	49%
50 000 до 99 999	7	12%
100 000 до 499 999	8	13%
500 000 и више	3	5%



Сл. 47: Број записа по скупу података у прегледаним радовима

Ова анализа не узима у обзир утицај техника као што су k -струка унакрсна валидација (која је веома корисна код малих количина података) и клизни прозори, које се користе у бројним прегледаним радовима. Међутим, општа препорука о величини скупа података сасвим је очигледна из табеле и са слике.

ТАБ. 14 приказује статистику у вези са величинама скупова података груписаних по методама прогнозирања. Табела је сортирана по просечном броју записа, опадајућим редоследом. Нпр. ред „Заснована на конволуцији” укључује CNN, GCN, TCN и њихове хибриде, „Заснована на трансформеру” такође укључује информер и хибриде оба, „Заснована на LSTM-у” укључује основну, модификоване и хибридне варијанте, итд. Очигледно је да су скоро све методе коришћене и за мале и за велике скупове података – ниједна од метода не истиче се као специјализована или неприкладна за неку категорију величине.

ТАБ. 14: Статистички подаци о величинама скупова података по методама прогнозирања

Категорија метода	Број скупова података	Мин.	Макс.	Просек	Медијана
VAE	2	35 040	1 578 240	806 640,00	806 640
Засноване на трансформеру	8	5 848	966 711	145 011,88	26 400
Физичке	5	11 837	525 600	126 776,60	31 579
Засноване на конволуцији	20	1 746	966 711	114 722,30	35 088
ARMA и сличне	4	3 640	157 248	59 902,00	39 360
Засноване на LSTM-у	32	366	420 768	58 712,94	32 640
SVR	8	335	157 248	53 519,00	33 330
Засноване на GRU-у	9	1 096	210 528	53 471,11	20 952
Засноване на RF-у	7	335	131 616	34 655,29	19 728
LR	6	335	105 792	32 110,67	21 998,5
Засноване на MLP-у	15	335	105 792	28 464,13	29 232
Засноване на XGBoost-у	3	1 461	49 247	28 402,67	34 500
Засноване на kNN-у	3	17 520	34 500	23 916,00	19 728

Изузимајући VAE, који се појављује само у једном раду [35], просечан број записа највећи је за методе засноване на трансформеру, а затим следе физичке и методе засноване на конволуцији. У следећој групи сличних просека су ARMA, LSTM, SVR и GRU. Групу метода са најмањим просецима чине RF, LR, MLP, XGBoost и kNN. С друге стране, медијана је релативно слична за већину метода. Треба споменути да су статистике за LSTM и GRU сличне, што је очекивано.


3.3.6 Временске резолуције података

Још један важан аспект података је њихова временска резолуција или грануларност, тј. временски интервал између узастопних записа у улазним подацима. Грануларност података јасно утиче не само на грануларност резултата, већ и на оствариве хоризонте прогнозе, при чему су та два циља супротстављена. Штавише, временска резолуција је један од главних фактора од којих зависи број записа у скуповима података, а самим тим и простор потребан за складиштење, као и време обраде. Скупови података не појављују се *ex nihilo* – сви ти подаци морају бити измерени, снимљени, израчунати или прикупљени на неки други начин, анализирани, предобрађени, сачувани, итд. Очигледно је да треба направити компромис између потребних ресурса и жељене временске резолуције, с обзиром на практичне потребе.

У неким од прегледаних радова, временска резолуција сирових података мења се током предобраде да би се олакшала прорачуни. У таквим случајевима анализира се резолуција након предобраде, зато што се та резолуција користи за обуку и тестирање модела. Нпр. у [16], интервал између узорака у оригиналним (сировим) подацима је 15 минута, али за обуку и тестирање примењују се просеци за 1 сат; због тога, резолуција тих података у овој анализи је 1 сат.

ТАБ. 15: Временске резолуције улазних података у прегледаним радовима

Временска резолуција	Број радова	Радови
1 мин	3 (5%)	[14], [26], [35]
5 мин	11 (18,33%)	[5], [10], [17], [24], [30], [31], [41], [42], [44], [46], [48]
15 мин	18 (30%)	[1], [2], [4], [8], [11], [15], [18], [20], [21], [22], [23], [25], [29], [31], [32], [35], [36], [45]
30 мин	1 (1,67%)	[50]
1 сат	20 (33,33%)	[1], [3], [5], [7], [9], [12], [13], [16], [19], [23], [25], [28], [33], [37], [38], [39], [40], [42], [47], [49]
3 сата	3 (5%)	[8], [25], [28]
1 дан	4 (6,67%)	[1], [6], [27], [34]



СЛ. 48: Временске резолуције улазних података у прегледаним радовима

Резиме временских резолуција улазних података приказан је у ТАБ. 15 и на СЛ. 48. Неки радови спомињу се више пута у табели јер користе податке са различитим временским резолуцијама (нпр. различити скупови података, различите врсте података, различити извори података). У неким другим радовима, резолуција се не спомиње и не може се утврдити. Укупан број референци у табели је 60. Очигледно је да је најчешћа временска резолуција која се примењује

у прегледаним радовима 1 сат (коришћена у 20 радова), затим 15 минута (18 радова) и 5 минута (11 радова).

3.3.7 Хоризонти прогнозе

Поред тачности, хоризонт прогнозе (тј. временска удаљеност у будућност за коју се прогноза прави, одн. интервал између тренутка на који се односе последњи одговарајући улазни подаци и тренутка на који се односи прогноза) вероватно је најважнија особина било ког модела који се користи за прогнозирање производње фотонапонских система. Очекивано је да тачност опада са повећањем хоризонта. Типична класификација прогноза по хоризонту у посматраној области истраживања дата је у ТАБ. 16 [2], [34]. Класификација је очигледно прилично широка и разликује се у различитим изворима; у табели су дата два могућа интервала за средњорочне прогнозе, као покушај да се помире те разлике. Фокус је на практичним применама, што узрокује празнине у укљученим хоризонтима. Очигледно је да су различити хоризонти прогнозе оптимални за различите кориснике: оператере мреже, власнике фотонапонских постројења, владе итд.

ТАБ. 16: Класификација прогноза по хоризонту

Категорија прогнозе	Хоризонт	Примене
Веома краткорочна	До 1 сата	Стабилност мреже, регулација снаге и напона („изглађивање”), диспечерски рад у реалном времену
Краткорочна	Од 1 сата до 1 дана	Безбедност мреже, управљање резервама снаге, оптимално ангажовање ресурса, евалуација купопродајних уговора
Средњорочна	Од 7 до 30 дана (или од 30 дана до 1 године)	Оперативно планирање, заказивање одржавања
Дугорочна	Преко 1 године	Планирање електроенергетског система


Радови у којима се хоризонт није могао са сигурношћу одредити, због тога што није споменут или је нејасан или сумњив, изостављени су из ове анализе. С друге стране, као што је већ описано, неки радови појављују се више пута у табелама.

У ТАБ. 17 и на СЛ. 49 приказани су максимални хоризонти прогнозе коришћени у прегледаним радовима, изражени у временским јединицама. Убедљиво најчешћи максимални хоризонт, који се јавља у 18 радова, даје прогнозе за 1 дан унапред. То је сасвим очекивано, с обзиром на то што у многим земљама произвођачи фотонапонске енергије морају да се придржавају захтева тржишта и шаљу своје прогнозе оператерима мреже за 1 дан унапред. Остали појединачни хоризонти које треба споменути су 5 и 15 минута, 1 сат и 7 дана унапред; сви су примењени у по 3 до 4 рада. (Распон од 1,5 до 6 сати садржи 10 радова, али за 7 појединачних хоризоната од којих је сваки коришћен у по 1 до 2 рада.) Табела садржи укупно 49 референци.

Из табеле је такође очигледно да само мали број радова истражује дуге хоризонте. Најдужи хоризонт укључен у ову анализу је 60 дана унапред [34], а само још 2 рада баве се хоризонтима дужим од 7 дана унапред [37], [39]. То се може објаснити чињеницом да се технологија машинског учења, која се користи у великој већини прегледаних радова, сматра неприкладном за дугорочне прогнозе. Такође, може се претпоставити да су се истраживачи фокусирали на дневне потребе произвођача фотонапонских система и оператера мреже. Међутим, дугорочно прогнозирање производње фотонапонских система свакако је област коју треба детаљније испитати у будућим истраживањима.

ТАБ. 17: Максимални хоризонти прогнозе изражени у временским јединицама

Хоризонт	Број радова	Радови
5 мин	3 (6,12%)	[17], [30], [46]
15 мин	4 (8,16%)	[26], [35], [36], [41]
30-45 мин	2 (4,08%)	[43], [44]
1 сат	4 (8,16%)	[8], [21], [24], [49]
1,5-6 сати	10 (20,41%)	[2], [5], [11], [16], [25], [31], [35], [45], [48], [50]
12 сати	1 (2,04%)	[42]
1 дан	18 (36,73%)	[1], [3], [4], [6], [9], [12], [13], [15], [18], [20], [23], [27], [29], [33], [38], [40], [42], [47]
3-7 дана	4 (8,16%)	[1], [5], [7], [28]
10-14 дана	2 (4,08%)	[37], [39]
60 дана	1 (2,04%)	[34]



СЛ. 49: Максимални хоризонти прогнозе изражени у временским јединицама

Што се тиче максималног броја корака унапред, хоризонти прогнозе у прегледаним радовима крећу се од 1 до 336, као што је приказано у ТАБ. 18. Уколико није експлицитно наведен у раду, број корака унапред израчунат је као количник хоризонта прогнозе (израженог као време) и улазне временске резолуције; при томе је претпостављено да је излазна временска резолуција иста као улазна, што је скоро увек случај. Коришћена терминологија не имплицира технике које употребљене израду прогноза за велики број корака унапред; генерално, итеративни приступ није погодан за то због акумулације грешака. Најчешћи појединачни максимални бројеви корака су следећи:

- 24 корака (12 радова, обично за прогнозу за 1 дан унапред са резолуцијом од 1 сата),
- 96 корака (7 радова, обично за прогнозу за 1 дан унапред са резолуцијом од 15 минута), и
- 1 корак (7 радова).

ТАБ. 18: Максимални хоризонти прогнозе изражени бројем корака унапред

Број корака	Број радова	Радови
1	7 (14%)	[6], [17], [27], [30], [36], [46], [49]
3-9	8 (16%)	[1], [2], [8], [16], [21], [41], [44], [50]
12-16	6 (12%)	[11], [24], [26], [31], [35], [45]
24	12 (24%)	[1], [3], [9], [12], [13], [23], [25], [33], [38], [40], [42], [47]
48-72	5 (10%)	[5], [7], [31], [34], [48]
96	7 (14%)	[1], [4], [15], [18], [20], [23], [29]
144-336	5 (10%)	[5], [28], [37], [39], [42]

Највећи број корака, 336 [39], одговара прогнози за 14 дана унапред са резолуцијом од 1 сата. Свега још 4 рада баве се прогнозама за више од 100 корака унапред: 144 [42], 168 [5], [28] и 240 корака [37]. То је очекивано, пошто тачност скоро увек опада са повећањем броја корака унапред. Као што је већ описано, неки радови нису наведени у табели, док су неки споменути више пута; међутим, ненамерно се испоставило да је укупан број референци у табели једнак укупном броју прегледаних радова, тј. 50.

У ТАБ. 19 представљен је резиме свих (не само максималних) хоризоната прогнозе коришћених у прегледаним радовима. Мотивација за такву табелу лежи у чињеници да максимални хоризонти сами за себе не представљају у потпуности ширину истраживања. Већина радова даје резултате само за један хоризонт или за неколико дискретних хоризоната, али неки истражују утицај различитих хоризоната у широким интервалима, нпр. од 5 минута до 6 сати са кораком од 5 минута [5], од 1 сата до 10 дана са кораком од 1 сата [37], или 8 дискретних хоризоната у распону од 1 сата до 14 дана [39]. Радови који се појављују у неколико редова табеле дају резултате за шири скуп хоризоната. У табели је наведено укупно 97 референци.

Још једна информација која се није могла видети из претходних табела јесте да неки радови истражују прогнозе са веома кратким хоризонтима, познатим као *nowcasts* [26], [35]. Као и у претходним табелама, најчешћи појединачни хоризонти су 1 дан (јављају се у 22 рада), 1 сат (16 радова) и 15 минута унапред (14 радова). Само 7 радова укључених у ову анализу истражује хоризонте прогнозе дуже од 1 дана унапред.

ТАБ. 19: Укључени хоризонти прогнозе изражени у временским јединицама

Хоризонт	Број радова	Радови
< 5 мин	2 (2,06%)	[26], [35]
5-10 мин	8 (8,25%)	[5], [17], [30], [35], [41], [42], [44], [46]
15 мин	14 (14,43%)	[1], [2], [5], [11], [20], [23], [25], [26], [31], [35], [36], [41], [44], [45]
20-55 мин	8 (8,25%)	[5], [11], [25], [35], [43], [44], [45], [50]
1 сат	16 (16,49%)	[1], [5], [8], [11], [16], [21], [23], [24], [25], [35], [37], [39], [42], [45], [49], [50]
65 мин – 6 сати	14 (14,43%)	[2], [5], [9], [11], [16], [25], [31], [35], [37], [39], [42], [45], [48], [50]
7-23 сата	4 (4,12%)	[9], [37], [39], [42]
1 дан	22 (22,68%)	[1], [3], [4], [5], [6], [7], [9], [12], [13], [15], [18], [20], [23], [27], [29], [33], [37], [38], [39], [40], [42], [47]
25 сати – 7 дана	6 (6,19%)	[1], [5], [7], [28], [37], [39]
10-14 дана	2 (2,06%)	[37], [39]
30-60 дана	1 (1,03%)	[34]

ТАБ. 20: Методе прогнозирања коришћене за 96 или више корака унапред у више од једног рада

Категорија метода	Број радова	Радови
Засноване на MLP-у	5	[1], [4], [18], [23], [29]
Засноване на LR-у	4	[1], [4], [29], [39]
Засноване на LSTM-у	4	[20], [23], [39], [42]
Засноване на конволуцији	3	[5], [28], [37]
Физичке	3	[5], [15], [18]
Засноване на информеру	2	[37], [39]
RF	2	[1], [4]
SVR	2	[1], [4]
Засноване на XGBoost-у	2	[4], [23]


У ТАБ. 20 дат је списак метода прогнозирања које се користе за 96 или више корака унапред у више од једног рада. Хибридна и ансамбл решења у тој табели су разложена на појединачне методе; нпр. ред „заснована на LSTM-у” садржи ставке не само за основну методу, већ и за модификована и хибридна решења. Методе засноване на конволуцији (CNN, GCN и TCN) спојене су у табели.

Донекле је изненађујуће што је LR, најједноставнија метода од свих наведених у табели, и генерално не баш прецизна, на деоби другог места. Можда је популарна у таквим ситуацијама због своје брзине. У [39], та метода користи се као слаб метамодел у стекованом ансамблу. Познато је да су физичке методе погодне за дуже хоризонте. Информер се појављује у 2 рада у табели, али управо та 2 рада дају прогнозе за највећи број корака унапред. Све методе које су примењене за више од 100 корака унапред представљају хибридна или ансамбл решења:

- наслагани ансамбл LSTM-а и информера као основних модела и LR-а као метамодела – 336 корака унапред [39]
- хибрид GCN-информер – 240 корака унапред [37]
- хибрид GRU-CNN – 168 корака унапред [28]
- хибрид TCN-физички – 168 корака унапред [5]
- хибрид NARX-LSTM – 144 корака унапред [42].

3.3.8 Врсте улазних података

Различите врсте улазних података коришћене у прегледаним радовима наведене су у ТАБ. 21 и на СЛ. 50.



СЛ. 50: Врсте улазних података у прегледаним радовима

Пошто је излазна снага фотонапонских модула циљна променљива у свим прегледаним радовима, историјске вредности те променљиве користе се у свим радовима у којима је имплементирано машинско учење бар за минимизовање грешака током обуке, а често и као улазно обележје. Примењене су чак и у једном од два прегледана рада у којима се не користи машинско учење, за сличну сврху – калибрацију ланаца физичких модела [15]. Рад у ком се израчунава излаз појединачних фотонапонских модула [14] једини је у ком се не спомиње употреба фотонапонске снаге као улазног обележја и/или за оптимизовање поступка.

Следећих 8 радова (16%) користи историјске временске серије фотонапонске снаге као једини улаз у модел машинског учења: [2], [11], [16], [20], [35], [43], [45], [46]. С друге стране, неки аутори свесни су да историјски подаци о снази фотонапонских система нису доступни за потпуно нове електране и стога покушавају да минимизују њихову употребу.

Енергија примљена од Сунца неопходна је за производњу фотонапонске снаге, стога је сасвим разумно узети је у обзир у моделу за прогнозирање такве производње. Од 50 прегледаних радова, 38 (76%) користи барем једну улазну променљиву повезану са том енергијом, обично

неку врсту ирадијансе (тренутне снаге сунчевог зрачења по јединици површине, изражене у W/m^2), или понекад ирадијацију (укупну енергију сунчевог зрачења по јединици површине током временског периода, изражену у J/m^2 или Wh/m^2 , тј. снагу примљену током одређеног времена).

ТАБ. 21: Врсте улазних података у прегледаним радовима

Врста података	Број радова	Радови
Фотонапонска снага	49 (98%)	сви осим [14]
Ирадијанса и слично	38 (76%)	[3], [4], [5], [6], [7], [8], [9], [10], [12], [13], [14], [15], [17], [18], [19], [22], [23], [24], [25], [27], [28], [29], [30], [32], [33], [34], [36], [37], [38], [39], [40], [41], [42], [44], [47], [48], [49], [50]
Облачност	14 (28%)	[1], [3], [8], [9], [13], [19], [27], [28], [29], [31], [38], [40], [42], [47]
Температура ваздуха	38 (76%)	[1], [3], [4], [5], [6], [7], [8], [9], [10], [12], [13], [14], [15], [17], [18], [19], [22], [23], [24], [25], [27], [28], [29], [30], [32], [33], [34], [37], [38], [39], [40], [41], [42], [44], [47], [48], [49], [50]
Температура модула	10 (20%)	[5], [6], [8], [14], [17], [24], [29], [32], [39], [48]
Остали метеоролошки подаци	34 (68%)	[1], [3], [4], [6], [8], [9], [10], [12], [13], [14], [15], [17], [18], [19], [22], [23], [24], [27], [28], [29], [30], [32], [33], [34], [36], [37], [38], [39], [40], [41], [42], [44], [47], [48]
Профил времена	2 (4%)	[21], [49]
Датум и време	16 (32%)	[1], [3], [6], [9], [13], [19], [23], [31], [34], [37], [38], [40], [41], [42], [48], [49]
Соларни углови	6 (12%)	[4], [12], [18], [31], [33], [38]
Слике неба са земље	2 (4%)	[26], [41]
Сателитске слике	1 (2%)	[31]
Остало	3 (6%)	[31], [37], [42]

Ирадијанса се најчешће изражава као глобална хоризонтална ирадијанса (енгл. *Global Horizontal Irradiance* – GHI) или директна нормална ирадијанса (енгл. *Direct Normal Irradiance* – DNI). Међутим, за прогнозирање фотонапонске снаге, вероватно најбоља верзија је ирадијанса равни низа (енгл. *Plane of Array* – POA, тј. укупна соларна ирадијанса коју прими фотонапонски панел, а која долази од директног, дифузног и зрачења рефлектованог од тла), ако је доступна. Неки аутори користе ирадијансу ведрога неба (енгл. *Clear-Sky Irradiance* – CSI); нпр. у [28], CSI се израчунава на основу датума, времена и географске локације. Иста скраћеница у неким радовима, нпр. [18], означава индекс ведрога неба (однос стварне ирадијансе и ирадијансе ведрога неба).

Слични изрази постоје и за ирадијацију. Она се понекад назива радијација (вероватно намерно да би се добиле различите скраћенице, нпр. GHR) или инсолација, а понекад се ирадијанса погрешно назива ирадијацијом.

Различите променљиве које изражавају облачност користе се у 14 прегледаних радова (28%). Неки аутори примењују прецизне индикације облачности са фином просторно-временском резолуцијом, док други, нпр. [9], узимају у обзир само просечно стање неба током целог дана, од сунчаног до веома облачног. У [27], уместо облачности користи се број сунчаних сати.

Изнаенајујуће је што само 2 рада, [1] и [31], употребљавају облачност уместо ирадијансе; осталих 12 користи их заједно. У [31], облачност се одређује на основу сателитских снимака.

Температура ваздуха (температура амбијента) најчешћа је метеоролошка променљива која се примењује за прогнозирање снаге фотонапонских система – користи се у 38 радова (76%). Температура фотонапонских модула обично има бољу корелацију са циљном променљивом него температура ваздуха, али захтева сензоре на модулима; то је вероватно разлог због ког се примењује у само 10 радова (20%). У неким радовима, нпр. [29], температура модула израчунава се на основу температуре амбијента и ирадијансе.

У чак 34 рада (68%) користе се друге метеоролошке променљиве, нпр. брзина ветра, правац ветра, ваздушни притисак, влажност, падавине итд., што указује на то да већина аутора верује да чак и променљиве које типично имају малу корелацију са циљном могу допринети прогнози. Два рада (4%) употребљавају профил времена или тип дана (нпр. сунчано, слабо кишовито итд.) уместо осталих метеоролошких променљивих или као додатак њима.

Метеоролошке променљиве могу се користити као историјске временске серије и/или као прогнозиране вредности. Таква прогноза добија се помоћу нумеричке прогнозе времена (NWP), обично од јавних агенција. Проблем са NWP прогнозама представља њихова ниска просторно-временска резолуција, што их чини мање употребљивим за краће хоризонте прогнозе и мала географска подручја. Типична учесталост ажурирања износи 3-6 сати, а типична величина подручја 10×10 km или више; стога, таква прогноза не може да обухвати краткотрајне метеоролошке флукуације и локалне појаве.

NWP прогнозе високе резолуције, добијене коришћењем модела са резолуцијама од 15-20 мин и 1 km, обично издају специјализоване компаније и те прогнозе могу бити прилично скупе. Бесплатни NWP подаци најбоље се примењују за средњорочне и дугорочне прогнозе фотонапонске снаге. Ако се морају користити за краће хоризонте прогнозе, мора им се побољшати резолуција скалирањем и морају се комбиновати са подацима из других извора.

Ирадијанса се такође може прогнозирати помоћу слика и снимака, а такве методе споменуте су касније у овом одељку. У [9], синтетичка прогноза ирадијансе генерисана је из историјских података о ирадијанси и јавно доступне прогнозе типа неба.

Променљиве у вези са датумом и временом користе се у 16 радова (32%). Фотонапонска снага очигледно зависи од доба дана и од месеца у години, али да би имали користи од таквих променљивих, истраживачи их прво морају претворити у одговарајући облик. У неким радовима примењују се синусне и косинусне трансформације [33], а у неким чак кодира месец у години помоћу једноактивног (енгл. *one-hot*) кодирања [49], које у том случају производи 12 бинарних променљивих. Међутим, једноставнија решења могу се постићи помоћу одузимања од средњих вредности. У [3], користи се тривијална бинарна променљива која означава дан или ноћ.

Соларни углови, тј. променљиве које описују положај Сунца у односу на фотонапонску електрану или модул, примењени су у 6 радова (12%). Променљиве из те групе које се уобичајено користе су соларна елевација (угао између Сунчевих зрака и хоризонта), соларни азимут (позиција Сунца у односу на север), а понекад и соларна деклинација (угао између Сунчевих зрака и екваторијалне равни Земље). У неким радовима, уместо соларне елевације користи се угао соларног зенита – та два угла су комплементарна. Све променљиве у тој групи могу се израчунати на основу географске локације фотонапонске електране, датума и времена.

Слике и снимци користе се у 3 рада; од тога, у 2 рада (4%) примењују се слике неба са земље, а у 1 раду (2%) сателитске слике. Слике неба са земље омогућавају тачне прогнозе са веома кратким роковима, до 1 сата, али захтевају посебне камере и могу захтевати значајне ресурсе за складиштење и обраду. Међутим, оба рада која користе ту методу извештавају о ниској тачности током веома облачних и кишних дана, делимично зато што кишне капи умањују квалитет слике.

С друге стране, јавно доступни сателитски снимци не нуде довољну просторну резолуцију за прогнозе на нивоу постројења; за релативно мала постројења, они не могу довољно детаљно да прикажу локалну расподелу облака изнад постројења. Такви снимци могу боље послужити за регионалне прогнозе. Штавише, обично имају извесно кашњење и не могу се користити у реалном времену. Проблем ниске просторне резолуције компензован је у [31] употребом података из суседних постројења.

Неки радови користе декомпозицију улазних променљивих, примењујући технике као што су брза Фуријеова трансформација (FFT) [21], декомпозиција пакета таласића (WPD) [30], варијациона декомпозиција мода (VMD) [40] или временски променљива филтерско-емпиријска декомпозиција мода (TVF-EMD) [43]. Помоћу таквих техника, временски низ може се поделити на компоненте које су релативно стабилне и стога их је лакше предвидети.

3.3.9 Предобрада

Значај предобrade (припремне обраде, енгл. *pre-processing*) код метода вођених подацима може се видети из чињенице да је скоро сви прегледани радови описују или барем спомињу. У тој фази типично се изводе следеће операције:

- Решавање недостајућих вредности: обично се попуњавају линеарном интерполацијом или другим врстама интерполације. У [1], користи се покретни просек. У [5], узимају се вредности из записа који корелирају у другим пољима. У [7], записи са недостајућим подацима се уклањају, док се за неке врсте података примењује кубична сплајн интерполација. У неким радовима користе се одговарајуће вредности из сличних дана; нпр. у [23], просек у исто време из претходних дана. Неколико метода импутације недостајућих података описано је и упоређено у [8] и [20]. У [38] и [44], ако недостаје превише података за неки дан, цео тај дан се уклања.
- Детекција и решавање одступајућих вредности (енгл. *outliers*): обично се проналазе помоћу кутијастих дијаграма или сличне анализе и обрађују се слично као недостајуће вредности. У [16], користи се Хампелов филтер. У [30], одступајуће вредности замењују се најближом границом у анализи помоћу кутијастих дијаграма. У [33], примењује се DBSCAN (енгл. *Density-Based Spatial Clustering of Applications with Noise* – просторно груписање апликација са шумом засновано на густини).
- Детекција и решавање других абнормалних вредности, нпр. записа са нултом снагом током дана, записа са негативном снагом и слично, у зависности од коришћених улазних обележја.
- У неким радовима, ноћни записи такође се уклањају, али само ако употребљена метода прогнозирања дозвољава временске дисконтинуитете (нпр. неке статистичке методе их не дозвољавају).
- Скалирање је такође веома важно, зато што осигурава да модели машинског учења третирају сва улазна обележја подједнако, тј. спречава да обележја са већим вредностима доминирају. Најчешћа метода скалирања је *min-max* нормализација у опсег [0, 1], описана једначином (50). Неки радови, нпр. [18], [24], [33], користе стандардизацију, такође названу нормализација *z*-скора (тј. нормализација за нулту средњу вредност и јединичну стандардну девијацију), описану једначином (51). У [10], изведени су експерименти са и без нормализације, а већина метрика много су лошије без нормализације.
- Статистичке анализе, провере конзистентности и квалитета података (нпр. параметри расподеле, корелација итд.)
- Промена узорковања података чија временска резолуција мора бити прилагођена: надузорковање (повећање густине узорака, енгл. *upsampling*) или подузорковање (смањење густине узорака, енгл. *downsampling*).

Предобрада може такође укључивати неке посебне операције у зависности од коришћених података, метода и техника, нпр. обраду слике (исечање, скалирање, поновно узорковање итд.), декомпозицију, кодирање (нпр. једноактивно кодирање, тригонометријске трансформације итд.), изглађивање података [27] и сличне операције.

3.3.10 Вршне снаге

У ТАБ. 22 наведене су величине фотонапонских електрана употребљених у прегледаним радовима, изражене у вршним снагама. У већини радова користе се подаци из једне или малог броја електрана, док се у неким примењују подаци из десетина или чак стотина електрана; нпр. у [25], узети су подаци из 304 стварне и 1000 симулираних електрана. Стога, што се тиче величина електрана, бројани су радови, а не појединачне електране. Неки радови користе електране из различитих распона величина, и сходно томе, појављују се у табели више пута. У неким радовима, вршне снаге посматраних електрана разликују се за више од реда величине (нпр. [4], [5], [15], итд.), чак и преко 50 пута у [43]. Укупан број референци у табели је 53. Радови који се баве само регионалним прогнозама [7], [45] нису укључени у ову анализу.

Табела показује да се у прегледаним радовима користе постројења свих величина, са прилично равномерном расподелом. Анализирана постројења крећу се од микросистема од 500 W [38] до огромног система од 451,82 MW [11]. Просечна величина постројења у овој анализи је око 14,3 MW, али медијана је много мања, 67,5 kW. Међутим, за радове који садрже распоне величина електрана, у тај прорачун укључене су само најмања и највећа вредност, без обзира на број постројења у распону. У радовима који се баве појединачним модулима [14], [17], декларисане снаге модула крећу се од 80 до 305 W.

ТАБ. 22: Вршне снаге фотонапонских електрана коришћених у прегледаним радовима

Вршна снага	Број радова	Радови
< 5 kW	7 (13,21%)	[3], [6], [12], [23], [33], [38], [46]
[5-20] kW	8 (15,09%)	[10], [13], [23], [32], [33], [36], [38], [48]
(20-70) kW	8 (15,09%)	[1], [20], [25], [26], [27], [30], [39], [49]
[100-1000) kW	10 (18,87%)	[4], [5], [15], [18], [20], [29], [34], [35], [40], [42]
[1-20] MW	13 (24,53%)	[4], [5], [8], [15], [16], [18], [22], [28], [35], [41], [42], [43], [50]
> 20 MW	7 (13,21%)	[5], [9], [11], [21], [28], [37], [43]

Што се тиче величина система који су дали nRMSE мањи од 2%, не постоји јасна правилност – у тим радовима користе се различите величине, од једног модула до највећег ФН система.

3.3.11 Избор улазних обележја

Оптимални избор улазних обележја (улазних променљивих, предиктора) побољшава тачност прогнозе и смањује рачунске трошкове везане за обуку и извршавање модела. Пажљиво спроведена истраживачка анализа података (енгл. *Exploratory Data Analysis* – EDA) веома је корисна за избор обележја и израду модела. Нека обележја имају ниску корелацију са циљном (прогнозираном, излазном) променљивом и не доприносе моделу; штавише, могу чак и смањити његову тачност [39]. Обележја са ниском корелацијом могу се детектовати помоћу Пирсоновог коефицијента корелације (одељак 2.7.2) и других сличних показатеља.

С друге стране, међусобне зависности могу се јавити између три или више обележја; та ситуација назива се мултиколинearност (одељак 2.7.3). Обележја са високим међусобним зависностима су сувишна, и нека од њих, или чак сва осим једног, могу и вероватно треба да буду искључена из скупа обележја. Један од начина за откривање мултиколинearности је

помоћу фактора инфлације варијансе (енгл. *Variance Inflation Factor – VIF*), који показује повећање варијансе циљне променљиве ако се неко обележје дода скупу обележја.

Имајући све то у виду, донекле је изненађујуће што је методологија избора улазних обележја описана, или барем споменута, у само 18 (36%) прегледаних радова. Наравно, избор обележја није применљив у радовима где се користи само једно обележје, тј. историјски подаци о снази фотонапонских система; ти радови наведени су у одељку 3.3.8. За остале радове, може се претпоставити да су обележја или емпиријски одабрана, или да су употребљена сва доступна обележја.

На почетку треба споменути 3 рада у којима је фокус на поређењу различитих скупова улазних обележја. У [17], аутори су одабрали 9 обележја на основу прегледа литературе и креирали 20 комбинација тих обележја: 1 са свим укљученим обележјима, 9 у којима је изостављено по једно обележје, и преосталих 10 на основу Пирсонове анализе корелације. Затим су тестирали те комбинације помоћу 5 различитих метода машинског учења: MLP (назван ANN у раду), RF, DT, XGBoost и LSTM. Њихови резултати показали су да ниједна од комбинација није најбоља за све методе, као и да за сваку од метода неко обележје (генерално, другачије за сваку) треба да буде изостављено да би се побољшали резултати. Следећа обележја укључена су у све најбоље моделе: POA ирадијанса, GHI, DNI, температура задње површине ФН модула (енгл. *Back-Surface Temperature – BST*) и релативна влажност (RH).

Сличан концепт примењен је у [4]: аутори су креирали 3 скупа улазних обележја (названа основни, комплексни и скуп ниске резолуције) и тестирали их са чак 24 методе. Комплексни скуп обележја произвео је најбоље прогнозе. Међутим, једна од главних користи од тог истраживања је у томе што је скуп ниске резолуције (који садржи само дневну средњу вредност GHI и соларне углове) произвео сасвим прихватљиву тачност са неким методама; то је важно јер NWP прогнозе потребне за комплексни скуп обележја могу бити прилично скупе, док је прогноза потребна за скуп ниске резолуције бесплатна. Скуп ниске резолуције показао се као бољи од основног захваљујући коришћењу соларних углова. Један од закључака аутора је да избор улазних података може бити чак и важнији од избора модела.

Још један рад са сличним концептом је [13]: аутори су креирали 3 скупа улазних обележја (названа основни, алтернативни и оптимистични) да би утврдили да ли се измерени метеоролошки подаци могу користити уместо NWP прогноза. Креирани скупови представљају комбинације та два извора.

Методе селекције улазних обележја могу се класификовати у три типа: филтерске, омотачке и уграђене методе [39].

- Филтерске методе користе битне особине обележја, нпр. корелацију и друге статистичке показатеље.
- Омотачке (енгл. *wrapper*) методе процењују скупове обележја тако што више пута тренирају и процењују модел МУ помоћу различитих скупова, употребљавајући перформансе модела као критеријум. Код тог типа, избор обележја је спољашњи у односу на модел. Примери алгоритама који се користе у омотачким методама су секвенцијални избор унапред, елиминација уназад и рекурзивна елиминација обележја.
- Уграђене (енгл. *embedded*) методе интегришу селекцију обележја у обуку модела машинског учења, тако да се селекција дешава током обуке модела. Сам модел додељује важност обележјима и може их елиминисати. Алгоритми засновани на стаблу одлучивања (нпр. RF), технике регуларизације или механизми пажње често се примењују у таквим методама.

У [1], коришћен је алгоритам минималне редувантности и максималне релевантности (енгл. *minimal Redundancy Maximal Relevance – mRMR*). Та филтерска метода решава оба проблема споменута у уводу овог одељка – ниску корелацију са циљном променљивом и међусобне

зависности. Фокус у [19] је на објашњивој вештачкој интелигенцији (ХАИ); стога се важност обележја коју пружају ХАИ алати примењује за избор улазних обележја.

У [3], аутори описују своју методу као хибрид филтерске и омотачке: у фази филтера, подскупови обележја креирају се на основу Пирсоновог коефицијента корелације (ПКК), а у фази омотача, најбољи подскуп бира се евалуацијом на моделу МУ. ПКК се такође користи у [30], а избор се верификује израчунавањем средње вредности утицаја (енгл. *Mean Impact Value* – МИВ). У [37], ПКК се примењује на рудиментаран начин: обележја са $|\text{ПКК}| < 0,4$ се одбацују. У [48], креира се неколико подскупова обележја различитим методама: интуитивно, помоћу ПКК, на основу знања о физичким процесима, и коначно, претрагом грубом силом.

Неки радови примењују друге сличне показатеље уместо ПКК. У [39], Спирманов коефицијент корелације ранга (енгл. *Spearman's Rank Correlation Coefficient* – SRCC одн. ρ) израчунат је за сва улазна обележја, и обележја са највећом вредношћу SRCC додају се једно по једно у обуку основних модела. За више од 5 обележја, метрике почињу да се погоршавају. У [40], користе се вредности међусобне информације (енгл. *Mutual Information* – MI) између улазних и циљне променљиве. MI такође може да детектује нелинеарне односе између обележја. У [42], анализа важности обележја спроводи се одређивањем тежина обележја у Elastic Net-у и XGBoost-у.

У [12], коришћен је експериментални приступ за одређивање оптималног подскупа улазних обележја заједно са оптимизацијом хиперпараметара. Почетни подскуп обележја бира се емпиријски. Затим се фазе обуке и валидације рекурзивно извршавају док се мењају улазна обележја и хиперпараметри модела да би се одабрала оптимална обележја и конструисала оптимална неуронска мрежа.

У [27], RF са 200 стабала одлучивања користи се као омотачка метода за избор обележја. У [33], примењује се омотачка метода повратне елиминације (енгл. *backward elimination*). Модел се иницијално тренира са свим променљивим; затим, у свакој итерацији, најмање значајна променљива се уклања. Процес се зауставља када се не примети никакво побољшање.

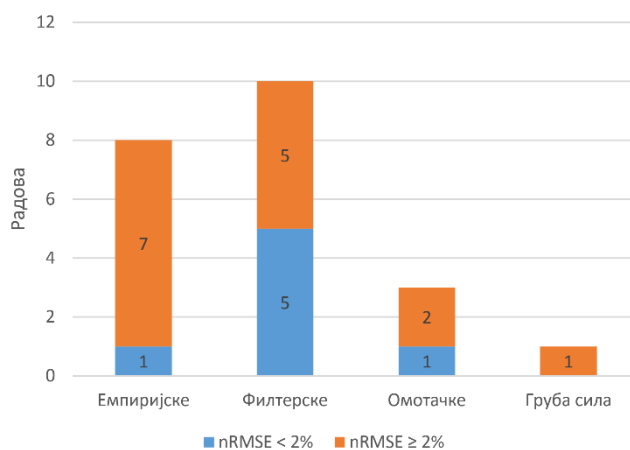
Коначно, у [18], [23] и [32], улазна обележја одабрана су на основу знања из области, прегледа литературе и препорука Међународне агенције за енергију (енгл. *International Energy Agency* – IEA), респективно.

Резиме метода за избор улазних обележја у прегледаним радовима приказан је у ТАБ. 23 и на сл. 51. Радови који користе више од једне врсте методе, или хибрид или комбинацију различитих врста, спомињу се у више од једног реда. Стога су у табели наведене укупно 22 референце. Ако се скупови обележја упоређују на моделу МУ на неформалан начин, без претраге или сличног алгорита, таква метода не сматра се омотачком. Претрага грубом силом може се сматрати омотачком методом, али у овом прегледу ипак је наведена засебно.

Експерименталне методе нису споменуте као засебан тип у табели јер је нека врста експеримента повезана са скоро свим типовима. Нпр. у [12], темељни експерименти делимично су вођени интуицијом и почињу од емпиријски одређеног подскупа, док су у [39] вредности SRCC основа за експерименте.

ТАБ. 23: Методе селекције улазних обележја у прегледаним радовима

Категорија метода	Број радова	Радови
Емпиријске	8 (36,36%)	[4], [12], [13], [17], [18], [23], [32], [48]
Филтерске	10 (45,45%)	[1], [3], [17], [19], [30], [37], [39], [40], [42], [48]
Омотачке	3 (13,64%)	[3], [27], [33]
Груба сила	1 (4,55%)	[48]



Сл. 51: Методе селекције улазних обележја у прегледаним радовима

У будућим истраживањима више пажње треба посветити селекцији улазних обележја, посебно алгоритамским, систематским методама, које се могу аутоматизовати. Прегледани радови описују неколико занимљивих метода селекције. Међутим, само 3 рада користе омотачке методе, а уграђене методе селекције обележја нису употребљаване у прегледаним радовима.

У ТАБ. 24 и плавим тракама на сл. 51 приказан је резиме метода за избор обележја које су произвеле nRMSE мањи од 2% у прегледаним радовима. У поређењу са претходном, ова табела садржи само 1 од 8 емпиријских, али 5 од 10 филтерских и 1 од 3 омотачке методе. Другим речима, за филтерске и омотачке методе вероватније је да ће произвести врхунску тачност него за емпиријске.

ТАБ. 24: Методе селекције улазних обележја које су произвеле nRMSE < 2%

Категорија метода	Број радова	Радови
Емпиријске	1 од 8 (12,5%)	[32]
Филтерске	5 од 10 (50%)	[3], [17], [30], [40], [42]
Омотачке	1 од 3 (33,33%)	[33]
Груба сила	0 од 1 (0%)	–

3.3.12 Оптимизација хиперпараметара

Оптимизација хиперпараметара представља суштински корак ка побољшаној тачности предвиђања, зато што хиперпараметри дефинишу архитектуру и комплексност модела, процес учења и сл. Нпр. у [4], чак 24 методе машинског учења примењене су и са оптимизованим и са подразумеваним вредностима хиперпараметара; у неким од метода, оптимизовани („подешени“) хиперпараметри резултирају 47% бољим метрикама од подразумеваних.

Најчешће коришћена метода оптимизације хиперпараметара позната је као претрага по мрежи (енгл. *grid search*). У тој методи, перформансе модела процењују се са свим могућим комбинацијама унапред дефинисаних вредности хиперпараметара, обично на подскупу података. Ако је број комбинација велики, то може довести до неприхватљиво дугог времена израчунавања. Због тога, мора се одабрати разумно мали број могућих вредности за сваки од хиперпараметара. Комбинације тих вредности дефинишу чворове мреже. При томе постоји ризик да се погрешно изабере могуће вредности.


Још већи проблем са претрагом по мрежи долази од чињенице да је ограничена на чворове, тј. унапред дефинисане вредности хиперпараметара, а функција коју треба да минимизује најчешће је непрекидна. Ако се минимум функције, тј. најбоља комбинација вредности хиперпараметара, налази негде између чворова, претрага по мрежи неће моћи да га пронађе. У зависности од грануларности мреже, можда се неће ни приближити минимуму.

Стога, да би се пронашле најбоље вредности хиперпараметара, морају се користити напредне методе претраживања. Оптимално решење за такве NP-тешке проблеме претраге лежи у метахеуристичким алгоритмима. Метахеуристике такође не могу гарантовати да ће увек пронаћи апсолутни минимум функције, али врло вероватно ће пронаћи довољно добро решење (у овом случају, комбинацију вредности хиперпараметара) уз разумну употребу рачунарских ресурса.

Резиме метода оптимизације хиперпараметара коришћених у прегледаним радовима дат је у ТАБ. 25 и на СЛ. 52. Такве методе споменуте су или описане у 25 од 50 прегледаних радова, а то је и број референци у табели. Емпиријски приступ није наведен у засебном реду табеле, због тога што је уско повезан са експерименталним приступом и увек се комбинује са њим.

ТАБ. 25: Методе оптимизације хиперпараметара у прегледаним радовима

Категорија метода	Број радова	Радови
Експерименталне	11 (44%)	[3], [5], [12], [16], [17], [24], [36], [37], [41], [43], [44]
Претрага по мрежи	9 (36%)	[4], [13], [18], [20], [23], [28], [38], [48], [49]
Метахеуристичке	2 (8%)	[30], [42]
Остало	3 (12%)	[33], [39], [40]



СЛ. 52: Методе оптимизације хиперпараметара у прегледаним радовима

Нажалост, међу прегледаним радовима, свега 2 користе метахеуристике за оптимизацију хиперпараметара. У [30], примењен је LFBAS (енгл. *Levy Flight Beetle Antennae Search*); свака од 4 GRU мреже оптимизована је засебно за сваки дан тестног подскупа. Оптималан број историјских података, тј. кашњења, одређен је парцијалном аутокорељацијом (PACF). У [42], употребљена је метахеуристика TSA (енгл. *Tabu Search Algorithm*).

У [13], користи се угнежђена унакрсна валидација. Вредности хиперпараметара одређују се у унутрашњој петљи и аутоматски примењују на спољашњу петљу. У [48], примењена је двострука претрага по мрежи, а опсеци за друго покретање заснивају се на резултатима првог покретања.

У [33], коришћен је комплет алата за аутоматизовано машинско учење Neural Network Intelligence (NNI). Врши се обука за сваку комбинацију хиперпараметара помоћу случајних подскупова из скупа података. NNI подржава већи број алгоритама за подешавање хиперпараметара, али аутори нису споменули који алгоритам је примењен. У [39], користи се случајна претрага. У [40], почетна величина неуронске мреже одређује се емпиријски, а потом модификује резивањем (уклањањем неурона са мањим тежинама); пошто се метахеуристика оптимизација колоније мравца (ACO) употребљава као екстерни оптимизатор параметара у том истраживању, може се рећи да су хиперпараметри индиректно оптимизовани том метахеуристиком.

Очигледно је да би у будућим истраживањима требало посветити више пажње оптимизацији хиперпараметара, посебно метахеуристичком приступу. Неколико истраживања наглашава предности метахеуристика за оптимизацију хиперпараметара у предвиђању и разним другим проблемима које решава машинско учење [57], [58], [59].

У ТАБ. 26 и плавим тракама на СЛ. 52 приказан је резиме метода оптимизације хиперпараметара које су произвеле $nRMSE$ мањи од 2% у прегледаним радовима. У поређењу са претходном табелом, ова садржи само 3 од 11 експерименталних, 0 од 9 претрага по мрежи, све 3 метахеуристичке (2 директне и 1 индиректну [40]) и NNI комплет алата [33]. Дакле, метахеуристичке методе скоро сигурно ће произвести врхунску тачност, експерименталне методе знатно су лошије, док претрагу по мрежи треба избегавати.

ТАБ. 26: Методе оптимизације хиперпараметара које су произвеле $nRMSE < 2\%$

Категорија метода	Број радова	Радови
Експерименталне	3 од 11 (27,27%)	[3], [17], [44]
Претрага по мрежи	0 од 9 (0%)	–
Метахеуристичке	2 од 2 (100%)	[30], [42]
Остало	2 од 3 (66,67%)	[33], [40]

3.3.13 Метрике


Метрике представљају суштински важан алат за процену резултата модела. Овај одељак садржи резиме метрика коришћених у прегледаним радовима, док се следећи одељак бави различитим факторима који утичу на метрике, као и неким односима између метрика. Резиме метрика употребљених за детерминистичко прогнозирање у прегледаним радовима дат је у ТАБ. 27 и на СЛ. 53. Дефиниције неких честих метрика дате су у одељку 2.2.

ТАБ. 27: Метрике за детерминистичко предвиђање у прегледаним радовима

Метрика	Број радова	Радови
RMSE и повезане	49 (98%)	сви осим [36]
MAE и повезане	37 (74%)	[3], [4], [6], [7], [8], [9], [10], [11], [13], [15], [17], [18], [22], [23], [24], [25], [26], [27], [29], [30], [31], [32], [33], [34], [35], [36], [37], [38], [39], [41], [42], [43], [44], [45], [46], [48], [50]
R ² и сличне	22 (44%)	[3], [6], [8], [10], [11], [14], [17], [22], [23], [24], [29], [30], [33], [35], [36], [39], [40], [41], [42], [44], [46], [48]
MAPE и повезане	11 (22%)	[1], [9], [12], [17], [20], [21], [22], [27], [36], [39], [48]
Пристрасност и повезане	10 (20%)	[4], [7], [9], [13], [14], [15], [18], [29], [32], [38]
Корелација	8 (16%)	[4], [7], [15], [16], [18], [21], [24], [43]
Остало	9 (18%)	[8], [10], [13], [15], [18], [33], [36], [38], [46]

Корен средње квадратне грешке (енгл. *Root Mean Square Error* – RMSE, једначина (7)) и/или неке од повезаних метрика користе се у 49 од 50 прегледаних радова. Као метрика, RMSE се примењује чешће од средње квадратне грешке (MSE, једначина (6)) зато што се изражава у истим јединицама мере као и циљна променљива, и стога је интуитивнија као индикатор. Друге повезане метрике употребљене у прегледаним радовима су нормализована RMSE ($nRMSE$), релативна RMSE ($rRMSE$) [8], [14], нормализована MSE ($nMSE$) [40] и RMSE оцена успешности (енгл. *RMSE skill score*), која се у неким радовима назива вештина прогнозе или

индекс вештине прогнозе (енгл. *forecast skill index*), нпр. [49], а представља побољшање RMSE у односу на модел постојаности (енгл. *persistence model*).



Сл. 53: Метрике за детерминистичко предвиђање у прегледаним радовима

Средња апсолутна грешка (енгл. *Mean Absolute Error* – MAE, једначина (8)) и повезане метрике чине другу најчешће коришћену групу, заступљену у 37 прегледаних радова. Повезане метрике су нормализована MAE (nMAE) и средња апсолутна скалирана грешка (енгл. *Mean Absolute Scaled Error* – MASE, тј. MAE у односу на модел постојаности) [33]. У [9], MAE нормализована номиналним капацитетом фотонапонске електране назива се средња релативна грешка (енгл. *Mean Relative Error* – MRE).

R² и сличне метрике представљају трећу најчешће примењивану групу, употребљену у 22 прегледана рада. Коефицијент детерминације (R², једначина (4)) показује проценат варијансе циљне променљиве који модел објашњава, тј. проценат стварних вредности које је модел исправно предвидео. Неки аутори користе сличне метрике назване објашњена варијанса (енгл. *Explained Variance* – EV) [35] или оцена објашњене варијансе (енгл. *EV Score* – EVS) [10].

Средња апсолутна процентуална грешка (енгл. *Mean Absolute Percentage Error* – MAPE, једначина (9)) и пондерисана MAPE (енгл. *Weighted MAPE* – WMAPE) [20] на четвртм су месту, одмах испред метрика у вези са пристрасношћу (енгл. *bias*). Ту групу чине средња грешка пристрасности (енгл. *Mean Bias Error* – MBE, једначина (10)), нормализована MBE (nMBE) [4], [18], релативна MBE (rMBE) [14], пристрасност (у неким радовима названа грешка предвиђања или само грешка) [7], [13], [29] и нормализована пристрасност (nBias) [13]. У 8 радова (16%), Пирсонов коефицијент корелације употребљава се као метрика.

На крају табеле налази се 9 радова у којима се користе различите метрике које нису укључене у претходне групе: средња релативна девијација (енгл. *Mean Relative Deviation* – MRD) [8], корен средње квадратне девијације (енгл. *Root Mean Squared Deviation* – RMSD) [8], медијана апсолутне грешке (енгл. *Median Absolute Error* – MedAE) [10], индекс слагања (енгл. *Index of Agreement* – IoA, једначина (11)) [13], однос варијансе (енгл. *variance ratio*) [15], [18], квантилни губитак (енгл. *quantile loss*) [33], корен средње квадратне процентуалне грешке (енгл. *Root Mean Square Percent Error* – RMSPE) [36], економски приход (енгл. *Economic Revenue* – ER) [38] и максимална грешка (енгл. *Max Error* – ME) [46].

Однос варијансе представља информативни индикатор расподеле прогноза. У овом прегледу није уврштен у исту групу са R² и осталим метрикама повезаним са варијансом, зато што има сасвим другачије значење и употребу. Економски приход (ER) процењује економске последице грешака у прогнози; зависи од тржишне цене и казни и може бити прилично релевантан за избор модела. Максимална грешка (ME) прилично је једноставна, али информативна метрика, која открива најлошију уочену прогнозу модела и тиме указује на његове перформансе у најгорем случају.

Просечан ранг (енгл. *Ranking Mean – RM*) [17] представља интерну метрику намењену за одређивање укупно најбољег модела у раду. Будући да је то интерна метрика у раду, није наведена у табели, али треба је истаћи и препоручити зато што знатно олакшава анализу резултата. Поред метрика наведених у табели, неки аутори, нпр. [1], [4], такође су упоредили време потребно за обуку и/или извршавање различитих модела, што може бити важно за избор модела у пракси.

Да би се упоредиле метрике из различитих ФН система, оне морају бити нормализоване, зато што њихове вредности зависе од величине система. Главни проблем који отежава поређење метрика јесте то што референтне вредности за њихову нормализацију нису стандардизоване. У домену прогнозирања ФН снаге, препорука у овом прегледу је да се користи номинални капацитет постројења, и он се и користи у неким радовима. Уколико номинални капацитет није познат, задовољавајућа замена је максимална уочена вредност циљне променљиве (под претпоставком да је скуп података довољно репрезентативан), па и опсег уочених вредности (који је у случају ФН снаге обично једнак максималној уоченој вредности). Али с друге стране, неки аутори примењују аритметичку средину уочених вредности, варијансу, чак и збир уочених вредности, а неки одузимају нормализоване вредности од 100%. Стога, приликом упоређивања нормализованих вредности, мора се узети у обзир начин њиховог добијања.

За процену различитих аспеката пробабилистичког предвиђања користи се потпуно другачији скуп метрика. Следеће метрике употребљавају се за процену поузданости (тј. статистичке конзистентности између запажања и прогноза) у прегледаним радовима:

- вероватноћа покривености интервала предвиђања (енгл. *Prediction Interval Coverage Probability – PICP*) [21], [42]
- просечна грешка покривености (енгл. *Average Coverage Error – ACE*) [20], [42]
- средња апсолутна грешка поузданости (енгл. *Mean Absolute Reliability Error – MARE*) [15]

Оштрина пробабилистичке прогнозе је концентрација предиктивне расподеле прогнозе. Оштрија прогноза има ужу, концентрисанију расподелу, што одражава већу поузданост и већу информативност. Метрике које се користе за процену оштрине у прегледаним радовима су следеће:

- ширина интервала предвиђања (енгл. *Prediction Interval Width – PIW*) [21]
- просечна ширина интервала предвиђања (енгл. *Prediction Interval Average Width – PIAW*) [15]
- нормализована просечна ширина интервала предвиђања (енгл. *Prediction Interval Normalized Average Width – PINAW*) [20], [42]

Следеће метрике користе се за процену укупних перформанси пробабилистичке прогнозе у прегледаним радовима:

- континуирани рангирани скор вероватноће (енгл. *Continuous Ranked Probability Score – CRPS*) [15], чије су компоненте поузданост (енгл. *Reliability – REL*) и резолуција (енгл. *Resolution – RES*)
- интервални скор (енгл. *Interval Score – IS*) [20]

Осим тога, неке метрике користе се да би се изразила тачност одређеног квантила. То су квантилни скор (енгл. *Quantile Score – QS*) [15] и нормализовани скор пинбол губитка (енгл. *Normalized Pinball Loss Score – L*) [42]; међутим, у [42], L је просек свих квантила за одређени хоризонт прогнозе и примењује се као метрика за укупне перформансе пробабилистичке прогнозе.

У раду који се бави прогнозирањем сценарија [28] употребљене су следеће метрике:

- унакрсна ентропија (енгл. *Cross Entropy – CE*) – одражава сличност између расподела вероватноће

- грешка дневне вршне снаге (енгл. *Daily Peak Power Error – DPPE*) – приказује релативну грешку између сценарија вршне снаге и уочене вршне снаге
- дневна грешка у производњи енергије (енгл. *Daily Energy Production Error – DEPE*) – процењује способност сценарија да симулирају производњу енергије
- фактор аутокорељације (енгл. *Autocorrelation Factor – ACF*) – у том раду процењује временску корелацију
- Спирманов коефицијент корелације ранга (енгл. *Spearman’s Rank Correlation Coefficient – SRCC* одн. ρ) – у том раду одражава просторну корелацију

3.3.14 Најбоље тачности

Поређење резултата различитих истраживања представља прилично незавидан задатак. Као што је наведено у претходном одељку, исте метрике коришћене су у више радова. Да би се омогућило поређење, морају бити нормализоване на исти начин; у овом прегледу, за нормализацију метрика примењен је номинални капацитет. Али чак и ако су ти захтеви испуњени, мора се имати на уму да резултати прогнозе зависе од многих фактора који су вероватно различити у различитим истраживањима.

Пре свега, метрике зависе од хоризонта прогнозе, како временског интервала, тако и броја корака унапред. Два произвољно изабрана примера из прегледаних радова приказана су у ТАБ. 28 и ТАБ. 29. У оба примера, повећање хоризонта доводи до очигледне деградације метрика. Штавише, метрике се обично мењају на неправилан начин, а иста метрика може се мењати на различите начине у различитим истраживањима. Нпр., nRMSE се променио за 112% у [25] и за 215% у [39]; с друге стране, nMAE се променио за 151% у [25], али за само 94% у [39], иако је број временских корака 24 у оба случаја.

ТАБ. 28: Промена метрика за различите хоризонте прогнозе у [25]

Метрика	Хоризонт		Промена
	15 мин	6 сати	
nRMSE	7,32%	15,53%	112,16%
nMAE	15,71%	39,44%	151,05%

ТАБ. 29: Промена метрика за различите хоризонте прогнозе у [39]

Метрика	Хоризонт		Промена
	1 сат	24 сата	
nRMSE	2,91%	9,18%	215,46%
nMAE	2,25%	4,37%	94,22%
MAPE	2,23%	8,04%	260,54%
R ²	0,973	0,910	-6,47%

Верује се да већи фотонапонски системи имају тенденцију да дају боље вредности нормализованих метрика, али анализа у овом прегледу није то доказала. Међутим, у [42], коришћена су два скупа података – из постројења од 211 kW и постројења од 4,7 MW; подаци из већег постројења пружили су 33% бољи nRMSE него из мањег, али само 3% бољи nMAE и 0,86% бољи R². У [3], nRMSE је 131% бољи, а nMAE 128% бољи за већи систем, али R² је 1,21% лошији. Свака метрика може се променити на специфичан начин.

Тачност прогнозе зависи чак и од годишњег доба; то је занимљив фактор који се често занемарује. Поново, метрике из два произвољно изабрана примера међу прегледаним радовима дате су у ТАБ. 30 и ТАБ. 31. У [32], и nRMSE и nMAE знатно су бољи за зиму него за лето, супротно ономе што би се могло очекивати. У [36], најбоље вредности свих метрика

остварене су за пролеће; занимљиво је да је најлошија вредност nMAE остварена за лето и јесен, MAPE за јесен, а R² за зиму.

ТАБ. 30: Промена метрика за различита годишња доба у [32]

Метрика	Годишње доба		Промена
	зима	лето	
nRMSE	0,72%	0,9%	25,00%
nMAE	0,36%	0,6%	66,67%


ТАБ. 31: Промена метрика за различита годишња доба у [36]

Метрика	Годишње доба				Промена од најбољег до најлошијег
	пролеће	лето	јесен	зима	
nMAE	1,24%	2,05%	2,05%	1,51%	65,32%
MAPE	2,96%	5,00%	5,18%	3,52%	75,00%
R ²	0,991	0,986	0,989	0,982	-0,91%

Још један фактор који утиче на метрике је функција губитка која се примењује за оптимизацију модела. MAE и MSE представљају супротстављене метрике, зато што се MAE минимизује медијаном, а MSE и RMSE минимизују се средњом вредношћу променљиве [4], [15]. Другим речима, ако се модел оптимизује помоћу MAE, вероватно неће произвести оптималну RMSE и обрнуто. Зато неки аутори, нпр. [18], чак изводе две одвојене оптимизације, користећи и MSE и MAE. RMSE се генерално мења конзистентно са MBE, RMSE оценом успешности и коефицијентом корелације, али не и са MAE [18]. С друге стране, MAPE се минимизује сложеном мером која се назива геометријска медијана; та мера није повезана ни са медијаном ни са средњом вредношћу.

Штавише, многи истраживачи обично имају специфичан фокус. Било би бесмислено упоређивати нпр. резултате истраживања које истражује импутацију недостајућих података [20] и неког истраживања које користи „беспрекоран” скуп података, или истраживања усмереног на потпуно другу област, нпр. ХАИ алате [19]. Поред тога, неки радови наводе просеке уместо најбољих метрика.


Због свих тих разлога, циљ навођења резултата из различитих радова у овом прегледу свакако није поређење квалитета спроведених истраживања, већ потреба да се, ради потпуности информације, пружи распони очекиваних вредности за најчешће метрике – nRMSE, nMAE, MAPE и R². За неке радове, nRMSE и nMAE израчунати су у оквиру ове анализе на основу датих метрика и номиналног капацитета. Радови у којима резултати нису специфицирани, или су нејасни или одступајући, изостављени су из ове анализе.




СЛ. 54: Расподела вредности nRMSE у прегледаним радовима

Најбоље вредности $nRMSE$ у прегледаним радовима крећу се од 0,46% [11] до око 14%, при чему 4 рада извештавају о вредностима $nRMSE$ мањим од 1%, а у 9 радова $nRMSE$ има вредности у распону од 1% до 2%. $nMAE$ обично има мање вредности од $nRMSE$; најбоље вредности $nMAE$ у прегледаним радовима крећу се од 0,23% [11] до 5%, при чему неки радови извештавају о знатно већим вредностима. Треба напоменути да је највећи ФН систем међу прегледаним радовима коришћен у [11]. Радови са $nRMSE$ мањим од 2% анализирани су у погледу метода прогнозирања, вршних снага, метода избора улазних обележја, метода оптимизације хиперпараметара, оптимизатора и величина неуронских мрежа, а резултати тих анализа представљени су у одговарајућим одељцима.

Типичне најбоље вредности $MAPE$ у прегледаним радовима крећу се од 2,23% [39] до око 9%, са само неколико већих вредности у неким радовима. Најбоље вредности R^2 у прегледаним радовима крећу се од 0,9991 [30] до 0,91. Нпр. у [33], најбоља вредност R^2 за појединачну фотонапонску електрану је 0,999, док је просек за све електране у том раду 0,991. Од 20 радова који дају вредност за ту метрику, чак 12 извештава о најбољим вредностима R^2 већим од 0,99! Хистограми који приказују расподеле вредности $nRMSE$, $nMAE$ и R^2 дати су на сл. 54, сл. 55 и сл. 56, респективно. Неколико вредности већих од 10% нису приказане. Са слика се може видети да су расподеле $nRMSE$, $nMAE$ и R^2 релативно сличне.



сл. 55: Расподела вредности $nMAE$ у прегледаним радовима



сл. 56: Расподела вредности R^2 у прегледаним радовима

3.3.15 Величине неуронских мрежа

Овај одељак описује величине неуронских мрежа коришћених у прегледаним радовима, изражене преко броја скривених слојева и укупног броја скривених ћелија (или LSTM/GRU јединица). Врсте мрежа чија се величина не може лако изразити бројем ћелија (нпр. мреже

засноване на конволуцији или на трансформеру) нису укључене у ову анализу. Ако модел МУ садржи више од једне неуронске мреже, анализирају се величине појединачних мрежа. За неке радове, неколико величина неуронских мрежа укључено је у ову анализу, док је за неке друге радове укључена само величина која даје најбољу тачност.

Емпиријско правило за број скривених ћелија у MLP мрежи [12] дато је у једначини (60):

$$N_h = N_i + N_o - 1 \quad (60)$$

У тој једначини, N_h , N_i и N_o представљају бројеве скривених ћелија, улазних и излазних обележја, респективно. Дакле, број скривених ћелија може се проценити као збир бројева улазних и излазних обележја, минус један. Међутим, знатно другачије правило [29], такође повезано са MLP мрежама, дато је у једначини (61):

$$N_h = \frac{N_i}{3} \quad (61)$$

Огромна разлика између те две формуле илуструје чињеницу да правила могу дати смернице, али оптимална величина неуронске мреже зависи од скупа података и стога би требало да се одреди током оптимизације хиперпараметара. Истраживања обично показују да коришћење превише скривених ћелија не само да повећава рачунске захтеве већ и смањује тачност.

ТАБ. 32: Статистике о броју скривених слојева и ћелија у прегледаним радовима

Тип неуронске мреже	Скривени слојеви				Скривене ћелије/јединице			
	Просек	Медијана	Мин.	Макс.	Просек	Медијана	Мин.	Макс.
MLP	1,49	1	1	3	40,63	16	4	388
LSTM	2,00	2	1	4	166,19	122,5	11	804
Све RNN	1,82	2	1	4	156,93	132,5	11	804
Све врсте	1,63	1	1	4	92,32	32	4	804

Број скривених слојева и ћелија примећен у прегледаним радовима сумиран је у ТАБ. 32. У MLP мрежама, број скривених слојева варира од 1 до 3 [4], [25], [28], а број скривених ћелија од само 4 [12], [18], [29] до 388 [28], са просеком од око 40 ћелија. LSTM мреже у прегледаним радовима типично су веће од MLP-ова, са 1 до 4 [2], [36] слоја, и од 11 [16] до чак 804 јединице [42], са просечно 166 јединица. Остале врсте RNN укључене у ову анализу углавном су GRU и Bi-LSTM, и стога је сасвим разумљиво што су статистике за све типове RNN-ова (укључујући LSTM) сличне резултатима искључиво за стандардне LSTM мреже. За све анализиране неуронске мреже, просечан број скривених слојева износи 1,63, а просечан број скривених ћелија или јединица је око 92, са медијаном једнаком 32.

Имајући у виду да је сама LSTM јединица много рачунски интензивнија од обичног вештачког неурона (ћелије MLP мреже), чињеница да су LSTM мреже у овој анализи обично знатно веће од MLP мрежа донекле је изненађујућа. Ипак, само 4 рада укључена у ову анализу користе MLP мреже са више од 64 скривене ћелије, док је ситуација за LSTM мреже супротна: само 5 радова примењује LSTM мреже са бројем скривених јединица мањим или једнаким 64.

Занимљиво истраживање описано у [18] сумирано је у ТАБ. 33. Аутори су оптимизовали MLP мреже 6 фиксних величина (са једним скривеним слојем који садржи 4, 8, 16, 32, 64 или 128 ћелија) за 12 метода прогнозирања, на скуповима података из 14 фотонапонских електрана, користећи и MAE и MSE као функције губитка. Нпр. MLP са 4 скривене ћелије, оптимизован помоћу MAE, дао је најмању грешку у 4 од 168 (12×14), тј. 2,38% експеримената. Њихови резултати показују да модели оптимизовани помоћу MAE обично захтевају више неурона – бар 16, са најбољом тачношћу када се примењује 64 или 128 неурона. Модели оптимизовани

помоћу MSE обично имају бољу тачност са мањим бројем неурона – 4 или 8, али за разлику од MAE, тачност при употреби MSE много је равномерније распоређена по целом опсегу величина мрежа.

ТАБ. 33: Оптималне величине MLP мрежа за моделе оптимизоване помоћу MAE и MSE (резултати добијени обрадом података из [18])

Број скривених ћелија	4	8	16	32	64	128
Најбољи за моделе оптимизоване помоћу MAE	2,38%	7,74%	17,26%	21,43%	25,00%	26,19%
Најбољи за моделе оптимизоване помоћу MSE	19,05%	19,05%	16,07%	13,69%	15,48%	16,67%

У истраживањима у којима је добијен nRMSE мањи од 2%, присутне су неуронске мреже свих величина, од MLP-а са 12 скривених ћелија [17] до највећег LSTM-а са 804 јединице. Просечан број скривених слојева у рекурентним мрежама при томе је 1,83 – готово идентичан оном у ТАБ. 32, док се број скривених јединица/ћелија креће од 20 до 804, са просеком 227. Чини се да рекурентним мрежама генерално треба више јединица/ћелија за добре резултате.

3.3.16 Функције активације

Активационе функције уводе нелинеарност у моделе неуронских мрежа и тиме им омогућавају да уче сложене обрасце. Пожељно је да активациона функција буде:

- диференцијабилна континуирано или барем скоро свуда (зато што су њени изводи потребни за израчунавање градијента функције губитка у оптимизаторима заснованим на градијенту),
- рачунски ефикасна,
- центрирана око нуле (што доводи до уравнотеженијег градијента и самим тим побољшава брзину конвергенције),
- монотона (што такође побољшава брзину конвергенције), и
- незасићена (тј. требало би да избегне проблем нестајања градијента).

Коначан опсег активационе функције обично промовише стабилност обуке засноване на градијенту, док бесконачан опсег обично промовише ефикасност обуке [60]. Описи најважнијих функција активације дати су у одељку 2.5.4.

У ТАБ. 34 и на сл. 57 приказан је резиме активационих функција коришћених у прегледаним радовима. Функције интерне за градивни блок неуронске мреже, нпр. логистичке („сигмоидне”) и \tanh функције интерне за LSTM јединицу, нису укључене у ову анализу. У неким радовима примењује се више од једне активационе функције, за различите типове неуронских мрежа или различите сврхе унутар исте мреже – за пренос између слојева, у излазном слоју, у слоју за искључивање (енгл. *dropout*), у механизму пажње, итд.; стога се одговарајући радови појављују у табели више пута. Укупан број референци у табели је 29.


Функције у табели класификоване су у 3 групе. Прва група састоји се од функције исправљене линеарне јединице (енгл. *Rectified Linear Unit* – ReLU) и сличних функција, углавном дизајнираних да превазиђу недостатке функције ReLU. Међутим, као што табела и други извори показују [18], ReLU (сл. 24, једначина (26)) и даље представља најкоришћенију функцију активације. То је једноставна, али ефективна и рачунски ефикасна функција; има недиференцијабилну тачку на нули, али то се лако може заобићи. Остале функције у тој групи су следеће:

- ReLU са цурењем (енгл. *Leaky ReLU*, сл. 25, једначина (27)) – иста као ReLU за позитивне улазе, користи мали линеарни нагиб за негативне; обично се примењује у слојевима за искључивање, нпр. у [44]
- softplus – континуирано диференцијабилна апроксимација ReLU помоћу природног логаритма и експоненцијалне функције
- експоненцијална линеарна јединица (енгл. *Exponential Linear Unit* – ELU) – иста као ReLU за позитивне улазе, користи експоненцијалну функцију за негативне
- линеарна јединица са Гаусовом грешком (енгл. *Gaussian Error Linear Unit* – GELU) – примењује Гаусову кумулативну функцију расподеле; обично се употребљава у трансформерским моделима због добрих перформанси; често се замењује својом рачунски ефикаснијом апроксимацијом

Функције у тој групи једнаке су или блиске линији $y = x$ за позитивне улазе, а једнаке нули или имају релативно мале вредности за негативне улазе.

ТАБ. 34: Функције активације у прегледаним радовима

Функција	Број радова	Радови
ReLU	10	[1], [13], [17], [18], [23], [28], [32], [37], [44], [50]
ReLU са цурењем	2	[44], [45]
softplus	2	[20], [42]
ELU	1	[8]
GELU	1	[39]
Укупно ReLU и сличне	16 (55,17%)	
логистичка	7	[12], [13], [18], [29], [37], [42], [44]
tanh	3	[13], [18], [24]
tansig	1	[29]
Укупно сигмоидне	11 (37,93%)	
softmax	2 (6,9%)	[22], [45]



СЛ. 57: Функције активације у прегледаним радовима

Другу групу чине сигмоидне функције. Прецизно говорећи, термин „сигмоидна функција” у машинском учењу заправо се односи на логистичку функцију (сл. 22, једначина (22)), а сигмоидне функције у општем смислу су све функције које производе криву у облику латиничног слова S (логистичка, хиперболички тангенс, аркус тангенс, итд.). Логистичка функција производи излаз у опсегу (0, 1), док је излаз функције хиперболички тангенс (tanh, сл. 23, једначина (24)) између -1 и 1. Тангенсна сигмоидна функција (tansig) математички је еквивалентна функцији tanh, али због специфичне имплементације, брже се извршава у MATLAB-у. У [29], функција tansig користи се уместо логистичке функције за негативне улазне или излазне вредности.

Функција softmax, дата у једначини (25), представља групу за себе. То је генерализација логистичке функције на више димензија и може јој визуелно бити слична под неким


околностима, али заправо је другачија у самој суштини. За разлику од свих осталих споменутих функција, softmax је мултиваријантна функција – она узима вектор улаза и враћа вектор вероватноћа, где је свака вредност између 0 и 1 и збир свих вредности износи 1. Често се користи у излазном слоју неуронске мреже да нормализује резултате у расподелу вероватноће [61].

3.3.17 Оптимизатори

Резиме алгоритама за оптимизацију примењених у прегледаним радовима дат је у ТАБ. 35 и на СЛ. 58. Као и код осталих анализа у овом прегледу, у неким радовима користи се више од једног оптимизатора, па се стога ти радови појављују у табели више пута. Укупан број референци у табели је 37. Алгоритми у табели груписани су по сличности. Додатне информације о алгоритмима за оптимизацију, као и описи неколико најважнијих, дати су у одељку 2.5.5.2.

ТАБ. 35: Оптимизатори у прегледаним радовима

Оптимизатор	Број радова	Радови
Adam	22 (59,46%)	[4], [5], [8], [13], [16], [17], [18], [20], [22], [23], [25], [30], [32], [35], [36], [39], [41], [42], [44], [45], [47], [50]
RMSProp	2 (5,41%)	[28], [35]
Nadam	1 (2,7%)	[34]
Levenberg-Marquardt	4 (10,81%)	[1], [16], [42], [24]
Levenberg-Marquardt са Бајесовом регуларизацијом	1 (2,7%)	[16]
SGD	2 (5,41%)	[3], [25]
SGD са Бајесовом инференцијом и L2 регуларизацијом	1 (2,7%)	[12]
ACO метахеуристика	1 (2,7%)	[40]
Остало	3 (8,11%)	[11], [29], [37]



СЛ. 58: Оптимизатори у прегледаним радовима

Фундаментални концепт у оптимизацији неуронских мрежа је пропација уназад (енгл. *backpropagation*) – метода за израчунавање градијента функције губитка у односу на тежинске коефицијенте мреже. Градијент је генерализација извода за функције више променљивих – то је вектор парцијалних извода. Сама по себи, пропација уназад не ажурира тежинске коефицијенте, али доставља градијенте оптимизатору, који их користи за ажурирање тежинских коефицијента. Више информација о пропацији уназад дато је у одељку 2.5.5.3.

Стохастички градијентни спуст (енгл. *Stochastic Gradient Descent* – SGD) представља најједноставнији од наведених алгоритама, али се и поред тога примењује у 3 рада. Смањује рачунску сложеност основног градијентног спуста (GD) апроксимацијом пуног градијента: уместо да користи цео скуп података као GD, SGD израчунава градијент на основу једне насумично одабране тачке података у свакој итерацији (или мале групе тачака података – та варијанта алгоритама назива се градијентни спуст по малим групама). У [12], SGD се употребљава заједно са Бајесовом инференцијом и L2 регуларизацијом.

Убедљиво најкоришћенији оптимизатор у прегледаним радовима је Adam (енгл. *Adaptive Moment Estimation* – адаптивна процена момента). То је комбинација алгоритама Adagrad (енгл. *Adaptive Gradient* – адаптивни градијент) и RMSProp (енгл. *Root Mean Square Propagation* – пропација средњег квадратног корена градијента), који су проширења алгоритама SGD [32]. Реч „адаптивни” у називима алгоритама значи да они динамички подешавају брзину учења за сваки параметар унутар модела, уместо да користе исту брзину учења за све. Adam примењује експоненцијално опадајући просек прошлих градијената (назван процена првог момента) и квадрата прошлих градијената (назван процена другог момента) да би убрзао конвергенцију и постигао бржу обуку [62]. RMSProp је такође адаптивни алгоритам, који користи прорачун сличан Adam-овој процени другог момента.

У [34], аутори упоређују чак 8 оптимизатора. По њиховој методологији, Nadam (енгл. *Nesterov-accelerated Adaptive Moment Estimation* – адаптивна процена момента убрзана Нестеровљевим моментом) постиже побољшање од 1,35%, 1,43%, 3,51%, 4,88%, 11,84%, 50,69% и 58,29% у односу на оптимизаторе RMSProp, Adam, Adamax, SGD, Adagrad, Adadelta и Ftrl, респективно. Међутим, резултати првих неколико веома су слични, а редослед је подложен тумачењу. Nadam комбинује квалитете Adam-а са Нестеровљевим моментом, што даје могућност подешавања параметара пре израчунавања градијента. То може побољшати брзину и перформансе конвергенције [63], [64].

Левенберг-Марквардов алгоритам (понекад се назива Левенберг-Марквардова пропација уназад, енгл. *Levenberg-Marquardt BackPropagation* – LMBP) [24] представља комбинацију градијентног спуста (GD) и Гаус-Њутновог алгоритама. Понаша се више као градијентни спуст (уз велике кораке) када је далеко од решења, а више као Гаус-Њутнов алгоритам (са финим корацима) када је близу решења, динамички прилагођавајући своје понашање. Користи пропацију уназад за израчунавање Јакобијеве матрице, која је кључна компонента LM алгоритма. У [16], упоређене су две верзије LM алгоритма – обичан Левенберг-Марквардов алгоритам (имплементиран као функција `trainlm` у MATLAB-у) и Левенберг-Марквардов алгоритам са Бајесовом регуларизацијом (функција `trainbr`); боље метрике у већини случајева пружио је `trainlm`.

Занимљиво решење описано је у [40]: параметри мреже екстерно се оптимизују помоћу добро познате метахеуристике оптимизације колоније мравца (енгл. *Ant Colony Optimization* – ACO).

У истраживањима у којима је nRMSE мање од 2%, 7 радова користи Adam (31,82% од 22), 1 LM (20% од 5), 1 SGD (33,33% од 3) и 1 ACO (100%). Ти резултати могу се сматрати конзистентним са претходном табелом, осим што је LM постигао нешто лошији, а SGD бољи резултат од очекиваног. Јединствено решење са метахеуристиком дало је веома добар резултат.

3.3.18 Функције губитка


Функција губитка (која се у неким радовима назива функција трошкова, функција грешке или функција циља, иако могу постојати суптилне разлике између тих термина) представља метрику грешке предвиђања, тј. разлику између предвиђених и стварних вредности, која служи као водич за оптимизацију модела током обуке. Минимизовањем те функције,

параметри модела подешавају се путем пропагације уназад, као што је описано у одељцима 2.5.5 и 3.3.17. Током тог процеса, израчунава се градијент функције губитка [65].

Као што је описано у одељку 3.3.14, функција губитка треба да буде конзистентна са метрикама које се користе за процену обученог модела. С обзиром на то што су RMSE и повезане функције најчешће метрике у прегледаним радовима, очекивано је што MSE представља најчешћу функцију губитка у прегледаним радовима. Из ТАБ. 36 и са СЛ. 59 види се да две трећине (18 од 27) прегледаних радова примењују основну или модификовану MSE као функцију губитка, 7 радова користи MAE, а 2 рада друге функције.

ТАБ. 36: Функције губитка у прегледаним радовима

Функција губитка	Број радова	Радови
MSE	15 (55,56%)	[3], [4], [5], [16], [17], [18], [22], [28], [29], [30], [37], [38], [41], [44], [50]
Модификована MSE	3 (11,11%)	[40], [45], [47]
MAE	7 (25,93%)	[8], [13], [18], [34], [36], [37], [48]
Остало	2 (7,41%)	[20], [35]



СЛ. 59: Функције губитка у прегледаним радовима

Као што је описано у претходним одељцима, и MSE и MAE користе се као функције губитка за обучавање неколико модела у [18], а аутори су открили да модели обучени помоћу MAE обично захтевају веће мреже од модела обучених помоћу MSE. Обе функције губитка такође се примењују у [37].

У [40], нормализована MSE (nMSE) користи се уместо MSE, док се у [45] збир квадрата грешака употребљава као функција губитка. У [47], примењује се MSE са губитком услед казне, тј. збир MSE за податке и MSE за пондерисане казне. Казне се употребљавају за укључивање физичких ограничења извучених из претходног знања о домену у обуку модела.

Остале функције губитка коришћене у прегледаним радовима су негативна логаритамска вероватноћа (са додатним бинарним параметром који искључује импутиране податке) [20] и унакрсна ентропија [35]. Такође у [35], метода прогнозирања је варијациони аутоенкодер (VAE), а подразумевана функција губитка за ту методу је губитак при реконструкцији, али у том раду од те функције одузима се вредност регуларизатора (Кулбек-Лајблерове дивергенције).

3.3.19 Програмски језици

Овај одељак наводи програмске језике, окружења и пакете коришћене у прегледаним радовима. ТАБ. 37 и СЛ. 60 приказују резиме примењених програмских језика. Овај преглед показује да је Python убедљиво најкоришћенији језик за развој модела машинског учења. У


неким радовима употребљено је више од једног језика, нпр. [8] – R и Python, [29] – R и MATLAB, [45] – Python и MATLAB. У табели се налази укупно 40 референци.

Што се тиче окружења, Jupyter Notebook спомиње се у [17], [26] и [32] (у [17] хостован на Google Colab-у), а Spyder у [23].

У ТАБ. 38 наведени су Python пакети који су истакнути у прегледаним радовима. Наравно, у многим радовима спомиње се више од једног пакета, а основни пакети попут Pandas и NumPy нису укључени у ову анализу. У тој табели такође се налази укупно 40 референци. Најчешће коришћени пакети у прегледаним радовима су Keras и TensorFlow.

ТАБ. 37: Програмски језици у прегледаним радовима

Језик	Број радова	Радови
Python	31 (77,5%)	[4], [6], [8], [10], [13], [15], [17], [18], [19], [20], [21], [22], [23], [25], [26], [27], [28], [30], [32], [33], [34], [37], [38], [39], [41], [42], [44], [45], [48], [49], [50]
MATLAB	7 (17,5%)	[9], [16], [29], [31], [40], [43], [45]
R	2 (5%)	[8], [29]



Сл. 60: Програмски језици у прегледаним радовима

ТАБ. 38: Најважнији Python пакети у прегледаним радовима

Пакет	Број радова	Радови
Keras	13 (32,5%)	[8], [10], [13], [18], [22], [23], [28], [32], [34], [42], [44], [49], [50]
TensorFlow	10 (25%)	[17], [21], [23], [26], [32], [38], [42], [44], [49], [50]
Scikit-learn	9 (22,5%)	[4], [10], [15], [17], [19], [32], [38], [42], [49]
PyTorch	4 (10%)	[37], [39], [41], [45]
PyTorch Forecasting	1 (2,5%)	[33]
PVlib	2 (5%)	[25], [38]
pmdarima	1 (2,5%)	[34]

Keras је интерфејс за програмирање апликација (енгл. *Application Programming Interface* – API) високог нивоа који поједностављује процес израде и обуке модела МУ. Једноставан је за коришћење и интуитиван, што олакшава креирање, обуку и евалуацију модела МУ. С друге стране, може бити мање погодан за високо специјализоване или експерименталне архитектуре које захтевају дубинско прилагођавање. Стога га често преферирају истраживачи који траже брзи развој.

TensorFlow је библиотека и оквир отвореног кода (енгл. *open-source framework*) који нуди скуп функција, алата и структура за израду, обуку, евалуацију и имплементацију апликација за

машинско учење. Тензори су вишедимензионални низови који се користе за представљање података при машинском учењу. TensorFlow може интерно да представља израчунавања као графове тока података, где чворови представљају математичке операције, а ивице токове тензора између њих. Пружа API-је и високог и ниског нивоа, али генерално ради на нижем нивоу од Keras-а, пружајући детаљнију контролу над израчунавањима и архитектуром модела. Стога, може бити сложенији за употребу.

Што се тиче спомињања Keras-а и TensorFlow-а у радовима, треба имати на уму да се у актуелним верзијама, по подразумеваним подешавањима, они користе заједно. Keras може да употребљава и друге позадинске механизме (енгл. *backend engine*), нпр. PyTorch, али његов подразумевани позадински механизам је TensorFlow. Постоје алати трећих страна са графичким корисничким интерфејсом који генеришу Keras код у позадини, али ниједан од прегледаних радова не спомиње такво решење.

Scikit-learn је библиотека отвореног кода која пружа свеобухватан скуп алата и функција за различите методе машинског учења, метрике и помоћне технике (нпр. импутацију, унакрсну валидацију итд.).

PyTorch представља оквир отвореног кода за дубоко учење који пружа алате за израду и тренирање неуронских мрежа. Поддржава тензорске операције ниског нивоа, аутоматско израчунавање градијената и друге функционалности које олакшавају истраживање и развој машинског учења. PyTorch Forecasting је библиотека високог нивоа за предвиђање временских серија, која користи PyTorch и PyTorch Lightning. Поједностављује рад са PyTorch-ом слично као што Keras поједностављује рад са TensorFlow-ом.

PVlib пружа скуп функција и класа за симулацију перформанси фотонапонских система. Pmdarima је библиотека за рад са ARIMA моделима.

3.4 Закључци

Ово поглавље представља преглед 50 најбољих радова који се баве прогнозирањем производње фотонапонске снаге, одабраних према критеријумима актуелности, репрезентативности и доступности. Радови су анализирани у односу на низ фактора који утичу на прогнозирање.

Класификација радова у категорије открива изразиту превагу метода машинског учења у овој области: свега 2 од 50 прегледаних радова користе искључиво решења која нису заснована на машинском учењу. Нове, побољшане методе машинског учења предложене су у 54% радова. 11 радова примењује методе машинског учења без модификација, али остварује напредак употребом методе која досад није коришћена у овој области, или тиме што тежи да побољша друге аспекте процеса прогнозирања, нпр. избор улазних обележја, предобраду података, итд. Поређење различитих метода представља главни фокус у 20% радова.

Најчешће коришћена метода прогнозирања је LSTM, како у основном облику, тако и као модификовано или хибридно решење. Та метода посебно је ефикасна у раду са временским серијама, али није погодна за све типове података: неки истраживачи известили су да LSTM није донео никакво побољшање или је чак пружио лошије перформансе у поређењу са једноставнијим методама. То би такође могло бити узроковано неадекватним подешавањем хиперпараметара. Осим тога, у неколико радова примењен је GRU, који је сличан LSTM-у.

Методе засноване на стаблима одлучивања, посебно RF, и методе засноване на конволуцији, посебно CNN, деле друго место, а следи их MLP. Остале методе прогнозирања, свака за себе, користе се знатно мање од 4 споменуте групе; ипак, та анализа показала је да се широк спектар различитих метода примењује за прогнозирање снаге фотонапонских система.

Методе прогнозирања засноване на LSTM-у, GRU-у и конволуцији углавном пружају најбољу тачност, тј. оне су најчешће међу методама које су произвеле nRMSE мањи од 2% у

прегледаним радовима. Према тој анализи, хибридне и/или модификоване методе генерално дају бољу тачност од основних.

Што се тиче врста прогнозирања у погледу одређености резултата, 90% радова бави се детерминистичким прогнозирањем, док би пробабилистичко (интервално) и сценаријско прогнозирање требало више испитати у будућности. Анализа обухвата прогноза показала је да 88% радова даје прогнозе само за једну електрану; преосталих 12% подједнако је подељено између прогноза за један модул, групу електрана и регион, што показује да је у тим обухватима потребно више истраживања. Регионалне прогнозе могу бити занимљиве не само оператерима мреже већ и државним властима, док прогнозе за групу електрана могу бити занимљиве и већим произвођачима.

Број записа у коришћеним скуповима података (након предобраде) варира од само 335 до чак 1,6 милиона, али скоро половина скупова података има између 10 000 и 50 000 записа. Најчешће временске резолуције (након предобраде) су 1 сат, 15 минута и 5 минута. Временска резолуција (грануларност) утиче на изводљиве хоризонте прогнозе и на број записа у скуповима података; стога, треба направити компромис између потребних ресурса и жељене временске резолуције.

Убедљиво најчешћи хоризонт прогнозе у прегледаним радовима је 1 дан унапред, вероватно због обавезе произвођача у неким земљама да достављају такве прогнозе на тржишту. Остали појединачни хоризонти који се јављају у по 3 до 4 рада су 5 и 15 минута, 1 сат и 7 дана унапред. С друге стране, само 3 рада укључена у ту анализу истраживала су хоризонте дуже од 7 дана; очигледно је да такве хоризонте треба пажљивије испитати у будућим истраживањима. Исто важи и за хоризонте краће од 5 минута.

Што се тиче максималног броја корака унапред, хоризонти прогнозе у прегледаним радовима крећу се од 1 до чак 336. (Наравно, то не подразумева итеративни приступ.) Најчешћи бројеви корака унапред су 24 (типично за прогнозу за 1 дан унапред са резолуцијом од 1 сата), 96 (типично за прогнозу за 1 дан унапред са резолуцијом од 15 минута) и 1. Све методе прогнозирања које се користе за више од 100 корака унапред представљају хибридна или ансамбл решења.

Што се тиче врста података, очекивано је што се историјски подаци о снази фотонапонског система примењују у скоро свим прегледаним радовима барем за минимизовање грешака, а у многим радовима и као улазни подаци за модел. У 8 радова не користе се никакви други подаци осим историјских података о снази фотонапонског система. Остала најчешћа улазна обележја су температура ваздуха и нека врста ирадијансе. Од других обележја треба истаћи соларне углове, иако се примењују у само 6 радова, због тога што се лако могу израчунати, а постоје извештаји да су врло корисни за тачност прогнозе. Свега 3 рада баве се снимцима неба и сателитским снимцима; ти радови извештавају о нерешеним проблемима, тако да би то подручје могло захтевати више пажње у будућим истраживањима.

Предобрада података описана је или барем споменута у скоро свим прегледаним радовима, што је доказ њеног широко препознатог значаја.

У прегледаним радовима коришћени су соларни системи снаге од 500 W до 451,82 MW, са прилично равномерном расподелом. Просечна величина постројења у тој анализи износи око 14,3 MW, али медијана је много мања, 67,5 kW.

Избор улазних обележја требало би детаљније испитати у будућим истраживањима, зато што није адекватно истражен у прегледаним радовима. То посебно важи за алгоритамске методе селекције обележја, које омогућавају аутоматизацију. Уочено је да свега 3 рада примењују омотачке методе, док уграђене методе селекције обележја нису коришћене ни у једном од прегледаних радова. Штавише, неки истраживачи упоредили су неколико скупова обележја и навели да избор обележја може бити чак и важнији од избора методе прогнозирања. Анализа

радова са најбољим $nRMSE$ мањим од 2% показује да филтерске и омотачке методе селекције обележја имају већу вероватноћу да произведу врхунску тачност него емпиријске.

Оптимизација хиперпараметара представља још један аспект ком би требало посветити много више пажње у будућим истраживањима, посебно метахеуристичким методама оптимизације, које генерално производе боље вредности хиперпараметара од осталих приступа. Нажалост, само 2 рада директно и 1 индиректно користе метахеуристике за ту сврху; већина се ослања на експерименталне и емпиријске приступе, који се не могу аутоматизовати. На основу анализе радова са најбољим $nRMSE$ мањим од 2%, веома је препоручљива употреба метахеуристике за оптимизацију хиперпараметара, због тога што су све коришћене метахеуристике произвеле врхунску тачност. Насупрот томе, оптимизацију путем претраге по мрежи треба избегавати.

Најчешћа група метрика за детерминистичке прогнозе у прегледаним радовима састоји се од $RMSE$ и повезаних метрика (MSE , $nRMSE$, $RMSE$ оцена успешности, итд.), затим следе MAE са повезаним метрикама ($nMAE$, $MASE$) и R^2 (кофицијент детерминације) са сличним метрикама. Међутим, постоји очигледна потреба да се стандардизује референтна вредност за нормализацију метрика. Због недостатка заједничког стандарда, у прегледаним радовима за нормализацију се користи више различитих вредности, што онемогућава поређење нормализованих метрика. У овом прегледу, за нормализацију се предлаже употреба максималне могуће вредности; у области прогнозирања снаге фотонапонског система, то је номинални капацитет фотонапонског система. Ако та вредност није позната, може се апроксимирати максималном уоченом вредношћу, под претпоставком да је скуп података довољно репрезентативан.

Уочени распони неколико најрепрезентативнијих метрика наведени су у одељку 3.3.14, заједно са примерима који се односе на неке факторе који могу утицати на тачност предвиђања. Анализа величина неуронских мрежа показује да су MLP мреже обично знатно мање од $LSTM$ и других рекурентних мрежа. Просечан број скривених ћелија за MLP у прегледаним радовима износи 40,63, док је просек за све рекурентне мреже 156,93 скривених јединица или ћелија. Што се тиче функција активације у прегледаним радовима, $ReLU$ је најчешће коришћена, а затим следи логистичка („сигмоидна“) функција.

Најчешћи оптимизатор у прегледаним радовима је $Adam$. Левенберг-Марквардов алгоритам, на другом месту, далеко заостаје, а следе га SGD и $RMSProp$. Занимљиво решење са метахеуристичком као екстерним оптимизатором у [40] произвело је одличну тачност. У складу са тим што су $RMSE$ и повезане метрике најчешће, MSE је најчешћа функција губитка у овом прегледу. $Python$ је убедљиво најкоришћенији програмски језик у прегледаним радовима; остали употребљени језици су $MATLAB$ и R . Најчешће $Python$ библиотеке укључују $Keras$, $TensorFlow$ и $Scikit-learn$.

Овај преглед показао је задовољавајућу разноликост у погледу метода прогнозирања и неких других аспеката као што су величине скупова података, капацитети постројења, грануларност, величине неуронских мрежа итд. Насупрот томе, потребно је посветити више пажње прогнозама за регион и групу постројења, дужим хоризонтима, пробабилистичком и сценаријском прогнозирању, а посебно избору улазних обележја и оптимизацији хиперпараметара.

4 Предложено решење

Ово поглавље представља нови алгоритам који је коришћен у експериментима. Након описа алгоритма представљени су скупови података, истраживачка анализа и преобрада података, као и поставке симулација помоћу којих је предложени алгоритам тестиран.

4.1 Модификовани метахеуристички алгоритам

У овом одељку најпре је описана основна верзија алгоритма оптимизације роја честица (енгл. *Particle Swarm Optimization* – PSO). Након тога, описани су уочени недостаци те методе и детаљно је објашњена модификована имплементација PSO која решава те недостатке.

4.1.1 Оригинални PSO алгоритам

Основни PSO алгоритам представља еволутивну рачунарску технику инспирисану друштвеним интеракцијама уоченим у јатима птица и риба [80]. То је стратегија оптимизације заснована на популацији. Тај алгоритам обрађује вишедимензионални домен претраге, при чему његова решења (честице) одговарају могућим резултатима функције прилагођености, и могу се кретати унутар тог простора претраге. Свака честица прати и своју претходну најбољу позицију (тј. позицију за коју је добијена најбоља вредност функције прилагођености, енгл. *personal best* – *pbest*) и најбољу позицију коју су утврдиле њене суседне честице (енгл. *neighbor best* – *nbest*). Оптимална позиција сматра се глобално најбољом (енгл. *global best* – *gbest*) у случају да се све честице унутар популације сматрају суседима; то је варијанта која се разматра у овом истраживању, с обзиром на мали број честица у популацији. Може се рећи да честице „комуницирају” о региону претраге, пошто свака честица има увид у *gbest*.

Оптимизација роја честица почиње случајним синтетисањем положаја сваке честице. Свака честица затим се креће ка најбољем решењу док цео рој колективно идентификује глобално оптималну локацију. Као део процеса иницијализације, положаји и брзине (тј. помераји) свих честица насумично се производе коришћењем поступка иницијализације PSO, представљеног једначинама (62) и (63).

$$x_{i,d}(0) = \text{rnd}() \times (x_{\max,d} - x_{\min,d}) + x_{\min,d} \quad (62)$$

$$v_{i,d}(0) = \text{rnd}() \times 2 \times v_{\max,d} - v_{\max,d} \quad (63)$$

При томе $x_{i,d}(0)$ одговара почетној позицији честице (индивидуе) i у димензији d , функција $\text{rnd}()$ користи се за генерисање произвољног броја унутар опсега $[0, 1]$, док $x_{\min,d}$ и $x_{\max,d}$ означавају границе домена претраге у датој димензији. Аналогно томе, $v_{i,d}(0)$ представља почетну брзину честице i у димензији d . Брзина честице ограничена је унутар опсега $[-v_{\max,d}, v_{\max,d}]$, где је $v_{\max,d}$ унапред дефинисана граница. То ограничење осигурава да кретање честице остане унутар додељеног подручја претраге. Поред тога, вредност $v_{\max,d}$ ограничава обим претраге између тренутне позиције и циљне локације.

Свака честица ажурира своју локацију и прати сопствену брзину током итерација. Претходна најбоља позиција честице i у димензији d (тј. компонента $pbest_i$ у тој димензији) дата је са $p_{i,d}$, а $p_{g,d}$ означава глобално најбољу позицију у тој димензији (тј. компоненту $gbest$ у тој димензији). Једначине (64) и (65) користе се за утврђивање тренутне брзине честице i кроз димензију d током итерације t :

$$\begin{aligned}
v_{i,d}(t) &= w \times v_{i,d}(t-1) \\
&+ c_1 \times \text{rnd}() \times (p_{i,d}(t-1) - x_{i,d}(t-1)) \\
&+ c_2 \times \text{rnd}() \times (p_{g,d}(t-1) - x_{i,d}(t-1))
\end{aligned} \tag{64}$$

$$v_{i,d} \in [-v_{max,d}, v_{max,d}] \tag{65}$$

Горње једначине састоје се од неколико кључних делова. Функција $\text{rnd}()$ производи произвољну вредност у опсегу $[0, 1]$, различиту при сваком позиву. Вредности c_1 и c_2 познате су као коефицијенти убрзања и одговарају утицајима индивидуалног и друштвеног искуства, респективно; од тих вредности зависи у којој мери честица тежи да се креће ка сопственој најбољој позицији и глобалној најбољој позицији. Тежина инерције, означена са w , служи за уравнотежење локалног и глобалног интензитета претраге.

Локација честице i кроз димензију d током итерације t одређује се на основу претходне локације и тренутне брзине (тј. помераја) на начин приказан једначинама (66) и (67). Локације честица у свакој димензији ограничене су унутар дозвољеног опсега за ту димензију.

$$x_{i,d}(t) = x_{i,d}(t-1) + v_{i,d}(t) \tag{66}$$

$$x_{i,d} \in [x_{min,d}, x_{max,d}] \tag{67}$$

Процедурални псеудокод за основни PSO дат је у алгоритму 1.

Алгоритам 1: Процедурални псеудокод за основни PSO

```

1  # Део I: Иницијализација
2  За сваку честицу i
3      За сваку димензију d
4          Иницијализуј  $x_{i,d}(0)$  по једначини (62)
5          Иницијализуј  $v_{i,d}(0)$  по једначини (63)
6          Постави  $p_{i,d}(0) = x_{i,d}(0)$ 
7      Крај
8      Израчунај  $f[x_i(0)]$ , тј. функцију прилагођености за честицу
9      Ако је  $i = 1$  или је  $f[x_i(0)]$  боље од  $f[gbest(0)]$ 
10         Ажурирај  $gbest(0)$ , тј. за сваку димензију  $d$  постави  $p_{g,d}(0) = x_{i,d}(0)$ 
11     Крај
12 Крај
13 # Део II: Итерације
14 За сваку итерацију t
15     Постави  $gbest(t) = gbest(t-1)$ 
16     За сваку честицу i
17         Постави  $pbest_i(t) = pbest_i(t-1)$ 
18         За сваку димензију d
19             Израчунај  $v_{i,d}(t)$  по једначинама (64) и (65)
20             Израчунај  $x_{i,d}(t)$  по једначинама (66) и (67)
21         Крај
22     Израчунај функцију прилагођености за честицу  $f[x_i(t)]$ 
23     Ако је  $f[x_i(t)]$  боље од  $f[pbest_i(t)]$ , за сваку дим.  $d$  постави  $p_{i,d}(t) = x_{i,d}(t)$ 
24     Ако је  $f[x_i(t)]$  боље од  $f[gbest(t)]$ , за сваку дим.  $d$  постави  $p_{g,d}(t) = x_{i,d}(t)$ 
25     Крај
26 Крај

```

27 # Део III: Резултати

28 Врати $gbest(t)$, тј. решење које има најбољу вредност функције прилагођености

4.1.2 Предложени измењени PSO алгоритам

Основна имплементација PSO генерално се сматра веома моћном техником оптимизације, која је и даље применљива у многим савременим проблемима, иако је развијена пре скоро тридесет година. И поред тога што тај алгоритам издржава тест времена, опсежне симулације са најновијим референтним функцијама [107] откривају нека подручја где се могу направити побољшања. То се пре свега односи на ограничени потенцијал истраживања (експлорације) који се може приметити током каснијих итерација. Осим тога, примећено је и да би алгоритам могао имати користи од почетног повећања разноликости решења. Да би се превазишли уочени недостаци основног PSO, у овом истраживању предлаже се модификована имплементација тог алгоритма која је заснована на контроли разноликости популације.

Да би се повећала разноликост решења током фазе иницијализације, у алгоритам је додат поступак квази-рефлексивног учења (енгл. *Quasi-Reflexive Learning* – QRL) [108]. Половина почетних решења („јединки”) синтетисана је коришћењем процедуре основног PSO дате у једначини (62). Затим је друга половина произведена на основу прве помоћу QRL механизма, ради побољшања разноликости укупне синтетисане популације. За решење x_i генерише се квази-рефлексивно решење x_i^{qr} на начин описан једначином (68).

$$x_{i,d}^{qr} = \text{rnd}\left(\frac{x_{min,d} + x_{max,d}}{2}, x_{i,d}\right) \quad (68)$$

При томе је $\frac{x_{min,d} + x_{max,d}}{2}$ средња вредност граница дате компоненте у димензији d , а функција $\text{rnd}()$ генерише случајан број унутар задатих граница.

За праћење разноликости (диверзитета) популације може се користити L1 норма [109]. Та мера узима у обзир и разноликост међу решењима и димензионалност проблема оптимизације који се решава. За популацију од N решења и димензионалност D , L1 норма може се израчунати на начин приказан у једначинама (69)-(71):

$$\bar{x}_d = \frac{1}{N} \sum_{i=1}^N x_{i,d} \quad (69)$$

$$Ds_d^p = \frac{1}{N} \sum_{i=1}^N |x_{i,d} - \bar{x}_d| \quad (70)$$

$$Ds^p = \frac{1}{D} \sum_{d=1}^D Ds_d^p \quad (71)$$

При томе је \bar{x} низ средњих вредности позиција решења по димензијама простора претраге, Ds_d^p су разноликости по димензијама, док Ds^p представља показатељ разноликости популације као целине, тј. L1 норму популације.

Пошто је већа разноликост пожељна током почетне фазе, разноликост треба динамички прилагођавати током процеса обуке. L1 норма користи се за регулисање разноликости помоћу параметра динамичког прага разноликости Ds_t . У свакој итерацији неколико најлошијих решења брише се из популације и замењује новим, која се производе у зависности од

разноликости популације. Разноликост се прати помоћу параметра DS_t , при чему се почетни праг разноликости DS_{t_0} израчунава на основу једначине (72).

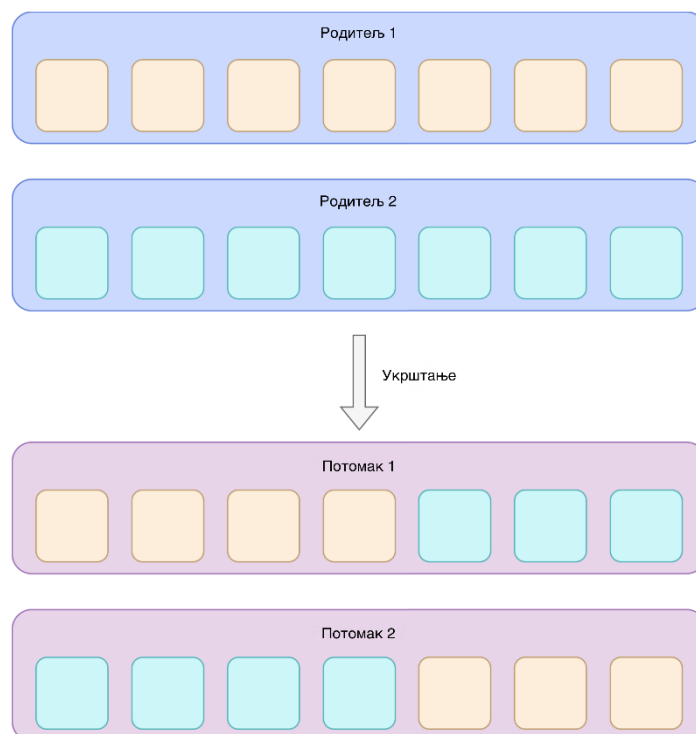
$$DS_{t_0} = \sum_{d=1}^D \frac{x_{max,d} - x_{min,d}}{2D} \quad (72)$$

Током извршавања алгоритма, када решења почну да конвергирају ка оптималној области, вредност DS_t треба смањивати од почетне $DS_t = DS_{t_0}$ на начин описан једначином (73).

$$DS_{t+1} = DS_t - DS_t \cdot \frac{t}{T} \quad (73)$$

При томе су t и $t + 1$ текућа и следећа итерација, респективно, док T означава укупан број итерација по извршењу. Током каснијих фаза извршења, пошто се DS_t динамички смањује, процедура прилагођавања разноликости ће престати да се покреће, без обзира на вредност DS^p .

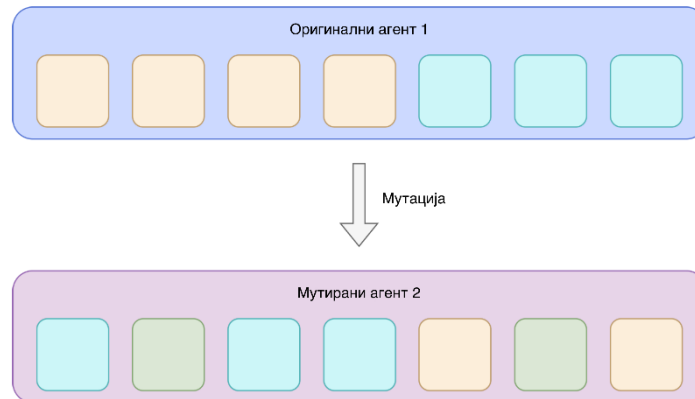
На крају сваке итерације, укупно nrs решења избацује се из популације и замењује свеже произведеним решењима. Емпиријски и експериментално утврђено је да су перформансе оптималне за $nrs = 2$. Ако је $DS^p < DS_t$, тј. ако је разноликост популације мања од динамичког прага, нова решења производе се рекомбиновањем (укрштањем) два насумично одабрана решења из популације, што доводи до повећања разноликости и стимулише истраживање. У супротном, нова решења производе се од два најбоља решења, чиме се стимулише експлоатација. Нова решења синтетичу се механизмима укрштања и мутације инспирисаним генетским алгоритмом (енгл. *Genetic Algorithm* – GA) [110]. Процес укрштања комбинује параметре из родитељских решења да би се произвела решења-потомци, као што је илустровано на сл. 61.



сл. 61: Механизам генетског укрштања

Процес мутације омогућава даље мање модификације произведених решења финим мењањем параметара произведеног решења у произвољном смеру. Тај поступак илустрован је на сл. 62. Процесе укрштања и мутације контролишу параметри CP (вероватноћа укрштања, енгл. *Crossover Probability*) и MP (вероватноћа мутације, енгл. *Mutation Probability*), који су

емпиријски подешени за најбоље перформансе при $CP = 0,9$ и $MP = 0,1$. Укрштање се врши само ако је случајан број мањи од CP . У случају мутације, провера помоћу MP и случајних бројева врши се за сваки параметар засебно.



Сл. 62: Механизам генетске мутације

Узимајући у обзир извршене измене, предложени алгоритам назван је оптимизација роја честица вођена разноликошћу (енгл. *Diversity-Guided PSO – DGPSO*). Процедурални псеудокод дат је у алгоритму 2.

Алгоритам 2: Процедурални псеудокод за предложени DGPSO

```

1 # Део I: Иницијализација
2 Иницијализуј позиције  $x_{i,d}(0)$  за 50% популације као у основном PSO
3 Синтеши другу половину популације на основу прве по једначини (68)
4 Иницијализуј  $v_{i,d}(0)$ ,  $p_{i,d}(0)$  и  $p_{g,d}(0)$  као у основном PSO
5 Израчунај  $Ds_t = Ds_{t0}$  по једначини (72)
6 # Део II: Итерације
7 За сваку итерацију  $t$ 
8     Постави  $gbest(t) = gbest(t - 1)$ 
9     За сваку честицу  $i$ 
10        Постави  $pbest_i(t) = pbest_i(t - 1)$ 
11        За сваку димензију  $d$ 
12           Израчунај  $v_{i,d}(t)$  по једначинама (64) и (65)
13           Израчунај  $x_{i,d}(t)$  по једначинама (66) и (67)
14        Крај
15     Израчунај функцију прилагођености за честицу  $f[x_i(t)]$ 
16     Ако је  $f[x_i(t)]$  боље од  $f[pbest_i(t)]$ , за сваку дим.  $d$  постави  $p_{i,d}(t) = x_{i,d}(t)$ 
17     Ако је  $f[x_i(t)]$  боље од  $f[gbest(t)]$ , за сваку дим.  $d$  постави  $p_{g,d}(t) = x_{i,d}(t)$ 
18     Крај
19 # Део III: Корекција разноликости популације
20 Израчунај  $Ds^p$  по једначинама (69)-(71)
21 Ако је  $Ds^p < Ds_t$ 
22     Синтеши заменска решења укрштањем  $nrs$  произвољних решења
23 Иначе
24     Синтеши заменска решења укрштањем  $nrs$  најбољих решења
25 Крај
26 Мутирај заменска решења
27 Замени  $nrs$  најлошијих решења
28 Израчунај  $Ds_{t+1}$  по једначини (73)
    
```

29	Крај
30	# Део III: Резултати
31	Врати $g_{best}(t)$, тј. решење које има најбољу вредност функције прилагођености

4.2 Скупови података

У овом истраживању коришћена су два скупа података. Први скуп података садржи податке о производњи фотонапонске енергије из две електране у Индији и јавно је доступан на веб сајту Kaggle. Други скуп креиран је из сирових података у оквиру овог истраживања.

4.2.1 Јавно доступан скуп података из Индије

Први скуп података садржи податке о производњи фотонапонске енергије и метеоролошким условима из две фотонапонске електране у Индији. Електрана 1 налази се у близини Гандикоте у савезној држави Андра Прадеш, а електрана 2 је у близини Нашика у савезној држави Махараштра. Електране су удаљене једна од друге око 750 km у ваздушној линији, али имају исти број инвертора – 22, сличне метеоролошке услове и сличне перформансе. На сваки инвертор повезан је исти број соларних панела. Скуп података покрива период од 15. маја 2020. до 17. јуна 2020. године, укупно 34 дана, са посматрањима забележеним у интервалима од 15 минута. Јавно је доступан на адреси <https://www.kaggle.com/datasets/anikannal/solar-power-generation-data> и последњи пут му је приступљено 1. децембра 2024.

Скуп података изворно се налази у 4 датотеке – за сваку од електрана, у засебним датотекама су подаци о производњи фотонапонске енергије и подаци са метеоролошких сензора. У свакој од датотека недостаје одређени број записа, вероватно због одржавања или кварова. Колоне у обе датотеке са подацима о фотонапонској производњи су следеће:

- DATE_TIME – временска ознака (датум и време) записа,
- PLANT_ID – исто за целу електрану,
- SOURCE_KEY – ознака инвертора,
- DC_POWER – тренутна снага једносмерне струје на инвертору,
- AC_POWER – тренутна снага наизменичне струје на инвертору,
- DAILY_YIELD – принос инвертора тог дана до тог тренутка,
- TOTAL_YIELD – укупан принос инвертора до тог тренутка.

Колоне у обе датотеке са подацима о метеоролошким условима су следеће:

- DATE_TIME – временска ознака (датум и време) записа,
- PLANT_ID – исто за целу електрану,
- SOURCE_KEY – ознака сензорског панела (заједничка за целу датотеку јер постоји само један сензорски панел по електрани),
- AMBIENT_TEMPERATURE – температура ваздуха,
- MODULE_TEMPERATURE – температура соларног панела повезаног на сензорски панел,
- IRRADIATION – сунчево зрачење.

Према аутору скупа података, снаге су дате у kW. У овом истраживању претпостављено је да су вредности колоне DC_POWER за електрану 1 грешком помножене са десет; стога је вредност за спроведене симулације подељена са десет. Пошто јединица мере за температуре није наведена, на основу вредности у скупу података, претпоставља се да су температуре дате у °C.

Да би се избегла забуна, колона IRRADIATION преименована је у IRRADIANCE. Соларна ирадијација (енгл. *irradiation*, назива се и инсолација) представља меру кумулативне енергије примљене од Сунца по јединици површине током дефинисаног периода, док је ирадијанса (енгл. *irradiance*) мера тренутне соларне снаге по јединици површине. На основу вредности у

скупу података, може се претпоставити да је ирадијанса изражена у kW/m^2 . Међутим, да би се та колона ускладила са другим скупом података и уобичајеном јединицом мере, помножена је са 1000 и изражава се у W/m^2 .

У наставку овог поглавља, након описа другог скупа података, следе описи спроведене истраживачке анализе података и предобrade.

4.2.2 Нови скуп података

Други скуп података садржи податке о производњи фотонапонске енергије и метеоролошким условима из фотонапонске електране која се налази на крову Института „Михајло Пупин” (ИМП) у Београду. Та електрана много је мања од оних из првог скупа података – садржи 2 инвертора са укупно 180 соларних панела, сваки снаге 280 W. Са инвертором од 30 kW повезано је 6 низова са укупно 108 панела, а са инвертором од 20 kW повезана су 4 низа са укупно 72 панела. Скуп података обухвата целу 2020. годину и састављен је од сирових података добијених из система за надзор и аквизицију података (енгл. *Supervisory Control and Data Acquisition – SCADA*) ИМП-а. Сирови подаци садрже велики број узорака за преко 200 различитих променљивих. Око 90 променљивих у сировим подацима односи се на фотонапонску електрану, а остале потичу из неких других система у ИМП-у.

Колоне сирових података су следеће:

- `elementId` – нумерички идентификатор променљиве,
- `time` – време записа,
- `msec` – милисекунде (не користи се),
- `value` – вредност променљиве,
- `status` – статус записа (добијен спајањем могућих вредности операцијом ИЛИ на нивоу бита).

У сировим подацима, сваки датум чува се у посебној табели. Као пример, на сл. 63 приказан је мали део сирових података за 3. август 2020. Осим тога, у заједничким табелама дефинисане су променљиве, компоненте статуса и слично.

	elementId	time	msec	value	status
▶	139	12:00:00	0	430312	32
	143	12:00:00	0	36.2105	0
	145	12:00:00	0	-36.1903	0
	155	12:00:00	0	395.54	0
	156	12:00:00	0	395.134	0
	157	12:00:00	0	395.995	0
	225	12:00:00	0	200.791	0
	226	12:00:00	0	1.98681	0
	227	12:00:00	0	890.256	0
	433	12:00:00	0	571	0

Сл. 63: Исечак из сирових података за други скуп

Статус се мора узети у обзир приликом обраде сирових података зато што записи са неким статусима не би требало да се користе за коначни скуп података. Штавише, скупови могућих статуса варирају за различите променљиве. Када се неки статуси јаве, приликом одређивања како обрадити запис мора се узети у обзир и контекст (нпр. доба дана, да ли је генерисање почело, итд.), а неки статуси чак утичу на обраду наредних записа за исту променљиву! То је био један од изазова приликом обраде сирових података. Да би се олакшало машинско учење, интервал у другом скупу података исти је као у првом – 15 минута. Пошто су узорци у сировим подацима узети у произвољним тренуцима, недостајуће вредности додате су помоћу линеарне

интерполације, а након тога израчунате су средње вредности за сваки интервал од 15 минута. Пошто су инвертори неједнаки и много мањи од оних у првом скупу података, снаге у другом скупу података представљене су као збир снага оба инвертора, а не средње вредности као у првом скупу података.

Следеће променљиве постоје само у другом скупу података:

- WIND_DIRECTION – смер ветра у степенима,
- WIND_SPEED – брзина ветра у m/s.


Остале променљиве у другом скупу података исте су као оне које су задржане у првом скупу података након предобrade (описане у одељку 4.4), са истим називима, значењима и јединицама мере.

4.3 Истраживачка анализа података

Истраживачка анализа података (*Exploratory Data Analysis* – EDA) представља предуслов за добијање било какве употребљиве информације из неког скупа података. Зато је над изабраним скуповима података најпре извршена анализа и одређене припремне радње, тј. предобrada. Те две фазе обављају се упоредо, и зато су у неке од извршених анализа укључене и променљиве додате током предобrade (TIME, DAY_OF_YEAR, EFF, EFF_PREV, AC_POWER_PREV). Више информација о тим променљивим дато је у одељку 4.4.


4.3.1 Приказ вредности података

На сл. 64, сл. 65 и сл. 66 приказано је мењање просечне снаге наизменичне струје (АС снаге) и просечне ирадијансе за оба скупа података, током читавих периода који ти скупови података обухватају: 34 дана за први, односно годину дана за други скуп података. Свака трака на графикону представља просек тренутних вредности тих променљивих током интервала који је њоме обухваћен; за први скуп података, свака трака представља један дан, а за други, једну седмицу. Просечна АС снага означена је плавом, а просечна ирадијанса црвеном бојом.




Сл. 64: Просечне АС снаге и ирадијансе по данима за први скуп података – електрана 1

Са слика је очигледна тесна повезаност те две променљиве, одн. чињеница да генерисана електрична енергија превасходно зависи од интензитета сунчевог зрачења. Ипак, треба имати у виду да се ради о просечним вредностима, и то током релативно дугих интервала (нарочито у случају другог скупа података), а у многим практичним применама потребна је краткорочна прогноза тренутних вредности. Осим тога, са слика се види да је у појединим интервалима било извесних одступања при мењању те две променљиве. Може се закључити да има простора за побољшање квалитета прогнозе тиме што ће се приликом прогнозирања генерисане електричне енергије користити и друге доступне променљиве, а не само ирадијанса.




Сл. 65: Просечне АС снаге и ирадијансе по данима за први скуп података – електрана 2




Сл. 66: Просечне АС снаге и ирадијансе по седмицама за други скуп података

На сл. 67, сл. 68 и сл. 69 приказано је мењање просечних температура – температуре модула и температуре амбијента (тј. ваздуха) за оба скупа података, током читавих периода који ти скупови података обухватају. Свака трака на графикону представља просек тренутних вредности тих променљивих током интервала који је њоме обухваћен; за први скуп података, свака трака представља један дан, а за други, једну седмицу. Просечна температура модула означена је плавом, а просечна температура ваздуха црвеном бојом.




Сл. 67: Просечне температуре ваздуха и модула по данима за први скуп података – електрана 1

Са слика је очигледно да се те две температуре мењају на сличан начин, тј. по истим трендовима. При томе је просечна температура модула скоро увек већа од просечне температуре ваздуха. Разлика између те две температуре израженија је током пролећних и летњих месеци, приближно од краја марта до краја октобра. Разлог за то је што се соларни модули загревају брже од амбијента који их окружује.



Сл. 68: Просечне температуре ваздуха и модула по данима за први скуп података – електрана 2



Сл. 69: Просечне температуре ваздуха и модула по седмицама за други скуп података

Просечна разлика између те две температуре мања је у другом него у првом скупу података. Разлог за то је што други скуп података обухвата и јесен и зиму. Још један разлог је то што су измерене температуре ваздуха у другом скупу података знатно више од очекиваних, тј. од мерења РХМЗ, што је описано у одељку 4.4.

Када се свака од тих слика које приказују просечне температуре упореди са одговарајућом сликом просечних АС снага и ирадијанси, уочава се извесна сличност приказаних графикана: температуре ваздуха и модула у принципу се мењају по истим трендовима као интензитет сунчевог зрачења. Осим тога, постоји извесан утицај температуре модула и температуре ваздуха на циљну променљиву.

4.3.2 Анализа нормалности података

Асиметричност (енгл. *skewness*) и спљоштеност (енгл. *kurtosis*) често се користе као показатељи у којој мери расподела података одступа од нормалне. Начин рачунања коефицијената асиметричности и спљоштености описан је у одељку 2.7.1. Прихватљиве вредности коефицијента асиметричности су у опсегу $[-2, 2]$, а коефицијента спљоштености у опсегу $[-7, 7]$, мада се у литератури могу наћи и другачији предлози.

У ТАБ. 39 и ТАБ. 40 дате су вредности коефицијената асиметричности и спљоштености за први и други скуп података, респективно. Може се видети да су за све променљиве вредности тих коефицијената у наведеним опсезима, што значи да расподеле података не показују битнија одступања од нормалне расподеле.

ТАБ. 39: Вредности коефицијената асиметричности и спљоштености за први скуп података

Променљива	Електрана 1		Електрана 2	
	Асиметричност	Сплљоштеност	Асиметричност	Сплљоштеност
IRRADIANCE	1,047586	-0,207574	1,068811	-0,311171
MODULE_TEMPERATURE	0,854903	-0,637280	0,960009	-0,381987
AMBIENT_TEMPERATURE	0,684766	-0,515818	0,654174	-0,677571
TIME	-0,024704	-1,184542	0,004095	-1,204568
DAY_OF_YEAR	-0,048072	-1,190709	0,002388	-1,202970
AC_POWER_PREV	0,942092	-0,551008	1,032859	-0,392852
EFF_PREV	-0,129932	-1,982545	-0,114526	-1,984887
AC_POWER	0,942092	-0,551008	1,032859	-0,392852

ТАБ. 40: Вредности коефицијената асиметричности и спљоштености за други скуп података


Променљива	Асиметричност	Сплљоштеност
WIND_DIRECTION	0,152067	-0,934940
WIND_SPEED	1,818856	4,037461
IRRADIANCE	1,753171	1,783454
MODULE_TEMPERATURE	0,865789	0,164143
AMBIENT_TEMPERATURE	0,284214	-0,611439
TIME	0,000000	-1,200260
DAY_OF_YEAR	0,000000	-1,200018
AC_POWER_PREV	1,678623	1,533296
EFF_PREV	-0,125608	-1,984048
AC_POWER	1,678623	1,533296

4.3.3 Анализа корелације


Корелација (лат. *con* = са, *relatio* = однос) означава међусобну повезаност између различитих појава представљених вредностима две променљиве [164]. Најчешће се изражава Пирсоновим коефицијентом корелације, чије вредности могу бити у опсегу [-1, 1]. Начин израчунавања тог коефицијента описан је у одељку 2.7.2. Што је апсолутна вредност тог коефицијента ближа 1, то је већи међусобни утицај атрибута на које се коефицијент односи. Позитивне вредности коефицијента корелације показују директну (растућу) везу између две променљиве. Негативне вредности показују инверзну (опадајућу) везу, тј. да повећање једне променљиве доводи до смањења друге.

На сл. 70, сл. 71 и сл. 72 приказане су међусобне корелације атрибута у посматраним скуповима података. Врста дијаграма употребљена на тим сликама назива се топлотна мапа (енгл. *heatmap*) зато што су вредности корелација представљене бојама у складу са легендом поред дијаграма: светлије боје одговарају већим вредностима, и обрнуто. Топлотне мапе представљају податке у току предобrade, агрегиране по податку DATE_TIME, а садрже и неке од колона уведених током предобrade. (Топлотне мапе корелација након предобrade дате су у одељку 4.4.)

AC_POWER је циљна променљива за прогнозе, зато што наизменична струја представља коначни излаз фотонапонске електране. Јасно је да ирадијанса има највећи утицај на циљну променљиву, али и неке друге променљиве битно доприносе циљној, нпр. температура модула. Са слика је очигледно да на циљну променљиву AC_POWER највише утичу променљиве IRRADIANCE и MODULE_TEMPERATURE. Нешто је мањи утицај променљивих AMBIENT_TEMPERATURE и EFF, док је утицај осталих променљивих на циљну променљиву веома мали.



Сл. 70: Топлотна мапа корелација за први скуп података – електрана 1, у току предобраде



Сл. 71: Топлотна мапа корелација за први скуп података – електрана 2, у току предобраде

На основу високих вредности коефицијената корелације променљиве DC_POWER према циљној променљивој, очигледно је да те две променљиве нису међусобно независне, те стога променљиву DC_POWER не треба користити за прогнозирање циљне променљиве. Други скуп података креиран је тако да не садржи променљиву DC_POWER.

Са слика се такође може видети да постоји битан утицај ирадијансе на температуре, као што је претпостављено на основу визуелног приказа вредности тих променљивих у одељку 4.3.1. Тај утицај нешто је мањи у другом скупу података у односу на први, вероватно због утицаја подлоге описаног у одељку 4.4.

Помало је изненађујућа релативно мала корелација променљивих TIME и DAY_OF_YEAR са ирадијансом и температурама, иако је из података очигледно да ирадијанса и температуре зависе и од доба дана и од доба године. (Та корелација нарочито је мала у другом скупу података, што је вероватно додатна последица споменутог утицаја подлоге.) То указује на потребу да се доба дана и доба године представе на другачији начин, тако да вредности одговарајућих променљивих буду боље усаглашене са природом посматраних процеса. На

пример, да се доба дана представи променљивом чији би максимум био у подне а минимуми у поноћ, а доба године, аналогно томе, променљивом чији би максимум био на средини године а минимуми на крајевима.



Сл. 72: Топлотна мапа корелација за други скуп података, у току предобrade

4.3.4 Анализа мултиколинеарности

Предикторски атрибути су атрибути који се користе као улаз у модел за предикцију циљног атрибута. Предикторски атрибути који су у јакој међусобној корелацији су редундантни, тј. не дају битан допринос предикцији.

Анализа мултиколинеарности, тј. међусобне зависности више од две променљиве, извршена је израчунавањем фактора инфлације варијансе (енгл. *Variance Inflation Factor – VIF*), на начин описан у одељку 2.7.3. Израчунавања тог фактора изведена су у неколико итерација, при чему је након сваке итерације променљива са највећом вредношћу тог фактора изостављена из следећих итерација. Тај поступак понављан је све док нису добијене прихватљиве вредности фактора инфлације варијансе за све преостале променљиве.

4.3.4.1 Анализа мултиколинеарности за први скуп података – електрана 1

Најпре је фактор инфлације варијансе израчунат за све променљиве осим циљне променљиве AC_POWER и не-нумеричке променљиве DATE_TIME, и резултати тог израчунавања приказани су у ТАБ. 41.

ТАБ. 41: Вредности фактора инфлације варијансе у почетној итерацији (први скуп података – електрана 1)

Променљива	VIF
AMBIENT_TEMPERATURE	443,144165
MODULE_TEMPERATURE	570,067014
IRRADIANCE	39,605013
TIME	4,875935
DAY_OF_YEAR	67,838021
AC_POWER_PREV	35,313506
EFF_PREV	4,893858

Највећа вредност фактора инфлације варијансе у почетној итерацији израчуната је за променљиву `MODULE_TEMPERATURE`. То значи да у скупу података постоји јака мултиколинеарност у којој учествује та променљива. Зато је та променљива изостављена из даљих израчунавања фактора инфлације варијансе. Вредности тог фактора израчунате у другој итерацији приказане су у ТАБ. 42.

ТАБ. 42: Вредности фактора инфлације варијансе након изостављања променљиве `MODULE_TEMPERATURE` (први скуп података – електрана 1)

Променљива	VIF
<code>AMBIENT_TEMPERATURE</code>	92,141447
<code>IRRADIANCE</code>	18,278962
<code>TIME</code>	4,837570
<code>DAY_OF_YEAR</code>	65,703262
<code>AC_POWER_PREV</code>	20,208415
<code>EFF_PREV</code>	4,882925

На основу промена вредности фактора инфлације варијансе у другој у односу на прву итерацију, може се закључити да изостављена променљива `MODULE_TEMPERATURE` има јаку мултиколинеарност са променљивима `AMBIENT_TEMPERATURE`, `IRRADIANCE` и `AC_POWER_PREV`. У другој итерацији, највећа вредност фактора инфлације варијансе израчуната је за променљиву `AMBIENT_TEMPERATURE`, и зато је та променљива изостављена из даљих израчунавања тог фактора. Резултати треће итерације приказани су у ТАБ. 43.

ТАБ. 43: Вредности фактора инфлације варијансе након изостављања променљиве `AMBIENT_TEMPERATURE` (први скуп података – електрана 1)

Променљива	VIF
<code>IRRADIANCE</code>	18,274443
<code>TIME</code>	4,061224
<code>DAY_OF_YEAR</code>	4,865805
<code>AC_POWER_PREV</code>	19,413579
<code>EFF_PREV</code>	4,676209

Највећа вредност фактора инфлације варијансе у трећој итерацији израчуната је за променљиву `AC_POWER_PREV`, и зато је та променљива изостављена из даљих израчунавања тог фактора. Вредности израчунате у четвртој итерацији приказане су у ТАБ. 44.

ТАБ. 44: Вредности фактора инфлације варијансе након изостављања променљиве `AC_POWER_PREV` (први скуп података – електрана 1)

Променљива	VIF
<code>IRRADIANCE</code>	3,262813
<code>TIME</code>	4,029887
<code>DAY_OF_YEAR</code>	4,843510
<code>EFF_PREV</code>	4,442096

Пошто први скуп података обухвата знатно мањи период од другог, на први скуп података примењен је блажи критеријум при анализи мултиколинеарности, тако да се прихватљивим сматрају вредности фактора инфлације варијансе мање од 5. Зато се вредности тог фактора израчунате у четвртој итерацији могу сматрати прихватљивим, што значи да се преостале променљиве одликују малом мултиколинеарношћу.

4.3.4.2 Анализа мултиколинеарности за први скуп података – електрана 2

Најпре је фактор инфлације варијансе израчунат за све променљиве осим циљне променљиве AC_POWER и не-нумеричке променљиве DATE_TIME, и резултати тог израчунавања приказани су у ТАБ. 45.

ТАБ. 45: Вредности фактора инфлације варијансе у почетној итерацији
(први скуп података – електрана 2)

Променљива	VIF
AMBIENT_TEMPERATURE	419,503297
MODULE_TEMPERATURE	533,321779
IRRADIANCE	44,068524
TIME	4,805751
DAY_OF_YEAR	50,462631
AC_POWER_PREV	24,823646
EFF_PREV	4,496485

Највећа вредност фактора инфлације варијансе у почетној итерацији израчуната је за променљиву MODULE_TEMPERATURE. Зато је та променљива изостављена из даљих израчунавања тог фактора. Резултати друге итерације приказани су у ТАБ. 46.

ТАБ. 46: Вредности фактора инфлације варијансе након изостављања променљиве
MODULE_TEMPERATURE (први скуп података – електрана 2)

Променљива	VIF
AMBIENT_TEMPERATURE	70,438989
IRRADIANCE	19,614008
TIME	4,805710
DAY_OF_YEAR	50,038335
AC_POWER_PREV	21,271485
EFF_PREV	4,479647

На основу промена вредности фактора инфлације варијансе у другој у односу на прву итерацију, може се закључити да изостављена променљива MODULE_TEMPERATURE има јаку мултиколинеарност са променљивима AMBIENT_TEMPERATURE и IRRADIANCE. У другој итерацији, највећа вредност фактора инфлације варијансе израчуната је за променљиву AMBIENT_TEMPERATURE, и зато је та променљива изостављена из даљих израчунавања тог фактора. Вредности израчунате у трећој итерацији приказане су у ТАБ. 47.

ТАБ. 47: Вредности фактора инфлације варијансе након изостављања променљиве
AMBIENT_TEMPERATURE (први скуп података – електрана 2)

Променљива	VIF
IRRADIANCE	19,613942
TIME	3,978423
DAY_OF_YEAR	4,700208
AC_POWER_PREV	20,249266
EFF_PREV	4,435526

Највећа вредност фактора инфлације варијансе у трећој итерацији израчуната је за променљиву AC_POWER_PREV, и зато је та променљива изостављена из даљих израчунавања тог фактора. Резултати четврте итерације приказани су у ТАБ. 48.

ТАБ. 48: Вредности фактора инфлације варијансе након изостављања променљиве AC_POWER_PREV (први скуп података – електрана 2)

Променљива	VIF
IRRADIANCE	3,079817
TIME	3,928434
DAY_OF_YEAR	4,664744
EFF_PREV	4,295078

За све преостале променљиве, вредности фактора инфлације варијансе мање су од 5 и могу се сматрати прихватљивим; дакле, те променљиве одликују се малом мултиколинеарношћу. За обе електране у првом скупу података добијен је исти завршни скуп променљивих, и то уз исти редослед изостављања редувантних променљивих.

4.3.4.3 Анализа мултиколинеарности за други скуп података

Најпре је фактор инфлације варијансе израчунат за све променљиве осим циљне променљиве AC_POWER и не-нумеричке променљиве DATE_TIME, и резултати тог израчунавања приказани су у ТАБ. 49.

ТАБ. 49: Вредности фактора инфлације варијансе у почетној итерацији (други скуп података)

Променљива	VIF
WIND_DIRECTION	5,307595
WIND_SPEED	2,837083
IRRADIANCE	37,214322
MODULE_TEMPERATURE	199,704464
AMBIENT_TEMPERATURE	114,039707
TIME	3,679360
DAY_OF_YEAR	3,729060
AC_POWER_PREV	18,915412
EFF_PREV	3,189935

Убедљиво највећа вредност фактора инфлације варијансе у почетној итерацији израчуната је за променљиву MODULE_TEMPERATURE. То значи да у скупу података постоји јака мултиколинеарност у којој учествује та променљива. Зато је та променљива изостављена из даљих израчунавања фактора инфлације варијансе. Резултати друге итерације израчунавања тог фактора приказани су у ТАБ. 50.

ТАБ. 50: Вредности фактора инфлације варијансе након изостављања променљиве MODULE_TEMPERATURE (други скуп података)

Променљива	VIF
WIND_DIRECTION	5,273882
WIND_SPEED	2,819668
IRRADIANCE	17,760229
AMBIENT_TEMPERATURE	4,837523
TIME	3,639701
DAY_OF_YEAR	3,696481
AC_POWER_PREV	18,482498
EFF_PREV	3,149688

На основу промена вредности фактора инфлације варијансе у другој у односу на прву итерацију, може се закључити да изостављена променљива `MODULE_TEMPERATURE` има јаку мултиколинеарност са променљивима `IRRADIANCE` и `AMBIENT_TEMPERATURE`. У другој итерацији, највећа вредност фактора инфлације варијансе израчуната је за променљиву `AC_POWER_PREV`, и зато је та променљива изостављена из даљих израчунавања тог фактора. Вредности израчунате у трећој итерацији приказане су у ТАБ. 51.

Вредности фактора инфлације варијансе добијене у трећој итерацији могу се сматрати прихватљивим, зато што је само за променљиву `WIND_DIRECTION` израчуната вредност тог фактора мало већа од 5, а из раније спроведене анализе корелације види се да та променљива има занемарљив утицај на циљну променљиву `AC_POWER`. Још је само за променљиву `AMBIENT_TEMPERATURE` израчуната вредност фактора инфлације варијансе између 4 и 5, а за све остале променљиве вредност тог фактора је испод 4. Пробе ради, ипак су извршене још две итерације израчунавања фактора инфлације варијансе. У четвртој итерацији изостављена је променљива `WIND_DIRECTION`, и добијени резултати приказани су у табели ТАБ. 52.

ТАБ. 51: Вредности фактора инфлације варијансе након изостављања променљиве `AC_POWER_PREV` (други скуп података)

Променљива	VIF
<code>WIND_DIRECTION</code>	5,270154
<code>WIND_SPEED</code>	2,818526
<code>IRRADIANCE</code>	2,194856
<code>AMBIENT_TEMPERATURE</code>	4,779399
<code>TIME</code>	3,634378
<code>DAY_OF_YEAR</code>	3,676574
<code>EFF_PREV</code>	3,099422

ТАБ. 52: Вредности фактора инфлације варијансе након изостављања променљиве `WIND_DIRECTION` (други скуп података)

Променљива	VIF
<code>WIND_SPEED</code>	2,636325
<code>IRRADIANCE</code>	2,190778
<code>AMBIENT_TEMPERATURE</code>	4,652185
<code>TIME</code>	3,158974
<code>DAY_OF_YEAR</code>	3,488346
<code>EFF_PREV</code>	2,833475

Још је само за променљиву `AMBIENT_TEMPERATURE` вредност фактора инфлације варијансе већа од 4, и зато у петој итерацији изостављамо ту променљиву. Добијени резултати приказани су у ТАБ. 53.

ТАБ. 53: Вредности фактора инфлације варијансе након изостављања променљиве `AMBIENT_TEMPERATURE` (други скуп података)

Променљива	VIF
<code>WIND_SPEED</code>	2,634474
<code>IRRADIANCE</code>	1,926243
<code>TIME</code>	2,719717
<code>DAY_OF_YEAR</code>	2,967451
<code>EFF_PREV</code>	2,695074

За све преостале променљиве вредност фактора инфлације варијансе мања је од 3, дакле знатно мања од граничних вредности које се спомињу у литератури (4 или 5). То значи да се преостале променљиве одликују веома малом мултиколинеарношћу, тј. да веома мало утичу једна на другу. Нарочито је битно што је за променљиву IRRADIANCE, за коју се из раније спроведене анализе корелације види да највише утиче на циљну променљиву AC_POWER, израчуната веома мала вредност фактора инфлације варијансе, што значи да та променљива има веома малу међусобну зависност са преосталим променљивима.

Може се приметити да су преостале променљиве за други скуп података исте као за обе електране у првом скупу података, уз додатак променљиве WIND_SPEED која не постоји у првом скупу података.

4.3.5 Анализа помоћу линеарне регресије

Додатна анализа скупова података извршена је помоћу готовог модела OLS (енгл. *Ordinary Least Squares* – обични најмањи квадрати) у ком је коришћена метода најмањих квадрата. Анализа је извршена у неколико итерација, и у свакој се анализирају исте променљиве као у одговарајућој итерацији приликом анализе мултиколинеарности. Дакле, након сваке итерације једна од променљивих избачена је из даље анализе, а затим поновљено креирање, обука и извршавање модела. У додатној последњој итерацији, у модел је унета само променљива IRRADIANCE.

На крају сваке итерације генерисан је детаљан статистички извештај. Пример таквог извештаја дат је у ТАБ. 54, која приказује резултате за прву електрану из првог скупа података, у првој итерацији. Сажет опис статистичких показатеља приказаних у тим резултатима дат је у [167], а најбитнији показатељи описани су у одељку 2.7.5.

ТАБ. 54: Комплетни статистички резултати регресије помоћу модела OLS, за електрану 1 из првог скупа података, у првој итерацији

OLS Regression Results						
Dep. Variable:	y	R-squared:	0.994			
Model:	OLS	Adj. R-squared:	0.994			
Method:	Least Squares	F-statistic:	7.740e+04			
Date:	Tue, 24 Dec 2024	Prob (F-statistic):	0.00			
Time:	18:00:00	Log-Likelihood:	-15207.			
No. Observations:	3158	AIC:	3.043e+04			
Df Residuals:	3150	BIC:	3.048e+04			
Df Model:	7					
Covariance Type:	nonrobust					
	coef	std err	t	P> t	[0.025 0.975]	
const	-19.4911	13.040	-1.495	0.135	-45.059	6.077
AMBIENT_TEMPERATURE	2.3940	0.492	4.862	0.000	1.429	3.359
MODULE_TEMPERATURE	-3.2237	0.379	-8.504	0.000	-3.967	-2.480
IRRADIANCE	1.2348	0.009	139.790	0.000	1.217	1.252
TIME	-0.0100	0.089	-0.113	0.910	-0.184	0.164
DAY_OF_YEAR	0.2145	0.059	3.648	0.000	0.099	0.330
AC_POWER_PREV	0.1145	0.007	17.617	0.000	0.102	0.127
EFF_PREV	24.6256	1.691	14.565	0.000	21.310	27.941
Omnibus:	831.098	Durbin-Watson:	1.503			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	34954.851			
Skew:	-0.489	Prob(JB):	0.00			
Kurtosis:	19.269	Cond. No.:	1.55e+04			

Међу наведеним резултатима нарочито су битне тзв. t -вредности (дате у колони „ t ”), које показују релевантност појединачних променљивих за прогнозирање циљне променљиве. Већа t -вредност указује на већу релевантност одговарајуће променљиве (атрибута).

У колони „ $P>|t|$ ” дате су тзв. p -вредности, које показују статистичку значајност одговарајућих променљивих. Ако је $p \leq \alpha$, при чему се најчешће бира $\alpha = 0,05$, то је добар показатељ да променљива на коју се односи та p -вредност утиче на прогнозу циљне променљиве. И обрнуто, ако је $p > \alpha$, одговарајућа променљива највероватније нема битан утицај на прогнозу циљне променљиве.

Коефицијент детерминације (R^2), описан у одељку 2.2.1, показује који проценат варијансе циљне променљиве је објашњен моделом, тј. за који део података је модел дао тачно предвиђање. Прилагођени коефицијент детерминације R^2_{adj} кажњава додавање регресора који не доприносе експланаторном капацитету регресије; другим речима, за разлику од R^2 , смањује се приликом додавања ирелевантних променљивих у модел. Пожељно је да та два коефицијента буду што већи, тј. да модел буде што успешнији у предвиђању. Такође је пожељно да прилагођени коефицијент детерминације буде што ближи или чак једнак коефицијенту детерминације, што указује на то да у моделу нема ирелевантних променљивих, одн. да све променљиве у моделу доприносе прогнози.

Од ТАБ. 55 до ТАБ. 57 приказани су најбитнији статистички параметри издвојени из комплетних статистичких резултата, а то су коефицијент детерминације, прилагођени коефицијент детерминације, t -вредности и p -вредности.

ТАБ. 55: Најважнији статистички резултати регресије помоћу модела OLS за електрану 1 из првог скупа података

Итерација	1		2		3		4		5	
	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $
MODULE_TEMP.	-8,504	0,000								
AMBIENT_TEMP.	4,862	0,000	-2,825	0,005						
AC_POWER_PREV	17,617	0,000	15,671	0,000	15,601	0,000				
TIME	-0,113	0,910	0,586	0,558	-0,826	0,409	0,576	0,565		
DAY_OF_YEAR	3,648	0,000	4,412	0,000	5,877	0,000	5,997	0,000		
EFF_PREV	14,565	0,000	14,016	0,000	13,779	0,000	17,082	0,000		
IRRADIANCE	139,790	0,000	194,184	0,000	194,180	0,000	475,109	0,000	665,718	0,000
R^2		0,994		0,994		0,994		0,994		0,993
Прилагођено R^2		0,994		0,994		0,994		0,994		0,993

ТАБ. 56: Најважнији статистички резултати регресије помоћу модела OLS за електрану 2 из првог скупа података

Итерација	1		2		3		4		5	
	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $
MODULE_TEMP.	-9,998	0,000								
AMBIENT_TEMP.	7,634	0,000	-1,618	0,106						
AC_POWER_PREV	27,787	0,000	25,541	0,000	26,294	0,000				
TIME	-0,243	0,808	0,136	0,892	-0,740	0,459	1,967	0,049		
DAY_OF_YEAR	0,415	0,678	-0,466	0,641	0,224	0,822	-0,380	0,704		
EFF_PREV	4,115	0,000	4,971	0,000	4,724	0,000	8,688	0,000		
IRRADIANCE	57,919	0,000	75,122	0,000	75,336	0,000	225,244	0,000	326,239	0,000
R^2		0,977		0,976		0,976		0,971		0,970
Прилагођено R^2		0,977		0,976		0,976		0,971		0,970

На основу t -вредности наведених у ТАБ. 55 може се закључити да променљива IRRADIANCE има највећи предиктивни капацитет у свим итерацијама по моделу OLS, тј. највећи утицај на прогнозу циљне променљиве. Међутим, на основу p -вредности види се да све променљиве осим TIME имају статистичку везу са циљном променљивом, што значи да и оне доприносе

прогнози и утичу на резултате модела. Вредности коефицијента детерминације и прилагођеног коефицијента детерминације показују да је модел у свим итерацијама остварио изванредне резултате, тј. успешно прогнозирао вредност циљне променљиве у бар 99,3% случајева.

Слични су резултати за другу електрану из првог скупа података, приказани у ТАБ. 56. Разлика је у томе што у неким итерацијама и друге променљиве имају p -вредности веће од типичног нивоа значајности α , пре свега DAY_OF_YEAR. На основу коефицијената детерминације R^2 и R_{adj}^2 види се да је вредност циљне променљиве успешно прогнозирана у бар 97% случајева, што је одлично. Ти коефицијенти помало падају са избацивањем променљивих кроз итерације, што значи да и избачене променљиве дају макар мали допринос поузданости прогнозе.

У другом скупу података (ТАБ. 57), у прве две итерације високе t -вредности (тј. висок предиктивни капацитет) забележене су не само за променљиву IRRADIANCE већ и за променљиву AC_POWER_PREV, а променљива DAY_OF_YEAR има високе p -вредности (тј. слабу везу са циљном променљивом). Међутим, почев од треће итерације променљива AC_POWER_PREV избачена је због високе мултиколинеарности (што је описано у претходном одељку) и зато IRRADIANCE остаје најрелевантнија. У тим итерацијама високе p -вредности забележене су за променљиву TIME. Коефицијенти детерминације кроз итерације опадају од 98,2% до 96,6%, а највећи пад забележен је управо између друге и треће итерације, што такође указује на допринос променљиве AC_POWER_PREV.

ТАБ. 57: Најважнији статистички резултати регресије помоћу модела OLS за други скуп података

Итерација Променљива	1		2		3		4		5		6	
	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $	t	$P> t $
MODULE_TEMP.	-20,712	0,000										
AC_POWER_PREV	166,513	0,000	164,264	0,000								
WIND_DIRECTION	5,803	0,000	5,663	0,000	7,883	0,000						
AMBIENT_TEMP.	18,469	0,000	-8,351	0,000	8,910	0,000	8,317	0,000				
WIND_SPEED	-4,301	0,000	-3,568	0,000	-1,359	0,174	-2,728	0,006	-3,707	0,000		
TIME	-11,716	0,000	-10,288	0,000	-0,404	0,686	-0,706	0,480	0,688	0,491		
DAY_OF_YEAR	1,817	0,069	-0,613	0,540	-5,815	0,000	-6,953	0,000	-5,279	0,000		
EFF_PREV	11,222	0,000	8,659	0,000	23,413	0,000	24,108	0,000	25,125	0,000		
IRRADIANCE	160,026	0,000	209,246	0,000	775,244	0,000	774,898	0,000	830,964	0,000	1002,868	0,000
R^2		0,982		0,981		0,967		0,967		0,967		0,966
Прилагођено R^2		0,982		0,981		0,967		0,967		0,967		0,966

У свим експериментима коефицијенти детерминације су одлични, али најбољи коефицијенти детерминације забележени су када се користе све променљиве. Такође, у свим итерацијама коефицијент детерминације R^2 једнак је прилагођеном коефицијенту детерминације R_{adj}^2 . То значи да, уопштено говорећи, нема потпуно ирелевантних променљивих, тј. све коришћене променљиве бар мало утичу на прогнозу. С друге стране, на основу t -вредности и p -вредности види се да неке од променљивих имају ниску релевантност.

Важно је истаћи да ова анализа важи за линеарне моделе. За неуронску мрежу у принципу је повољније ако се користи већи број атрибута, зато што она трансформише атрибуте кроз нелинеарне комбинације, стварајући тиме дискриминативније атрибуте који уносе већу поузданост у прогнозу.

4.3.6 Квартилна анализа


Одступајуће вредности (енгл. *outliers*), тј. вредности које се значајно разликују од просечних, могу се препознати на основу теорије квантила на начин описан у одељку 2.7.4. Кутијасте дијаграми (енгл. *box plots*) олакшавају визуализовање квантила и одступајућих вредности, а доприносе и бољем разумевању расподеле података. На таквом дијаграму, оквир („кутија”)

означава централних 50% података, тј. границе кутије су први и трећи квартил (Q_1 и Q_3). Линеја у кутији означава други квартил (Q_2), тј. медијану (вредност на средини сортираног скупа података). Краци око кутије (тзв. „бркови”, енгл. *whiskers*) означавају најмању и највећу вредност које су унутар доње и горње границе (енгл. *Lower Fence* – LF, и *Upper Fence* – UF), а евентуалне тачке изван „бркова” представљају одступајуће вредности [175], [176].

У овом одељку такође су дати статистички описи најважнијих променљивих у току предобраде. Статистички описи за комплетан скуп података након предобраде дати су у одељку 4.4.

4.3.6.1 Квартилна анализа за први скуп података – електрана 1

На сл. 73 дати су кутијасте дијаграми за прву електрану из првог скупа података. Са дијаграма се види да има веома мало одступајућих вредности, а то потврђује и ТАБ. 58.



сл. 73: Кутијасте дијаграми за електрану 1 из првог скупа података (сви записи)

ТАБ. 58: Број одступајућих вредности за електрану 1 из првог скупа података (сви записи)

Променљива	Број одступајућих вредности
AMBIENT_TEMPERATURE	0
MODULE_TEMPERATURE	0
IRRADIANCE	2
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	0
EFF_PREV	0

Међутим, са дијаграма се такође види да на расподелу података и ову анализу битно утиче што су обухваћени и периоди у којима нема сунчевог зрачења, а самим тим ни генерисане електричне енергије. Нпр. медијане за променљиве IRRADIANCE и AC_POWER_PREV блиске су нули, што је нереално за период који је најбитнији са становишта овог рада.

Ради прецизнијих испитивања, спроведене су и додатне анализе одступајућих вредности којима су обухваћени само периоди у којима постоји генерисање електричне енергије. У ТАБ. 59 дати су зборови генерисане АС снаге по 15-минутним интервалима за читав период обухваћен скупом података. Из табеле се види да бар мало генерисане електричне енергије

постоји у интервалима који почињу од 6:00 до 18:30. Након додатног испитивања броја записа без генерисане снаге у том периоду, изабрани су интервали који почињу од 6:15 до 18:15. Средина тог периода је у 12:15, али збир је највећи у интервалу од 11:15.

ТАБ. 59: Укупна АС снага по интервалима за електрану 1 из првог скупа података

Време	Ук. снага	Време	Ук. снага	Време	Ук. снага	Време	Ук. снага
0:00	0,00	6:00	228,21	12:00	32444,21	18:00	1851,14
0:15	0,00	6:15	1090,17	12:15	31446,37	18:15	845,16
0:30	0,00	6:30	2115,83	12:30	31686,35	18:30	140,62
0:45	0,00	6:45	3610,08	12:45	32710,49	18:45	0,00
1:00	0,00	7:00	5521,96	13:00	32013,45	19:00	0,00
1:15	0,00	7:15	7448,07	13:15	31188,09	19:15	0,00
1:30	0,00	7:30	9038,14	13:30	29223,09	19:30	0,00
1:45	0,00	7:45	11273,63	13:45	29841,07	19:45	0,00
2:00	0,00	8:00	13685,33	14:00	27525,06	20:00	0,00
2:15	0,00	8:15	16118,38	14:15	25933,65	20:15	0,00
2:30	0,00	8:30	18235,20	14:30	25969,23	20:30	0,00
2:45	0,00	8:45	19820,41	14:45	23825,64	20:45	0,00
3:00	0,00	9:00	22333,23	15:00	23808,27	21:00	0,00
3:15	0,00	9:15	23585,03	15:15	20898,44	21:15	0,00
3:30	0,00	9:30	25299,80	15:30	20533,36	21:30	0,00
3:45	0,00	9:45	25314,09	15:45	18244,98	21:45	0,00
4:00	0,00	10:00	26479,19	16:00	16466,71	22:00	0,00
4:15	0,00	10:15	27799,46	16:15	13918,34	22:15	0,00
4:30	0,00	10:30	30252,39	16:30	12058,67	22:30	0,00
4:45	0,00	10:45	31514,10	16:45	10400,55	22:45	0,00
5:00	0,00	11:00	31884,48	17:00	8399,96	23:00	0,00
5:15	0,00	11:15	33022,87	17:15	6539,02	23:15	0,00
5:30	0,00	11:30	32619,94	17:30	4849,92	23:30	0,00
5:45	0,00	11:45	32019,82	17:45	3227,72	23:45	0,00


Када се за прву електрану у првом скупу података узме у обзир само изабрани период (од 6:15 до 18:15), остаје 1637 записа. Статистички описи тих података дати су у ТАБ. 60, кутијасте дијаграми приказани су на СЛ. 74, а број одступајућих вредности у ТАБ. 61.

ТАБ. 60: Статистички описи најважнијих променљивих у електрани 1 из првог скупа података (само током дана)

	IRRADIANCE (W/m ²)	MODULE_ TEMP. (°C)	AMBIENT_ TEMP. (°C)	AC_POWER_ PREV (kW)	EFF_PREV	AC_POWER (kW)
Записа	1637	1637	1637	1637	1637	1637
Сред. вр.	443,8744	40,2010	27,6887	589,6845	0,9711	590,0614
Стан. дев.	283,6470	10,9162	3,1383	361,1878	0,0754	360,5918
Мин.	0,3286	18,7289	20,8384	0	0	0
25%	193,7693	30,7913	25,4051	261,1851	0,9761	261,1851
50%	437,6690	40,7786	27,7427	606,5544	0,9785	606,5544
75%	661,3622	48,4874	29,9117	872,1119	0,9802	872,1119
Макс.	1221,6518	65,5457	35,2525	1394,7520	0,9831	1394,7520

Из кутијастих дијаграма види се да су расподеле података сада сличније нормалној. Такође, нема више одступајућих вредности за променљиву IRRADIANCE, али сада постоје одступајуће вредности за променљиву EFF_PREV. То се може протумачити чињеницом да су вредности променљиве EFF_PREV веома груписане, што се види и из одговарајућег кутијастог

дијаграма. Интерквартилно растојање за променљиву EFF_PREV веома је мало – износи само око 0,004. Самим тим, у случају те променљиве ова метода проглашава нереално много вредности за одступајуће. Додатном анализом утврђено је да су око 96% тих „одступајућих” вредности ефикасности заправо сасвим прихватљиве. Осим тога, све вредности проглашене за одступајуће јавиле су се на самом почетку или крају, или близу почетка или краја генерисања електричне енергије током дана, дакле, у прелазним периодима када се по природи процеса могу очекивати извесна одступања и нестабилности. На примеру те променљиве види се да није могуће једним правилом (тј. фиксним фактором од 1,5) обухватити све ситуације, али у великој већини случајева то правило даје задовољавајуће резултате.




Сл. 74: Кутијасте дијаграми за електрану 1 из првог скупа података (само током дана)

ТАБ. 61: Број одступајућих вредности за електрану 1 из првог скупа података (само током дана)

Променљива	Број одступајућих вредности
AMBIENT_TEMPERATURE	0
MODULE_TEMPERATURE	0
IRRADIANCE	0
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	0
EFF_PREV	137

4.3.6.2 Квартилна анализа за први скуп података – електрана 2

Са сл. 75 и из таб. 62 види се да и у електрани 2, када се узму у обзир сви записи, има веома мало одступајућих вредности, и то за променљиве IRRADIANCE и MODULE_TEMPERATURE.



сл. 75: Кутијасте дијаграми за електрану 2 из првог скупа података (сви записи)


таб. 62: Број одступајућих вредности за електрану 2 из првог скупа података (сви записи)

Променљива	Број одступајућих вредности
AMBIENT_TEMPERATURE	0
MODULE_TEMPERATURE	2
IRRADIANCE	1
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	0
EFF_PREV	0

Анализа одступајућих вредности такође је спроведена и само за записе прикупљене током дана, тј. у периоду током ког соларна електрана производи електричну енергију. У таб. 63 дати су зборови генерисане АС снаге по 15-минутним интервалима за читав период обухваћен скупом података. У тој електрани бар мало генерисане електричне енергије јавило се у интервалима који почињу од 5:45 до 18:45; међутим, вредности генерисане снаге забележене у 5:45 и 18:45 биле су занемарљиве. Након додатног испитивања броја записа без генерисане електричне енергије у том периоду, због нешто веће неуједначености почетака и крајева генерисања, изабрани су интервали који почињу од 6:30 до 18:00. Средина тог периода је у 12:15, а у том интервалу забележен је и највећи збир. Просечне снаге наизменичне струје по сатима за електрану 2 приказане су на сл. 76.

ТАБ. 63: Укупна АС снага по интервалима за електрану 2 из првог скупа података

Време	Ук. снага	Време	Ук. снага	Време	Ук. снага	Време	Ук. снага
0:00	0,00	6:00	367,95	12:00	33277,57	18:00	2310,89
0:15	0,00	6:15	1274,64	12:15	35024,64	18:15	1285,46
0:30	0,00	6:30	2399,44	12:30	34460,97	18:30	491,39
0:45	0,00	6:45	3811,94	12:45	33044,29	18:45	28,16
1:00	0,00	7:00	5342,94	13:00	31747,28	19:00	0,00
1:15	0,00	7:15	7177,62	13:15	32434,69	19:15	0,00
1:30	0,00	7:30	9298,56	13:30	29898,49	19:30	0,00
1:45	0,00	7:45	11362,71	13:45	28661,49	19:45	0,00
2:00	0,00	8:00	13663,70	14:00	28547,02	20:00	0,00
2:15	0,00	8:15	16116,23	14:15	27188,16	20:15	0,00
2:30	0,00	8:30	18925,33	14:30	24725,68	20:30	0,00
2:45	0,00	8:45	20500,94	14:45	23932,11	20:45	0,00
3:00	0,00	9:00	23183,42	15:00	23279,92	21:00	0,00
3:15	0,00	9:15	23307,01	15:15	20914,43	21:15	0,00
3:30	0,00	9:30	25205,07	15:30	19677,54	21:30	0,00
3:45	0,00	9:45	26494,41	15:45	18804,40	21:45	0,00
4:00	0,00	10:00	28030,40	16:00	15115,69	22:00	0,00
4:15	0,00	10:15	29564,44	16:15	14614,78	22:15	0,00
4:30	0,00	10:30	30741,76	16:30	12843,18	22:30	0,00
4:45	0,00	10:45	29417,44	16:45	11302,65	22:45	0,00
5:00	0,00	11:00	31089,63	17:00	8955,75	23:00	0,00
5:15	0,00	11:15	32691,05	17:15	6652,07	23:15	0,00
5:30	0,00	11:30	33914,39	17:30	5192,04	23:30	0,00
5:45	0,43	11:45	32662,31	17:45	3622,67	23:45	0,00



Сл. 76: Просечне АС снаге по сатима за електрану 2 из првог скупа података

Када се за другу електрану у првом скупу података узме у обзир само изабрани период (од 6:30 до 18:00), остају 1584 записа. Статистички описи тих података дати су у ТАБ. 64, кутијасте дијаграми приказани су на СЛ. 77, а број одступајућих вредности у ТАБ. 65.

И у случају друге електране, када се узму у обзир само записи прикупљени током дана, нема више одступајућих вредности за променљиве IRRADIANCE и MODULE_TEMPERATURE, али се јављају одступајуће вредности за променљиву EFF_PREV. Важе скоро све исте напомене као код прве електране: вредности променљиве EFF_PREV веома су груписане, интерквartilно растојање такође износи само око 0,004, а вредности квилта скоро су исте као за прву електрану. Од вредности проглашених за одступајуће, у 4 записа ради се о нултим


вредностима забележеним на самом почетку рада, а све остале „одступајуће” ефикасности заправо су сасвим прихватљиве.

ТАБ. 64: Статистички описи најважнијих променљивих у електрани 2 из првог скупа података (само током дана)

	IRRADIANCE (W/m ²)	MODULE_TEMP. (°C)	AMBIENT_TEMP. (°C)	AC_POWER_PREV (kW)	EFF_PREV	AC_POWER (kW)
Записа	1584	1584	1584	1584	1584	1584
Сред. вр.	473,4978	41,3702	30,4770	618,7455	0,9747	619,3997
Стан. дев.	292,9688	10,5261	3,8930	373,6096	0,0495	372,6511
Мин.	0	21,1217	22,0126	0	0	0
25%	214,3282	32,6828	27,3269	285,0754	0,9757	285,0754
50%	447,1517	40,6833	30,2848	600,4120	0,9783	600,4120
75%	744,3152	50,3408	33,6523	938,5499	0,9802	938,5499
Макс.	1098,7660	66,6360	39,1816	1308,2733	0,9974	1308,2733

ТАБ. 65: Број одступајућих вредности за електрану 2 из првог скупа података (само током дана)


Променљива	Број одступајућих вредности
AMBIENT_TEMPERATURE	0
MODULE_TEMPERATURE	0
IRRADIANCE	0
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	0
EFF_PREV	92



СЛ. 77: Кутијасте дијаграми за електрану 2 из првог скупа података (само током дана)

4.3.6.3 Квартилна анализа за други скуп података

У другом скупу података, када се узму у обзир сви записи, нарочито долазе до изражаја нереално ниски квантили као последица тога што су обухваћени и периоди у којима нема сунчевог зрачења ни генерисања електричне енергије. Као што се види са СЛ. 78 и ТАБ. 66, скоро за све променљиве постоји велики број одступајућих вредности.



СЛ. 78: Кутијасте дијаграми за други скуп података (сви записи)

ТАБ. 66: Број одступајућих вредности за други скуп података (сви записи)

Променљива	Број одступајућих вредности
WIND_DIRECTION	0
WIND_SPEED	1932
IRRADIANCE	5334
MODULE_TEMPERATURE	1076
AMBIENT_TEMPERATURE	46
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	5042
EFF_PREV	0

Зато је за други скуп података било нарочито битно да се анализа одступајућих вредности спроведе и само за период током ког постоји генерисање електричне енергије. У ТАБ. 67 дати су зборови генерисане АС снаге по 15-минутним интервалима за читав период обухваћен скупом података. Бар мало генерисане електричне енергије јавило се у интервалима који почињу од 2:30 до 18:30 (сва времена наведена су по зимском рачунању). Међутим, након додатног испитивања броја записа без генерисане електричне енергије у том периоду, изабрани су интервали који почињу од 6:15 до 14:45. Средина тог периода је у 10:30, а у том интервалу забележен је и највећи збир.

ТАБ. 67: Укупна АС снага по интервалима за други скуп података

Време	Ук. снага	Време	Ук. снага	Време	Ук. снага	Време	Ук. снага
0:00	0,00	6:00	2407,06	12:00	7364,96	18:00	13,90
0:15	0,00	6:15	2948,31	12:15	7013,92	18:15	3,93
0:30	0,00	6:30	3462,26	12:30	6670,74	18:30	0,73
0:45	0,00	6:45	3948,40	12:45	6218,64	18:45	0,00
1:00	0,00	7:00	4566,48	13:00	5746,83	19:00	0,00
1:15	0,00	7:15	5127,50	13:15	5227,45	19:15	0,00
1:30	0,00	7:30	5601,84	13:30	4899,54	19:30	0,00
1:45	0,00	7:45	6162,51	13:45	4462,98	19:45	0,00
2:00	0,00	8:00	6624,53	14:00	3909,51	20:00	0,00
2:15	0,00	8:15	7042,50	14:15	3355,08	20:15	0,00
2:30	0,16	8:30	7374,82	14:30	2813,69	20:30	0,00
2:45	3,35	8:45	7888,56	14:45	2366,98	20:45	0,00
3:00	11,23	9:00	8119,75	15:00	1959,45	21:00	0,00
3:15	33,44	9:15	8370,88	15:15	1544,88	21:15	0,00
3:30	65,04	9:30	8503,74	15:30	1228,59	21:30	0,00
3:45	108,70	9:45	8593,88	15:45	910,75	21:45	0,00
4:00	161,41	10:00	8755,18	16:00	658,66	22:00	0,00
4:15	239,33	10:15	8815,16	16:15	466,19	22:15	0,00
4:30	355,50	10:30	8837,51	16:30	325,78	22:30	0,00
4:45	519,29	10:45	8684,99	16:45	231,07	22:45	0,00
5:00	772,84	11:00	8559,76	17:00	163,68	23:00	0,00
5:15	1127,94	11:15	8245,54	17:15	111,76	23:15	0,00
5:30	1540,10	11:30	8045,94	17:30	65,47	23:30	0,00
5:45	1979,85	11:45	7720,59	17:45	33,77	23:45	0,00


Када се из другог скупа података посматрају само записи у изабраном периоду (од 6:15 до 14:45), остаје 12 810 записа. Статистички описи тих података дати су у ТАБ. 68, кутијасте дијаграми приказани су на СЛ. 79, а број одступајућих вредности у ТАБ. 69.

ТАБ. 68: Статистички описи најважнијих променљивих у другом скупу података (само током дана)

	IRRADIANCE (W/m ²)	MODULE_ TEMP. (°C)	AMBIENT_ TEMP. (°C)	AC_POWER_ PREV (kW)	EFF_PREV	AC_POWER (kW)
Записа	12 810	12 810	12 810	12 810	12 810	12 810
Сред. вр.	406,7478	27,0790	17,5017	17,3373	0,9805	17,3342
Стан. дев.	322,7600	15,9320	9,8406	13,1298	0,0156	13,1293
Мин.	0,0741	-4,7209	-2,9014	0	0	0,0032
25%	98,0163	13,1699	9,2829	4,5548	0,9798	4,5674
50%	347,2237	26,2057	17,6617	15,8676	0,9809	15,8910
75%	698,8869	40,4386	25,3844	28,8528	0,9820	28,8528
Макс.	1107,4278	62,7144	47,2820	47,4297	0,9999	47,4297

Као што је случај са обе електране из првог скупа података, и за други скуп података одступајуће вредности знатно се мењају када се посматрају само записи прикупљени током дана. За променљиве IRRADIANCE, MODULE_TEMPERATURE, AMBIENT_TEMPERATURE и AC_POWER_PREV нема више одступајућих вредности, за променљиву WIND_SPEED број одступајућих вредности је мањи, али за променљиву EFF_PREV пријављен је релативно велики број одступајућих вредности. С обзиром на то што променљива WIND_SPEED има релативно мали утицај на циљну променљиву, одступајуће вредности за ту

променљиву нису додатно анализиране, а и логички је разумљиво да те одступајуће вредности одговарају ударима ветра.



Сл. 79: Кутијасте дијаграми за други скуп података (само током дана)

ТАБ. 69: Број одступајућих вредности за други скуп података (само током дана)

Променљива	Број одступајућих вредности
WIND_DIRECTION	0
WIND_SPEED	702
IRRADIANCE	0
MODULE_TEMPERATURE	0
AMBIENT_TEMPERATURE	0
TIME	0
DAY_OF_YEAR	0
AC_POWER_PREV	0
EFF_PREV	2148

У случају променљиве EFF_PREV важе скоро све напомене као код обе електране из првог скупа података. Вредности те променљиве још израженије су груписане него у првом скуп података – интерквартилно растојање износи само око 0,002. Толика стабилност и уједначеност је неочекивана с обзиром на број записа и чињеницу да скуп података обухвата читаву годину. Вредности квантила сличне су као код обе електране из првог скупа података. Од чак 2148 одступајућих вредности, 3 су нулте вредности које су се јавиле на самом почетку генерисања, што је очекивано. Свих осталих 2145 „одступајућих” ефикасности износе од око 0,95 до нешто мање од 1, што је сасвим задовољавајуће и не може се сматрати погрешним вредностима. Као што је већ речено, на примеру те променљиве види се да није могуће једним правилом за одређивање одступајућих вредности обухватити све ситуације које се могу јавити.

4.4 Предобрада података

Као што је већ речено, истраживачка анализа података врши се упоредо са предобрадом и усмерава је својим резултатима, а поједине фазе истраживачке анализе и предобраде врше се итеративно. На основу резултата истраживачке анализе података, за први скуп података извршени су следећи кораци предобраде, наведеним редом, засебно за сваку електрану:

- 1) Обрисане су колоне PLANT_ID (за податке о метеоролошким условима и производњи електричне енергије) и SOURCE_KEY (само за податке о метеоролошким условима), зато што не доприносе прогнози производње фотонапонске енергије.
- 2) Такође су обрисане колоне DAILY_YIELD и TOTAL_YIELD, зато што неће одговарати подацима који преостану након чишћења.
- 3) Спојени су подаци о производњи фотонапонске енергије и подаци са метеоролошких сензора на основу податка DATE_TIME.
- 4) Вредности података са метеоролошких сензора које су недостајале након спајања попуњене су помоћу линеарне интерполације. Била су 4 таква записа за електрану 1, и ниједан за електрану 2.
- 5) Записи у којима су недостајали подаци о снази су одбачени. Било је 25 таквих записа за електрану 1, и ниједан за електрану 2.
- 6) Уведене су колоне TIME и DAY_OF_YEAR да би се укључио утицај доба дана и годишњег доба.
- 7) Записи у којима је вредност податка AC_POWER једнака нули између 7:00 и 17:30 су одбачени. Пошто је сунчево зрачење било присутно (тј. вредности податка IRRADIANCE у тим записима веће су од нуле), може се претпоставити да су такви записи настали због одржавања или кварова инвертора. За електрану 1 била су 63 таква записа, а за електрану 2 чак 3808.
- 8) Додата је колона EFF (ефикасност инвертора), где је $EFF = \frac{AC_POWER}{DC_POWER}$. Као што је већ наведено, вредности податка DC_POWER за електрану 1 пре тога су подељене са десет јер је претпостављено да су у оригиналном скупу података грешком помножене са десет.
- 9) Записи са $EFF > 1$ су одбачени. Било је 18 таквих записа за електрану 1 и такође 18 за електрану 2.
- 10) Одбачени су записи са малом снагом, тј. записи код којих је вредност податка AC_POWER мања од граничних вредности. Граничне вредности израчунате су као $0,5 \cdot quantile(0,5)$, тј. 50% медијане податка AC_POWER. Већина записа са малом снагом претходи или следи горепоменуте записе са нултом снагом. Било је 17 записа са малом снагом за електрану 1 и 263 за електрану 2.
- 11) Након чишћења, преостало је 68 680 записа за електрану 1 и 63 609 за електрану 2.
- 12) Обрисана је колона SOURCE_KEY (за податке о производњи електричне енергије) јер не доприноси прогнози производње фотонапонске енергије. (Не сме се раније обрисати зато што служи као идентификатор записа – без те колоне при описаном чишћењу података били би обрисани сви записи са истим DATE_TIME, а не само запис у ком се јавила погрешна вредност.)
- 13) Подаци су груписани по податку DATE_TIME. Приликом груписања, колоне AC_POWER, DC_POWER и EFF агрегиране су помоћу средњих вредности, док преостале колоне (AMBIENT_TEMPERATURE, MODULE_TEMPERATURE, IRRADIANCE, TIME и DAY_OF_YEAR) имају исте вредности за све записе са истим DATE_TIME, тако да су узете вредности из првих записа.
- 14) Након груписања, било је 3158 записа за електрану 1 и 3249 за електрану 2.
- 15) Додате су колоне AC_POWER_PREV и EFF_PREV, које садрже вредности AC_POWER и EFF, респективно, из претходног интервала.
- 16) Обрисана је колона DC_POWER, зато што је у јакој корелацији са циљном променљивом AC_POWER; те две колоне представљају исте информације.
- 17) Колона EFF такође је обрисана, зато што се та променљива израчунава помоћу циљне променљиве AC_POWER и стога се не може користити за предвиђање њене вредности.

Коначно, након предобrade, у првом скупу података остале су следеће колоне:

- DATE_TIME (не користи се у даљим обрадама, остављена ради једноставнијег праћења),
- AMBIENT_TEMPERATURE,
- MODULE_TEMPERATURE,

- IRRADIANCE,
- TIME,
- DAY_OF_YEAR,
- AC_POWER_PREV,
- EFF_PREV, и
- AC_POWER (циљна променљива).

Што се тиче другог скупа података, издвајање из сирових података изведено је тако да подаци већ буду у истом облику као у првом скупу података, тако да већина наведених корака нису били потребни. Као што је већ речено, у другом скупу података постоје и следеће променљиве:

- WIND_DIRECTION – смер ветра у степенима,
- WIND_SPEED – брзина ветра у m/s.

Статистички описи најважнијих променљивих након спроведене предобrade дати су од ТАБ. 70 до ТАБ. 72. Ради потпуности, те табеле садрже и променљиву DC_POWER, иако се не користи у даљем поступку. (Статистички описи само за податке током дана дати су у одељку 4.3.6.)

ТАБ. 70: Статистички описи најважнијих променљивих у првом скупу података, електрана 1

	Ирадијанса (W/m ²)	Темп. модула (°C)	Темп. ваздуха (°C)	АС снага (kW)	DC снага (kW)
Број	3158	3158	3158	3158	3158
Ср. вред.	230,2316	31,1806	25,5610	305,9846	312,8912
Ст. дев.	301,3871	12,2742	3,3508	392,7650	401,9680
Мин.	0	18,1404	20,3985	0	0
25%	0	21,1308	22,7403	0	0
50%	28,0575	24,8075	24,6815	37,4106	38,7058
75%	451,7225	41,4497	27,9484	625,7021	638,6999
Макс.	1221,6518	65,5457	35,2525	1394,7520	1430,5154

ТАБ. 71: Статистички описи најважнијих променљивих у првом скупу података, електрана 2

	Ирадијанса (W/m ²)	Темп. модула (°C)	Темп. ваздуха (°C)	АС снага (kW)	DC снага (kW)
Број	3249	3249	3249	3249	3249
Ср. вред.	231,6925	32,7333	28,0620	303,0401	309,9787
Ст. дев.	312,2441	11,3269	4,0629	403,6897	413,3009
Мин.	0	20,2651	20,9424	0	0
25%	0	23,7145	24,6015	0	0
50%	18,0381	27,4923	26,9553	24,4316	25,2992
75%	437,2462	40,3954	31,0458	586,5306	598,5880
Макс.	1098,7660	66,6360	39,1816	1308,2733	1341,6764

ТАБ. 72: Статистички описи најважнијих променљивих у другом скупу података

	Ирадијанса (W/m ²)	Темп. модула (°C)	Темп. ваздуха (°C)	АС снага (kW)	DC снага (kW)
Број	35 136	35 136	35 136	35 136	35 136
Ср. вред.	160,0215	18,4220	15,4875	6,8048	6,9384
Ст. дев.	273,5964	13,6455	9,2889	11,3968	11,6216
Мин.	0	-5,1583	-2,9014	0	0
25%	0	7,9696	7,8063	0	0
50%	2,9633	15,9042	15,1734	0,0984	0,0991
75%	184,8019	25,0915	22,2730	8,5674	8,7259
Макс.	1107,4278	62,7144	48,8336	47,4297	48,5308

Занимљиво је споменути да су вредности променљиве AMBIENT_TEMPERATURE (температура ваздуха у °C) у електрани на крову ИМП-а генерално знатно више од званичних мерења температуре РХМЗ [163], посебно током лета. Наиме, мерења РХМЗ врше се у хладу, а равни кров Института „Михајло Пупин”, на ком се налази посматрана соларна електрана, не само што је директно изложен сунцу, већ је и прекривен каменим облацима, који се загревају услед сунчевог зрачења а затим ослобађају апсорбовану топлоту.


Топлотне мапе корелација након предобrade приказане су на сл. 80, сл. 81 и сл. 82. У ТАБ. 73 и ТАБ. 74 нумерички су представљене корелације свих атрибута са циљним атрибутом. Ради потпуности, ТАБ. 73 садржи и променљиву DC_POWER, иако се не користи у даљем поступку.



сл. 80: Топлотна мапа корелација за први скуп података – електрана 1, након предобrade



сл. 81: Топлотна мапа корелација за први скуп података – електрана 2, након предобrade



Сл. 82: Топлотна мапа корелација за други скуп података, након предобrade

ТАБ. 73: Вредности коефицијента корелације са циљним атрибутом за први скуп података, након предобrade

Променљива	Електрана 1 AC_POWER	Електрана 2 AC_POWER
AMBIENT_TEMPERATURE	0,725304	0,674616
MODULE_TEMPERATURE	0,961175	0,939157
IRRADIANCE	0,996458	0,985086
TIME	0,017840	0,032680
DAY_OF_YEAR	-0,023874	-0,098652
AC_POWER_PREV	0,959434	0,965712
EFF_PREV	0,731146	0,712232
DC_POWER	0,999997	0,999996
AC_POWER	1,000000	1,000000

ТАБ. 74: Вредности коефицијента корелације са циљним атрибутом за други скуп података, након предобrade

Променљива	AC_POWER
WIND_DIRECTION	0,063493
WIND_SPEED	-0,016809
IRRADIANCE	0,982978
MODULE_TEMPERATURE	0,793157
AMBIENT_TEMPERATURE	0,427765
TIME	-0,130793
DAY_OF_YEAR	-0,051591
AC_POWER_PREV	0,978458
EFF_PREV	0,560054
AC_POWER	1,000000

Осим наведених корака предобrade, пре симулација извршена је нормализација у опсег [0, 1], засебно за сваку електрану у оба скупа података, по једначини (50).

4.5 Поставке симулација

Оба скупа података подељени су на делове од 70% / 10% / 20% за обуку, валидацију и тестирање, респективно. Улазна обележја су:

- WIND_DIRECTION – смер ветра (постоји само у другом скупу података),
- WIND_SPEED – брзина ветра (постоји само у другом скупу података),
- IRRADIANCE – ирадијанса,
- MODULE_TEMPERATURE – температура модула,
- AMBIENT_TEMPERATURE – температура амбијента, тј. ваздуха,
- TIME – време,
- DAY_OF_YEAR – дан у години,
- AC_POWER_PREV – претходна снага наизменичне струје,
- EFF_PREV – претходна ефикасност инвертора, и
- AC_POWER – снага наизменичне струје, која је циљна променљива.

Прогнозе су направљене за 1, 2 и 3 корака унапред, тј. хоризонти прогноза су 15, 30 и 45 минута унапред. При томе није коришћен итеративни приступ, већ су жељени хоризонти обезбеђени дизајном мреже: број неурона у потпуно повезаном излазном слоју једнак је максималном броју корака унапред, тј. 3. Број историјских података који су узети у обзир, тј. кашњења (енгл. *lags*), емпиријски је одређен и постављен на 8. Хиперпараметри који су у овом истраживању одабрани да буду оптимизовани и за LSTM и за LSTM са пажњом, заједно са својим просторима претраживања, дати су у ТАБ. 75. Границе за број слојева и број неурона по слоју изабране су у складу са најчешћим вредностима уоченим у актуелној литератури, што је описано у одељку 3.3.15. Познато је да додавање четвртог и даљих слојева за већину проблема не доноси значајно повећање тачности LSTM мреже. Висока доња граница за број неурона омогућава моделирање комплексних зависности а смањује простор претраге оптимизатора.

ТАБ. 75: Скуп хиперпараметара који се оптимизују

Метода	Хиперпараметар	Доња граница	Горња граница
LSTM	величина корака (енгл. <i>learning rate</i>)	0,0001	0,01
	искључивање (енгл. <i>dropout</i>)	0,05	0,2
	број епоха	100	300
	број слојева (енгл. <i>layers</i>)	1	3
	број неурона по слоју	100	300
LSTM-ATT	величина корака	0,0001	0,01
	искључивање	0,05	0,2
	број епоха	100	300
	број слојева	1	3
	број неурона по слоју	100	300

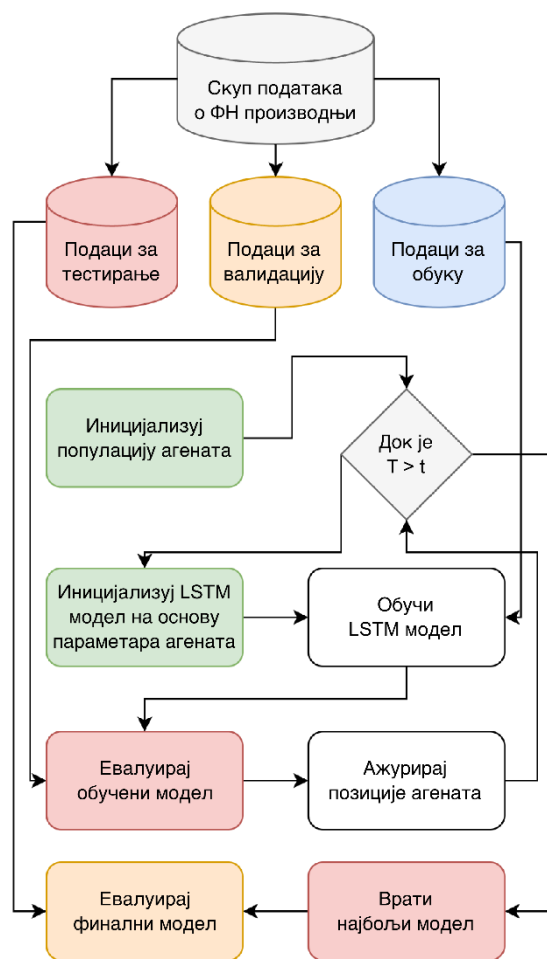
Нова DGPSO метахеуристика употребљена је да оптимизује хиперпараметре приказане у ТАБ. 75. Ради упоредне евалуације, исти задатак спроведен је са још 7 савремених метода оптимизације, а то су основни PSO [80], GA [110], VNS [90], FA [92], SCHO [93], ChOA [111] и COLSHADE [112]. (Метода претраге променљивог суседства /енгл. *Variable Neighborhood Search* – VNS/ у основној варијанти [89] не користи популацију агената. Ради конзистентности са осталим примењеним методама, које су све засноване на популацији, уместо основног VNS употребљава се VNS заснован на популацији /енгл. *Population-based VNS* – PVNS/. Дакле, у овој тези под VNS заправо се мисли на PVNS.)

Сваки од тих супротстављених алгоритама имплементиран је независно, са препорученим подешавањима контролних параметара које су предложили њихови аутори. Број димензија за свако решење био је $D = 4 + layers(upper_bound) = 7$. Свака од посматраних метахеуристика

имала је на располагању 6 решења у популацији ($N = 6$), а свако покретање било је ограничено на 8 итерација ($T = 8$). Свака метахеуристика извршена је у по 30 одвојених покретања, да би се умањио утицај фактора случајности који постоји код свих стохастичких алгоритама. Мањи број решења у популацији и итерација у сваком покретању били су неопходни због високих рачунских трошкова и интензивних прорачуна функције циља.

Особине модела процењене су традиционалним скупом регресионих метрика [113], који чине MSE, RMSE, MAE и R^2 , дате у једначинама (6), (7), (8) и (4), респективно. Додатна метрика, индекс слагања (енгл. *Index of Agreement* – IoA, једначина (11)) [114], такође је праћена током оптимизације зато што може допринети свеобухватнијем увиду у могућности модела.

За спроведене симулације, MSE је постављена као функција прилагођености која се минимизује (функција циља), док R^2 игра улогу индикаторске функције. Да би се омогућила поређења, при приказу резултата MSE је нормализована квадратом максималне вредности циљне променљиве, а RMSE и MAE максималном вредношћу циљне променљиве. За нормализацију се примењују максималне вредности циљне променљиве због тога што за електране из Индије нису познати номинални капацитети. Такође, због стохастичке природе метахеуристичких оптимизатора, већина резултата представљени су као просеци, независни од броја корака унапред. У симулацијама је коришћено рано заустављање (енгл. *early stopping*), а подешено је на број епоха подељен са 3. Дијаграм тока целог оквира за обуку и тестирање модела дат је на сл. 83. Тај дијаграм представља конкретизацију поступка описаног у одељку 2.5.7, тј. његово прилагођење за процес метахеуристичке оптимизације.



сл. 83: Дијаграм тока оквира за обуку и тестирање модела

Алгоритми су реализовани помоћу програмског језика Python. Прилог А садржи изворни код за неке од реализованих алгоритама. Коришћене библиотеке укључују Keras, TensorFlow и

Scikit-learn. Као развојно окружење (енгл. *Integrated Development Environment – IDE*) употребљен је PyCharm. Обуке су трајале укупно око 5 дана. Рачунар на ком су вршене обуке и експерименти опремљен је јединицом за графичку обраду (енгл. *Graphics Processing Unit – GPU*) NVIDIA GeForce RTX 3090. Најважније особине те графичке картице су:

- Количина RAM меморије:.....24 GB
- Ширина меморијске магистрале:.....384 бита
- Пропусни опсег меморије:936,2 GB/s
- Број CUDA језгара:10 496
- Број тензорских језгара:328
- Такт:.....1 395-1 695 MHz
- Архитектура:.....Ampere

5 Резултати симулација

Ово поглавље приказује резултате симулација у свим спроведеним експериментима. Укупно је извршено шест експеримената: симулације помоћу LSTM и LSTM са пажњом спроведене су за сваку од три електране у коришћеним скуповима података – обе електране из првог (индијског) скупа података и електрану из другог (ИМП) скупа података. У свакој табели која приказује резултате симулације, најбољи појединачни резултат у свакој разматраној категорији је подебљан.

5.1 Први скуп података – електрана 1

У овом одељку дати су резултати симулација за прву електрану из првог скупа података.

5.1.1 Први скуп података – електрана 1 – LSTM модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM модела за електрану 1 из првог скупа података приказане су у ТАБ. 76. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих разматраних оптимизатора, достигавши вредност $nMSE$ од 0,007297. Што се тиче осталих статистичких показатеља, најбољи резултат за најлошије извршење постигнут је помоћу ChOA алгоритма са вредношћу од 0,007535, док су најбоља средња вредност (0,007437) и медијана (0,007398) добијене помоћу SCHO метахеуристике. COLSHADE алгоритам дао је најстабилније резултате, што се види из најмањег стандардног одступања (стандардне девијације) и варијансе.

Расподеле функције циља (MSE) приказане су помоћу виолинских дијаграма на СЛ. 84. Може се приметити да, упркос томе што није остварила најстабилније резултате попут COLSHADE алгоритма, нова DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. На СЛ. 85 дати су дијаграми разноликости роја за функцију циља за сваку од посматраних метахеуристике. Расподеле индикаторске функције (R^2) приказане су помоћу кутијастих дијаграма на СЛ. 86, а дијаграми разноликости роја за индикаторску функцију за сваку од посматраних метахеуристике на СЛ. 87.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристике приказани су на СЛ. 88 и СЛ. 89.

Све метрике најбољих конструисаних LSTM модела за електрану 1 из првог скупа података приказане су у ТАБ. 77. Одличне перформансе LSTM-DGPSO методе (тј. LSTM модела подешеног помоћу нове DGPSO метахеуристике) очигледне су на основу тога што је остварио најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,007297, R^2 (индикаторска функција) од 0,893873, $nRMSE$ од 0,085421 и IoA од 0,972556. У тим симулацијама, најбољи $nMAE$ од 0,046504 постигнут је помоћу метахеуристике SCHO.

Детаљни резултати најбољих конструисаних LSTM модела помоћу сваке од посматраних метахеуристике при предвиђањима за 1, 2 и 3 корака унапред дати су у ТАБ. 78. Предложена LSTM-DGPSO метода остварила је најбоље резултате при предвиђањима за 2 и 3 корака унапред, док је LSTM-ChOA метода показала најбоље перформансе при предвиђањима за 1 корак унапред. Такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различити алгоритми могу бити ефикасни у различитим сценаријима.


Визуализација најбољих предвиђања за 1, 2 и 3 корака унапред добијених предложеном LSTM-DGPSO методом приказана је на сл. 90. Најбоље комбинације LSTM хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у таб. 79, да би се олакшала евентуална репликација резултата у другим истраживањима.

ТАБ. 76: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података

Метода	Најбоље	Најлошије	Средња вр.	Медијана	Ст. дев.	Варијанса
LSTM-DGPSO	0,007297	0,007758	0,007507	0,007526	1,51E-04	2,27E-08
LSTM-PSO	0,007557	0,007801	0,007685	0,007700	7,27E-05	5,28E-09
LSTM-GA	0,007402	0,007674	0,007541	0,007556	1,00E-04	1,00E-08
LSTM-VNS	0,007435	0,007636	0,007518	0,007507	7,11E-05	5,06E-09
LSTM-FA	0,007429	0,007733	0,007585	0,007599	1,07E-04	1,14E-08
LSTM-SCHO	0,007302	0,007561	0,007437	0,007398	1,04E-04	1,08E-08
LSTM-ChOA	0,007320	0,007535	0,007452	0,007477	8,58E-05	7,36E-09
LSTM-COLSHADE	0,007424	0,007583	0,007497	0,007500	5,63E-05	3,17E-09

ТАБ. 77: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података

Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-DGPSO	0,893873	0,048644	0,007297	0,085421	0,972556
LSTM-PSO	0,890088	0,047849	0,007557	0,086931	0,971383
LSTM-GA	0,892347	0,047497	0,007402	0,086033	0,971628
LSTM-VNS	0,891858	0,047805	0,007435	0,086228	0,971870
LSTM-FA	0,891951	0,047569	0,007429	0,086191	0,972164
LSTM-SCHO	0,893802	0,046504	0,007302	0,085450	0,972509
LSTM-ChOA	0,893531	0,046972	0,007320	0,085559	0,971397
LSTM-COLSHADE	0,892030	0,047909	0,007424	0,086160	0,972103




Сл. 84: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података

ТАБ. 78: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-DGPSO	R ²	0,877317	0,899100	0,905203
	nMAE	0,052741	0,046959	0,046232
	nMSE	0,008435	0,006937	0,006518
	nRMSE	0,091843	0,083291	0,080733
	IoA	0,968341	0,973835	0,975493
LSTM-PSO	R ²	0,879375	0,891392	0,899496
	nMAE	0,050892	0,047501	0,045156
	nMSE	0,008294	0,007467	0,006910
	nRMSE	0,091069	0,086414	0,083127
	IoA	0,968221	0,971895	0,974032
LSTM-GA	R ²	0,876647	0,897570	0,902824
	nMAE	0,051747	0,046090	0,044655
	nMSE	0,008481	0,007043	0,006681
	nRMSE	0,092093	0,083920	0,081740
	IoA	0,967411	0,973142	0,974331
LSTM-VNS	R ²	0,877538	0,894831	0,903205
	nMAE	0,051724	0,046733	0,044960
	nMSE	0,008420	0,007231	0,006655
	nRMSE	0,091760	0,085035	0,081579
	IoA	0,968092	0,972665	0,974852
LSTM-FA	R ²	0,879009	0,896465	0,900378
	nMAE	0,051440	0,045488	0,045779
	nMSE	0,008319	0,007119	0,006850
	nRMSE	0,091207	0,084372	0,082762
	IoA	0,968601	0,973371	0,974521
LSTM-SCHO	R ²	0,878571	0,898604	0,904230
	nMAE	0,051051	0,044762	0,043700
	nMSE	0,008349	0,006972	0,006585
	nRMSE	0,091372	0,083496	0,081146
	IoA	0,968266	0,973853	0,975409
LSTM-ChOA	R ²	0,883967	0,896368	0,900258
	nMAE	0,049766	0,045651	0,045499
	nMSE	0,007978	0,007125	0,006858
	nRMSE	0,089319	0,084411	0,082812
	IoA	0,968773	0,972177	0,973242
LSTM-COLSHADE	R ²	0,877455	0,896904	0,901731
	nMAE	0,051659	0,046034	0,046033
	nMSE	0,008426	0,007088	0,006756
	nRMSE	0,091791	0,084193	0,082198
	IoA	0,968332	0,973370	0,974606

ТАБ. 79: Најбољи одабрани LSTM хиперпараметри за експерименте са електраном 1 из првог скупа података


Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3
LSTM-DGPSO	1,85E-03	1,31E-02	283	1	228	150	287
LSTM-PSO	5,07E-03	7,99E-02	220	3	180	180	286
LSTM-GA	1,00E-02	7,60E-02	205	1	179	177	300
LSTM-VNS	2,01E-03	1,21E-01	143	3	300	143	291
LSTM-FA	1,00E-02	2,00E-01	167	2	185	136	181
LSTM-SCHO	7,42E-03	5,00E-02	296	1	189	117	271
LSTM-ChOA	9,07E-03	1,83E-01	161	3	246	192	134
LSTM-COLSHADE	4,23E-03	1,17E-01	282	2	251	235	146




Сл. 85: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података




Сл. 86: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података




Сл. 87: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података



Сл. 88: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података



Сл. 89: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM модела за електрану 1 из првог скупа података



Сл. 90: Најбоља предвиђања за 1, 2 и 3 корака унапред методом LSTM-DGPSO за електрану 1 из првог скупа података

5.1.2 Први скуп података – електрана 1 – LSTM-АТТ модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM-АТТ (LSTM са пажњом) модела за електрану 1 из првог скупа података приказане су у ТАБ. 80. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих разматраних оптимизатора, достижући вредност $nMSE$ од 0,007300. Што се тиче осталих показатеља, најбољи резултат за најлошије извршење постигнут је помоћу основног PSO алгоритма са вредношћу од 0,007535, док је најбоља средња вредност од 0,007510 постигнута помоћу алгоритма FA. Најбоља медијана од 0,007462 добијена је помоћу нове DGPSO метахеуристике. Основни PSO алгоритам дао је најстабилније резултате, што се види на основу најмањег стандардног одступања и варијансе.

ТАБ. 80: Статистике функције циља за LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података

Метода	Најбоље	Најлошије	Сред. вр.	Медијана	Ст. дев.	Варијанса
LSTM-АТТ-DGPSO	0,007300	0,007738	0,007513	0,007462	1,70E-04	2,88E-08
LSTM-АТТ-PSO	0,007485	0,007535	0,007511	0,007509	1,77E-05	3,14E-10
LSTM-АТТ-GA	0,007405	0,007665	0,007521	0,007560	9,83E-05	9,66E-09
LSTM-АТТ-VNS	0,007421	0,007642	0,007548	0,007528	7,43E-05	5,52E-09
LSTM-АТТ-FA	0,007416	0,007590	0,007510	0,007506	6,46E-05	4,17E-09
LSTM-АТТ-SCHO	0,007477	0,007640	0,007577	0,007587	6,22E-05	3,86E-09
LSTM-АТТ-ChOA	0,007416	0,007658	0,007561	0,007557	8,84E-05	7,81E-09
LSTM-АТТ-COLSHADE	0,007422	0,007667	0,007583	0,007627	9,22E-05	8,50E-09

Расподеле функције циља (MSE) приказане су помоћу виолинских дијаграма на сл. 91. Може се приметити да, упркос томе што није остварила стабилне резултате попут основног PSO алгоритма, предложена DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. На сл. 92 дати су дијаграми разноликости роја за функцију циља за сваку од посматраних метахеуристике. Расподеле индикаторске функције (R^2) приказане су помоћу кутијастих дијаграма на сл. 93, а дијаграми разноликости роја за индикаторску функцију за сваку од посматраних метахеуристике на сл. 94.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристике приказани су на сл. 95 и сл. 96. Може се приметити снажна конвергенција алгоритма DGPSO, који је успешно конвергирао ка најбољем укупном резултату упркос лошијем квалитету решења током фазе иницијализације, што указује на то да су уведене модификације заиста побољшале могућности алгоритма.


Све метрике најбољих конструисаних LSTM-АТТ модела за електрану 1 из првог скупа података приказане су у ТАБ. 81. Одличне перформансе LSTM-АТТ модела подешеног помоћу предложене DGPSO метахеуристике виде се по томе што је постигао најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,007300, R^2 (индикаторска функција) од 0,893833, $nRMSE$ од 0,085437 и $nMAE$ од 0,046916. У тим симулацијама, најбољу вредност IoA од 0,972034 постигла је метахеуристика GA.

Детаљни резултати најбољих конструисаних LSTM-АТТ модела помоћу сваке од посматраних метахеуристике при предвиђањима за 1, 2 и 3 корака унапред дати су у ТАБ. 82. Предложена LSTM-АТТ-DGPSO метода остварила је најбоље резултате при предвиђањима за 1 корак унапред, метода LSTM-АТТ-FA показала је најбоље перформансе при предвиђањима за 2 корака унапред, док је метода LSTM-АТТ-GA показала најбоље резултате при предвиђањима за 3 корака унапред. Такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различити алгоритми могу да се истакну у различитим сценаријима. Предложена LSTM-АТТ-DGPSO метода постигла је најбоље укупне резултате.


Најбоље комбинације LSTM-ATT хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у ТАБ. 83, да би се олакшала евентуална репликацијска истраживања.

ТАБ. 81: Све метрике за најбоље LSTM-ATT моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података

Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-ATT-DGPSO	0,893833	0,046916	0,007300	0,085437	0,971634
LSTM-ATT-PSO	0,891132	0,047406	0,007485	0,086517	0,971556
LSTM-ATT-GA	0,892292	0,048008	0,007405	0,086055	0,972034
LSTM-ATT-VNS	0,892060	0,047490	0,007421	0,086148	0,970936
LSTM-ATT-FA	0,892135	0,049030	0,007416	0,086118	0,971434
LSTM-ATT-SCHO	0,891247	0,050427	0,007477	0,086472	0,971111
LSTM-ATT-ChOA	0,892141	0,048220	0,007416	0,086116	0,971611
LSTM-ATT-COLSHADE	0,892047	0,047509	0,007422	0,086153	0,971511



Сл. 91: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података




Сл. 92: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података

ТАБ. 82: Детаљне метрике за најбоље LSTM-ATT моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 1 из првог скупа података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-ATT-DGPSO	R ²	0,889122	0,894101	0,898276
	nMAE	0,048269	0,046903	0,045577
	nMSE	0,007623	0,007281	0,006994
	nRMSE	0,087312	0,085330	0,083631
	IoA	0,970529	0,971710	0,972664
LSTM-ATT-PSO	R ²	0,875921	0,894949	0,902528
	nMAE	0,052045	0,046066	0,044107
	nMSE	0,008531	0,007223	0,006702
	nRMSE	0,092364	0,084987	0,081864
	IoA	0,967547	0,972501	0,974621
LSTM-ATT-GA	R ²	0,877155	0,895584	0,904138
	nMAE	0,052236	0,046636	0,045151
	nMSE	0,008446	0,007179	0,006591
	nRMSE	0,091903	0,084730	0,081185
	IoA	0,968184	0,972854	0,975063
LSTM-ATT-VNS	R ²	0,885859	0,895684	0,894638
	nMAE	0,050387	0,046232	0,045852
	nMSE	0,007848	0,007172	0,007244
	nRMSE	0,088588	0,084689	0,085113
	IoA	0,969558	0,971828	0,971421
LSTM-ATT-FA	R ²	0,880008	0,896223	0,900175
	nMAE	0,052555	0,047009	0,047526
	nMSE	0,008250	0,007135	0,006864
	nRMSE	0,090830	0,084470	0,082846
	IoA	0,968416	0,972501	0,973386
LSTM-ATT-SCHO	R ²	0,880718	0,893154	0,899870
	nMAE	0,054298	0,049794	0,047189
	nMSE	0,008201	0,007346	0,006884
	nRMSE	0,090561	0,085710	0,082973
	IoA	0,968343	0,971594	0,973395
LSTM-ATT-ChOA	R ²	0,881201	0,895010	0,900211
	nMAE	0,051046	0,047330	0,046283
	nMSE	0,008168	0,007219	0,006861
	nRMSE	0,090377	0,084962	0,082831
	IoA	0,968826	0,972381	0,973626
LSTM-ATT-COLSHADE	R ²	0,879920	0,894301	0,901921
	nMAE	0,051800	0,046298	0,044429
	nMSE	0,008256	0,007267	0,006743
	nRMSE	0,090863	0,085249	0,082119
	IoA	0,968088	0,972115	0,974330

ТАБ. 83: Најбољи одабрани LSTM-ATT хиперпараметри за експерименте са електраном 1 из првог скупа података

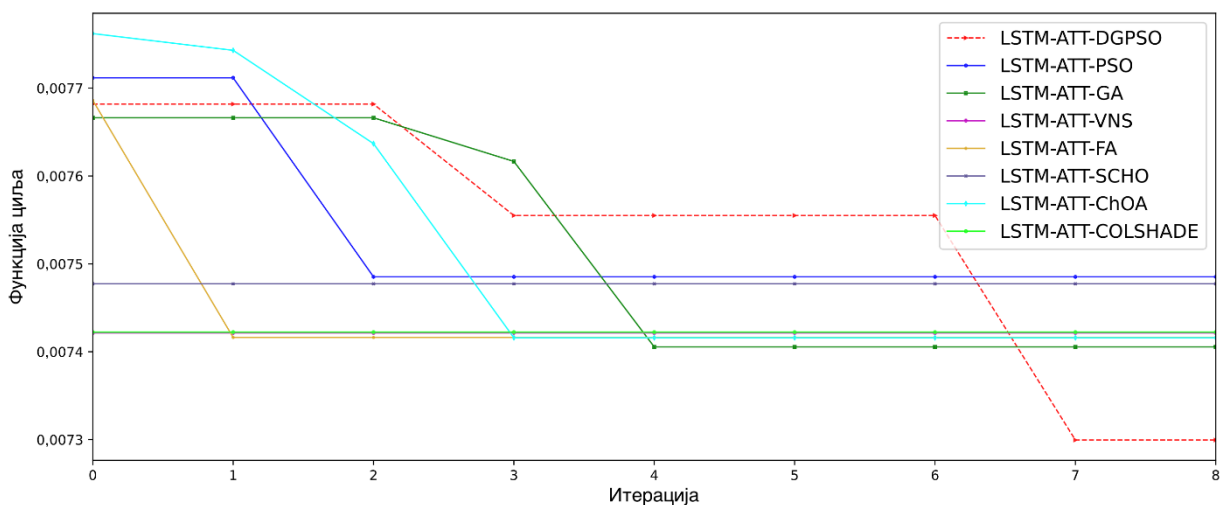
Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3	ATT
LSTM-ATT-DGPSO	1,00E-02	2,00E-01	100	3	299	100	100	300
LSTM-ATT-PSO	1,00E-02	1,66E-01	149	2	235	257	100	152
LSTM-ATT-GA	1,38E-03	2,00E-01	176	3	300	115	100	300
LSTM-ATT-VNS	6,23E-03	2,00E-01	222	3	300	100	300	270
LSTM-ATT-FA	1,00E-02	2,00E-01	100	3	100	225	100	100
LSTM-ATT-SCHO	5,35E-03	2,00E-01	100	3	300	194	100	300
LSTM-ATT-ChOA	8,63E-03	1,19E-01	105	3	300	100	124	169
LSTM-ATT-COLSHADE	4,69E-03	1,94E-01	136	3	102	154	260	101




Сл. 93: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података



Сл. 94: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података



Сл. 95: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података



Сл. 96: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM-ATT модела за електрану 1 из првог скупа података

5.2 Први скуп података – електрана 2

У овом одељку дати су резултати симулација за другу електрану из првог скупа података.

5.2.1 Први скуп података – електрана 2 – LSTM модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM модела за електрану 2 из првог скупа података приказане су у ТАБ. 84. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих разматраних оптимизатора, достигавши вредност $nMSE$ од 0,007662. Што се тиче осталих показатеља, најбољи резултат за најлошије извршење постигнут је помоћу ChOA алгоритма са вредношћу од 0,008008, док су најбоља средња вредност (0,007893) и медијана (0,007692) добијене помоћу основног PSO и FA метахеуристике, респективно. GA алгоритам дао је најстабилније резултате, на шта указују најмање стандардно одступање и варијанса у тим експериментима. Стохастичка природа метахеуристичких алгоритама очигледна је у том сценарију, зато што су се различите методе истакле за различите статистичке показатеље.

Виолински дијаграми на Сл. 97 приказују расподеле функције циља (MSE). Може се приметити да, упркос томе што није остварила најстабилније резултате попут GA алгоритма, предложена DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. На Сл. 98 приказани су дијаграми разноликости роја за функцију циља за сваку од посматраних метахеуристике. Расподеле индикаторске функције (R^2) приказане су помоћу кутијастих дијаграма на Сл. 99, а дијаграми разноликости роја за индикаторску функцију за сваку од посматраних метахеуристике на Сл. 100.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристике приказани су на Сл. 101 и Сл. 102. Може се приметити брза и снажна конвергенција DGPSO алгоритма, који је успешно и брзо конвергирао ка најбољем укупном резултату упркос лошијем квалитету решења током фазе иницијализације, што указује на то да су уведене модификације заиста побољшале могућности алгоритма.

Све метрике најбољих конструисаних LSTM модела за електрану 2 из првог скупа података приказане су у ТАБ. 85. Одличне перформансе LSTM модела подешеног помоћу предложеног DGPSO алгоритма јасно су видљиве по томе што је остварио најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,007662, R^2 (индикаторска функција) од 0,857440 и

nRMSE од 0,087531. У тим симулацијама, најбољи IoA од 0,961885 постигнут је помоћу SCHO метахеуристике, док је најбољи nMAE од 0,047984 постигнут помоћу алгоритма COLSHADE.

Детаљни резултати најбољих конструисаних LSTM модела помоћу сваке од посматраних метахеуристике при предвиђањима за 1, 2 и 3 корака унапред дати су у ТАБ. 86. Предложена LSTM-DGPSO метода дала је најбоље резултате при предвиђањима за 2 корака унапред, док је LSTM-FA метода показала најбоље перформансе при предвиђањима за 1 корак унапред, а LSTM-SCHO метода остварила је најбоље резултате при предвиђањима за 3 корака унапред. Такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различити алгоритми могу да се истакну у различитим сценаријима.

Визуализација најбољих прогноза за 1, 2 и 3 корака унапред направљених предложеном LSTM-DGPSO методом приказана је на сл. 103. Најбоље комбинације LSTM хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у ТАБ. 87, да би се олакшала евентуална репликацијска истраживања.

ТАБ. 84: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података

Метода	Најбоље	Најлошије	Средња вр.	Медијана	Ст. дев.	Варијанса
LSTM-DGPSO	0,007662	0,008077	0,007961	0,008003	0,000127	1,62E-08
LSTM-PSO	0,007684	0,008035	0,007893	0,007933	0,000113	1,28E-08
LSTM-GA	0,008055	0,008134	0,008084	0,008074	0,000031	9,54E-10
LSTM-VNS	0,007887	0,008070	0,007959	0,007918	0,000074	5,47E-09
LSTM-FA	0,007679	0,008507	0,007949	0,007692	0,000321	1,03E-07
LSTM-SCHO	0,007800	0,008105	0,007970	0,007981	0,000113	1,29E-08
LSTM-ChOA	0,007857	0,008008	0,007903	0,007865	0,000061	3,66E-09
LSTM-COLSHADE	0,007699	0,008085	0,007972	0,008037	0,000136	1,85E-08

ТАБ. 85: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података


Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-DGPSO	0,857440	0,049667	0,007662	0,087531	0,961150
LSTM-PSO	0,857031	0,048599	0,007684	0,087656	0,961511
LSTM-GA	0,850124	0,048327	0,008055	0,089749	0,961229
LSTM-VNS	0,853239	0,050169	0,007887	0,088811	0,961602
LSTM-FA	0,857112	0,049284	0,007679	0,087632	0,961590
LSTM-SCHO	0,854869	0,049955	0,007800	0,088317	0,961885
LSTM-ChOA	0,853808	0,049146	0,007857	0,088639	0,958773
LSTM-COLSHADE	0,856742	0,047984	0,007699	0,087745	0,961854

ТАБ. 86: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-DGPSO	R ²	0,859623	0,863166	0,849532
	nMAE	0,049637	0,048182	0,051182
	nMSE	0,007544	0,007354	0,008087
	nRMSE	0,086858	0,085755	0,089926
	IoA	0,960963	0,962712	0,959776
LSTM-PSO	R ²	0,861963	0,860423	0,848708
	nMAE	0,048972	0,047374	0,049452
	nMSE	0,007419	0,007501	0,008131
	nRMSE	0,086131	0,086610	0,090172
	IoA	0,962456	0,962345	0,959731
LSTM-GA	R ²	0,857229	0,857433	0,835709
	nMAE	0,048811	0,046441	0,049729
	nMSE	0,007673	0,007662	0,008830
	nRMSE	0,087596	0,087533	0,093966
	IoA	0,961718	0,963072	0,958896
LSTM-VNS	R ²	0,856676	0,858476	0,844566
	nMAE	0,050009	0,049155	0,051343
	nMSE	0,007703	0,007606	0,008354
	nRMSE	0,087765	0,087212	0,091398
	IoA	0,961398	0,963123	0,960285
LSTM-FA	R ²	0,862361	0,858848	0,850127
	nMAE	0,047736	0,048838	0,051279
	nMSE	0,007397	0,007586	0,008055
	nRMSE	0,086007	0,087098	0,089748
	IoA	0,962762	0,962169	0,959839
LSTM-SCHO	R ²	0,854859	0,855506	0,854241
	nMAE	0,049915	0,048919	0,051029
	nMSE	0,007800	0,007766	0,007834
	nRMSE	0,088320	0,088123	0,088507
	IoA	0,961891	0,962178	0,961586
LSTM-ChOA	R ²	0,853111	0,860616	0,847698
	nMAE	0,049308	0,047337	0,050793
	nMSE	0,007894	0,007491	0,008185
	nRMSE	0,088850	0,086550	0,090472
	IoA	0,958853	0,960740	0,956727
LSTM-COLSHADE	R ²	0,860216	0,860351	0,849661
	nMAE	0,048065	0,046909	0,048978
	nMSE	0,007512	0,007505	0,008080
	nRMSE	0,086674	0,086633	0,089887
	IoA	0,962224	0,962897	0,960442

ТАБ. 87: Најбољи одабрани LSTM хиперпараметри за експерименте са електраном 2 из првог скупа података


Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3
LSTM-DGPSO	1,99E-03	1,62E-01	142	2	282	222	162
LSTM-PSO	1,00E-02	2,00E-01	230	3	219	246	262
LSTM-GA	8,59E-04	6,36E-02	258	3	168	170	100
LSTM-VNS	6,13E-03	2,00E-01	100	2	300	300	116
LSTM-FA	1,00E-02	2,00E-01	100	3	100	300	217
LSTM-SCHO	1,00E-02	5,00E-02	100	3	100	213	124
LSTM-ChOA	2,80E-03	1,83E-01	155	3	218	260	171
LSTM-COLSHADE	3,90E-03	1,42E-01	131	3	216	182	197




Сл. 97: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података




Сл. 98: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података




Сл. 99: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података




Сл. 100: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података



Сл. 101: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података



Сл. 102: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM модела за електрану 2 из првог скупа података



сл. 103: Најбоља предвиђања за 1, 2 и 3 корака унапред методом LSTM-DGPSO за електрану 2 из првог скупа података

5.2.2 Први скуп података – електрана 2 – LSTM-АТТ модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM-АТТ (LSTM са пажњом) модела за електрану 2 из првог скупа података приказане су у таб. 88. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих посматраних оптимизатора, достижући вредност $nMSE$ од 0,007686. Што се тиче осталих статистичких показатеља, најбољи резултат за најлошије извршење постигнут је помоћу ChOA алгоритма са вредношћу од 0,007968, док је најбољу средњу вредност од 0,007877 такође постигао алгоритам ChOA. Најбоља медијана од 0,007850 добијена је помоћу алгоритма COLSHADE. Најстабилније резултате дао је алгоритам ChOA, на шта указују најмање стандардно одступање и варијанса у том сценарију.

Расподеле функције циља (MSE) дате су помоћу виолинских дијаграма на сл. 104. Може се приметити да, упркос томе што није остварила стабилне резултате попут алгоритма ChOA, предложена DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. Дијаграми разноликости роја за функцију циља за сваку од посматраних метахеуристика дати су на сл. 105. Расподеле индикаторске функције (R^2) приказане су помоћу кутијастих дијаграма на сл. 106, а дијаграми разноликости роја за индикаторску функцију за сваку од посматраних метахеуристика на сл. 107.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристика приказани су на сл. 108 и сл. 109. Може се приметити снажна конвергенција алгоритма DGPSO, који је успешно конвергирао ка најбољем укупном резултату упркос лошијем квалитету решења током фазе иницијализације, што указује на то да су уведене модификације заиста побољшале могућности алгоритма.

Све метрике најбољих конструисаних LSTM-АТТ модела за електрану 2 из првог скупа података приказане су у таб. 89. Одличне перформансе LSTM-АТТ модела подешеног помоћу предложеног DGPSO алгоритма виде се по томе што је постигао најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,007686, R^2 (индикаторска функција) од 0,856993 и $nRMSE$ од 0,087668. У тим симулацијама, основни PSO алгоритам постигао је најбољу вредност $nMAE$ од 0,048022, док је најбоља вредност IoA од 0,961740 постигнута помоћу алгоритма FA.

Детаљни резултати најбољих конструисаних LSTM-АТТ модела помоћу сваке од посматраних метахеуристика при предвиђањима за 1, 2 и 3 корака унапред дати су у таб. 90. Предложена LSTM-АТТ-DGPSO метода остварила је најбоље резултате при предвиђањима за 3 корака унапред, метода LSTM-АТТ-GA показала је најбоље перформансе при предвиђањима за 2 корака унапред, док је метода LSTM-АТТ-FA пружила најбоље резултате при предвиђањима

за 1 корак унапред. Такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различити алгоритми могу да се истакну у различитим сценаријима. Најбоље укупне резултате постигла је предложена LSTM-ATT-DGPSO метода.


Визуализација најбољих прогноза за 1, 2 и 3 корака унапред направљених предложеном LSTM-ATT-DGPSO методом приказана је на сл. 110. Најбоље комбинације LSTM-ATT хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у ТАБ. 91, да би се олакшала евентуална репликацијска истраживања.

ТАБ. 88: Статистике функције циља за LSTM-ATT моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података

Метода	Најбоље	Најлошије	Сред. вр.	Медијана	Ст. дев.	Варијанса
LSTM-ATT-DGPSO	0,007686	0,008042	0,007894	0,007874	0,000120	1,45E-08
LSTM-ATT-PSO	0,007976	0,008288	0,008123	0,008101	0,000116	1,36E-08
LSTM-ATT-GA	0,007705	0,008184	0,008007	0,008080	0,000179	3,19E-08
LSTM-ATT-VNS	0,007803	0,008118	0,007933	0,007903	0,000106	1,13E-08
LSTM-ATT-FA	0,007732	0,008210	0,008000	0,008012	0,000175	3,06E-08
LSTM-ATT-SCHO	0,007820	0,008138	0,007979	0,007942	0,000129	1,66E-08
LSTM-ATT-ChOA	0,007768	0,007968	0,007877	0,007881	0,000078	6,09E-09
LSTM-ATT-COLSHADE	0,007756	0,008028	0,007912	0,007850	0,000109	1,20E-08

ТАБ. 89: Све метрике за најбоље LSTM-ATT моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података

Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-ATT-DGPSO	0,856993	0,048774	0,007686	0,087668	0,961346
LSTM-ATT-PSO	0,851589	0,048022	0,007976	0,089309	0,959450
LSTM-ATT-GA	0,856640	0,049308	0,007705	0,087776	0,961513
LSTM-ATT-VNS	0,854819	0,048887	0,007803	0,088332	0,960647
LSTM-ATT-FA	0,856139	0,049645	0,007732	0,087929	0,961740
LSTM-ATT-SCHO	0,854491	0,048468	0,007820	0,088431	0,961695
LSTM-ATT-ChOA	0,855468	0,049372	0,007768	0,088134	0,961314
LSTM-ATT-COLSHADE	0,855679	0,049176	0,007756	0,088070	0,961262




Сл. 104: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података

ТАБ. 90: Детаљне метрике за најбоље LSTM-ATT моделе при предвиђањима за 1, 2 и 3 корака унапред за електрану 2 из првог скупа података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-ATT-DGPSO	R ²	0,859817	0,859736	0,851427
	nMAE	0,048958	0,048334	0,049029
	nMSE	0,007534	0,007538	0,007985
	nRMSE	0,086798	0,086823	0,089358
	IoA	0,961841	0,962173	0,960022
LSTM-ATT-PSO	R ²	0,847557	0,857276	0,849934
	nMAE	0,049762	0,046957	0,047347
	nMSE	0,008193	0,007670	0,008065
	nRMSE	0,090514	0,087581	0,089806
	IoA	0,957731	0,961091	0,959529
LSTM-ATT-GA	R ²	0,861302	0,862253	0,846366
	nMAE	0,048888	0,048016	0,051021
	nMSE	0,007454	0,007403	0,008257
	nRMSE	0,086337	0,086041	0,090867
	IoA	0,961483	0,963372	0,959683
LSTM-ATT-VNS	R ²	0,859426	0,857726	0,847304
	nMAE	0,049149	0,048050	0,049464
	nMSE	0,007555	0,007646	0,008206
	nRMSE	0,086919	0,087443	0,090589
	IoA	0,961828	0,961399	0,958715
LSTM-ATT-FA	R ²	0,862981	0,860407	0,845029
	nMAE	0,048362	0,048506	0,052066
	nMSE	0,007364	0,007502	0,008329
	nRMSE	0,085813	0,086615	0,091262
	IoA	0,963361	0,962794	0,959065
LSTM-ATT-SCHO	R ²	0,862052	0,859696	0,841725
	nMAE	0,047705	0,046740	0,050958
	nMSE	0,007414	0,007540	0,008506
	nRMSE	0,086103	0,086835	0,092229
	IoA	0,962693	0,962977	0,959416
LSTM-ATT-ChOA	R ²	0,861632	0,861682	0,843089
	nMAE	0,049069	0,047534	0,051512
	nMSE	0,007436	0,007434	0,008433
	nRMSE	0,086234	0,086219	0,091831
	IoA	0,962210	0,962971	0,958761
LSTM-ATT-COLSHADE	R ²	0,861783	0,860132	0,845122
	nMAE	0,049018	0,047795	0,050716
	nMSE	0,007428	0,007517	0,008324
	nRMSE	0,086187	0,086701	0,091234
	IoA	0,962330	0,962436	0,959018

ТАБ. 91: Најбољи одабрани LSTM-ATT хиперпараметри за експерименте са електраном 2 из првог скупа података


Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3	ATT
LSTM-ATT-DGPSO	6,81E-03	1,24E-01	164	3	189	147	267	149
LSTM-ATT-PSO	1,00E-02	2,00E-01	300	3	300	100	143	300
LSTM-ATT-GA	4,04E-03	1,63E-01	100	2	114	290	300	300
LSTM-ATT-VNS	1,00E-02	9,03E-02	100	3	198	300	133	300
LSTM-ATT-FA	1,00E-02	2,00E-01	100	2	100	100	100	300
LSTM-ATT-SCHO	2,55E-03	2,00E-01	125	3	100	100	125	249
LSTM-ATT-ChOA	2,57E-03	1,43E-01	100	3	232	143	175	228
LSTM-ATT-COLSHADE	1,00E-02	9,15E-02	146	3	126	100	100	300




Сл. 105: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података




Сл. 106: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података




Сл. 107: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података



Сл. 108: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података



Сл. 109: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM-ATT модела за електрану 2 из првог скупа података



Сл. 110: Најбоља предвиђања за 1, 2 и 3 корака унапред методом LSTM-ATT-DGPSO за електрану 2 из првог скупа података

5.3 Други скуп података

У овом одељку дати су резултати симулација за електрану из другог скупа података.

5.3.1 Други скуп података – LSTM модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM модела за други скуп података приказане су у ТАБ. 92. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих разматраних оптимизатора, достижући вредност $nMSE$ од 0,001855. Што се тиче осталих показатеља, најбољи резултат за најлошије извршење (0,002132), као и најбоља средња вредност (0,002021) и медијана (0,002011) добијени су помоћу основног PSO алгоритма. Алгоритам ChOA дао је најстабилније резултате, што се види из најмањег стандардног одступања и варијансе у тој серији експеримената. Стохастичка природа метахеуристичких алгоритама очигледна је у том сценарију, зато што су се различите методе истакле за различите статистичке показатеље. Осим тога, морају се споменути запажене перформансе основног PSO алгоритма.

Расподеле функције циља (MSE) приказане су помоћу виолинских дијаграма на сл. 111. Може се приметити да, упркос томе што није остварила најстабилније резултате попут алгоритма ChOA, предложена DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. На сл. 112 дати су дијаграми разноликости роја за функцију циља за сваку од посматраних метахеуристичких алгоритама. Расподеле индикаторске функције (R^2) приказане су помоћу кутијастих дијаграма на сл. 113, а дијаграми разноликости роја за индикаторску функцију за сваку од посматраних метахеуристичких алгоритама на сл. 114.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристичких алгоритама приказани су на сл. 115 и сл. 116. Може се приметити снажна конвергенција DGPSO алгоритма, који је успешно конвергирао ка најбољем укупном резултату упркос лошијем квалитету решења током фазе иницијализације, што указује на то да су уведене модификације заиста побољшале могућности алгоритма.

Све метрике најбољих конструисаних LSTM модела за други скуп података приказане су у ТАБ. 93. Одличне перформансе LSTM модела подешеног помоћу предложеног DGPSO алгоритма су очигледне, зато што је остварио најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,001855, R^2 (индикаторска функција) од 0,893008, $nRMSE$ од 0,043065, $nMAE$ од 0,018280 и друга најбоља IoA вредност од 0,972371. У тим симулацијама, најбољи IoA од 0,972688 постигнут је помоћу SCHO метахеуристике, што је незнатно виша вредност од предложеног DGPSO алгоритма.

Детаљни резултати најбољих конструисаних LSTM модела помоћу сваке од посматраних метахеуристичких алгоритама при предвиђањима за 1, 2 и 3 корака унапред дати су у ТАБ. 94. LSTM-SCHO метода дала је најбоље резултате при прогнозама за 1 и 2 корака унапред, док је LSTM-PSO дала најбоље резултате при прогнозама за 3 корака унапред. Поново, такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различити алгоритми могу да се истакну у различитим сценаријима. Међутим, најбоље укупне резултате постигла је предложена LSTM-DGPSO метода, а мора се истаћи и одличан учинак основног PSO алгоритма у том конкретном сценарију.


Визуализација најбољих прогноза за 1, 2 и 3 корака унапред направљених предложеном LSTM-DGPSO методом приказана је на сл. 117. Најбоље комбинације LSTM хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у ТАБ. 95, да би се олакшала репликација тих резултата у другим истраживањима.

ТАБ. 92: Статистике функције циља за LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података

Метода	Најбоље	Најлошије	Средња вр.	Медијана	Ст. дев.	Варијанса
LSTM-DGPSO	0,001855	0,002213	0,002058	0,002083	1,33E-04	1,78E-08
LSTM-PSO	0,001940	0,002132	0,002021	0,002011	7,41E-05	5,50E-09
LSTM-GA	0,002029	0,002333	0,002130	0,002068	1,19E-04	1,41E-08
LSTM-VNS	0,002026	0,002317	0,002118	0,002102	9,75E-05	9,51E-09
LSTM-FA	0,002024	0,002481	0,002128	0,002049	1,77E-04	3,14E-08
LSTM-SCHO	0,001867	0,002286	0,002083	0,002084	1,49E-04	2,21E-08
LSTM-ChOA	0,001918	0,002133	0,002047	0,002060	7,14E-05	5,10E-09
LSTM-COLSHADE	0,002048	0,002262	0,002150	0,002144	7,96E-05	6,34E-09

ТАБ. 93: Све метрике за најбоље LSTM моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података

Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-DGPSO	0,893008	0,018280	0,001855	0,043065	0,972371
LSTM-PSO	0,888082	0,021790	0,001940	0,044045	0,971346
LSTM-GA	0,882919	0,020705	0,002029	0,045050	0,968693
LSTM-VNS	0,883144	0,021198	0,002026	0,045007	0,970725
LSTM-FA	0,883260	0,021348	0,002024	0,044984	0,971212
LSTM-SCHO	0,892267	0,019064	0,001867	0,043214	0,972688
LSTM-ChOA	0,889344	0,018692	0,001918	0,043796	0,971734
LSTM-COLSHADE	0,881867	0,020503	0,002048	0,045252	0,971373




Сл. 111: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM модела за други скуп података

ТАБ. 94: Детаљне метрике за најбоље LSTM моделе при предвиђањима за 1, 2 и 3 корака унапред за други скуп података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-DGPSO	R ²	0,881314	0,893940	0,903770
	nMAE	0,019222	0,018204	0,017413
	nMSE	0,002057	0,001838	0,001668
	nRMSE	0,045358	0,042877	0,040842
	IoA	0,969270	0,972737	0,975105
LSTM-PSO	R ²	0,869630	0,889756	0,904859
	nMAE	0,024518	0,021619	0,019232
	nMSE	0,002260	0,001911	0,001649
	nRMSE	0,047538	0,043715	0,040610
	IoA	0,967005	0,971821	0,975213
LSTM-GA	R ²	0,871089	0,883545	0,894122
	nMAE	0,021276	0,020277	0,020562
	nMSE	0,002235	0,002019	0,001835
	nRMSE	0,047271	0,044929	0,042840
	IoA	0,965470	0,968809	0,971800
LSTM-VNS	R ²	0,871649	0,888026	0,889756
	nMAE	0,020896	0,020010	0,022687
	nMSE	0,002225	0,001941	0,001911
	nRMSE	0,047168	0,044056	0,043715
	IoA	0,967437	0,971949	0,972790
LSTM-FA	R ²	0,880940	0,889510	0,879329
	nMAE	0,020657	0,020212	0,023174
	nMSE	0,002064	0,001915	0,002092
	nRMSE	0,045429	0,043763	0,045735
	IoA	0,969880	0,972711	0,971046
LSTM-SCHO	R ²	0,881633	0,895591	0,899579
	nMAE	0,019646	0,018331	0,019215
	nMSE	0,002052	0,001810	0,001741
	nRMSE	0,045297	0,042542	0,041722
	IoA	0,969939	0,973544	0,974581
LSTM-ChOA	R ²	0,876525	0,891828	0,899679
	nMAE	0,019625	0,017850	0,018602
	nMSE	0,002140	0,001875	0,001739
	nRMSE	0,046264	0,043302	0,041701
	IoA	0,968441	0,972373	0,974387
LSTM-COLSHADE	R ²	0,871037	0,884920	0,889644
	nMAE	0,020469	0,019721	0,021318
	nMSE	0,002235	0,001995	0,001913
	nRMSE	0,047280	0,044663	0,043737
	IoA	0,968724	0,972070	0,973325

ТАБ. 95: Најбољи одабрани LSTM хиперпараметри за експерименте са другим скупом података


Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3
LSTM-DGPSO	9,69E-03	1,05E-01	244	3	201	244	218
LSTM-PSO	1,00E-02	2,00E-01	300	3	300	133	300
LSTM-GA	6,76E-03	5,00E-02	151	2	100	246	171
LSTM-VNS	8,55E-03	5,00E-02	300	3	277	176	181
LSTM-FA	1,00E-02	2,00E-01	230	3	211	180	160
LSTM-SCHO	9,53E-03	8,96E-02	289	3	181	227	100
LSTM-ChOA	5,14E-03	1,67E-01	255	3	237	262	140
LSTM-COLSHADE	1,00E-02	9,88E-02	282	3	119	100	100




Сл. 112: Дијаграми разноликости роја за функцију циља при предвиђањима помоћу LSTM модела за други скуп података




Сл. 113: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM модела за други скуп података




Сл. 114: Дијаграми разноликости роја за индикаторску функцију при предвиђањима помоћу LSTM модела за други скуп података



Сл. 115: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM модела за други скуп података



Сл. 116: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM модела за други скуп података



Сл. 117: Најбоља предвиђања за 1, 2 и 3 корака унапред методом LSTM-DGPSO за други скуп података

5.3.2 Други скуп података – LSTM-АТТ модели

Статистике нормализованих вредности функције циља (MSE) приликом предвиђања помоћу LSTM-АТТ (LSTM са пажњом) модела за други скуп података приказане су у ТАБ. 96. Нова DGPSO метахеуристика постигла је најбољи резултат за најбоље извршење од свих посматраних оптимизатора, достижући вредност $nMSE$ од 0,001812. Што се тиче осталих статистичких показатеља, најбољи резултат за најлошије извршење (0,002080) постигнут је помоћу алгоритма FA, док су најбоља средња вредност (0,001971) и медијана (0,001955) добијене помоћу алгоритма GA. Алгоритам SCHO пружио је најстабилније резултате, на шта указују најмање стандардно одступање и варијанса. Стохастичка природа метахеуристичких алгоритама види се јасно у том сценарију по томе што су се различите методе истакле за различите показатеље.

ТАБ. 96: Статистике функције циља за LSTM-АТТ моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података

Метода	Најбоље	Најлошије	Сред. вр.	Медијана	Ст. дев.	Варијанса
LSTM-АТТ-DGPSO	0,001812	0,002215	0,002018	0,002066	0,000146	2,13E-08
LSTM-АТТ-PSO	0,001831	0,002190	0,001978	0,001997	0,000116	1,35E-08
LSTM-АТТ-GA	0,001832	0,002153	0,001971	0,001955	0,000110	1,21E-08
LSTM-АТТ-VNS	0,001981	0,002249	0,002070	0,002045	0,000094	8,79E-09
LSTM-АТТ-FA	0,001877	0,002080	0,001978	0,002008	0,000091	8,20E-09
LSTM-АТТ-SCHO	0,002007	0,002176	0,002110	0,002117	0,000061	3,63E-09
LSTM-АТТ-ChOA	0,001888	0,002165	0,001999	0,001968	0,000108	1,17E-08
LSTM-АТТ-COLSHADE	0,001858	0,002151	0,002032	0,002040	0,000112	1,25E-08

Виолински дијаграми расподела функције циља (MSE) приказани су на сл. 118. Може се приметити да, упркос томе што није остварила стабилне резултате попут алгоритма SCHO, предложена DGPSO метахеуристика постигла је солидне укупне резултате, уз најбољи резултат за најбоље извршење међу свим посматраним методама. Кутијасте дијаграми расподела индикаторске функције (R^2) приказани су на сл. 119.

Дијаграми конвергенције функције циља (MSE) и индикаторске функције (R^2) за сваку од посматраних метахеуристика приказани су на сл. 120 и сл. 121. Брза и снажна конвергенција алгоритма DGPSO може се приметити по томе што је успешно конвергирао ка најбољем укупном резултату упркос лошијем квалитету решења током фазе иницијализације, што указује на то да су уведене модификације заиста побољшале могућности алгоритма.


Све метрике најбољих конструисаних LSTM-АТТ модела за други скуп података приказане су у ТАБ. 97. Одличне перформансе LSTM-АТТ модела подешеног помоћу предложеног DGPSO алгоритма су очигледне, зато што је постигао најбоље резултате у погледу $nMSE$ (нормализована функција циља) од 0,001812, R^2 (индикаторска функција) од 0,895476, $nMAE$ од 0,018890 и $nRMSE$ од 0,042565. У тим симулацијама, најбољу вредност IoA од 0,973117 постигао је алгоритам COLSHADE.

Детаљни резултати најбољих конструисаних LSTM-АТТ модела помоћу сваке од посматраних метахеуристика при предвиђањима за 1, 2 и 3 корака унапред дати су у ТАБ. 98. Предложена LSTM-АТТ-DGPSO метода постигла је најбоље резултате при предвиђањима за 3 корака унапред, метода LSTM-АТТ-PSO показала је најбоље перформансе при предвиђањима за 2 корака унапред, док је метода LSTM-АТТ-GA пружила најбоље резултате при предвиђањима за 1 корак унапред. Као што је већ речено, такви резултати су очекивани због стохастичке природе метахеуристичких алгоритама, где различите технике могу бити ефикасне за различите сценарије. Предложена LSTM-АТТ-DGPSO метода постигла је најбоље укупне резултате.


Најбоље комбинације LSTM-ATT хиперпараметара утврђене сваким од посматраних метахеуристичких алгоритама приказане су у ТАБ. 99, да би се олакшала евентуална репликацијска истраживања.

ТАБ. 97: Све метрике за најбоље LSTM-ATT моделе – просеци при предвиђањима за 1, 2 и 3 корака унапред за други скуп података

Метода	R ²	nMAE	nMSE	nRMSE	IoA
LSTM-ATT-DGPSO	0,895476	0,018890	0,001812	0,042565	0,971596
LSTM-ATT-PSO	0,894354	0,019800	0,001831	0,042793	0,971815
LSTM-ATT-GA	0,894284	0,019030	0,001832	0,042807	0,972200
LSTM-ATT-VNS	0,885736	0,020080	0,001981	0,044505	0,971611
LSTM-ATT-FA	0,891731	0,019403	0,001877	0,043321	0,972654
LSTM-ATT-SCHO	0,884220	0,021228	0,002007	0,044799	0,970459
LSTM-ATT-ChOA	0,891075	0,020132	0,001888	0,043452	0,972534
LSTM-ATT-COLSHADE	0,892826	0,020594	0,001858	0,043102	0,973117



Сл. 118: Дијаграми расподеле функције циља при предвиђањима помоћу LSTM-ATT модела за други скуп података




Сл. 119: Дијаграми расподеле индикаторске функције при предвиђањима помоћу LSTM-ATT модела за други скуп података

ТАБ. 98: Детаљне метрике за најбоље LSTM-ATT моделе при предвиђањима за 1, 2 и 3 корака унапред за други скуп података


Метода	Метрика	1 корак	2 корака	3 корака
LSTM-ATT-DGPSO	R ²	0,879868	0,899405	0,907155
	nMAE	0,019967	0,017845	0,018859
	nMSE	0,002082	0,001744	0,001609
	nRMSE	0,045633	0,041758	0,040117
	IoA	0,967550	0,972790	0,974447
LSTM-ATT-PSO	R ²	0,883337	0,900739	0,898987
	nMAE	0,019906	0,018294	0,021201
	nMSE	0,002022	0,001721	0,001751
	nRMSE	0,044969	0,041480	0,041845
	IoA	0,967665	0,973615	0,974166
LSTM-ATT-GA	R ²	0,884801	0,894717	0,903335
	nMAE	0,019943	0,018786	0,018361
	nMSE	0,001997	0,001825	0,001676
	nRMSE	0,044686	0,042720	0,040934
	IoA	0,970216	0,972221	0,974162
LSTM-ATT-VNS	R ²	0,874192	0,889217	0,893799
	nMAE	0,020820	0,018906	0,020514
	nMSE	0,002181	0,001920	0,001841
	nRMSE	0,046699	0,043821	0,042906
	IoA	0,968719	0,972477	0,973636
LSTM-ATT-FA	R ²	0,877040	0,896792	0,901361
	nMAE	0,020318	0,018281	0,019608
	nMSE	0,002131	0,001789	0,001710
	nRMSE	0,046167	0,042297	0,041350
	IoA	0,968723	0,973922	0,975317
LSTM-ATT-SCHO	R ²	0,877873	0,888788	0,886000
	nMAE	0,020337	0,020509	0,022838
	nMSE	0,002117	0,001928	0,001976
	nRMSE	0,046010	0,043906	0,044453
	IoA	0,968178	0,971703	0,971496
LSTM-ATT-ChOA	R ²	0,877714	0,897075	0,898435
	nMAE	0,020217	0,018862	0,021317
	nMSE	0,002120	0,001784	0,001761
	nRMSE	0,046040	0,042239	0,041959
	IoA	0,969170	0,974053	0,974381
LSTM-ATT-COLSHADE	R ²	0,876409	0,897226	0,904843
	nMAE	0,022050	0,019420	0,020313
	nMSE	0,002142	0,001781	0,001649
	nRMSE	0,046285	0,042208	0,040613
	IoA	0,969047	0,974167	0,976138

ТАБ. 99: Најбољи одабрани LSTM-ATT хиперпараметри за експерименте са другим скупом података

Метода	Корак	Искључивање	Епоха	Слојева	L1	L2	L3	ATT
LSTM-ATT-DGPSO	1,00E-02	5,00E-02	274	2	300	300	300	101
LSTM-ATT-PSO	1,00E-02	2,00E-01	300	3	134	239	154	188
LSTM-ATT-GA	7,98E-03	1,49E-01	223	2	263	106	258	227
LSTM-ATT-VNS	1,00E-02	1,08E-01	300	2	100	300	300	252
LSTM-ATT-FA	1,00E-02	2,00E-01	300	3	288	136	300	213
LSTM-ATT-SCHO	7,28E-03	1,70E-01	157	2	181	299	201	264
LSTM-ATT-ChOA	5,85E-03	8,91E-02	258	2	154	161	148	257
LSTM-ATT-COLSHADE	1,00E-02	5,00E-02	300	3	100	104	194	120



Сл. 120: Дијаграми конвергенције функције циља при предвиђањима помоћу LSTM-ATT модела за други скуп података



Сл. 121: Дијаграми конвергенције индикаторске функције при предвиђањима помоћу LSTM-ATT модела за други скуп података

5.4 Примена помоћу TinyML-а

Недавни напредак у уграђеним (енгл. *embedded*) системима, као и вештачкој интелигенцији, довео је до покретања занимљивог концепта минијатурног машинског учења (енгл. *TinyML*). Извршавање моћних модела вештачке интелигенције на ограниченом хардверу представља изазов који обухвата неколико области истраживања, од електротехнике и уграђеног рачунарства до математичког и статистичког моделирања и оптимизације. Важан аспект TinyML апликација је релативно ниска цена хардвера који се користи за имплементацију

модела, за разлику од високих трошкова хардвера који се примењује за обуку модела. Модерни модели машинског учења могу се тренирати на моћним графичким и тензорским процесорским јединицама, а након валидације компајлирати за употребу на прилично ограниченом хардверу са прихватљивим перформансама. То повећава потенцијал за примену модела и чини машинско учење доступнијим и јефтинијим.

Оптимизација игра важну улогу у припреми модела за употребу у TinyML апликацијама. Избор модела који поседују одговарајућу тачност, а довољно су рачунски лаки за примену на уграђеним уређајима, представља изазов сам по себи. Избор хиперпараметара сматра се NP-тешким проблемом и стога истраживачи често користе специјализоване оптимизаторе у том процесу. Ограничавањем региона претраге оптимизатора унутар граница које се сматрају прихватљивим за уграђене апликације, модели се могу оптимизовати тако да пружају најбоље могуће перформансе уз одржавање рачунских захтева на прихватљивом нивоу.

Додатна предност извршавања модела машинског учења на уграђеним уређајима је релативно мала величина уређаја. Уређаји као што је ESP32 опремљени су свим потребним компонентама и периферним уређајима за обављање сензорских и мрежних операција. Међутим, трошкови умрежавања, посебно на удаљеним локацијама, не могу се потценити. Коришћење TinyML уређаја са предиктивним моделима омогућава доношење одлука на лицу места и тако може помоћи у смањењу мрежног саобраћаја. Употреба компајлираних TensorFlow Lite модела који се могу пренети на ESP32 смањује трошкове имплементације и побољшава интеграцију постројења за производњу фотонапонске енергије са постојећим електроенергетским системима.

ESP32 нуди разне могућности за проширења, као што је хостовање веб сервера за праћење података у реалном времену и компатибилност са спољним периферним уређајима за прикупљање мерења. За посматране примене важно је и што садржи аналогно-дигитални конвертор за претварање аналогних улазних сигнала у дигитални облик. Конкретан модел коришћен у овом истраживању је ESP32-D0WDQ6. То је високо интегрисани систем на чипу (енгл. *System on a Chip* – SoC) са 32-битним Xtensa LX6 микропроцесором са два језгра (енгл. *dual-core*), чији је радни такт до 240 MHz. Садржи 2,4 GHz Wi-Fi, Bluetooth 4.2 LE, 520 KB SRAM меморије и смештен је у QFN48 кућиште димензија 6×6 mm, што га чини идеалним за примене у којима се тражи мала потрошња енергије. Најважније особине тог уређаја су [154]:

- Процесор: Tensilica Xtensa LX6 32-битни CPU са два језгра
- Такт: до 240 MHz
- Перформансе: до 600 DMIPS
- Меморија: 520 KB SRAM, 448 KB ROM, подржава екстерни флеш
- Бежичне мреже: ... 2,4 GHz Wi-Fi (802.11 b/g/n) и Bluetooth 4.2 (BR/EDR + BLE)
- Кућиште: QFN48 (6×6 mm)
- Периферије: 22 GPIO пина, 18 ADC и 2 DAC канала, SPI, I2C, UART, I2S и CAN
- Напон напајања: .. 2,3-3,6 V

С обзиром на то што нема уграђену подршку за USB повезивање, примењени модел повезан је на PC рачунар помоћу FTDI адаптера за повезивање USB и серијског порта. При томе се пинови за пријем и предају укрштају, а адаптер се мора подесити да ради на 3,3 V. Повезивање пинова описано је у ТАБ. 100. Користи се UART 0, тј. улазно-излазни пинови опште намене (енгл. *General-Purpose Input/Output* – GPIO) 1 и 3. Параметри за подешавање серијске везе морају бити исти на обе стране. Употребљене су следеће вредности параметара серијске везе:

- Брзина преноса: 115 200 bps
- Број бита података: .. 8
- Број стоп бита: 1
- Парност: Без парности
- Контрола протока: Без контроле протока

ТАБ. 100: Повезивање пинова FTDI адаптера и ESP32-D0WDQ6 чипа [154]

Пин на FTDI адаптеру	Пин на ESP32-D0WDQ6
GND	GND
Tx	GPIO 3 (Rx0)
Rx	GPIO 1 (Tx0)
3,3 V / VCC	3,3 V

На основу резултата спроведених симулација, модели са најбољим перформансама, оптимизовани за тачност предвиђања у све три електране, компајлирани су за употребу као TinyML апликације на ESP32 платформи. Иако су ограничени рачунарски ресурси представљали изазов, коришћење TensorFlow Lite-а и конвертовање коначног модела у C-компатибилан бинарни програм омогућили су примену на тој платформи преко развојног окружења отвореног кода (енгл. *open-source*) Arduino.

Након што је одговарајући модел имплементиран на ESP32, подешен је да прати серијске улазе и враћа прогнозе на основу улазних података. Програм на РС рачунару шаље податке преко серијског порта и прима прогнозе које генерише ESP32. Подаци за тај експеримент нису скалирани. Симулације су поновљене уз коришћење дела скупа података за тестирање, при чему су добијени идентични резултати као у претходним симулацијама. Тиме је доказана исправност и практична применљивост концепта. Тај експеримент показује потенцијал за скалирање система кроз примену ЈоТ (енгл. *Internet of Things*) уређаја за прогнозирање енергије, чиме би се побољшала доступност. Такав напредак могао би да игра кључну улогу у бољој интеграцији обновљивих извора енергије у постојеће електроенергетске мреже, уз оптимизацију дистрибуције, али и минимизовање губитака од прекомерне производње из необновљивих извора.

6 Закључак

Природна ограниченост фосилних горива и њихов неповољан утицај на животну средину покренули су стално растући прелаз ка обновљивим изворима енергије. Међутим, интеграција тих алтернативних извора енергије у постојеће електроенергетске системе праћена је бројним техничким и оперативним изазовима. Иако побољшање поузданости нуди значајан потенцијал за унапређење енергетске одрживости, зависност фотонапонске енергије од метеоролошких услова често захтева скупа решења за складиштење да би се одржала константна производња.

У оквиру овог истраживања спроведен је детаљан преглед стања у области прогнозирања фотонапонске производње. Тај преглед обухватио је 50 најбољих радова који испуњавају постављене критеријуме актуелности, репрезентативности и доступности. Прегледани радови детаљно су анализирани у погледу више фактора који утичу на квалитет прогнозе, као што су методе прогнозирања, обухват, временске резолуције, хоризонти, предобрада, избор улазних обележја, оптимизација хиперпараметара, метрике, величине неуронских мрежа, функције активације, оптимизатори, функције губитка, итд.

У прегледаним радовима запажена је задовољавајућа разноликост у погледу метода прогнозирања, величина скупова података, капацитета постројења, грануларности, величина неуронских мрежа и других аспеката. Међутим, треба посветити више пажње прогнозама за регион и групу постројења, дужим хоризонтима, пробабилистичком и сценаријском прогнозирању, а посебно избору улазних обележја и оптимизацији хиперпараметара.

Главни фокус овог истраживања био је на коришћењу метахеуристичких алгоритама за оптимизацију хиперпараметара LSTM модела са и без пажње, да би се подржало прецизно прогнозирање производње фотонапонске енергије. Овим истраживањем попуњава се тај недостатак уочен у актуелној литератури у вези са посматраном облашћу.

За потребе овог истраживања, осмишљена је нова варијанта добро познатог PSO алгорита и прилагођена за дати проблем прогнозирања. Нови алгоритам назван је оптимизација роја честица вођена разноликошћу (енгл. *Diversity-Guided PSO – DGPSO*) и употребљен је за подешавање хиперпараметара LSTM мрежа за задатак предвиђања фотонапонске производње. Спроведени су свеобухватни експерименти уз примену података из стварног света и детаљну упоредну анализу у односу на друге напредне метахеуристичке алгоритме.

У овом истраживању коришћен је јавно доступан скуп података о фотонапонској производњи који се састоји од мерења из две електране у Индији, као и додатни скуп података прикупљен из мање фотонапонске електране на крову Института „Михајло Пупин” (ИМП) у Београду. Модели са најбољим перформансама постигли су одличне вредности нормализоване средње квадратне грешке ($nMSE$) од само 0,007297 за индијску електрану 1, 0,007662 за индијску електрану 2 и 0,001812 за електрану у ИМП-у, што указује на значајну применљивост предложеног приступа у стварном свету.

Кроз 6 експеримената (за сваку од 3 електране оптимизовани су LSTM и LSTM-ATT модели) упоређене су перформансе новог DGPSO алгоритма са 7 познатих метахеуристичких. У свих 6 експеримената, модели оптимизовани предложеним DGPSO алгоритмом остварили су најбоље вредности нормализоване функције циља ($nMSE$) и индикаторске функције (R^2) за најбоља извршења. У 3 од 6 експеримената, модели оптимизовани предложеним алгоритмом остварили су и најбоље вредности $nMAE$, што је врло добро с обзиром на познату особину да модел обучен помоћу MSE често не даје најбољу вредност MAE, и обрнуто. Међутим, само у 1 експерименту остварили су најбољу вредност IoA, чиме се поново потврђује да ниједна метода не може бити најбоља у свим ситуацијама и за све метрике.

У сваком случају, нови DGPSO алгоритам показао је изванредне резултате за најбоља извршења, као и одличну конвергенцију. Међутим, што се тиче осталих статистичких показатеља у вези са оствареним вредностима функције циља, нови алгоритам није се истакао. Постоји очигледна потреба да се додатним модификацијама побољша стабилност резултата тог алгоритма, и то ће бити један од праваца у будућим истраживањима.

У сваком од 6 експеримената, помоћу најбољих креираних модела извршена су предвиђања на подскуповима за тестирање, и то за 1, 2 и 3 корака унапред. Од тих 18 ситуација предвиђања, модели оптимизовани новим DGPSO алгоритмом били су најбољи у 6, што је убедљиво највише од свих посматраних метахеуристичких алгоритама. Осим тога, остварили су најбоље укупне резултате. Због стохастичке природе метахеуристичких алгоритама, сасвим је очекивано да се различити алгоритми истакну у различитим ситуацијама.

Модели са најбољим перформансама додатно су тестирани на ESP32 микроконтролеру, уз симулацију извршења помоћу UART терминала. Модели су показали конзистентне перформансе уз минимално кашњење. Примена таквих модела директно на локацији где су потребни могла би смањити трошкове мрежне инфраструктуре у будућности и омогућити интеграцију локалних функционалности, као што су побољшано управљање понудом и потражњом и упозорења о критичним ситуацијама.

Ово истраживање суочило се са неколико ограничења, пре свега са ограниченом величином популације додељене метахеуристичким алгоритмима, као и ограниченим бројем итерација по извршењу, што је било неопходно због великог броја експеримената, високих рачунских захтева и трајања. Као последица тих ограничења, остварене вредности коефицијента детерминације R^2 ниже су од очекиваних, али још увек врло добре.

Циљеви будућих активности и даљих истраживања, осим већ споменуте потребе да се побољша стабилност резултата предложеног метахеуристичког алгоритма, биће проширење примене предложене методологије, испитивање додатних алгоритама, као и даље унапређење експерименталног оквира. Један од кључних праваца даљих истраживања биће и унапређење примене у TinyML окружењу, као што је имплементација ажурирања модела у реалном времену, интеграција бежичних сензорских мрежа и Интернета ствари, а такође и развој дистрибуираних система предвиђања за различите обновљиве изворе енергије као што су енергија ветра, хидроелектране и соларна енергија. Осим тога, биће испитан утицај шума у улазним подацима, као и недостајућих података, на метрике остварене помоћу модела обучених предложеним алгоритмом. С обзиром на споменута ограничења, биће испитано понашање предложеног алгоритма са већом популацијом и већим бројем итерација по извршењу. Такође, на основу најбољих вредности изабраних током експеримената, види се да би било добро испитати понашање алгоритма са ширим границама претраге, нарочито за број ћелија по слоју LSTM мреже. Може се испитати и решавање посматраног проблема помоћу других метода прогнозирања (нпр. MLP мрежа), других функција циља (нпр. MAE) и сл.

Следи збирни приказ научних доприноса остварених овим истраживањем:

- Извршен је детаљан преглед и анализа актуелне литературе у вези са прогнозирањем производње електричне енергије у фотонапонским електранама, која се у овом истраживању посматра као пример индустријске производње. Постојећи модели машинског учења и друге технике анализирани су у односу на више релевантних чинилаца.
- Креиран је нови скуп података на основу сирових података из индустријске производње, који може бити коришћен и у другим сличним истраживањима. Нови скуп података употребљен је у експериментима упоредо са јавно доступним скупом података.
- На основу анализе недостатака основног PSO алгоритма креиран је нови, модификовани метахеуристички алгоритам за оптимизацију хиперпараметара модела машинског учења, који може бити коришћен и у другим областима у којима се примењује машинско учење.
- Перформансе новог алгоритма упоређене су са 7 познатих метахеуристичких кроз 6 експеримената оптимизације хиперпараметара. Компаративна анализа резултата показала

је да нови алгоритам производи најбоље вредности метрика за најбоља извршења, као и да снажно конвергира. Тиме је потврђено да је новим алгоритмом унапређено решавање посматраног проблема помоћу модела машинског учења.

На крају треба још једном истаћи да су модели оптимизовани предложеним метахеуристичким алгоритмом у свих 6 експеримената остварили најбољу вредност функције циља и индикаторске функције за најбоља извршења. Тиме је експериментално показано да је могуће направити метахеуристички алгоритам за оптимизацију хиперпараметара модела машинског учења за прогнозу фотонапонске производње који би унапредио прецизност постојећих метода. На тај начин дат је потврдан одговор на главно питање којим се бавило ово истраживање.

Литература

- [1] C. Scott, M. Ahsan, and A. Albarbar, "Machine learning for forecasting a photovoltaic (PV) generation system," *Energy*, vol. 278, Sep. 2023, Art. no. 127807.
- [2] M. Konstantinou, S. Peratikou, and A. G. Charalambides, "Solar photovoltaic forecasting of power output using LSTM networks," *Atmosphere*, vol. 12, no. 1, p. 124, Jan. 2021.
- [3] X. Luo, D. Zhang, and X. Zhu, "Deep learning based forecasting of photovoltaic power generation by incorporating domain knowledge," *Energy*, vol. 225, Jun. 2021, Art. no. 120240.
- [4] D. Markovics and M. J. Mayer, "Comparison of machine learning methods for photovoltaic power forecasting based on numerical weather prediction," *Renew. Sustain. Energy Rev.*, vol. 161, Jun. 2022, Art. no. 112364.
- [5] Y. Li, L. Song, S. Zhang, L. Kraus, T. Adcox, R. Willardson, A. Komandur, and N. Lu, "A TCN-based hybrid forecasting framework for hours-ahead utility-scale PV forecasting," *IEEE Trans. Smart Grid*, vol. 14, no. 5, pp. 4073-4085, Sep. 2023.
- [6] A. Abdellatif, H. Mubarak, S. Ahmad, T. Ahmed, G. M. Shafiullah, A. Hammoudeh, H. Abdellatef, M. M. Rahman, and H. M. Ghenni, "Forecasting photovoltaic power generation with a stacking ensemble model," *Sustainability*, vol. 14, no. 17, Sep. 2022, Art. no. 11083.
- [7] M. Pierro, D. Gentili, F. R. Liolli, C. Cornaro, D. Moser, A. Betti, M. Moschella, E. Collino, D. Ronzio, and D. van der Meer, "Progress in regional PV power forecasting: A sensitivity analysis on the Italian case study," *Renew. Energy*, vol. 189, pp. 983-996, Apr. 2022.
- [8] D.-S. Lee and S.-Y. Son, "PV forecasting model development and impact assessment via imputation of missing PV Power Data," *IEEE Access*, vol. 12, pp. 12843-12852, 2024.
- [9] M. S. Hossain and H. Mahmood, "Short-term photovoltaic power forecasting using an LSTM neural network and synthetic weather forecast," *IEEE Access*, vol. 8, pp. 172524-172533, 2020.
- [10] K. Mahmud, S. Azam, A. Karim, S. Zobaed, B. Shanmugam, and D. Mathur, "Machine learning based PV power generation forecasting in Alice Springs," *IEEE Access*, vol. 9, pp. 46117-46128, 2021.
- [11] G. Li, S. Xie, B. Wang, J. Xin, Y. Li, and S. Du, "Photovoltaic power forecasting with a hybrid deep learning approach," *IEEE Access*, vol. 8, pp. 175871-175880, 2020.
- [12] S. Theocharides, G. Makrides, A. Livala, M. Theristis, P. Kaimakis, and G. E. Georghiou, "Day-ahead photovoltaic power production forecasting methodology based on machine learning and statistical post-processing," *Appl. Energy*, vol. 268, Jun. 2020, Art. no. 115023.
- [13] C. Brester, V. Kallio-Myers, A. V. Lindfors, M. Kolehmainen, and H. Niska, "Evaluating neural network models in site-specific solar PV forecasting using numerical weather prediction data and weather observations," *Renew. Energy*, vol. 207, pp. 266-274, May 2023.
- [14] M. Wang, J. Peng, Y. Luo, Z. Shen, and H. Yang, "Comparison of different simplistic prediction models for forecasting PV power output: assessment with experimental measurements," *Energy*, vol. 224, Jun. 2021, Art. no. 120162.
- [15] M. J. Mayer and D. Yang, "Pairing ensemble numerical weather prediction with ensemble physical model chain for probabilistic photovoltaic power forecasting," *Renew. Sustain. Energy Rev.*, vol. 175, Apr. 2023, Art. no. 113171.
- [16] H. Sharadga, S. Hajimirza, and R. Balog, "Time series forecasting of solar power generation for large-scale photovoltaic plants," *Renew. Energy*, vol. 150, pp. 797-807, May 2020.
- [17] Y. Essam, A. N. Ahmed, R. Ramli, K.-W. Chau, M. S. I. Ibrahim, M. Sherif, A. Sefelnasr, and A. El-Shafie, "Investigating photovoltaic solar power output forecasting using machine learning algorithms," *Eng. Appl. Comput. Fluid Mech.*, vol. 16, no. 1, pp. 2002-2034, 2022.
- [18] M. J. Mayer, "Benefits of physical and machine learning hybridization for photovoltaic power forecasting," *Renew. Sustain. Energy Rev.*, vol. 168, Oct. 2022, Art. no. 112772.

- [19] M. Kuzlu, U. Cali, V. Sharma, and Ö. Güler, "Gaining insight into solar photovoltaic power generation forecasting utilizing explainable artificial intelligence tools," *IEEE Access*, vol. 8, pp. 187814-187823, 2020.
- [20] Q. Li, Y. Xu, B. S. H. Chew, H. Ding, and G. Zhao, "An integrated missing-data tolerant model for probabilistic PV power generation forecasting," *IEEE Trans. Power Syst.*, vol. 37, no. 6, pp. 4447-4459, Nov. 2022.
- [21] J. Yan, L. Hu, Z. Zhen, F. Wang, G. Qiu, Y. Li, L. Yao, M. Shafie-khah, and J. P. S. Catalão, "Frequency-domain decomposition and deep learning based solar PV power ultra-short-term forecasting model," *IEEE Trans. Ind. Appl.*, vol. 57, no. 4, pp. 3282-3295, 2021.
- [22] F. Harrou, F. Kadri, and Y. Sun, "Forecasting of photovoltaic solar power production using LSTM approach," in *Advanced Statistical Modeling, Forecasting, and Fault Detection in Renewable Energy Systems*. London, United Kingdom: IntechOpen, 2020, pp. 3-18.
- [23] W. Khan, S. Walker, and W. Zeiler, "Improved solar photovoltaic energy generation forecast using deep learning-based ensemble stacking approach," *Energy*, vol. 240, Feb. 2022, Art. no. 122812.
- [24] M. N. Akhter, S. Mekhilef, H. Mokhlis, Z. M. Almohaimeed, M. A. Muhammad, A. S. M. Khairuddin, R. Akram, and M. M. Hussain, "An hour-ahead PV power forecasting method based on an RNN-LSTM model for three different PV plants," *Energies*, vol. 15, no. 6, Mar. 2022, Art. no. 2243.
- [25] J. Simeunović, B. Schubnel, P.-J. Alet, and R. E. Carrillo, "Spatio-temporal graph neural networks for multi-site PV power forecasting," *IEEE Trans. Sustain. Energy*, vol. 13, no. 2, pp. 1210-1220, Apr. 2022.
- [26] Y. Nie, X. Li, A. Scott, Y. Sun, V. Venugopal, and A. Brandt, "SKIPP'D: A SKy Images and Photovoltaic Power generation Dataset for short-term solar forecasting," *Sol. Energy*, vol. 255, pp. 171-179, May 2023.
- [27] Y. Dai, Y. Wang, X. Yang, and Q. Zhou, "LOWESS smoothing and random forest based GRU model: A short-term photovoltaic power generation forecasting method," *Energy*, vol. 256, Oct. 2022, Art. no. 124661.
- [28] H. Li, Z. Ren, Y. Xu, W. Li, and B. Hu, "A multi-data driven hybrid learning method for weekly photovoltaic power scenario forecast," *IEEE Trans. Sustain. Energy*, vol. 13, no. 1, pp. 91-100, Jan. 2022.
- [29] M. AlShafeey and C. Csáki, "Evaluating neural network and linear regression photovoltaic power forecasting models based on different input methods," *Energy Rep.*, vol. 7, pp. 7601-7614, Nov. 2021.
- [30] X. Liu, Y. Liu, X. Kong, L. Ma, A. H. Besheer, and K. Y. Lee, "Deep neural network for forecasting of photovoltaic power based on wavelet packet decomposition with similar day analysis," *Energy*, vol. 271, May 2023, Art. no. 126963.
- [31] F. Wang, X. Lu, S. Mei, Y. Su, Z. Zhen, Z. Zou, X. Zhang, R. Yin, N. Duić, M. Shafie-khah, and J. P. S. Catalão, "A satellite image data based ultra-short-term solar PV power forecasting method considering cloud information from neighboring plant," *Energy*, vol. 238, Jan. 2022, Art. no. 121946.
- [32] V. Suresh, P. Janik, J. Rezmer, and Z. Leonowicz, "Forecasting solar PV output using convolutional neural networks with a sliding window algorithm," *Energies*, vol. 13, no. 3, Feb. 2020, Art. no. 723.
- [33] M. López Santos, X. García-Santiago, F. Echevarría Camarero, G. Blázquez Gil, and P. Carrasco Ortega, "Application of temporal fusion transformer for day-ahead PV power forecasting," *Energies*, vol. 15, no. 14, Jul. 2022, Art. no. 5232.
- [34] J. Sharma, S. Soni, P. Paliwal, S. Saboor, P. K. Chaurasiya, M. Sharifpur, N. Khalilpoor, and A. Afzal, "A novel long term solar photovoltaic power forecasting approach using LSTM with Nadam optimizer: A case study of India," *Energy Sci. Eng.*, vol. 10, pp. 2909-2929, 2022.

- [35] A. Dairi, F. Harrou, Y. Sun, and S. Khadraoui, "Short-term forecasting of photovoltaic solar power production using variational auto-encoder driven deep learning approach," *Appl. Sci.*, vol. 10, no. 23, Dec. 2020, Art. no. 8400.
- [36] D. K. Dhaked, S. Dadhich, and D. Birla, "Power output forecasting of solar photovoltaic plant using LSTM," *Green Energy Intell. Transp.*, vol. 2, no. 5, Oct. 2023, Art. no. 100113.
- [37] W. Zhuang, Z. Li, Y. Wang, Q. Xi, and M. Xia, "GCN-Informer: A novel framework for mid-term photovoltaic power forecasting," *Appl. Sci.*, vol. 14, no. 5, Mar. 2024, Art. no. 2181.
- [38] L. Visser, T. AlSkaif, and W. van Sark, "Operational day-ahead solar power forecasting for aggregated PV systems with a varying spatial distribution," *Renew. Energy*, vol. 183, pp. 267-282, Jan. 2022.
- [39] Y. Cao, G. Liu, D. Luo, D. P. Bavirisetti, and G. Xiao, "Multi-timescale photovoltaic power forecasting using an improved Stacking ensemble algorithm based LSTM-Informer model," *Energy*, vol. 283, Nov. 2023, Art. no. 128669.
- [40] S. Netsanet, Z. Dehua, Z. Wei, and G. Teshager, "Short-term PV power forecasting using variational mode decomposition integrated with Ant colony optimization and neural network," *Energy Rep.*, vol. 8, pp. 2022-2035, Nov. 2022.
- [41] S. Xu, R. Zhang, H. Ma, C. Ekanayake, and Y. Cui, "On vision transformer for ultra-short-term forecasting of photovoltaic generation using sky images," *Sol. Energy*, vol. 267, Jan. 2024, Art. no. 112203.
- [42] M. Massaoudi, I. Chihi, L. Sidhom, M. Trabelsi, S. S. Refaat, H. Abu-Rub, and F. S. Oueslati, "An effective hybrid NARX-LSTM model for point and interval PV power forecasting," *IEEE Access*, vol. 9, pp. 36571-36588, 2021.
- [43] R. Khelifi, M. Guermoui, A. Rabehi, A. Taallah, A. Zoukel, S. S. M. Ghoneim, M. Bajaj, K. M. AboRas, and I. Zaitsev, "Short-term PV power forecasting using a hybrid TVF-EMD-ELM strategy," *Int. Trans. Electr. Energy Syst.*, 2023, Art. no. 6413716.
- [44] X. Xiang, X. Li, Y. Zhang, and J. Hu, "A short-term forecasting method for photovoltaic power generation based on the TCN-ECANet-GRU hybrid model," *Sci. Rep.*, vol. 14, 2024, Art. no. 6744.
- [45] Y. Wang, W. Fu, X. Zhang, Z. Zhen, and F. Wang, "Dynamic directed graph convolution network based ultra-short-term forecasting method of distributed photovoltaic power to enhance the resilience and flexibility of distribution network," *IET Gener., Transmiss. Distrib.*, vol. 18, no. 2, pp. 337-352, Jan. 2024.
- [46] A. Ait Mansour, A. Tilioua, and M. Touzani, "Bi-LSTM, GRU and 1D-CNN models for short-term photovoltaic panel efficiency forecasting case amorphous silicon grid-connected PV system," *Results Eng.*, vol. 21, Mar. 2024, Art. no. 101886.
- [47] X. Luo, D. Zhang, and X. Zhu, "Combining transfer learning and constrained long short-term memory for power generation forecasting of newly-constructed photovoltaic plants," *Renew. Energy*, vol. 185, pp. 1062-1077, Feb. 2022.
- [48] D. V. Pombo, P. Bacher, C. Ziras, H. W. Bindner, S. V. Spataru, and P. E. Sørensen, "Benchmarking physics-informed machine learning-based short term PV-power forecasting tools," *Energy Rep.*, vol. 8, pp. 6512-6520, Nov. 2022.
- [49] E. Sarmas, E. Spiliotis, E. Stamatopoulos, V. Marinakis, and H. Doukas, "Short-term photovoltaic power forecasting using meta-learning and numerical weather prediction independent Long Short-Term Memory models," *Renew. Energy*, vol. 216, Nov. 2023, Art. no. 118997.
- [50] M. S. Ibrahim, S. M. Gharghory, and H. A. Kamal, "A hybrid model of CNN and LSTM autoencoder-based short-term PV power generation forecasting," *Electr. Eng.*, vol. 106, pp. 4239-4255, 2024.
- [51] Australian Space Weather Forecasting Centre, "The sun and solar activity: The solar constant," *Bureau of Meteorology, Australian Government*. Accessed: Nov. 9, 2025. [Online]. Available: <https://www.sws.bom.gov.au/Educational/2/1/12>

- [52] "Growth of photovoltaics," in *Wikipedia: The Free Encyclopedia*. Accessed: Nov. 9, 2025. [Online]. Available: https://en.wikipedia.org/wiki/Growth_of_photovoltaics
- [53] SolarVision, "Global solar capacity to surpass 3 terawatts by 2025," Nov. 2024. Accessed: Nov. 9, 2025. [Online]. Available: <https://solarvision.org/global-solar-capacity-to-surpass-3-terawatts-by-2025/>
- [54] European Parliament and Council of the European Union, "Directive (EU) 2023/2413 of the European Parliament and of the Council of 18 October 2023," *Official Journal of the European Union*, Oct. 18, 2023. Accessed: Nov. 9, 2025. [Online]. Available: <https://eur-lex.europa.eu/eli/dir/2023/2413/oj>
- [55] European Commission, "Renewable energy directive," *Energy Efficiency and Renewables*. Accessed: Nov. 9, 2025. [Online]. Available: https://energy.ec.europa.eu/topics/renewable-energy/renewable-energy-directive-targets-and-rules/renewable-energy-directive_en
- [56] International Renewable Energy Agency (IRENA), *Global Energy Transformation: A Roadmap to 2050 (2019 Edition)*. Abu Dhabi, UAE: IRENA, 2019. Accessed: Nov. 9, 2025. [Online]. Available: www.irena.org
- [57] A. Stojkovic, B. Nikolic, M. Zivkovic, and N. Bacanin, "Photovoltaic farm production forecasting: Modified metaheuristic optimized long short-term memory-based networks approach," *IEEE Access*, vol. 13, pp. 25198-25222, 2025.
- [58] N. Bacanin, C. Stoean, M. Zivkovic, M. Rakic, R. Strulak-Wójcikiewicz, and R. Stoean, "On the benefits of using metaheuristics in the hyperparameter tuning of deep learning models for energy load forecasting," *Energies*, vol. 16, no. 3, p. 1434, Feb. 2023.
- [59] M. Salb, L. Jovanovic, A. Elsadai, N. Bacanin, V. Simic, D. Pamucar, and M. Zivkovic, "Cloud spot instance price forecasting multi-headed models tuned using modified PSO," *J. King Saud Univ.-Sci.*, vol. 36, no. 11, Dec. 2024, Art. no. 103473.
- [60] D. Shah, "Activation functions in neural networks," *Medium*, Aug. 24, 2017. Accessed: Oct. 29, 2025. [Online]. Available: <https://medium.com/@devalshah1619/activation-functions-in-neural-networks-58115cda9c96>
- [61] "Softmax function," in *Wikipedia: The Free Encyclopedia*. Accessed: Oct. 28, 2025. [Online]. Available: https://en.wikipedia.org/wiki/Softmax_function
- [62] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," in *Proc. 3rd Int. Conf. Learn. Represent. (ICLR)*, San Diego, CA, USA, May 2015.
- [63] T. Dozat, "Incorporating Nesterov momentum into Adam," in *Proc. 4th Int. Conf. Learn. Represent. (ICLR)*, San Juan, Puerto Rico, May 2016.
- [64] S. Ruder, "An overview of gradient descent optimization algorithms," 2016, *arXiv:1609.04747*. [Online]. Available: arxiv.org
- [65] "What is a loss function?" *IBM Think*, Aug. 1, 2024. Accessed: Oct. 30, 2025. [Online]. Available: <https://www.ibm.com/think/topics/loss-function>
- [66] M. N. Akhter, S. Mekhilef, H. Mokhlis, and N. M. Shah, "Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques," *IET Renew. Power Gener.*, vol. 13, no. 7, pp. 1009-1023, May 2019.
- [67] S. M. Miraftebadeh and M. Longo, "High-resolution PV power prediction model based on the deep learning and attention mechanism," *Sustain. Energy, Grids Netw.*, vol. 34, Jun. 2023, Art. no. 101025.
- [68] L. Wang, M. Mao, J. Xie, Z. Liao, H. Zhang, and H. Li, "Accurate solar PV power prediction interval method based on frequency-domain decomposition and LSTM model," *Energy*, vol. 262, Jan. 2023, Art. no. 125592.
- [69] J. Ospina, A. Newaz, and M. O. Faruque, "Forecasting of PV plant output using hybrid wavelet-based LSTM-DNN structure model," *IET Renew. Power Gener.*, vol. 13, no. 7, pp. 1087-1095, May 2019.
- [70] W.-C. Tsai, C.-S. Tu, C.-M. Hong, and W.-M. Lin, "A review of state-of-the-art and short-term forecasting models for solar PV power generation," *Energies*, vol. 16, no. 14, p. 5436, Jul. 2023.

- [71] S. S. Chandel, A. Gupta, R. Chandel, and S. Tajjour, "Review of deep learning techniques for power generation prediction of industrial solar photovoltaic plants," *Sol. Compass*, vol. 8, Dec. 2023, Art. no. 100061.
- [72] T. Polasek and M. Čadík, "Predicting photovoltaic power production using high-uncertainty weather forecasts," *Appl. Energy*, vol. 339, Jun. 2023, Art. no. 120989.
- [73] V. Prema, M. S. Bhaskar, D. Almahles, N. Gowtham, and K. U. Rao, "Critical review of data, models and performance metrics for wind and solar power forecast," *IEEE Access*, vol. 10, pp. 667-688, 2022.
- [74] S. Feron, R. R. Cordero, A. Damiani, and R. B. Jackson, "Climate change extremes and photovoltaic power output," *Nature Sustainability*, vol. 4, no. 3, pp. 270-276, Nov. 2020.
- [75] B. Zazoum, "Solar photovoltaic power prediction using different machine learning methods," *Energy Rep.*, vol. 8, pp. 19-25, Apr. 2022.
- [76] R. Ahmed, V. Sreeram, Y. Mishra, and M. D. Arif, "A review and evaluation of the state-of-the-art in PV solar power forecasting: Techniques and optimization," *Renew. Sustain. Energy Rev.*, vol. 124, May 2020, Art. no. 109792.
- [77] D. H. Wolpert and W. G. Macready, "No free lunch theorems for optimization," *IEEE Trans. Evol. Comput.*, vol. 1, no. 1, pp. 67-82, Apr. 1997.
- [78] B. Akay, D. Karaboga, and R. Akay, "A comprehensive survey on optimizing deep learning models by metaheuristics," *Artif. Intell. Rev.*, vol. 55, no. 2, pp. 829-894, Feb. 2022.
- [79] M. Tayebi and S. E. Kafhali, "Performance analysis of metaheuristics based hyperparameters optimization for fraud transactions detection," *Evol. Intell.*, vol. 17, no. 2, pp. 921-939, Apr. 2024.
- [80] J. Kennedy and R. C. Eberhart, "Particle swarm optimization," in *Proc. Int. Conf. Neural Netw.*, vol. 4, Nov. 2002, pp. 1942-1948.
- [81] B. Predić, L. Jovanovic, V. Simic, N. Bacanin, M. Zivkovic, P. Spalevic, N. Budimirovic, and M. Dobrojevic, "Cloud-load forecasting via decomposition-aided attention recurrent neural network tuned by modified particle swarm optimization," *Complex Intell. Syst.*, vol. 10, no. 2, pp. 2249-2269, Apr. 2024.
- [82] O. Kocak, U. Erkan, A. Toktas, and S. Gao, "PSO-based image encryption scheme using modular integrated logistic exponential map," *Expert Syst. Appl.*, vol. 237, Mar. 2024, Art. no. 121452.
- [83] O. S. T. A. Butti, M. Burunkaya, J. Rahebi, and J. M. Lopez-Guede, "Optimal power flow using PSO algorithms based on artificial neural networks," *IEEE Access*, vol. 12, pp. 154778-154795, 2024.
- [84] C. J. Hillar and L.-H. Lim, "Most tensor problems are NP-hard," *J. ACM*, vol. 60, no. 6, pp. 1-39, Nov. 2013.
- [85] L. Velasco, H. Guerrero, and A. Hospitaler, "A literature review and critical analysis of metaheuristics recently developed," *Arch. Comput. Methods Eng.*, vol. 31, no. 1, pp. 125-146, Jan. 2024.
- [86] K. Rajwar, K. Deep, and S. Das, "An exhaustive review of the metaheuristic algorithms for search and optimization: Taxonomy, applications, and open challenges," *Artif. Intell. Rev.*, vol. 56, no. 11, pp. 13187-13257, Nov. 2023.
- [87] H. Rezk, A. G. Olabi, T. Wilberforce, and E. T. Sayed, "A comprehensive review and application of metaheuristics in solving the optimal parameter identification problems," *Sustainability*, vol. 15, no. 7, p. 5732, Mar. 2023.
- [88] M. Dorigo, M. Birattari, and T. Stützle, "Ant colony optimization," *IEEE Comput. Intell. Mag.*, vol. 1, no. 4, pp. 28-39, Nov. 2006.
- [89] N. Mladenović and P. Hansen, "Variable neighborhood search," *Comput. Oper. Res.*, vol. 24, no. 11, pp. 1097-1100, Nov. 1997.
- [90] X. Wang and L. Tang, "A population-based variable neighborhood search for the single machine total weighted tardiness problem," *Comput. Oper. Res.*, vol. 36, no. 6, pp. 2105-2110, Jun. 2009.

- [91] D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: Artificial bee colony (ABC) algorithm," *J. Global Optim.*, vol. 39, no. 3, pp. 459-471, Oct. 2007.
- [92] X. S. Yang and X. He, "Firefly algorithm: Recent advances and applications," *Int. J. Swarm Intell.*, vol. 1, no. 1, p. 36, 2013.
- [93] J. Bai, Y. Li, M. Zheng, S. Khatir, B. Benaissa, L. Abualigah, and M. A. Wahab, "A sinh cosh optimizer," *Knowl.-Based Syst.*, vol. 282, Dec. 2023, Art. no. 111081.
- [94] L. Abualigah, M. A. Elaziz, P. Sumari, Z. W. Geem, and A. H. Gandomi, "Reptile search algorithm (RSA): A nature-inspired meta-heuristic optimizer," *Expert Syst. Appl.*, vol. 191, Apr. 2022, Art. no. 116158.
- [95] D. Połap and M. Woźniak, "Red fox optimization algorithm," *Expert Syst. Appl.*, vol. 166, Mar. 2021, Art. no. 114107.
- [96] N. Bacanin, A. Petrovic, L. Jovanovic, M. Zivkovic, T. Zivkovic, and M. Sarac, "Parkinson's disease induced gain freezing detection using gated recurrent units optimized by modified crayfish optimization algorithm," in *Proc. 5th Int. Conf. Mobile Comput. Sustain. Informat. (ICMCSI)*, Jan. 2024, pp. 1-8.
- [97] N. Bacanin, L. Jovanovic, M. Zivkovic, T. Zivkovic, P. Bisevac, M. Dobrojevic, M. Sarac, and M. Antonijevic, "Parkinson's disease detection with deep long short-term memory networks optimized by modified metaheuristic algorithm," in *Collective Intelligence*. Boca Raton, FL, USA: CRC Press, 2024, pp. 204-229.
- [98] M. Dobrojevic, L. Jovanovic, L. Babic, M. Cajic, T. Zivkovic, M. Zivkovic, S. Muthusamy, M. Antonijevic, and N. Bacanin, "Cyberbullying sexism harassment identification by metaheuristics-tuned eXtreme gradient boosting," *Comput., Mater. Continua*, vol. 80, no. 3, pp. 4997-5027, 2024.
- [99] S. Saroja and S. Haseena, "A metaheuristic harmony search optimization-based approach for hateful and offensive speech detection in social media," in *Computational Intelligence Methods for Sentiment Analysis in Natural Language Processing Applications*. Amsterdam, The Netherlands: Elsevier, 2024, pp. 251-264.
- [100] D. Mladenovic, M. Antonijevic, L. Jovanovic, V. Simic, M. Zivkovic, N. Bacanin, T. Zivkovic, and J. Perisic, "Sentiment classification for insider threat identification using metaheuristic optimized machine learning classifiers," *Sci. Rep.*, vol. 14, no. 1, p. 25731, Oct. 2024.
- [101] K. Zhu, S. Ying, N. Zhang, and D. Zhu, "Software defect prediction based on enhanced metaheuristic feature selection optimization and a hybrid deep neural network," *J. Syst. Softw.*, vol. 180, Oct. 2021, Art. no. 111026.
- [102] T. Zivkovic, B. Nikolic, V. Simic, D. Pamucar, and N. Bacanin, "Software defects prediction by metaheuristics tuned extreme gradient boosting and analysis based on Shapley additive explanations," *Appl. Soft Comput.*, vol. 146, Oct. 2023, Art. no. 110659.
- [103] N. Bacanin, L. Jovanovic, M. Djordjevic, A. Petrovic, T. Zivkovic, M. Zivkovic, and M. Antonijevic, "Crop yield forecasting based on echo state network tuned by crayfish optimization algorithm," in *Proc. IEEE Int. Conf. Contemp. Comput. Commun. (InC4)*, Mar. 2024, pp. 1-6.
- [104] L. Jovanovic, M. Zivkovic, N. Bacanin, M. Dobrojevic, V. Simic, K. K. Sadasivuni, and E. B. Tirkolaee, "Evaluating the performance of metaheuristic-tuned weight agnostic neural networks for crop yield prediction," *Neural Comput. Appl.*, vol. 36, no. 24, pp. 14727-14756, Aug. 2024.
- [105] L. Jovanovic, K. Kumpf, N. Bačanin, M. Antonijević, J. Mani, H. Shaker, and M. Živković, "Decomposition aided bidirectional long short-term memory optimized by hybrid metaheuristic applied for wind power forecasting," in *Proc. Int. Conf. Comput. Sci. Sustain. Technol.* Cham, Switzerland: Springer, Jan. 2024, pp. 30-42.
- [106] S. Petrović, V. Mizdraković, M. Kljajić, L. Jovanovic, M. Živković, and N. Bačanin, "Employing tuned VMD-based long short-term memory neural network for household power

- consumption forecast,” in *Proc. Congr. Control, Robot., Mechatronics*. Cham, Switzerland: Springer, Nov. 2023, pp. 357-371.
- [107] W. Luo, X. Lin, C. Li, S. Yang, and Y. Shi, “Benchmark functions for CEC 2022 competition on seeking multiple optima in dynamic environments,” 2022, *arXiv:2201.00523*.
- [108] S. Rahnamayan, H. R. Tizhoosh, and M. M. A. Salama, “Quasioppositional differential evolution,” in *Proc. IEEE Congr. Evol. Comput.*, Sep. 2007, pp. 2229-2236.
- [109] S. Cheng and Y. Shi, “Diversity control in particle swarm optimization,” in *Proc. IEEE Symp. Swarm Intell.*, Apr. 2011, pp. 1-9.
- [110] S. Mirjalili, “Genetic algorithm,” in *Evolutionary Algorithms and Neural Networks*. Cham, Switzerland: Springer, 2019, ch. 4, pp. 43-55.
- [111] M. Khishe and M. R. Mosavi, “Chimp optimization algorithm,” *Expert Syst. Appl.*, vol. 149, Jul. 2020, Art. no. 113338.
- [112] J. Gurrola-Ramos, A. Hernández-Aguirre, and O. Dalmau-Cedeño, “COLSHADE for real-world single-objective constrained optimization problems,” in *Proc. IEEE Congr. Evol. Comput. (CEC)*, Jul. 2020, pp. 1-8.
- [113] A. V. Tatachar, “Comparative assessment of regression models based on model evaluation metrics,” *Int. J. Innov. Technol. Exploring Eng.*, vol. 8, no. 9, pp. 853-860, 2021.
- [114] C. J. Willmott, S. M. Robeson, and K. Matsuura, “A refined index of model performance,” *Int. J. Climatol.*, vol. 32, no. 13, pp. 2088-2094, Nov. 2012.
- [115] M. F. Bear, B. W. Connors, and M. A. Paradiso, *Neuroscience: Exploring the Brain*, 4th ed. Philadelphia, PA, USA: Wolters Kluwer, 2016.
- [116] J. Brownlee, *Long Short-Term Memory Networks with Python: Develop Sequence Prediction Models with Deep Learning*. Machine Learning Mastery, 2017.
- [117] P. Bruce, A. Bruce, and P. Gedeck, *Practical Statistics for Data Scientists*, 2nd ed. Sebastopol, CA, USA: O’Reilly Media, Inc., 2020.
- [118] T. Chai and R. R. Draxler, “Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature,” *Geosci. Model Dev.*, vol. 7, pp. 1247-1250, 2014.
- [119] A. Géron, *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd ed. Sebastopol, CA, USA: O’Reilly Media, Inc., 2019.
- [120] B. C. Gupta, I. Guttman, and K. P. Jayalath, *Statistics and Probability with Applications for Engineers and Scientists Using MINITAB, R and JMP*, 2nd ed. Hoboken, NJ, USA: Wiley, 2020.
- [121] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2009.
- [122] S. Hochreiter and J. Schmidhuber, “Long short-term memory,” *Neural Comput.*, vol. 9, no. 8, pp. 1735-1780, Nov. 1997.
- [123] S. C. Welch, “Neural networks demystified [part 1: data and architecture],” *Welch Labs via YouTube*, Oct. 5, 2014. Accessed: Mar. 24, 2024. [Online Video]. Available: <https://www.youtube.com/watch?v=bxe2T-V8XR8>
- [124] W. C. Navidi, *Statistics for Engineers and Scientists*, 3rd ed. New York, NY, USA: McGraw-Hill, 2010.
- [125] C. Olah, “Understanding LSTM networks,” *Christopher Olah's Blog*, Aug. 27, 2015. Accessed: Mar. 24, 2024. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [126] H. Ritchie, P. Rosado, and M. Roser, “Energy production and consumption,” *Our World in Data*, 2020. Accessed: Mar. 22, 2024. [Online]. Available: <https://ourworldindata.org/energy-production-consumption>
- [127] M. Milovanović, “Nervni sistem 1 – opšta neurofiziologija,” *FASPER, University of Belgrade*, 2016. Accessed: Mar. 24, 2024. [Online]. Available: https://www.fasper.bg.ac.rs/do2016/nastavnici/Milovanovic_Maja/predavanja/5%20-%20Nervni%20sistem%201%20-%20opsta%20neurofiziologija.pdf

- [128] “Deskriptivna statistika,” *Faculty of Economics, University of Novi Sad*, Jan. 10, 2020. Accessed: Mar. 9, 2024. [Online]. Available: <https://www.ef.uns.ac.rs/predmeti/oas/statistika/2020-01-10-des-deskriptivna-statistika.pdf>
- [129] S. Radu, “Frequency distribution: Types and importance,” *Nave Blog*, Nov. 25, 2020. Accessed: Mar. 22, 2024. [Online]. Available: <https://getnave.com/blog/frequency-distribution-types/>
- [130] StatQuest with Josh Starmer, “Skewness clearly explained,” *YouTube*, Oct. 16, 2017. Accessed: Mar. 17, 2024. [Online Video]. Available: <https://www.youtube.com/watch?v=ojZPOIPemys>
- [131] S. Glen, “Pearson's coefficient of skewness,” *Statistics How To*. Accessed: Mar. 17, 2024. [Online]. Available: <https://www.statisticshowto.com/probability-and-statistics/statistics-definitions/pearsons-coefficient-of-skewness/>
- [132] “Strength of correlation,” *Academic Skills Kit, Newcastle University*. Accessed: Mar. 17, 2024. [Online]. Available: <https://www.ncl.ac.uk/webtemplate/ask-assets/external/maths-resources/statistics/regression-and-correlation/strength-of-correlation.html>
- [133] “Pearson product-moment correlation coefficient,” in *Wikipedia: The Free Encyclopedia*. Accessed: Mar. 17, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Pearson_product-moment_correlation_coefficient
- [134] “Variance inflation factor,” in *Wikipedia: The Free Encyclopedia*. Accessed: Mar. 17, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Variance_inflation_factor
- [135] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, “Learning internal representations by error propagation,” in *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol. 1, D. E. Rumelhart and J. L. McClelland, Eds. Cambridge, MA, USA: MIT Press, 1986, pp. 318-362.
- [136] Huawei Technologies Co., Ltd., *Artificial Intelligence Technology*. Singapore: Springer, 2023.
- [137] “Supervised vs. unsupervised learning,” *Google Cloud*. Accessed: Mar. 27, 2024. [Online]. Available: <https://cloud.google.com/discover/supervised-vs-unsupervised-learning>
- [138] “Types of machine learning algorithms,” *Proft.me*, Dec. 24, 2015. Accessed: Mar. 27, 2024. [Online]. Available: <https://en.proft.me/2015/12/24/types-machine-learning-algorithms/>
- [139] M. Castelli, L. Vanneschi, and Á. R. Largo, “Supervised learning: Classification,” in *Encyclopedia of Bioinformatics and Computational Biology*, vol. 1. Oxford, U.K.: Academic Press, 2019, pp. 342-349.
- [140] N. S. Ayub, M. F. Ghazali, and W. Z. Wan Ahmad, “A review on deep learning for condition monitoring of machinery: From research to practice,” *Int. J. Non-Linear Mech.*, vol. 143, p. 103984, Jul. 2022.
- [141] M. M. Forootan, I. Larki, R. Zahedi, and A. Ahmadi, “Machine learning and deep learning in energy systems: A review,” *Sustainability*, vol. 14, no. 8, p. 4832, Apr. 2022.
- [142] “Detecting multicollinearity using variance inflation factors,” *STAT462 – Applied Regression Analysis, PennState Eberly College of Science*. Accessed: Mar. 30, 2024. [Online]. Available: <https://online.stat.psu.edu/stat462/node/180/>
- [143] “Quartile,” in *Wikipedia: The Free Encyclopedia*. Accessed: Mar. 30, 2024. [Online]. Available: <https://en.wikipedia.org/wiki/Quartile>
- [144] P. M. J. Jeyaseelan, “Manual calculation of odds ratio and confidence interval using Microsoft Excel,” *J. Pharmacol. Pharmacother.*, vol. 2, no. 3, pp. 195-199, Jul.-Sep. 2011.
- [145] “Coefficient of determination,” in *Wikipedia: The Free Encyclopedia*. Accessed: Mar. 17, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Coefficient_of_determination
- [146] SolarPower Europe, “Global market outlook for solar power 2023-2027,” Jun. 13, 2023. Accessed: Mar. 31, 2024. [Online]. Available: <https://www.solarpowereurope.org/insights/outlooks/global-market-outlook-for-solar-power-2023-2027/detail>
- [147] International Renewable Energy Agency (IRENA), *Future of Solar Photovoltaic: Deployment, Investment, Technology, Grid Integration and Socio-economic Aspects*. Abu Dhabi, UAE: IRENA, 2019. Accessed: Mar. 31, 2024. [Online]. Available: <https://www.irena.org/publications/2019/Nov/Future-of-Solar-Photovoltaic>

- [148] “What is solar power forecasting?” *gridX Knowledge*. Accessed: Mar. 31, 2024. [Online]. Available: <https://www.gridx.ai/knowledge/what-is-solar-power-forecasting>
- [149] K. J. Iheanetu, “Solar photovoltaic power forecasting: A review,” *Sustainability*, vol. 14, no. 24, p. 17005, Dec. 2022.
- [150] J. W. Tukey, *Exploratory Data Analysis*. Reading, MA, USA: Addison-Wesley, 1977.
- [151] “Linear regression,” in *Wikipedia: The Free Encyclopedia*. Accessed: Apr. 7, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Linear_regression
- [152] “Yearly electricity data,” *Ember Climate*. Accessed: Apr. 14, 2024. [Online]. Available: <https://ember-climate.org/data-catalogue/yearly-electricity-data/>
- [153] “Otvorena najveća solarna elektrana u Srbiji – 9,9 megavata,” *Balkan Green Energy News*, Apr. 5, 2023. Accessed: May 18, 2024. [Online]. Available: <https://balkangreenenergynews.com/rs/otvorena-najveca-solarna-elektrana-u-srbiji-99-megavata/>
- [154] “Documentation,” *Espressif*. Accessed: May 18, 2024. [Online]. Available: <https://www.espressif.com/en/support/documents/technical-documents>
- [155] “Fintel Energija i MK Group u okviru projekta Agrosolar Kula grade najveću solarnu elektranu u Evropi snage 660 MW,” *Balkan Green Energy News*, Jul. 1, 2021. Accessed: May 18, 2024. [Online]. Available: <https://balkangreenenergynews.com/rs/fintel-energija-i-mk-group-u-okviru-projekta-agrosolar-kula-grade-najvecu-solarnu-elektranu-u-evropi-snage-660-mw/>
- [156] “Aktivni kupci – novi učesnici na tržištu,” *Elektroprivreda Srbije*, Apr. 4, 2025. Accessed: Aug. 3, 2025. [Online]. Available: <https://www.eps.rs/lat/vesti/Stranice/panel-zakon-energetica.aspx>
- [157] “OIE Srbija i BDK Advokati donose pregled ključnih izmena Zakona o energetici za OIE sektor,” *OIE Srbija*, Dec. 4, 2024. Accessed: Aug. 3, 2025. [Online]. Available: <https://oie.rs/oie-srbija-i-bdk-advokati-donose-pregled-kljucnih-izmena-zakona-o-energetici-za-oie-sektor/>
- [158] J. F. Hair, W. C. Black, B. J. Babin, and R. E. Anderson, *Multivariate Data Analysis*, 7th ed. Upper Saddle River, NJ, USA: Prentice-Hall, 2010.
- [159] R. B. Kline, *Principles and Practice of Structural Equation Modeling*, 3rd ed. New York, NY, USA: Guilford Press, 2011.
- [160] T. A. Brown, *Confirmatory Factor Analysis for Applied Research*, 2nd ed. New York, NY, USA: Guilford Press, 2015.
- [161] “Detecting multicollinearity with VIF in Python,” *GeeksforGeeks*, Jan. 8, 2024. Accessed: May 24, 2024. [Online]. Available: <https://www.geeksforgeeks.org/detecting-multicollinearity-with-vif-python/>
- [162] “Variance inflation factor,” *statsmodels v0.14.1 Documentation*. Accessed: Jun. 28, 2024. [Online]. Available: https://www.statsmodels.org/stable/generated/statsmodels.stats.outliers_influence.variance_inflation_factor.html
- [163] Republički hidrometeorološki zavod Srbije (RHMZ), “Godišnji bilten za Srbiju – 2020. godina,” 2020. Accessed: Oct. 27, 2024. [Online]. Available: <https://www.hidmet.gov.rs/data/klimatologija/latin/2020.pdf>
- [164] “Korelacija,” in *Wikipedia: The Free Encyclopedia* (in Serbian). Accessed: Dec. 29, 2024. [Online]. Available: <https://sr.wikipedia.org/sr-ec/Корелација>
- [165] “Ordinary least squares,” in *Wikipedia: The Free Encyclopedia*. Accessed: Dec. 31, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Ordinary_least_squares
- [166] “Linearna regresija,” *Mathematical Grammar School*, Belgrade, Serbia. Accessed: Jan. 7, 2025. [Online]. Available: http://ni.mg.edu.rs/static/resources/v9.0/linearna_regresija.pdf
- [167] J. He, “Interpreting linear regression through statsmodels summary,” *The Startup (Medium)*, Mar. 24, 2020. Accessed: Jan. 12, 2025. [Online]. Available: <https://medium.com/swlh/interpreting-linear-regression-through-statsmodels-summary-4796d359035a>

- [168] “Student's t-distribution,” in *Wikipedia: The Free Encyclopedia*. Accessed: Dec. 31, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Student's_t-distribution
- [169] “Student's t-test,” in *Wikipedia: The Free Encyclopedia*. Accessed: Dec. 31, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Student's_t-test
- [170] “Null hypothesis,” in *Wikipedia: The Free Encyclopedia*. Accessed: Dec. 31, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Null_hypothesis
- [171] “P-value,” in *Wikipedia: The Free Encyclopedia*. Accessed: Dec. 31, 2024. [Online]. Available: <https://en.wikipedia.org/wiki/P-value>
- [172] “T-test formula,” *Cuemath*. Accessed: Jan. 22, 2025. [Online]. Available: <https://www.cuemath.com/t-test-formula/>
- [173] “Kurtosis,” in *Wikipedia: The Free Encyclopedia*. Accessed: Jan. 22, 2025. [Online]. Available: <https://en.wikipedia.org/wiki/Kurtosis>
- [174] R. Bevans, “Kurtosis | definition, types & examples,” *Scribbr*, Mar. 6, 2023. Accessed: Jan. 22, 2025. [Online]. Available: <https://www.scribbr.com/statistics/kurtosis/>
- [175] “Box plot: A complete guide,” *Atlassian*. Accessed: Jan. 23, 2025. [Online]. Available: <https://www.atlassian.com/data/charts/box-plot-complete-guide>
- [176] “matplotlib.pyplot.boxplot,” *Matplotlib v3.8.2 Documentation*. Accessed: Jan. 23, 2025. [Online]. Available: https://matplotlib.org/stable/api/_as_gen/matplotlib.pyplot.boxplot.html
- [177] B. García and J. Orrego, “Pronóstico de potencia solar fotovoltaica mediante redes neuronales artificiales,” Undergraduate thesis, *Universidad de Antioquia*, Medellín, Colombia, 2022.
- [178] F. E. Gazaniga, “Previsão de geração de energia solar fotovoltaica utilizando redes neurais artificiais,” Final project, *Instituto Federal de Santa Catarina*, Florianópolis, Brazil, 2021.
- [179] “Energijska sunca,” *Energetski Portal*. Accessed: Jan. 29, 2025. [Online]. Available: <https://energetskiportal.rs/obnovljivi-izvori-energije/energija-sunca/>
- [180] A. Margiotta, “Short-term forecasting of photovoltaic power production using machine learning,” Master's thesis, Dept. Control Comput. Eng., *Politecnico di Torino*, Turin, Italy, 2021.
- [181] N. Shukla and K. Fricklas, *Machine Learning with TensorFlow*. Shelter Island, NY, USA: Manning Publications, 2018.
- [182] S. Herculano-Houzel, “The human brain in numbers: A linearly scaled-up primate brain,” *Front. Hum. Neurosci.*, vol. 3, p. 31, Nov. 2009.
- [183] F. Chollet *et al.*, “Keras,” 2015. Accessed: Feb. 17, 2024. [Online]. Available: <https://keras.io>
- [184] R. van Loon, “Machine learning explained: Understanding supervised, unsupervised, and reinforcement learning,” *Big Data Made Simple*, 2018. [Online]. Available: <https://bigdata-madesimple.com/machine-learning-explained-understanding-supervised-unsupervised-and-reinforcement-learning/>
- [185] J. Brownlee, “How to choose an activation function for deep learning,” *Machine Learning Mastery*, Jan. 11, 2021. [Online]. Available: <https://machinelearningmastery.com/choose-an-activation-function-for-deep-learning/>
- [186] J. Brownlee, “How to choose loss functions when training deep learning neural networks,” *Machine Learning Mastery*, Jan. 30, 2019. [Online]. Available: <https://machinelearningmastery.com/how-to-choose-loss-functions-when-training-deep-learning-neural-networks/>
- [187] F. Chollet, *Deep Learning with Python*. Shelter Island, NY, USA: Manning Publications, 2017.
- [188] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016.
- [189] F. van Veen, “The neural network zoo,” *The Asimov Institute*, 2016. [Online]. Available: <https://www.asimovinstitute.org/neural-network-zoo/>
- [190] S. Leva, A. Dolara, F. Grimaccia, M. Mussetta, and E. Ogliari, “Analysis and validation of 24 hours ahead neural network forecasting of photovoltaic output power,” *Math. Comput. Simulat.*, vol. 131, pp. 88-100, Jan. 2017.

- [191] A. Sharma V., “Understanding activation functions in neural networks,” *The Theory Of Everything*, 2017. [Online]. Available: <https://medium.com/the-theory-of-everything/understanding-activation-functions-in-neural-networks-9491262884e0>
- [192] S. Doshi, “Various optimization algorithms for training neural network,” *Towards Data Science*, 2019. Accessed: Feb. 5, 2024. [Online]. Available: <https://towardsdatascience.com/optimizers-for-training-neural-network-59450d71caf6>
- [193] S. Kostadinov, “Understanding backpropagation algorithm,” *Towards Data Science*, 2019. [Online]. Available: <https://towardsdatascience.com/understanding-backpropagation-algorithm-7bb3aa2f95fd>
- [194] B. Roy, “All about feature scaling,” *Towards Data Science*, 2020. [Online]. Available: <https://towardsdatascience.com/all-about-feature-scaling-bcc0ad75cb35>
- [195] M. J. Anzanello and F. S. Fogliatto, “Learning curve models and applications: Literature review and research directions,” *Int. J. Ind. Ergonomics*, vol. 41, no. 5, pp. 573-583, Sep. 2011.
- [196] J. Brownlee, “How to use learning curves to diagnose machine learning model performance,” *Machine Learning Mastery*, 2019. Accessed: Feb. 5, 2024. [Online]. Available: <https://machinelearningmastery.com/learning-curves-for-diagnosing-machine-learning-model-performance/>
- [197] V. Lo Brano, G. Ciulla, and M. Di Falco, “Artificial neural network to predict the power output of a PV panel,” *Int. J. Photoenergy*, vol. 2014, p. 193081, 2014.
- [198] M. S. Sheik and D. Devaraj, “Simulation and analysis of stand-alone photovoltaic system with boost converter using MATLAB/Simulink,” in *Proc. Int. Conf. Circuits, Power and Computing Technologies (ICCPCT)*, Nagercoil, India, 2014, pp. 814-821.
- [199] F. Spertino, “Power generation from renewable sources,” lecture notes, *Polytechnic University of Turin*, Italy, 2019.
- [200] V. Fthenakis, “Third generation photovoltaics,” in *Renewable Energy*, T. J. Hammons, Ed. London, U.K.: IntechOpen, 2012.
- [201] C. J. Cleveland and C. Morris, “Section 10 – Solar,” in *Handbook of Energy*. Oxford, U.K.: Elsevier, 2013, pp. 405-450.
- [202] R. Lindsey, “Climate and Earth’s energy budget,” *NASA Earth Observatory*, 2009. [Online]. Available: <https://earthobservatory.nasa.gov/features/EnergyBalance>
- [203] D. Heinemann, “Energy meteorology,” lecture notes, *Carl von Ossietzky University*, Oldenburg, Germany, 2002.
- [204] M. Günther *et al.*, “Solar radiation,” in *Advanced CSP Teaching Materials*, Chapter 2, 2011.
- [205] D. Caputo, F. Grimaccia, M. Mussetta, and R. E. Zich, “Photovoltaic plants predictive model by means of ANN trained by a hybrid evolutionary algorithm,” in *Proc. Int. Joint Conf. Neural Netw. (IJCNN)*, Barcelona, Spain, 2010, pp. 1-6.
- [206] “Machine learning methods,” *Big Data Tips*. Accessed: Jan. 29, 2024. [Online]. Available: <http://www.big-data.tips/machine-learning-methods>
- [207] M. Zakić and G. Kvašček, “Procena mesta nastanka kvara na električnom vodu primenom veštačkih neuralnih mreža,” *Energija, ekonomija, ekologija*, no. 4, pp. 68-74, 2022.
- [208] Đ. Grozdić, “Algoritmi za procenu parametara i stanja elektroenergetskog sistema bazirani na veštačkim neuronskim mrežama,” Ph.D. dissertation, *Faculty of Electrical Engineering, University of Belgrade*, Serbia, 2017.
- [209] “Sigmoid function,” in *Wikipedia: The Free Encyclopedia*. Accessed: Jan. 30, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Sigmoid_function
- [210] “Gradient descent,” in *Wikipedia: The Free Encyclopedia*. Accessed: Jan. 31, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Gradient_descent
- [211] “Stochastic gradient descent algorithm,” *4Wallspace Blog*, Mar. 2020. Accessed via WayBack Machine: Feb. 17, 2024. [Online]. Available: <https://web.archive.org/web/20200808065455/https://blogs.4wallspace.com/2020/03/stochastic-gradient-descent-algorithm.html>

- [212] “What is the difference between gradient descent and stochastic gradient descent?” *Data Science Stack Exchange*. Accessed: Feb. 17, 2024. [Online]. Available: <https://datascience.stackexchange.com/questions/36450/what-is-the-difference-between-gradient-descent-and-stochastic-gradient-descent>
- [213] “Momentum,” *CBE Cornell Optimization Wiki*. Accessed: Feb. 17, 2024. [Online]. Available: <https://optimization.cbe.cornell.edu/index.php?title=Momentum>
- [214] “Moment (mathematics),” in *Wikipedia: The Free Encyclopedia*. Accessed: Feb. 17, 2024. [Online]. Available: [https://en.wikipedia.org/wiki/Moment_\(mathematics\)](https://en.wikipedia.org/wiki/Moment_(mathematics))
- [215] L. Liu *et al.*, “On the variance of the adaptive learning rate and beyond,” 2019, *arXiv:1908.03265*. [Online]. Available: [arxiv.org](https://arxiv.org/abs/1908.03265)
- [216] “RAdam: A new state-of-the-art optimizer for RL,” *Autonomous Learning Library (Medium)*. Accessed: Feb. 17, 2024. [Online]. Available: <https://medium.com/autonomous-learning-library/radam-a-new-state-of-the-art-optimizer-for-rl-442c1e830564>
- [217] J. Brownlee, “Gentle introduction to the Adam optimization algorithm for deep learning,” *Machine Learning Mastery*, 2017. Accessed: Feb. 18, 2024. [Online]. Available: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/>
- [218] “Backpropagation,” in *Wikipedia: The Free Encyclopedia*. Accessed: Feb. 1, 2024. [Online]. Available: <https://en.wikipedia.org/wiki/Backpropagation>
- [219] J. Smith, “A disciplined approach to neural network hyper-parameters: Part 1 – learning rate, batch size, momentum, and weight decay,” 2018, *arXiv:1803.09820*. [Online]. Available: [arxiv.org](https://arxiv.org/abs/1803.09820)
- [220] “Convolution,” in *Wikipedia: The Free Encyclopedia*. Accessed: Feb. 2, 2024. [Online]. Available: <https://en.wikipedia.org/wiki/Convolution>
- [221] A. Bhandari, “Feature scaling for machine learning: Understanding the difference between normalization vs. standardization,” *Analytics Vidhya*, 2020. [Online]. Available: [www.analyticsvidhya.com](https://www.analyticsvidhya.com/blog/2020/07/feature-scaling-for-machine-learning-understanding-the-difference-between-normalization-vs-standardization/)
- [222] S. Doshi, “L1 and L2 regularization methods,” *Towards Data Science*, 2019. Accessed: Feb. 5, 2024. [Online]. Available: <https://towardsdatascience.com/l1-and-l2-regularization-methods-ce25e7fc831c>
- [223] “Topaz solar farm,” in *Wikipedia: The Free Encyclopedia*. Accessed: Feb. 10, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Topaz_Solar_Farm
- [224] L. Nešić, “Fizika okoline – glava 2,” lecture notes, *Faculty of Science and Mathematics, University of Niš*, Serbia, 2012.
- [225] “Rejljevo rasejanje,” in *Wikipedia: The Free Encyclopedia* (in Serbian). Accessed: Feb. 15, 2024. [Online]. Available: https://sr.wikipedia.org/wiki/Rejljevo_rasejanje
- [226] “The color of light,” *American Museum of Natural History (AMNH)*. Accessed: Feb. 15, 2024. [Online]. Available: <https://www.amnh.org/explore/ology/physics/see-the-light2/the-color-of-light>
- [227] “Rasejanje svetlosti,” *Fizikica*, 2013. Accessed: Feb. 15, 2024. [Online]. Available: <https://fizikica.wordpress.com/2013/04/15/rasejanje-svetlosti/>
- [228] “Boja neba,” in *Wikipedia: The Free Encyclopedia* (in Serbian). Accessed: Feb. 15, 2024. [Online]. Available: https://sr.wikipedia.org/sr-el/Боја_неба
- [229] “Mie scattering,” in *Wikipedia: The Free Encyclopedia*. Accessed: Feb. 15, 2024. [Online]. Available: https://en.wikipedia.org/wiki/Mie_scattering
- [230] “OIE 2: Energija sunca,” lecture notes, *Faculty of Electrical Engineering, University of Belgrade*, Serbia. [Online]. Available: http://ees.etf.bg.ac.rs/predmeti/13/OIE_2_energija_sunca.ppt
- [231] “Osvetljenje: Fizički parametri rizika,” lecture notes, *Faculty of Occupational Safety, University of Niš*, Serbia. [Online]. Available: <https://www.znrfak.ni.ac.rs/serbian/010-studije/oas-3-2/PREDMETI/II%20GODINA/203-FIZICKI%20PARAMETRI%20RIZIS/PREDAVANJA/Osvetljenje%20FP%20predavanja.pdf>
- [232] *Global Solar Atlas*. Accessed: Feb. 28, 2024. [Online]. Available: <https://globalsolaratlas.info>

- [233] “Solarna fotonaponska energija,” in *Wikipedia: The Free Encyclopedia* (in Serbian). Accessed: Feb. 15, 2024. [Online]. Available: https://sr.wikipedia.org/sr/Solarna_fotonaponska_energija
- [234] M. P. Lazarević, “Osnove neuralnih mreža: PINN skripta,” lecture notes, *Faculty of Engineering, University of Kragujevac*, Serbia. Accessed: Feb. 28, 2024. [Online]. Available: <https://scidar.kg.ac.rs/bitstream/123456789/18602/5/pinn-skripta-lat.pdf>
- [235] A. Savić, “Fotonaponska konverzija energije,” lecture notes, *Faculty of Electrical Engineering, University of Belgrade*, Serbia, 2020. Accessed: Feb. 19, 2024. [Online]. Available: http://tnt.etf.bg.ac.rs/~aes/index_files/2020_solar.pdf
- [236] H. Li, Y. Ma, J. Wang, and B. Wang, “Comprehensive performance analysis of photovoltaic modules based on standard and nominal operating cell temperature,” *Energies*, vol. 14, no. 22, p. 7806, Nov. 2021.
- [237] “What is nominal operating cell temperature?” *Amerisolar Knowledge Base*, Jun. 15, 2018. Accessed: Feb. 29, 2024. [Online]. Available: <https://www.weamerisolar.eu/what-is-nominal-operating-cell-temperature/>

Прилог А Примери кода

У овом прилогу дат је изворни код у програмском језику Python за неке од коришћених алгоритама.

А.1 Имплементација LSTM мреже у програмском језику Python

Овај одељак садржи изворни код у програмском језику Python за LSTM мрежу.

Листинг 1: Имплементација LSTM мреже

```
1  '''
2  funkcija koja kreira LSTM model
3  sastavljen od nekoliko stekovanih LSTM slojeva
4  '''
5
6  # osnovne biblioteke
7  import numpy as np
8  import pandas as pd
9  import math
10
11 from keras.callbacks import EarlyStopping
12 from sklearn import metrics
13
14 # funkcije za evaluaciju modela
15 from utilities.LSTMEvaluate import *
16
17 # funkcije za skaliranje
18 from utilities.load_dataset_multi import *
19
20 import warnings
21 import os
22
23
24 class LSTMFunction:
25
26     def __init__(self, trainData, valData, testData, test, test_denorm,
27                 D, features, lags, steps, intParams, bounds,
28                 early_stop=False, target=None, scaler=None,
29                 norm_metrics=True):
30
31         # vremenske serije - podaci za obuku, validaciju i test
32         self.trainData = trainData
33         self.valData = valData
34         self.testData = testData
35
36         # test podaci za evaluaciju - normalizovani
37         self.test = test
38
39         # denormalizovani test podaci za denormalizovane metrike
40         self.test_denorm = test_denorm
41
42         # broj parametara resenja
43         self.D = D
```

```

41     # scaler za denormalizovane metrike;
42     # medjutim, scaler se ucitava iz load_dataset_multi,
43     # ovaj nije potreban, zato je po def. None u konstruktoru
44     self.scaler = scaler
45
46     # da li se vracaju normalizovane ili denormalizovane metrike
47     self.norm_metrics = norm_metrics
48
49     # broj obelezja, kod univariate je features=1
50     self.features = features
51
52     # broj lag-ova
53     # kod univariate, ulaz mreze je u obliku [1,broj_lag-ova],
54     # npr. [1,6]
55     self.lags = lags
56
57     # broj koraka unapred, jednak broju neurona u izlaznom sloju
58     self.steps = steps
59
60     # lista sa pozicijama celobrojnih parametara metaheuristike
61     self.intParams = intParams
62
63     # dictionary sa granicama vrednosti parametara
64     self.bounds = bounds
65
66     # inicijalizacija early_stop
67     self.early_stop = early_stop
68
69     # postavljanje niza sa granicama vrednosti parametara
70     # D je ukupna duzina niza i prosledjuje se iz glavnog koda
71     self.ub = [None] * self.D
72     self.lb = [None] * self.D
73     self.name = "LSTM Function"
74
75     '''
76     parametri, najpre realni pa celobrojni:
77     [0] - learning rate (stopa ucenja)
78     [1] - dropout rate za dropout sloj koji ide na kraju
79     [2] - broj epoha za obuku
80     [3] - broj slojeva
81     [4] - broj neurona u sloju
82     [5] - isto kao [4]
83     [6] - isto kao [4]
84     [7] - ... broj parametara zavisi od maks. broja slojeva
85           Npr. ako je maks. broj slojeva 3, onda su osim prva
86           4 parametra ([0]-[3]) potrebna jos 3 (po jedan za broj
87           neurona u svakom sloju).
88     '''
89
90     self.lb[0] = bounds['lb_lr'] # LB za learning rate, float
91     self.ub[0] = bounds['ub_lr'] # UB za learning rate, float
92
93     self.lb[1] = bounds['lb_dropout'] # LB za dropout rate, float
94     self.ub[1] = bounds['ub_dropout'] # UB za dropout rate, float
95
96     self.lb[2] = bounds['lb_epochs'] # LB za broj epoha, int
97     self.ub[2] = bounds['ub_epochs'] # UB za broj epoha, int
98
99     self.lb[3] = bounds['lb_layers'] # LB za broj slojeva, int

```

```

100     self.ub[3] = bounds['ub_layers'] # UB za broj slojeva, int
101
102     # sve do kraja niza postavljaju se vrednosti donje i gornje
103     # granice broja neurona u sloju;
104     # D zavisi od ub_layers, ako je ub_layers npr. 2,
105     # onda je duzina nizova D=4 (osnovna 4 parametra) + 2 = 6
106
107     for i in range(4, D):
108         self.lb[i] = bounds['lb_nn'] # LB za broj neurona u sloju
109         self.ub[i] = bounds['ub_nn'] # UB za broj neurona u sloju
110
111     # ostali parametri i pocetne vrednosti
112     self.loss = 'mse'
113     self.metrics = ['mean_absolute_error']
114     self.epochs = 200
115     self.dropout = 0.01
116     self.recurrent_dropout = 0.01
117     self.activation = 'relu'
118     self.loss = 'mean_squared_error'
119     self.learning_rate = 0.001
120
121     # warnings.warn = self.warn
122
123     # target kolona za multivariate
124     self.target = target
125
126
127     # funkcija za evaluaciju
128     def function(self, x):
129         # lista sa brojem neurona
130         # swarm jedinka vec je lista i ne treba nista menjati
131         # uzima se samo prvi element liste ako ima vise parametara
132         # print(type(x))
133         # print(x)
134         # konvertovati u listu jer olaksava rad sa vise hiperparametara
135
136         learning_rate = x[0]
137         dropout = x[1]
138         epochs = int(x[2]) # broj epoha, int
139         layers_lstm = int(x[3]) # broj slojeva
140         # lista brojeva neurona, za svaki LSTM sloj po jedan element
141         # od indeksa 4 do 4 + broj LSTM slojeva
142         nn_list = x[4:(layers_lstm +4)]
143         # konvertovati u int
144         nn_list = [int(x) for x in nn_list]
145
146         print('NN list:',nn_list)
147
148         # kreiranje LSTM modela, treniranje i predikcija
149         LSTMModel = self.createLSTMModel(self.features, self.lags,
150                                         self.steps, nn_list, learning_rate)
151         self.trainLSTM(LSTMModel, epochs, self.trainData, self.valData,
152                       earlyStop=self.early_stop)
153         prediction = self.predictLSTM(LSTMModel, self.testData)
154
155         # izdvajanje rezultata i prikaz
156         results = extractResults(prediction, self.test, self.steps,
157                                 self.lags)
158         # print('RESULTS:',results)

```

```

157 # dodatni korak ako se radi sa denormalizovanim metrikama
158 dnormResults = denormalizeResultsEvaluation(results, self.test,
159                                             self.target, self.steps, self.lags, self.test)
160 # print('DENORM RESULTS:', dnormResults)
161
162 # evaluatePredictions i evaluatePredictionsOverall vracaju
163 # metriku kao tuple, sledim redosledom: r2, mae, mse, rmse;
164 # ako se prognozira za vise koraka unapred, prvi element je
165 # tuple sa r2 za sve brojeve koraka, zatim mae za sve brojeve
166 # koraka, itd.; npr. za 3 koraka: [r2-1step, r2-2steps, r2-3steps],
167 # [mae-1step, mae-2steps, mae-3steps], itd.
168
169 # najpre se cuvaju svi rezultati, sve metriku za sve korake;
170 # ako je self.norm_metrics=True, sve se generise i racuna prema
171 # normalizovanim rezultatima;
172 # ako je self.norm_metrics=False, denormalizovani rezultati
173 # vracaju se kao primarni
174
175 if self.norm_metrics:
176     allResults = evaluatePredictions(results,
177                                     self.test[self.target])
178     # print("ALL:", allResults)
179     # overall rezultati su proseci metrika za sve korake
180     overallResults = evaluatePredictionsOverall(results,
181                                                 self.test[self.target])
182
183     allResults1 = evaluatePredictions(dnormResults,
184                                     self.test_denorm[self.target])
185     overallResults1 = evaluatePredictionsOverall(dnormResults,
186                                                 self.test_denorm[self.target])
187
188 else:
189     allResults = evaluatePredictions(dnormResults,
190                                     self.test_denorm[self.target])
191     # print("ALL:", allResults)
192     # overall rezultati su proseci metrika za sve korake
193     overallResults = evaluatePredictionsOverall(dnormResults,
194                                                 self.test_denorm[self.target])
195
196     allResults1 = evaluatePredictions(results,
197                                     self.test[self.target])
198     overallResults1 = evaluatePredictionsOverall(results,
199                                                 self.test[self.target])
200
201 # funkcija vraca i normalizovane i denormalizovane metriku;
202 # od self.norm_metrics zavisi koje ce biti primarne,
203 # tj. po kojim se vrse izracunavanja
204
205 # objective (funkcija cilja) je prosecan mse
206 objective = overallResults[2] # mse
207
208 # r2 bi morao da se oduzima od 1 jer je cilj minimizacija
209 # objective = 1-overallResults[0]
210
211 print(list(overallResults))
212
213 return objective, list(overallResults), list(allResults),
214         list(overallResults1), list(allResults1), results,
215         LSTMModel

```

```

207 # Pomocna funkcija za kreiranje LSTM modela
208 def createLSTMModel(self, feature_size, inputs, outputs, nn_list,
                        dropout=0.01, recurrent_dropout=0.01,
                        loss='mean_squared_error', optimizer='adam',
                        activation='relu', metrics=['accuracy'],
                        learning_rate=0.001, batch_size=32):
209     '''
210     :param feature_size: broj obelezja
211     :param inputs:      broj lag-ova (istorijskih podataka)
212     :param outputs:     broj koraka unapred
213     :param nn_list:     lista sa brojem neurona po slojevima (zavisi od
214                         odabrane vrednosti za max broj LSTM slojeva)
215     :param dropout:     dropout probability za dropout sloj
216     :param recurrent_dropout: recurrent dropout parametar
217     :param loss:        funkcija gubitka
218     :param optimizer:   optimizator
219     :param activation:  aktivaciona funkcija
220     :param metrics:     metrike za funkciju gubitke
221     :param learning_rate: learning rate
222     :param batch_size:  batch size za obuku
223     '''
224
225     optimizer = keras.optimizers.Adam(learning_rate=learning_rate)
226     # optimizer = 'adam'
227
228     LSTMModel = keras.models.Sequential()
229     LSTMModel.add(keras.Input(shape=(inputs, feature_size)))
230     # Input_Size, sequence_length
231
232     # petlja kroz listu brojeva neurona po slojevima
233     for i in range(len(nn_list)):
234         # za sve slojeve osim poslednjeg return_sequences=True
235         # samo u prvom LSTM sloju postavlja se batch_size
236         if i==0 and len(nn_list)>1:
237             # ako je ovo prvi LSTM sloj i postoji vise od jednog sloja,
238             # postavlja se batch_size i return_sequences=True
239             LSTMModel.add(layers.LSTM(nn_list[i],
                                        batch_size=batch_size, activation=activation,
                                        recurrent_dropout=0, unroll=True,
                                        return_sequences=True))
240         elif i==0 and len(nn_list)==1:
241             # ako je ovo prvi LSTM sloj i postoji samo jedan sloj,
242             # postavlja se batch_size ali bez return_sequences=True
243             LSTMModel.add(layers.LSTM(nn_list[i],
                                        batch_size=batch_size, activation=activation,
                                        recurrent_dropout=0, unroll=True))
244         elif i==len(nn_list)-1:
245             # ako je ovo poslednji LSTM sloj, bez return_sequences=True
246             LSTMModel.add(layers.LSTM(nn_list[i],
                                        activation=activation,
                                        recurrent_dropout=0, unroll=True))
247         else:
248             LSTMModel.add(layers.LSTM(nn_list[i],
                                        activation=activation,
                                        recurrent_dropout=0, unroll=True,
                                        return_sequences=True))
249
250     # dropout i izlazni sloj
251     LSTMModel.add(layers.Dropout(dropout))
252     LSTMModel.add(layers.Dense(outputs))
253

```

```

254         LSTMModel.compile(loss=loss, optimizer=optimizer,
255                             metrics=metrics)
256     return LSTMModel
257
258
259     def trainLSTM(self, model, epochs, trainData, valData=None,
260                 earlyStop=False):
261         if (earlyStop):
262             es = EarlyStopping(monitor='val_loss', mode='min',
263                               verbose=False, patience=epochs / 3)
264             model.fit(trainData, epochs=epochs, verbose=False,
265                     validation_data=valData, callbacks=[es])
266         else:
267             if valData is None:
268                 model.fit(trainData, epochs=epochs, verbose=False)
269             else:
270                 model.fit(trainData, epochs=epochs, verbose=False,
271                         validation_data=valData)
272
273     def predictLSTM(self, model, testData):
274         predictions = []
275         predictions.append(model.predict(testData,
276                                       verbose=False).reshape((-1)))
277         predictions = np.array(predictions)
278         return predictions
279
280     # ignore warnings
281     def warn(*args, **kwargs):
282         pass

```

A.2 Имплементација LSTM-ATT мреже у програмском језику Python

Овај одељак даје изворни код у програмском језику Python за LSTM мрежу са пажњом.

Листинг 2: Имплементација LSTM-ATT мреже

```

1     '''
2     funkcija koja kreira LSTM-Attention model
3     sastavljen od nekoliko stekovanih LSTM slojeva
4     nakon kojih se nalazi attention sloj
5     '''
6
7     # osnovne biblioteke
8     import numpy as np
9     import pandas as pd
10    import math
11    from attention import Attention
12
13    from keras.callbacks import EarlyStopping
14    from sklearn import metrics
15
16    # funkcije za evaluaciju modela
17    from utilities.LSTMEvaluate import *
18
19    # funkcije za skaliranje

```

```
20 | from utilities.load_dataset_multi import *
21 |
22 | import warnings
23 | import os
24 |
25 |
26 | class LSTMFunction:
27 |
28 |     def __init__(self, trainData, valData, testData, test, test_denorm,
29 |                 D, features, lags, steps, intParams, bounds,
30 |                 early_stop=False, target=None, scaler=None,
31 |                 norm_metrics=True):
32 |         # vremenske serije - podaci za obuku, validaciju i test
33 |         self.trainData = trainData
34 |         self.valData = valData
35 |         self.testData = testData
36 |
37 |         # test podaci za evaluaciju - normalizovani
38 |         self.test = test
39 |
40 |         # denormalizovani test podaci za denormalizovane metrike
41 |         self.test_denorm = test_denorm
42 |
43 |         # broj parametara resenja
44 |         self.D = D
45 |
46 |         # scaler za denormalizovane metrike;
47 |         # medjutim, scaler se ucitava iz load_dataset_multi,
48 |         # ovaj nije potreban, zato je po def. None u konstruktoru
49 |         self.scaler = scaler
50 |
51 |         # da li se vracaju normalizovane ili denormalizovane metrike
52 |         self.norm_metrics = norm_metrics
53 |
54 |         # broj obelezja, kod univariate je features=1
55 |         self.features = features
56 |
57 |         # broj lag-ova
58 |         # kod univariate, ulaz mreze je u obliku [1,broj_lag-ova],
59 |         # npr. [1,6]
60 |         self.lags = lags
61 |
62 |         # broj koraka unapred, jednak broju neurona u izlaznom sloju
63 |         self.steps = steps
64 |
65 |         # lista sa pozicijama celobrojnih parametara metaheuristike
66 |         self.intParams = intParams
67 |
68 |         # dictionary sa granicama vrednosti parametara
69 |         self.bounds = bounds
70 |
71 |         # inicijalizacija early_stop
72 |         self.early_stop = early_stop
73 |
74 |         # postavljanje niza sa granicama vrednosti parametara
75 |         # D je ukupna duzina niza i prosledjuje se iz glavnog koda
76 |         self.ub = [None] * self.D
77 |         self.lb = [None] * self.D
78 |         self.name = "LSTM-Attention Function"
```

```

76
77     '''
78     parametri, najpre realni pa celobrojni:
79     [0] - learning rate (stopa ucenja)
80     [1] - dropout rate za dropout sloj koji ide na kraju
81     [2] - broj epoha za obuku
82     [3] - broj slojeva
83     [4] - broj neurona u sloju
84     [5] - isto kao [4]
85     [6] - isto kao [4]
86     [7] - ... broj parametara zavisi od maks. broja slojeva
87           Npr. ako je maks. broj slojeva 3, onda su osim prva
88           4 parametra ([0]-[3]) potrebna jos 3+1 (po jedan za broj
89           neurona u svakom LSTM sloju + jedan za broj neurona u
90           attention sloju).
91     '''
92
93     self.lb[0] = bounds['lb_lr'] # LB za learning rate, float
94     self.ub[0] = bounds['ub_lr'] # UB za learning rate, float
95
96     self.lb[1] = bounds['lb_dropout'] # LB za dropout rate, float
97     self.ub[1] = bounds['ub_dropout'] # UB za dropout rate, float
98
99     self.lb[2] = bounds['lb_epochs'] # LB za broj epoha, int
100    self.ub[2] = bounds['ub_epochs'] # UB za broj epoha, int
101
102    self.lb[3] = bounds['lb_layers'] # LB za broj LSTM slojeva, int
103    self.ub[3] = bounds['ub_layers'] # UB za broj LSTM slojeva, int
104
105    # sve do kraja nizova postavljaju se vrednosti donje i gornje
106    # granice broja neurona u sloju, ukljucujuci i attention sloj;
107    # D zavisi od ub_layers, ako je ub_layers npr. 2,
108    # onda je duzina nizova D=4 (osnovna 4 parametra)
109    # + 2 LSTM sloja + 1 attention sloj = 7
110
111    for i in range(4, D):
112        self.lb[i] = bounds['lb_nn'] # LB za broj neurona u sloju
113        self.ub[i] = bounds['ub_nn'] # UB za broj neurona u sloju
114        # poslednji su za attention sloj
115
116    # ostali parametri i pocetne vrednosti
117    self.loss = 'mse'
118    self.metrics = ['mean_absolute_error']
119    self.epochs = 200
120    self.dropout = 0.01
121    self.recurrent_dropout = 0.01
122    self.activation = 'relu'
123    self.loss = 'mean_squared_error'
124    self.learning_rate = 0.001
125
126    # warnings.warn = self.warn
127
128    # target kolona za multivariate
129    self.target = target
130
131
132    # funkcija za evaluaciju
133    def function(self, x):
134        # lista sa brojem neurona

```

```

135 # swarm jedinka vec je lista i ne treba nista menjati
136 # uzima se samo prvi element liste ako ima vise parametara
137 # print(type(x))
138 # print(x)
139 # konvertovati u listu jer olaksava rad sa vise hiperparametara
140
141 learning_rate = x[0]
142 dropout = x[1]
143 epochs = int(x[2]) # broj epoha, int
144 layers_lstm = int(x[3]) # broj slojeva
145 # lista brojeva neurona, za svaki LSTM sloj po jedan element
146 # od indeksa 4 do 4 + broj LSTM slojeva
147 nn_list = x[4:(layers_lstm +4)]
148 # konvertovati u int
149 nn_list = [int(x) for x in nn_list]
150 # broj neurona u attention sloju, posle poslednjeg LSTM sloja
151 nn_attention = int(x[len(nn_list)+4])
152
153 print('NN list:',nn_list)
154 print('NN attention:',nn_attention)
155
156 # kreiranje LSTM modela, treniranje i predikcija
157 LSTMModel = self.createLSTMAttentionModel(self.features,
158                                           self.lags, self.steps, nn_list, nn_attention,
159                                           learning_rate=learning_rate)
160 self.trainLSTM(LSTMModel, epochs, self.trainData, self.valData,
161               earlyStop=self.early_stop)
162 prediction = self.predictLSTM(LSTMModel, self.testData)
163
164 # izdvajanje rezultata i prikaz
165 results = extractResults(prediction, self.test, self.steps,
166                           self.lags)
167 # print('RESULTS:',results)
168
169 # dodatni korak ako se radi sa denormalizovanim metrikama
170 dnormResults = denormalizeResultsEvaluation(results, self.test,
171                                             self.target, self.steps, self.lags, self.test)
172 # print('DENORM RESULTS:',dnormResults)
173
174 # evaluatePredictions i evaluatePredictionsOverall vracaju
175 # metrike kao tuple, sledecim redosledom: r2, mae, mse, rmse;
176 # ako se prognozira za vise koraka unapred, prvi element je
177 # tuple sa r2 za sve brojeve koraka, zatim mae za sve brojeve
178 # koraka, itd.; npr. za 3 koraka: [r2-1step,r2-2steps,r2-3steps],
179 # [mae-1step,mae-2steps,mae-3steps], itd.
180
181 # najpre se cuvaju svi rezultati, sve metrike za sve korake;
182 # ako je self.norm_metrics=True, sve se generise i racuna prema
183 # normalizovanim rezultatima;
184 # ako je self.norm_metrics=False, denormalizovani rezultati
185 # vracaju se kao primarni
186
187 if self.norm_metrics:
188     allResults = evaluatePredictions(results,
189                                     self.test[self.target])
190     # print("ALL:",allResults)
191     # overall rezultati su proseci metrika za sve korake
192     overallResults = evaluatePredictionsOverall(results,
193                                                 self.test[self.target])

```

```

188         allResults1 = evaluatePredictions(dnormResults,
189                                           self.test_denorm[self.target])
190
191         overallResults1 = evaluatePredictionsOverall(dnormResults,
192                                                     self.test_denorm[self.target])
193
194     else:
195         allResults = evaluatePredictions(dnormResults,
196                                         self.test_denorm[self.target])
197         # print("ALL:",allResults)
198         # overall rezultati su proseci metrika za sve korake
199         overallResults = evaluatePredictionsOverall(dnormResults,
200                                                    self.test_denorm[self.target])
201
202         allResults1 = evaluatePredictions(results,
203                                         self.test[self.target])
204         overallResults1 = evaluatePredictionsOverall(results,
205                                                     self.test[self.target])
206
207         # funkcija vraca i normalizovane i denormalizovane metrike;
208         # od self.norm_metrics zavisi koje ce biti primarne,
209         # tj. po kojim se vrse izracunavanja
210
211         # objective (funkcija cilja) je prosecan mse
212         objective = overallResults[2] # mse
213
214         # r2 bi morao da se oduzima od 1 jer je cilj minimizacija
215         # objective = 1-overallResults[0]
216
217         print(list(overallResults))
218
219         return objective, list(overallResults), list(allResults),
220                list(overallResults1), list(allResults1), results,
221                LSTMModel
222
223 # Pomocna funkcija za kreiranje LSTM modela
224 def createLSTMAttentionModel(self, feature_size, inputs, outputs,
225                             nn_list, nn_attention,
226                             dropout=0.01, recurrent_dropout=0.01,
227                             loss='mean_squared_error', optimizer='adam',
228                             activation='relu', metrics=['accuracy'],
229                             learning_rate=0.001, batch_size=32):
230
231     '''
232     :param feature_size: broj obelezja
233     :param inputs: broj lag-ova (istorijskih podataka)
234     :param outputs: broj koraka unapred
235     :param nn_list: lista sa brojem neurona po slojevima (zavisi od
236                   odabrane vrednosti za max broj LSTM slojeva)
237     :param nn_attention: broj neurona u attention sloju koji ide na
238                         kraju
239     :param dropout: dropout probability za dropout sloj
240     :param recurrent_dropout: recurrent dropout parametar
241     :param loss: funkcija gubitka
242     :param optimizer: optimizator
243     :param activation: aktivaciona funkcija
244     :param metrics: metrike za funkciju gubitke
245     :param learning_rate: learning rate
246     :param batch_size: batch size za obuku
247     '''
248
249     optimizer = keras.optimizers.Adam(learning_rate=learning_rate)

```

```

236     # optimizer = 'adam'
237
238     LSTMModel = keras.models.Sequential()
239     LSTMModel.add(keras.Input(shape=(inputs, feature_size)))
240     # Input_Size, sequence_length
241
242     # petlja kroz listu brojeva neurona po LSTM slojevima
243     for i in range(len(nn_list)):
244         # samo u prvom LSTM sloju postavlja se batch_size
245         if i==0:
246             LSTMModel.add(layers.LSTM(nn_list[i],
247                                     batch_size=batch_size, activation=activation,
248                                     return_sequences=True))
249         else:
250             LSTMModel.add(layers.LSTM(nn_list[i],
251                                     activation=activation, return_sequences=True))
252
253     # na kraju, posle LSTM slojeva, dodaje se Attention sloj
254     LSTMModel.add(Attention(nn_attention))
255
256     # dropout i izlazni sloj
257     LSTMModel.add(layers.Dropout(dropout))
258     LSTMModel.add(layers.Dense(outputs))
259
260     LSTMModel.compile(loss=loss, optimizer=optimizer,
261                      metrics=metrics)
262
263     return LSTMModel
264
265 def trainLSTM(self, model, epochs, trainData, valData=None,
266              earlyStop=False):
267     if (earlyStop):
268         es = EarlyStopping(monitor='val_loss', mode='min',
269                             verbose=False, patience=epochs / 3)
270         model.fit(trainData, epochs=epochs, verbose=False,
271                 validation_data=valData, callbacks=[es])
272     else:
273         if valData is None:
274             model.fit(trainData, epochs=epochs, verbose=False)
275         else:
276             model.fit(trainData, epochs=epochs, verbose=False,
277                     validation_data=valData)
278
279 def predictLSTM(self, model, testData):
280     predictions = []
281     predictions.append(model.predict(testData,
282                                     verbose=False).reshape((-1)))
283     predictions = np.array(predictions)
284     return predictions
285
286 # ignore warnings
287 def warn(*args, **kwargs):
288     pass

```

Биографија аутора

Александар Стојковић рођен је 14.6.1970. у Београду од оца Слободана и мајке Зорке. Основну школу „Никола Тесла” у Раковици и XIII београдску гимназију завршио је као носилац Вукове дипломе. Током основне и средње школе освојио је неколико признања на такмичењима из математике на градском и републичком нивоу.

Основне студије на Електротехничком факултету Универзитета у Београду уписао је 1989. на смеру Рачунарска техника и информатика, а завршио 1994. године са просечном оценом 8,93. Дипломирао је 13.12.1994. код ментора проф. др Јована Ђорђевића са оценом 10 и стекао звање дипломираног инжењера електротехнике.

Постдипломске студије на ЕТФ-у уписао је 1995. на смеру Архитектура и организација рачунарских система и мрежа. Положио је све испите предвиђене програмом постдипломских студија са просечном оценом 9,83. Магистарску тезу под називом „Мрежно доступан систем за учење архитектуре и организације процесора са преклопљеним извршавањем инструкција” реализовао је код ментора проф. др Јована Ђорђевића и одбранио 28.6.2005. пред комисијом у саставу проф. др Јован Ђорђевић, проф. др Боривој Лазић и проф. др Мило Томашевић. Током израде магистарског рада детаљно је дефинисана архитектура и организација едукативног *pipeline* процесора и направљен симулатор истог који је затим коришћен у настави на ЕТФ-у.

Докторске академске студије на ЕТФ-у уписао је 2023. године на модулу Рачунарска техника и информатика. Области истраживачког рада којим се бави су вештачка интелигенција и машинско учење.

Од 1995. године запослен је у Институту „Михајло Пупин” у Београду, где се бави рачунарским LAN, WAN и VPN мрежама, IP телефонским системима и сл. Носилац је више индустријских сертификата реномираних светских компанија. Учествовао је у већем броју успешно реализованих пројеката за разне кориснике.

Изјава о ауторству

Име и презиме аутора: Александар Стојковић

Број индекса: 5030/2023

Изјављујем

да је докторска дисертација под насловом

Предвиђање индустријске производње применом модела машинског учења


оптимизованих метахеуристикама

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

У Београду,

26.3.2026

Потпис аутора



Изјава о истоветности штампане и електронске верзије докторског рада

Име и презиме аутора: Александар Стојковић
Број индекса: 5030/2023
Студијски програм: Електротехника и рачунарство
Наслов рада: Предвиђање индустријске производње применом модела машинског учења оптимизованих метахеуристикама
Ментор: проф. др Бошко Николић

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

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

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

У Београду,

26.3.2026

Потпис аутора



Изјава о коришћењу

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

Предвиђање индустријске производње применом модела машинског учења

оптимизованих метахеуристикама

која је моје ауторско дело.

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

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

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

(Молимо да заокружите само једну од шест понуђених лиценци.

Кратак опис лиценци је саставни део ове изјаве).

У Београду,

26.3.2026

Потпис аутора



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