



UNIVERZITET U NIŠU
ELEKTRONSKI FAKULTET



Aleksandar D. Pantić

Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema

Doktorska disertacija

Tekst ove doktorske disertacije stavlja se na uvid javnosti,
u skladu sa članom 30., stav 8. Zakona o visokom obrazovanju
(„Sl. glasnik RS“, br. 76/2005, 100/2007 – autentično tumačenje, 97/2008,
44/2010, 93/2012, 89/2013 i 99/2014).

NAPOMENA O AUTORSKIM PRAVIMA:

Ovaj tekst smatra se rukopisom i samo se saopštava javnosti
(član 7. Zakona o autorskim i srodnim pravima, „Sl. glasnik RS“,
br. 104/2009, 99/2011 i 119/2012).

Nijedan deo ove doktorske disertacije ne sme se koristiti ni u kakve svrhe,
osim za upoznavanje sa njenim sadržajem pre odbrane disertacije.

Niš, mart 2026.



UNIVERZITET U NIŠU
ELEKTRONSKI FAKULTET



Aleksandar D. Pantić

Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema

Doktorska disertacija

Niš, mart 2026.



UNIVERSITY OF NIŠ
FACULTY OF ELECTRONIC ENGINEERING



Aleksandar D. Pantić

Advanced Methods for Design and Predictive Modeling of Photovoltaic System Characteristics

Doctoral dissertation

Niš, March 2026.

Podaci o doktorskoj disertaciji	
Mentor:	dr Sanja Aleksić, vanredni profesor, Univerzitet u Nišu, Elektronski fakultet
Naslov:	Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema
Rezime:	<p>Doktorska disertacija pod naslovom „<i>Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema</i>“ bavi se razvojem i analizom savremenih metoda za modelovanje i predikciju proizvodnje solarnih fotonaponskih (PV) sistema primenom metoda mašinskog učenja i analitičkih energetske modela. Osnovni cilj istraživanja je unapređenje tačnosti i pouzdanosti procene proizvodnje PV sistema kroz integraciju meteoroloških podataka, simulacionih modela i metoda veštačke inteligencije.</p> <p>U radu je razvijen metodološki okvir za predikciju proizvodnje PV sistema zasnovan na kombinaciji fizičkih modela i metoda mašinskog učenja. Poseban fokus stavljen je na primenu veštačkih neuronskih mreža (ANN) za modelovanje nelinearne zavisnosti između meteoroloških parametara i izlazne snage i/ili proizvedene energije PV sistema.</p> <p>U okviru istraživanja analizirana su dva konceptualno različita pristupa predikciji proizvodnje PV sistema. Prvi pristup (M1) zasniva se na indirektnom modelovanju, pri čemu se najpre vrši predikcija globalnog horizontalnog zračenja (GHI), nakon čega se predviđene vrednosti transformišu u energetske proizvodnje primenom fizičkog modela PV sistema. Drugi pristup (M2) zasniva se na direktnoj predikciji izlazne snage ili energije PV sistema korišćenjem jedinstvene ANN arhitekture.</p> <p>Posebna pažnja posvećena je optimizaciji arhitekture neuronskih mreža i izboru algoritama treniranja, kao i razvoju postupka kombinovanja simulacionih i merenih podataka kroz dvostepeni proces obuke modela koji obuhvata faze predtreniranja (<i>pretraining</i>) i finog podešavanja (<i>fine-tuning</i>). Predtreniranje omogućava obuku modela na velikim simulacionim skupovima generisanim u softverskom alatu PVsyst, dok fino podešavanje omogućava prilagođavanje modela realnim merenim podacima proizvodnje PV sistema.</p> <p>Razvijeni modeli evaluirani su na osnovu višegodišnjih meteoroloških i energetske podataka za region Niša, uz korišćenje standardnih statističkih metrika greške kao što su MAE, RMSE i nRMSE. Dobijeni rezultati pokazuju da razvijeni modeli ostvaruju visok nivo tačnosti u predikciji proizvodnje PV sistema, uz stabilno ponašanje u različitim meteorološkim uslovima i relativno mali sistematski bias modela.</p>

Podaci o doktorskoj disertaciji (nastavak)	
	<p>Komparativna analiza indirektnog i direktnog pristupa predikciji proizvodnje PV sistema pokazuje da oba pristupa poseduju specifične prednosti u zavisnosti od ciljne aplikacije. Indirektni pristup omogućava veću interpretabilnost i bolju analizu fizičkih procesa, dok direktni pristup obezbeđuje jednostavniju strukturu modela i pogodniji je za operativne sisteme prognoze proizvodnje električne energije.</p> <p>Rezultati disertacije doprinose razvoju metodologije modelovanja i predikcije proizvodnje fotonaponskih sistema i predstavljaju osnovu za razvoj naprednih inteligentnih sistema za upravljanje proizvodnjom energije iz obnovljivih izvora. Predloženi metodološki okvir može imati značajnu primenu u planiranju rada elektroenergetskih sistema, proceni solarnih energetske potencijala i integraciji obnovljivih izvora energije u savremene elektroenergetske mreže.</p>
Naučna oblast:	Elektrotehničko i računarsko inženjerstvo
Naučna disciplina:	Mikroelektronika i mikrosistemi
Ključne reči:	fotonaponski sistemi (PV), predikcija proizvodnje PV sistema, veštačke neuronske mreže (ANN), mašinsko učenje, meteorološki podaci, PVsyst simulacije, solarna energija
UDK:	621.383.51:004.89:519.23(043.3)
CERIF klasifikacija:	T171 Mikroelektronika
Tip licence:	CC BY-NC-ND

Data on Doctoral Dissertation	
Doctoral Supervisor:	Dr. Sanja Aleksić, Associate Professor, University of Niš, Faculty of Electronic Engineering
Title:	Advanced Methods for Design and Predictive Modeling of Photovoltaic System Characteristics
Summary:	<p>The doctoral dissertation entitled “Advanced Techniques for Design and Prediction of Photovoltaic System Characteristics” addresses the development and analysis of advanced methods for modeling and forecasting the performance of solar photovoltaic (PV) systems. The primary objective of the research is to improve the accuracy and reliability of PV production forecasting through the integration of meteorological data, simulation-based models, and machine learning techniques.</p> <p>A methodological framework for PV power forecasting is developed based on the combination of physical modeling approaches and data-driven methods. Particular emphasis is placed on the application of artificial neural networks (ANN) for modeling the nonlinear relationships between meteorological parameters and the output power or generated energy of PV systems.</p> <p>Within the research, two conceptually different approaches to PV production forecasting are investigated. The first approach (M1) is based on an indirect modeling strategy, where global horizontal irradiance (GHI) is first predicted using machine learning techniques, and the obtained irradiance values are subsequently transformed into energy production using a physical PV system model. The second approach (M2) employs a direct forecasting strategy, in which a unified ANN architecture directly predicts the output power or energy of the PV system based on available meteorological inputs.</p> <p>Special attention is devoted to the optimization of neural network architectures and training algorithms, as well as to the development of a hybrid training procedure that combines simulated and measured datasets through a two-stage learning process consisting of pretraining and fine-tuning phases. In the pretraining stage, the model is trained on large datasets generated by the PVsyst simulation software, while the fine-tuning stage enables the adaptation of the model to real PV production measurements.</p> <p>The developed models are evaluated using multi-year meteorological and energy datasets for the Niš region, employing standard statistical performance metrics such as MAE, RMSE, and nRMSE. The obtained results demonstrate that the proposed models achieve high forecasting accuracy, stable performance under different meteorological conditions, and low systematic bias.</p>

Data on Doctoral Dissertation (cont.)	
	<p>The comparative analysis of the indirect (M1) and direct (M2) forecasting approaches reveals that each method offers specific advantages depending on the intended application. The indirect approach provides higher interpretability and better insight into the physical processes governing PV generation, while the direct approach offers a simpler model structure and improved suitability for operational PV power forecasting systems.</p> <p>The results of this dissertation contribute to the advancement of methodologies for modeling and forecasting photovoltaic system performance and provide a basis for the development of intelligent energy management systems for renewable energy sources. The proposed framework can be applied in power system planning, solar resource assessment, and the integration of photovoltaic systems into modern power grids.</p>
Scientific Field:	Electrical and Computer Engineering
Scientific Discipline:	Microelectronics and microsystems
Key Words:	photovoltaic (PV) systems, PV power forecasting, artificial neural networks (ANN), machine learning, meteorological data, energy system modeling, solar energy
UDC:	621.383.51:004.89:519.23(043.3)
CERIF Clasification:	T171 Microelectronics
Creative Commons Licence Type:	CC BY-NC-ND



Sadržaj

Zahvalnica	xvi
Lista skraćenica	xvii
Lista simbola i konstanti	xviii
1 Uvod	1
1.1 Energetska tranzicija u globalnom kontekstu	1
1.2 Stanje i trendovi u Republici Srbiji	6
1.3 Motivacija i značaj istraživanja	9
2 Pregled literature	13
2.1 Fotonaopne (PV) tehnologije	14
2.1.1 Princip rada i karakteristike solarnih ćelija	15
2.1.2 Tipovi solarnih ćelija i PV modula	17
2.1.3 Uticaj radnih uslova na karakteristike PV modula	17
2.2 Fizički i empirijski modeli PV sistema	18
2.2.1 Fizički modeli	18
2.2.2 Empirijski modeli	19
2.2.3 Uporedna analiza i ograničenja klasičnih pristupa	20
2.3 Prediktivni i hibridni modeli PV sistema	21
2.3.1 Modeli bazirani na podacima	22
2.3.2 Veštačka inteligencija (VI) i veštačke neuronske mreže (ANN)	23
2.3.3 Hibridni modeli: integracija fizičkih i AI pristupa	25
3 Metode projektovanja PV sistema	27
3.1 Tradicionalne metode projektovanja	28
3.1.1 Procena lokacije	28
3.1.2 Dimenzionisanje PV sistema - procena profila potrošnje	30
3.1.3 Izbor komponenata PV sistema	32
3.1.4 BOS - prateće mehaničke i električne komponente sistema	34

3.1.5	Ekonomska opravdanost i povratak ulaganja (ROI)	36
3.1.6	Bezbednosni standardi i propisi	38
3.1.7	Testiranje, puštanje u rad, monitoring i održavanje PV sistema	39
3.2	Softverski alati i simulacioni modeli	41
3.3	Ograničenja konvencionalnih metoda	43
4	Metodologija istraživanja	45
4.1	Integrirani okvir istraživanja	45
4.2	Ekperimentalno okruženje	48
4.2.1	Konfiguracija PV sistema i merni pod sistemi	49
4.2.2	Simulacija i emulacija priključenja na mrežu	51
4.2.3	Računarska infrastruktura i softverski alati	51
4.3	Izvori, integracija i struktura podataka	52
4.3.1	Pregled i klasifikacija izvora podataka	53
4.3.2	Lokalna merenja kao referentni izvor podataka	54
4.3.3	Satelitski i reanalizni izvori podataka	54
4.3.4	Integracija i vremenska sinhronizacija podataka	55
4.4	Predobrada, kontrola kvaliteta i normalizacija	56
4.4.1	Kontrola kvaliteta i obrada nedostajućih vrednosti	57
4.4.2	Maskiranje noćnih sati i niskih iradijacija	57
4.4.3	Normalizacija i skaliranje ulaznih promenljivih	58
4.4.4	Normalizacija grešaka i IEC-orijentisan pristup	59
4.5	Podele skupa podataka i konfiguracije modela	59
4.5.1	Vremenski konzistentna podela skupa podataka	59
4.5.2	Formiranje nadgledanog skupa podataka	60
4.5.3	Konfiguracije modela M1 i M2	61
4.6	Arhitektura modela i postupak treniranja	62
4.6.1	Arhitektura MLP modela	62
4.6.2	Optimizacija hiperparametara	63
4.6.3	Funkcija cilja, regularizacija i kriterijumi zaustavljanja	64
4.6.4	Reproduktivnost i robusnost treniranja	65
4.7	Metrike performansi i evaluacija	65
4.7.1	IEC-orijentisana interpretacija	65
4.8	Validacija i poredenje modela	66
5	Rezultati istraživanja	67
5.1	Skupovi podataka, evaluacija i referentni modeli	70
5.2	Matematička analiza metrika	76
5.3	Rezultati: modeli M1 metodologije	81
5.3.1	Model M1-A1: osnovni ANN model (bez optimizacije)	82
5.3.2	Optimizacija strukture i procesa učenja modela M1-A1	91
5.3.3	Model M1-A1b: optimizovana konfiguracija	93
5.3.4	Model M1-A2: formulacija sa vremenskim kašnjenjem	95

5.4	Model M2: direktno predviđanje karakteristika PV sistema	109
5.4.1	M2 metodološki okvir	109
5.4.2	Matematička formulacija dvofaznog učenja	113
5.4.3	Optimizacija arhitekture MLP M2 modela	114
5.4.4	Rezultati predtreniranja na PVsyst skupu	116
5.4.5	Rezultati faze finog podešavanja na merenim podacima	121
5.4.6	Detaljna analiza grešaka modela M2	127
5.4.7	Završna diskusija dobijenih rezultata	132
5.4.8	Ograničenja modela M2 i pravci budućeg razvoja	133
5.5	Komparativna analiza modela M1 i M2	135
5.5.1	Metodološko poređenje pristupa	135
5.5.2	Kvantitativno poređenje performansi	136
5.5.3	Diskusija komparativnih rezultata	137
6	Zaključak	139
6.1	Originalni naučni doprinosi disertacije	140
	Prilozi	143
A	Numerički primer proračuna LCOE za PV sistem (Srbija)	143
B	Algoritmi učenja	145
C	Definicije korišćenih metrika	151
D	PR-bazirani model	154
E	Persistence i Scaled Persistence modeli	156
F	XGBoost model	158
G	Analitička analiza odstupanja metrika bez daylight filtriranja	161
H	Multilayer Perceptron (MLP) model	163
I	Implementacija modela M1-A1 u MATLAB okruženju	166
J	Detaljna analiza modela M1-A1	183
J.1	Vizuelni pregled test perioda (GHI, 2022)	183
J.2	Analiza u GHI domenu	184
J.3	Analiza u energetsom domenu	187
J.4	Energetski domen vs. PVsyst simulacija (2022)	190

J.5	Integrirana uporedna analiza (2022)	192
K	Optimizacija modela M1–A1	194
L	Optimizacija modela M2	196
	Biografija autora	210
	Spisak radova autora	211
6.1	Pregled publikovanih radova	214



Spisak slika

1.1	Globalna ulaganja u čistu energiju po sektorima i poređenje sa ulaganjima u fosilna goriva (nafta, gas i uglj) u periodu 2015–2025 (3), (4).	3
1.2	Nivelisani trošak energije (LCOE) za različite tehnologije u periodu 2009–2024. godine (5), (6).	4
1.3	Godišnji dodatak instaliranih kapaciteta iz obnovljivih izvora energije u svetu (projekcije za 2023 i 2024) (4).	6
1.4	Prostorna raspodela glavnih projekata obnovljivih izvora energije u Srbiji (hidro, vetar, solar) prema podacima za 2024. godinu.	7
1.5	Mapa GHI za Srbiju: prosečne godišnje vrednosti prema bazi PVGIS (2005-2022) (20).	9
2.1	Hijerarhija modela predikcije karakteristika PV sistema.	14
2.2	Proces proračuna i predikcije karakteristika PV sistema.	15
2.3	Šematski prikaz principa rada solarne ćelije.	16
2.4	Karakteristika c-Si solarne ćelije ($I - V$ i $P - V$) sa označenim karakterističnim tačkama.	16
2.5	Najčešće korišćeni fizički modeli.	19
2.6	Najčešće korišćeni empirijski modeli.	20
2.7	Evolucija modela za predviđanje performansi PV sistema: od fizičkih i empirijskih ka prediktivnim i hibridnim pristupima.	22
2.8	Osnovni princip koncepta digitalnog blizanca PV sistema.	25
3.1	Postupak projektovanja PV sistema: od procene lokacije i dostupnih resursa do tehničke i ekonomske evaluacije.	27
3.2	Povezanost solarnog resursa i specifičnog prinosa PV sistema.	29
3.3	GIS-bazirana višekriterijumska procena pogodnosti lokacije za PV sisteme.	30
3.4	Uporedni dnevni profili potrošnje i proizvodnje PV sistema (68).	31
3.5	Ilustracija usklađivanja PV stringa i invertora.	33
3.6	Pregled osnovnih BOS (Balance of System) komponenti u PV sistemu.	34
3.7	Diskontovani tokovi gotovine PV sistema: početni troškovi - CAPEX, godišnje koristi i operativni troškovi - OPEX.	37

4.1	Principijelni prikaz metodološkog okvira istraživanja (S1-S5).	46
4.2	Uloga eksperimentalnog PV sistema u okviru metodološkog okvira disertacije. Sistem obezbeđuje referentne merene podatke za faze S1 i S5.	49
4.3	Šematski prikaz eksperimentalnog 1 kW on-grid PV sistema sa mikroinvertor-skom arhitekturom, SCADA slojem i konceptualnim nivoima simulacije/emulacije mrežnog priključenja.	50
4.4	Meteorološka stanica u Nišu koja se nalazi Tvrdavi u okolini Elektronskog fakulteta.	54
4.5	Integracija heterogenih izvora podataka u fazi S1 i formiranje jedinstvenog satnog skupa podataka.	55
4.6	Tok predobrade podataka (S2).	57
4.7	Vremenski konzistentna podela skupa podataka na trening, validacioni i test skup (2005–2022).	60
5.1	Uporedni konceptualni prikaz metodologija M1 i M2 za predviđanje izlaza PV sistema na osnovu meteoroloških podataka.	70
5.2	Histogram GHI sa označenim daylight pragom.	80
5.3	Primena maske dnevnog režima na reprezentativnom intervalu.	80
5.4	Konceptualni tok obrade podataka kod metodologije M1 (predikcija GHI i PR-bazirano mapiranje u energiju).	82
5.5	Konceptualni tok obrade podataka kod modela M1-A1: ANN predikcija GHI ($H = 1$ h), propagacija kroz PR-zasnovani fizički model i evaluacija u energetskom domenu.	83
5.6	Paritet dijagrami u GHI domenu za test skup ($H = 1$ h): (a) ANN model M1-A1, (b) model perzistencije, (c) skalirana perzistencija i (d) XGBoost model.	87
5.7	Mesečne vrednosti nRMSE u GHI domenu (test godina, $H = 1$ h).	88
5.8	Paritet dijagrami satne energije za 2022. godinu: (a) PR-bazirani ANN model M1-A1, (b) XGBoost model, (c) model perzistencije i (d) skalirana perzistencija.	90
5.9	Mesečne sume energije tokom 2022. godine.	90
5.10	Šematski prikaz procedure optimizacije strukture i procesa učenja ANN modela M1-A1.	92
5.11	Boxplot poređenje nRMSE vrednosti na test skupu (2022) za modele M1-A1 i M1-A1b kroz više ponavljanja treniranja. Prikazane su median vrednosti i raspon varijacije.	94
5.12	Konceptualni tok obrade u modelu M1-A2: formiranje lagovanog ulaznog vektora i MLP regresija za prognozu GHI za $H = 1$ h unapred (generička struktura za $L \in \{1, 6\}$).	98
5.13	Osetljivost nRMSE na dužinu lag-prozora L za model M1-A2 (GHI domen, test 2022).	99
5.14	Poređenje performansi modela bez vremenske memorije (M1-A1b) i modela sa jednim vremenskim kašnjenjem (M1-A2, $L = 1$) u GHI i energetskom domenu za test godinu 2022.	100
5.15	Paritet dijagrami (predikcija naspram merenja) za modele M1-A2 u GHI domenu za test godinu 2022 i horizont prognoze $H = 1$ h ($L = 1$).	101
5.16	Analiza nRMSE u GHI domenu tokom test godine 2022.	102
5.17	Mesečni nRMSE u GHI domenu (test 2022) za M1-A2 ($L = 1$): ANN, XGBoost, persistence i scaled-persistence; desna osa prikazuje \overline{GHI}_{meas}	103

5.18	Mesečne vrednosti $nRMSE$ u PR-baziranom energetskom domenu (merena PV energija, test 2022). Prikazana je i raspodela broja uzoraka po mesecima (N).	104
5.19	Primer dana sa izraženom promenljivošću oblačnosti (test 2022): poređenje merenog i predviđenog GHI za model M1–A2 ($L = 1$).	105
5.20	Primer dana sa izraženom promenljivošću oblačnosti (test 2022): struktura greške modela M1–A2 ($L = 1$).	105
5.21	Uporedni prikaz vrednosti $nRMSE$ u GHI domenu za različite modele u zavisnosti od režima neba (test skup 2022).	106
5.22	Višednevni prikaz GHI (test 2022, $H = 1$ h, $L = 1$): Measured vs ANN, XGBoost, persistence i scaled-persistence.	107
5.23	Vizuelni pregled unapređenja modela M1 kroz dve uzastopne faze.	108
5.24	Konceptualni pipeline modela M2–B1.	110
5.25	Uporedni prikaz srednjih validacionih vrednosti $nRMSE$ za razmatrane konfiguracije MLP arhitekture i algoritme treniranja u okviru optimizacije modela M2.	115
5.26	Kriva učenja tokom predtreniranja modela M2 na PVsyst simulacionom skupu podataka.	117
5.27	Paritet dijagram između referentnog izlaza PVsyst modela i predikcije ANN modela nakon predtreniranja, za test skup iz 2022. godine.	118
5.28	Zavisnost izlazne snage PV sistema od globalnog horizontalnog zračenja (GHI) u PVsyst simulacionom skupu.	119
5.29	Mesečne vrednosti energije dobijene iz PVsyst simulacionog skupa za period 2005–2022.	120
5.30	Kriva učenja tokom faze finog podešavanja modela M2 na merenim podacima.	122
5.31	Paritet dijagram između merenih vrednosti proizvodnje PV sistema i predikcije ANN modela nakon faze finog podešavanja, za test skup iz 2022. godine.	123
5.32	Histogram rezidualne greške modela M2 nakon faze finog podešavanja na merenim podacima.	124
5.33	Poređenje merenih i predviđenih vrednosti izlazne snage PV sistema tokom reprezentativnih perioda u test godini 2022.	126
5.34	Rezidualna greška modela M2 u funkciji globalnog horizontalnog zračenja (GHI) za test skup iz 2022. godine.	127
5.35	Mesečna raspodela rezidualne greške modela M2 prikazana pomoću boxplot dijagrama za test skup iz 2022. godine.	129
5.36	Rezidualna greška modela M2 u funkciji merene izlazne snage PV sistema.	130
5.37	Dnevni profil srednje greške (MBE) i RMSE modela M2 u funkciji sata u toku dana.	131
5.38	Toplotna mapa srednje rezidualne greške modela M2 u funkciji meseca i sata u toku dana.	132
5.39	Uporedni prikaz više metrika tačnosti (MAE, RMSE i $nRMSE$) za modele M1 i M2 na test skupu.	137
5.40	Radar dijagram normalizovanih performansi modela M1 i M2 na osnovu više metrika greške.	138
B.1	Iterativna šema Levenberg-Marquardt (LM) algoritma.	146

F.1	Šematski prikaz principa XGBoost modela zasnovanog na sekvencijalnom dodavanju regresionih stabala i aditivnoj kombinaciji njihovih izlaza.	158
H.1	Šematski prikaz strukture višeslojnog perceptrona (MLP) sa ulaznim, skrivenim i izlaznim slojem.	164
J.1	Satni GHI profil (2022): merenja i modeli.	183
J.2	Performanse modela M1–A1 u GHI domenu za test godinu ($H = 1$ h): (a) vremenski tok, (b) paritet dijagram, (c) reziduali i (d) raspodela greške.	184
J.3	Paritet dijagram ANN M1–A1 modela (GHI, $H = 1$ h).	185
J.4	Uporedni vremenski tokovi merenih i predikovanih vrednosti satne proizvedene energije za test godinu 2022 ($H = 1$ h) za PR(pred GHI), XGBoost, persistence i scaled persistence modele.	186
J.5	Uvećani vremenski tok satne proizvedene energije za prvih 800 uzoraka test godine 2022 ($H = 1$ h) za sve razmatrane modele.	187
J.6	Uporedni vremenski tokovi merenih i predikovanih vrednosti satne proizvedene energije za test godinu 2022 ($H = 1$ h) za PR(pred GHI), XGBoost, persistence i scaled persistence modele.	188
J.7	Paritet dijagram ANN modela u energetskom domenu, dobijen primenom PR-baziranog modela nad predikovanim GHI signalom, za test godinu 2022.	189
J.8	Satni profil energije: PVsyst vs PR(pred GHI) (2022).	190
J.9	Paritet dijagram: PR(pred GHI) vs PVsyst (2022).	191
J.10	Mesečne sume energije: PR(pred GHI) vs PVsyst (2022).	191
J.11	Satni profil energije: kompletno poredenje modela (2022).	192
J.12	Paritet dijagrami: uporedna analiza (2022).	192
J.13	Mesečno poredenje proizvedene energije za 2022. godinu između merenih vrednosti i modela PR(pred GHI), XGBoost, persistence i scaled persistence.	193



Spisak tabela

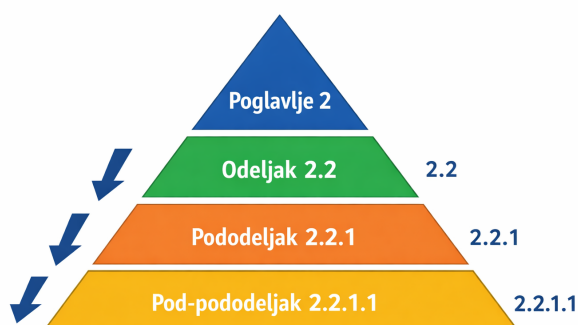
2.1	Uporedni prikaz fizičkih i empirijskih modela performansi PV sistema.	21
2.2	Pregled ANN arhitektura relevantnih za kratkoročnu prognozu solarne energije i njihova uloga u predloženim modelima M1 i M2.	24
3.1	Uporedni pregled najčešće korišćenih softverskih alata za projektovanje i simulaciju PV sistema.	42
4.1	Specifikacija eksperimentalnog PV sistema.	50
4.2	Klasifikacija i osnovne karakteristike izvora podataka korišćenih u istraživanju.	53
5.1	Sumarni prikaz korišćenih skupova podataka i njihove uloge u metodologijama M1 i M2.	72
5.2	Daylight parametri i efekat na metrike (2018–2022).	79
5.3	Osnovne karakteristike baznog modela M1–A1	85
5.4	Performanse modela M1–A1 i referentnim modela u GHI domenu (daytime uzorci, $H = 1$ h).	85
5.5	Energetske performanse (satni nivo, 2022) u odnosu na merenu proizvodnju.	89
5.6	Najbolje rangirane konfiguracije ANN modela M1–A1 za horizont $H = 1$ h.	93
5.7	Poređenje referentne i optimizovane konfiguracije (test skup, $H = 1$ h).	94
5.8	Uticaj dužine lag-prozora L na performanse modela M1–A2 (GHI domen, test skup 2022).	98
5.9	Uporedne karakteristike modela u GHI domenu za vedre i promenljive/oblačne dane (test skup 2022).	105
5.10	Promena $nRMSE$ u zavisnosti od režima neba (test 2022).	106
5.11	Poređenje M1-A1b i optimalnog M1-A2 modela (GHI i PR-bazirana energetska domena, test skup 2022).	108
5.12	Najbolje rangirane konfiguracije tokom optimizacije M2 modela na osnovu srednje validacione vrednosti $nRMSE$	115
5.13	Sintezna komparativna analiza metodoloških pristupa M1 i M2.	136
5.14	Poređenje performansi modela M1 i M2 na test skupu.	136

6.1 Povezanost identifikovanih naučnih doprinosa sa odgovarajućim poglavljima disertacije.	142
A.1 Ulazne pretpostavke za proračun LCOE (po 1 kW _p).	143
A.2 Osetljivost LCOE na diskontnu stopu r i početni prinos E_1 ($C_{total} = 900 \text{ €/kW}_p$).	144
A.3 Osetljivost LCOE na CAPEX i početni prinos E_1 (fiksno $r = 7\%$).	144
B.1 Komparativna analiza algoritama <code>trainlm</code> , <code>trainscg</code> i <code>trainbr</code>	150
C.1 Metrike i evaluacioni kriterijumi korišćeni za procenu performansi ANN modela	153
K.1 Rangiranje validnih konfiguracija modela M1–A1 za $H = 1$ h. Normalizacija je izvršena isključivo na osnovu trening skupa (2005–2020), a selekcija uzoraka sprovedena je u skladu sa IEC 61724-1 (dnevni režim).	194
L.1 Najbolje rangirane konfiguracije tokom optimizacije modela M2 (srednje vrednosti kroz dva ponavljanja).	197
L.2 Kompletni rezultati optimizacije M2 modela.	197
6.3 Pregled publikovanih radova kandidata sa odgovarajućim kategorijama i bodovima.	214

Napomena o strukturi rada

Struktura ove doktorske disertacije je organizovana hijerarhijski, u skladu sa standardnom akademskom praksom koja se odnosi na tehničke i inženjerske nauke. Najviši nivo organizacije su **poglavlja**, koja predstavljaju tematski zaokružene celine disertacije. Poglavlja su dalje podeljena na **odeljke** ili **sekcije**, koji sistematizuju pojedine koncepte, metodološke korake ili rezultate.

U okviru odeljaka, detaljnija razrada pojedinih aspekata data je kroz **pododeljke** ili **podsekcije**, dok se po potrebi koristi i dodatni nivo hijerarhije u vidu pod-pododeljaka. Numeričko označavanje prati hijerarhijsku strukturu (npr. 2, 2.2, 2.2.1), pri čemu svaka naredna cifra označava niži nivo razrade unutar nadređene celine.



U tekstu rada, reference na pojedine delove disertacije navode se u skladu sa ovom strukturom (npr. „videti Odeljak 2.2” i „videti Sekciju 2.2” ili „kao što je dato u Pododeljku 2.2.1” i „kao na primer u Podsekciji 2.2”).

Zahvalnica

Ova doktorska disertacija ne bi nastala bez ljudi koji su me tokom svih ovih godina pratili, podržavali i verovali u mene. Tokom procesa rada, učenja i istraživanja imao sam privilegiju da budem okružen brojnim ljudima čija je podrška, pomoć i razumevanje ostavila dubok trag na ovom putu. Ovu stranicu posvećujem upravo njima.

Pre svega, želim da izrazim iskrenu i duboku zahvalnost svom mentoru, prof. dr Sanji Aleksić, na stručnoj podršci, savetima i neprocenjivom strpljenju tokom izrade ovog rada. Hvala Vam što ste me usmeravali, ohrabrivali i nesebično delili svoje znanje i iskustvo. Vaša posvećenost nauci i obrazovanju ostavila je snažan utisak na mene.

Zahvaljujem se i članovima komisije na vremenu koje su posvetili oceni mog rada, kao i na dragocenim komentarima i sugestijama koje su doprinele njegovom unapređenju.

Veliko hvala mojim kolegama i saradnicima sa Elektronskog fakulteta u Nišu na deljenju ideja, pomoći pri rešavanju problema i na brojnim razgovorima koji su često bili podsticaj za nova razmišljanja i ideje. Posebnu zahvalnost dugujem koleginicama sa Prirodno-matematičkog fakulteta u Nišu, koje su mi nesebično pružile pomoć u radu i omogućile pristup svojim eksperimentalnim merenjima i rezultatima, što je dalo značajan doprinos ovom istraživanju i njegovoj eksperimentalnoj osnovi.

Tokom pripreme rukopisa koristio sam i savremene digitalne alate zasnovane na metodama veštačke inteligencije. Njihova pomoć u organizaciji pojedinih delova teksta, proveri formulacija i tehničkoj pripremi rukopisa doprinela je jasnijem oblikovanju ideja i efikasnijem procesu pisanja ove disertacije.

Prijateljima, hvala što ste verovali u mene čak i onda kada sam ja sumnjao. Vaše razumevanje, podrška i trenuci opuštanja davali su mi snagu u periodima kada je bilo najteže.

Na kraju, ali najvažnije, beskrajno hvala mojoj porodici. Hvala vam što ste uvek bili uz mene, što ste me bodrili, slušali i sa razumevanjem prihvatili sve izazove i odricanja koja je ovaj put nosio. Posebno hvala mojoj majci i ocu na neprekidnoj podršci i beskrajnoj veri u mene. Vaša snaga, posvećenost i ljubav temelj su svega što sam do sada postigao.

„Zahvalnost nije samo izraz pristojnosti ili društvene norme, već duboka svest o međuzavisnosti i povezanosti svih nas. Ona nas podseća da nijedan uspeh nije postignut sam, već u mreži podrške, razumevanja i ljubavi. Kroz zahvalnost pronalazimo snagu da se uzdignemo iznad izazova i da cenimo svaki korak na našem putu.“
— nepoznati autor

Aleksandar Pantić
Niš, mart 2026. godine

Lista skraćenica

Akronim	Engleski	Srpski
OIE	Renewable Energy Sources	Obnovljivi izvori energije
PV	Photovoltaic	Fotonaponski
MPPT	Maximum Power Point Tracking	Praćenje tačke maksimalne snage
I/V	Current-Voltage	Struja-napon
AI	Artificial Intelligence	Veštačka inteligencija
ANN	Artificial Neural Network	Veštačka neuronska mreža
ML	Machine Learning	Mašinsko učenje
RMSE	Root Mean Square Error	Koren srednje kvadratne greške
MAE	Mean Absolute Error	Srednja apsolutna greška
STC	Standard Test Conditions	Standardni test uslovi
NOCT	Nominal Operating Cell Temperature	Nominalna radna temperatura ćelije
GHI	Global Horizontal Irradiance	Globalno horizontalno zračenje
DNI	Direct Normal Irradiance	Direktno normalno zračenje
POA	Plane of Array Irradiance	Zračenje u ravni modula
PR	Performance Ratio	Odnos performansi
LCOE	Levelized Cost of Energy	Nivelisana cena energije
PVsyst	PVsyst Simulation Software	PVsyst softver za simulaciju
MATLAB	Matrix Laboratory	MATLAB programski jezik
BOS	Balance of System	Pomoćna oprema sistema
DC	Direct Current	Jednosmerna struja
AC	Alternating Current	Naizmenična struja
IoT	Internet of Things	Internet stvari
DT	Decision Tree	Stablo odlučivanja
EMS	Energy Management System	Sistem upravljanja energijom
SOC	State of Charge	Nivo napunjenosti
DL	Deep Learning	Duboko učenje
BMS	Battery Management System	Sistem upravljanja baterijama
EMS	Energy Management System	Sistem za upravljanje energijom

Lista simbola i konstanti

Simbol	Definicija	Jedinica
$A_{\lambda T}$	Ukupna apsorpciona moć	–
I	Solarno zračenje (irradiance)	W/m ²
G	Intenzitet sunčevog zračenja	W/m ²
G_{POA}	Intenzitet sunčevog zračenja u ravni modula	W/m ²
T	Temperatura ćelije	°C ili K
T_a	Temperatura okoline	°C ili K
T_c	Temperatura ćelije	°C ili K
V_{oc}	Napon na otvorenom kolu	V
I_{sc}	Struja kratkog spoja	A
P_{max}	Maksimalna izlazna snaga modula	W
η	Efikasnost modula	–
k	Bolcmanova konstanta	1.380649×10^{-23} J/K
q	Elementarni naboj	$1.602176634 \times 10^{-19}$ C
R_s	Serijski otpornik modula	Ω
R_{sh}	Paralelni otpornik modula	Ω
I_0	Reverzna saturaciona struja diode	A
n	Ideality factor diode	–
E_g	Energijski presek poluprovodnika	eV
λ	Talasna dužina svetlosti	nm
Φ	Foton-fluks	1/(m ² s)
C	Koeficijent temperaturne zavisnosti	–
P_{el}	Električna snaga sistema	W
τ	Vreme trajanja	s
ρ	Gustina materijala	kg/m ³
d	Debljina sloja	m
S	Površina modula	m ²
V	Napon	V
I	Struja	A

P	Električna snaga	W
R	Otpor	Ω
C_p	Specifična toplota pri konstantnom pritisku	J/(kg·K)
GHI	Globalno horizontalno zračenje	W/m ²
DNI	Direktno normalno zračenje	W/m ²
DHI	Difuzno horizontalno zračenje	W/m ²
WS	Brzina vetra	m/s
RH	Relativna vlažnost	%
P_{atm}	Atmosferski pritisak	Pa



1. Uvod

Obnovljivi izvori energije (OIE), koji obuhvataju energiju sunca, vetra, vode, geotermalne izvore, energiju biomase, talasa, plime i oseke, predstavljaju veoma važnu komponentu u procesu energetske tranzicije ka održivim i ekološki prihvatljivim izvorima energije. Ovo se posebno odnosi na globalne izazove povezane sa klimatskim promenama, smanjenjem emisije ugljen-dioksida (CO_2) i smanjenjem zavisnosti od fosilnih goriva, tako da istraživanja u oblasti OIE, kao i njihova eventualna eksploatacija, postaju prioritet mnogih država. Korišćenje i eksploatacija OIE ima brojne prednosti, od kojih su svakako najznačajnije smanjenje emisija gasova sa efektom staklene bašte, odgovorno i održivo korišćenje prirodnih resursa, kao i razvoj novih tehnologija i otvaranje novih radnih mesta u sektoru zelene energije.

1.1 Energetska tranzicija u globalnom kontekstu

Savremeni globalni energetska sistem nalazi se u procesu duboke transformacije, uslovljene sve izraženijim klimatskim promenama, kontinuiranim rastom potrošnje energije i imperativom dekarbonizacije privrednih sistema. Iako fosilna goriva, kao što su: uglj, nafta i gas, i dalje čine dominantan deo svetskog energetska miksa, njihova upotreba je praćena značajnim emisijama ugljen-dioksida (CO_2), koje doprinose intenziviranju efekta staklene bašte i globalnom porastu temperature.

U tom kontekstu, tokom poslednje decenije zabeležen je ubrzan prelazak ka obnovljivim izvorima energije (OIE), koji se sve češće prepoznaju kao jedan od ključnih elemenata održivog razvoja, smanjenja emisija gasova sa efektom staklene bašte i unapređenja dugoročne energetske bezbednosti.

Investicije u čistu energiju

U svetu se poslednjih godina beleži značajan porast interesovanja za ulaganja u istraživanja, koja se pre svega odnose na razvoj novih tehnologija povezanih sa eksploatacijom obnovljivih izvora energije. Na slici 1.1, prikazan je trend globalnih ulaganja u čistu energiju u poređenju sa fosilnim gorivima, izražen u trilionima dolara (T\$), za period od 2015. do 2025. godine [1], [2].

Ulaganja u čistu energiju su podeljena na sledeće sektore:

- **Obnovljivi izvori energije (Renewables)** – prikazana tamnoplavom bojom, koji obuhvataju solarne, vetro i druge niskougljenične tehnologije.
- **Elektrifikacija i poboljšanje efikasnosti (Electrification and efficiency improvements)** – označena zelenom bojom, koja uključuju električna vozila, toplotne pumpe i energetske efikasne uređaje.
- **Mreže i skladištenje energije (Grids & storage)** – predstavljena ljubičastom bojom, koja uključuju ulaganja u elektroenergetske mreže i baterijske sisteme.
- **Nuklearna energija (Nuclear)** – prikazana žutom bojom.
- **Goriva sa niskim emisijama (Low-emission fuels)** – data crvenom bojom, i ovde se ubrajaju biogoriva, zeleni vodonik i slično.

Pored stubičastog grafikona nalazi se linijski grafikon koji prikazuje iznos **ulaganja u fosilna goriva (oil + gas + coal)**, označen smeđom linijom. Može se primetiti:

- Pad ulaganja u fosilna goriva od 2015. do 2020. godine.
- Blagi oporavak nakon 2021. godine, ali ostaju ispod nivoa iz 2015. godine.


Na globalnom nivou ulaganja u čistu energiju premašila su 2023. godine iznos od 1,7 triliona dolara, dok se do 2025. godine očekuje rast na oko 2 triliona dolara godišnje. Struktura tih investicija prikazana je na slici 1.1, gde se jasno vidi preusmeravanje kapitala sa fosilnih goriva ka tehnologijama niskih emisija — obnovljivim izvorima, elektrifikaciji, mrežama i skladištima energije.

Iz grafika se mogu uočiti sledeći ključni trendovi:

- **Pad investicija u fosilne izvore** između 2015. i 2020. godine, praćen stagnacijom i delimičnim oporavkom nakon 2021. godine;
- **Stalan rast ulaganja u čistu energiju**, naročito u oblasti solarne i vetroenergije, elektrifikacije transporta, baterijskih sistema i mrežne infrastrukture;
- **Značajan pomak kapitala ka niskougljeničnim tehnologijama**, koje čine dominantan deo globalnih energetske ulaganja od 2022. godine.

Ekonomska konkurentnost tehnologija

Kada se radi o prednostima korišćenja obnovljivih izvora energije važno je posmatrati parametar koji se naziva nivelisani trošak energije (LCOE) (engl. *Levelized Cost of Energy*), koji predstavlja ekonomsku meru ukupnih troškova proizvodnje energije tokom životnog



Slika 1.1: Globalna ulaganja u čistu energiju po sektorima i poređenje sa ulaganjima u fosilna goriva (nafta, gas i ugalj) u periodu 2015–2025 [3], [4].

veka određenog energetskeg sistema, izraženih po jedinici proizvedene energije (npr. po kWh ili MWh). Drugim rečima, LCOE pokazuje prosečan trošak proizvodnje jednog kilovat-sata energije, uključujući sve relevantne troškove i faktore tokom celog perioda rada postrojenja, kao što su:

- **Kapitalni troškovi (CAPEX)** – inicijalna ulaganja u izgradnju i instalaciju energetskeg postrojenja.
- **Operativni i troškovi održavanja (OPEX)** – redovni troškovi rada, održavanja, popravki i upravljanja tokom rada postrojenja.
- **Troškovi goriva** (ako postoje) – za postrojenja koja koriste gorivo.
- **Vek trajanja postrojenja** – ukupno vreme u godinama tokom kog postrojenje proizvodi energiju.
- **Proizvodnja energije** – ukupna količina energije koju postrojenje proizvede tokom celog perioda rada (životnog veka).
- **Diskontna stopa** — parametar koji se koristi za diskontovanje budućih troškova i prihoda na sadašnju vrednost, kako bi se u ekonomskoj analizi pravilno uzela u obzir vremenska vrednost novca.

Nivelisani trošak energije predstavlja prosečan trošak proizvodnje energije tokom

čitavog veka trajanja postrojenja i omogućava direktno poređenje različitih tehnologija:

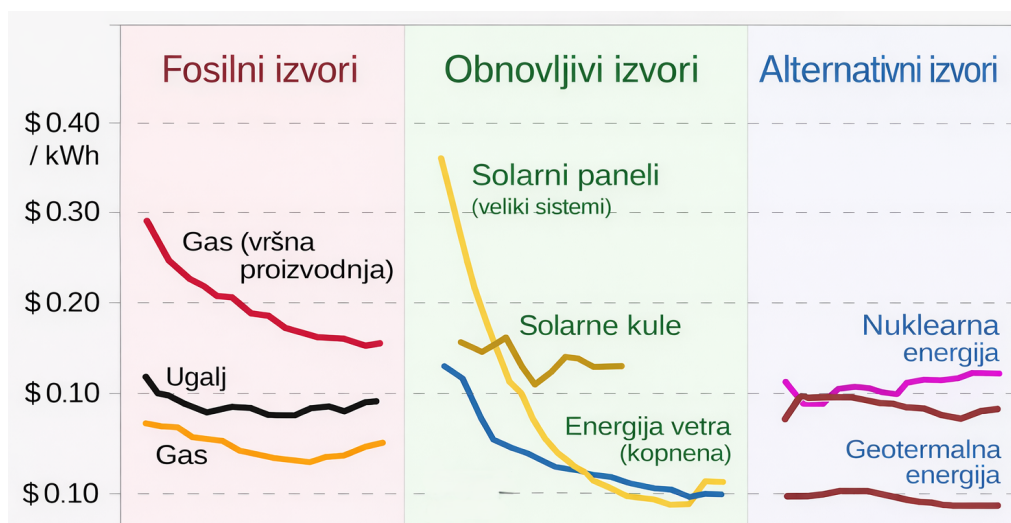
$$\text{LCOE} = \frac{\sum_{t=0}^N \frac{C_t}{(1+r)^t}}{\sum_{t=0}^N \frac{E_t}{(1+r)^t}}, \quad (1.1)$$

gde su:

- C_t – ukupni troškovi u godini t ,
- E_t – proizvedena energija u godini t ,
- r – diskontna stopa,
- N – broj godina života postrojenja.

Reprezentativni primer proračuna nivelisanog troška električne energije (LCOE) za mrežno povezani PV sistem u Srbiji (referentno: Niš region) je dat u Prilogu A. Važno je napomenuti da niža vrednost LCOE označava isplativiju i konkurentniju tehnologiju.

Na slici 1.2 prikazan je trend LCOE za različite energetske tehnologije u periodu 2009–2024. Uočava se da su solarne i vetroelektrane u tom periodu ostvarile pad troškova od preko 80%, čime su postale najkonkurentniji izvori nove, “zelene”, električne energije na globalnom nivou.



Slika 1.2: Nivelisani trošak energije (LCOE) za različite tehnologije u periodu 2009–2024. godine [5], [6].

Na grafiku su prikazane tri kategorije tehnologija:

1. Fosilna goriva (Fossil)

- **Gas (vršni režim rada)** – crvena linija, fleksibilne gasne elektrane koje služe za balansiranje sistema i pokrivanje vršnog opterećenja, naročito u sistemima sa visokim udelom varijabilnih obnovljivih izvora energije: visoka cena, iako opada od 2009. godine, i dalje iznad \$0.15/kWh.
- **Ugalj** – crna linija: stabilna cena oko \$0.10/kWh.

- **Gas** – narandžasta linija: pad do 2020. godine, potom blagi porast.
2. Obnovljivi izvori (Renewable)
- **Velike solarne elektrane (engl. utility scale)** – svetložuta linija: najveći pad, sa preko \$0.35/kWh na manje od \$0.05/kWh.
 - **Solarne kule (engl. solar towers)** – zlatna linija: veće oscilacije, ali blagi pad, i dalje skuplje od solarnih panela.
 - **Vetroparkovi na kopnu (engl. onshore wind)** – plava linija: pad sa oko \$0.15 na ispod \$0.05/kWh, predstavljaju visoko konkurentnu tehnologiju.
3. Alternativne tehnologije (Alternative)
- **Nuklearna energija** – roze linija: cena blago raste, trenutno je preko \$0.15/kWh.
 - **Geotermalna energija** – braon linija: stabilna i niska cena, ispod \$0.10/kWh.

Iz prikazanih podataka se može izvući nekoliko važnih zaključaka:

- trošak solarne energije opao je sa preko \$0.35/kWh na manje od \$0.05/kWh, dok je vetroenergija dostigla sličan nivo;
- fosilne tehnologije (ugalj, gas) zadržavaju LCOE u rasponu \$0.10–0.20/kWh, što ih čini manje konkurentnim u novim investicijama;
- alternativne tehnologije (nuklearna i geotermalna) beleže stabilne, ali znatno više troškove proizvodnje.


Rast kapaciteta obnovljivih izvora energije

Prema izveštajima Međunarodne agencije za energiju (IEA), smanjenje troškova i rast investicija doveli su do ubrzanog povećanja ukupnog instaliranog kapaciteta OIE u svetu. Na slici 1.3 prikazan je godišnji dodatak instaliranih kapaciteta po tehnologijama, u gigavatima (GW), za period 2012–2024. godina.

Dodati kapaciteti su podeljeni po vrstama obnovljivih izvora:

- **Utility solar** (žuta) – velike solarne elektrane, najbrže rastući segment.
- **Distribuisana solarna energija (Distrib. Solar)** (narandžasta) – krovne solarne instalacije i manji decentralizovani sistemi.
- **Vetrogeneratori na kopnu** (svetloplava) – značajan doprinos ukupnom kapacitetu.
- **Vetrogeneratori na moru** (tamnoplava) – manji ali konstantan, postojan rast.
- **Hidroenergija** (tirkizna) – stabilan doprinos bez većih fluktuacija.
- **Biomasa** (braon) – najmanji i stabilan udeo.

Ukupni godišnji dodatak instaliranih kapaciteta porastao je sa oko 150 GW 2015. godine na više od 450 GW u 2024., pri čemu više od 70% čine solarna i vetroenergija, dok hidroenergija i biomasa održavaju stabilan, ali manji udeo. Ovi podaci potvrđuju da obnovljivi izvori energije postaju ne samo ekološki, već i ekonomski najisplativiji vid proizvodnje električne energije u svetu.



Slika 1.3: Godišnji dodatak instaliranih kapaciteta iz obnovljivih izvora energije u svetu (projekcije za 2023 i 2024) [4].

1.2 Stanje i trendovi u Republici Srbiji

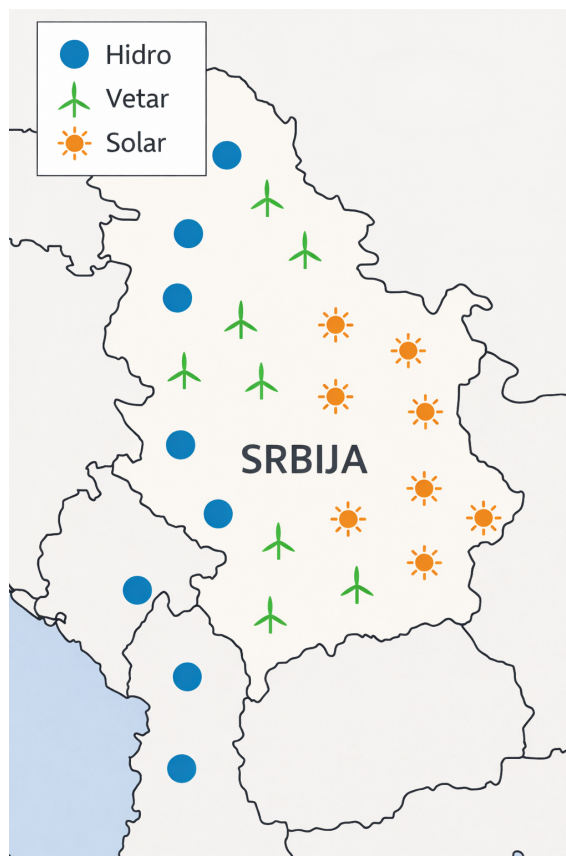
Energetski sektor Republike Srbije nalazi se u fazi postepene tranzicije ka održivom i niskougljeničnom modelu razvoja. Iako fosilna goriva, pre svega lignit, i dalje imaju dominantnu ulogu u strukturi proizvodnje električne energije, u poslednjoj deceniji zabeležen je rast interesovanja za obnovljive izvore energije, praćen povećanjem investicija u nove proizvodne kapacitete. Ovaj trend je u velikoj meri uslovljen preuzetim međunarodnim obavezama, procesom usklađivanja sa energetsom i klimatskom politikom Evropske unije, kao i potrebom za modernizacijom postojećeg elektroenergetskog sistema.

Struktura i kapaciteti obnovljivih izvora energije

U ukupnoj proizvodnji električne energije Srbije, obnovljivi izvori učestvuju sa oko 30–35%, pri čemu je hidroenergija i dalje dominantna, sa udelom većim od 25% u ukupnom miksu. Tokom poslednje decenije zabeležen je značajan napredak u oblasti vetroenergije: ukupna instalisana snaga vetrolektrana premašila je 500 MW, a u završnoj fazi realizacije nalazi se više novih projekata ukupne snage preko 800 MW [7], [8].

Razvoj PV elektrana bio je sporiji, ali poslednje tri godine beleže eksponencijalni rast interesa investitora. Do sredine 2024. godine u pogonu je više od 150 MW PV kapaciteta, dok su u fazi izgradnje ili pripreme projekti ukupne snage iznad 1 GW, uključujući nekoliko velikih elektrana u južnoj i istočnoj Srbiji (npr. Aleksinac, Vranje, Svilajnac, Niš region). Očekuje se da će do 2030. godine ukupan instalisani PV kapacitet dostići 1,5–2 GW, čime bi solarna energija postala drugi najzastupljeniji obnovljivi izvor u zemlji [9], [10].

Pored vetra i sunca, Srbija poseduje značajne potencijale i za biomasu (procene: 3,4 Mtoe



Slika 1.4: Prostorna raspodela glavnih projekata obnovljivih izvora energije u Srbiji (hidro, vetar, solar) prema podacima za 2024. godinu.

godišnje), geotermalne izvore (posebno u južnoj i centralnoj Srbiji), kao i male hidroelektrane. Ipak, iskorišćenost ovih resursa je još uvek ograničena, zbog nedostatka infrastrukture, investicionih mehanizama i nedovoljno razvijene regulative.

Posebno značajan potencijal za razvoj PV sistema identifikovan je u regionu južne i jugoistočne Srbije, uključujući šire područje Niša i Nišavskog okruga. Ovaj region karakterišu povoljne solarne resurse, sa prosečnim godišnjim globalnim horizontalnim zračenjem u opsegu od 1350 do 1550 kWh/m², što ga svrstava među najpovoljnije oblasti za eksploataciju solarne energije u Republici Srbiji [11], [12].

Prema dostupnim studijama i razvojnim dokumentima, područje Niša pokazuje izražen potencijal za realizaciju velikih PV elektrana, ali i za decentralizovane sisteme na industrijskim i stambenim objektima. Analize zasnovane na GIS alatima i višekriterijumskom odlučivanju ukazuju da su lokacije u južnoj i istočnoj periferiji grada Niša, kao i područja ka Aleksincu i Svrljigu, posebno pogodne za izgradnju PV postrojenja srednje i velike snage [13].

Pored tehničkog potencijala, region Niša ima i strateški značaj u pogledu razvoja istraživačke i obrazovne infrastrukture u oblasti obnovljivih izvora energije. Aktivnosti istraživačkih grupa sa Elektronskog fakulteta Univerziteta u Nišu obuhvataju analize

performansi PV sistema, modelovanje proizvodnje električne energije i razvoj metoda zasnovanih na veštačkoj inteligenciji za predviđanje solarnih resursa, što dodatno doprinosi validaciji i optimizaciji budućih projekata u ovom regionu [14], [15], [16], [17], [18], [19].

Regulatorni okvir i podsticaji

Reforma zakonodavnog okvira u oblasti energetike započeta je donošenjem novog *Zakona o korišćenju obnovljivih izvora energije (2021)*, kojim su uvedeni savremeni mehanizmi podsticaja:

- sistem aukcija za dodelu tržišnih premija (feed-in premium);
- podsticaji za investitore u projekte do 1 MW;
- mogućnost statusa kupca–proizvođača (*engl. prosumer*) za domaćinstva i privredu;
- obaveza integracije OIE u lokalne planove energetskeg razvoja.

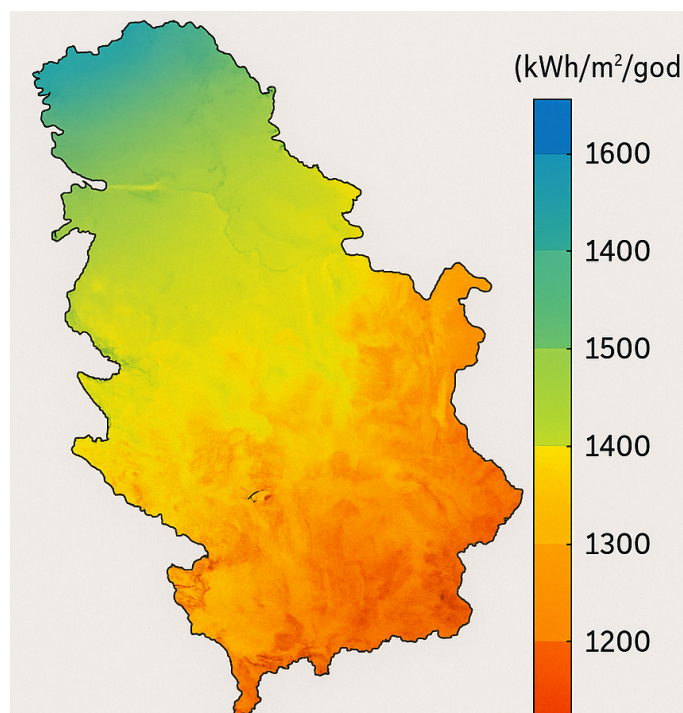
Ovi mehanizmi omogućili su značajno ubrzanje razvoja solarne energije, naročito kroz decentralizovane, krovne PV sisteme i industrijske elektrane za sopstvenu potrošnju. Međutim, i dalje postoje ograničenja u domenu priključenja novih kapaciteta, tehničkih uslova za balansiranje mreže i nepostojanja centralizovanog sistema za integraciju meteoroloških podataka i prognoza proizvodnje OIE.

Izazovi i mogućnosti daljeg razvoja

Razvoj obnovljivih izvora energije (OIE) u Srbiji suočava se sa nizom tehničkih, institucionalnih i infrastrukturnih ograničenja. Najznačajniji među njima odnose se na:

- **nedovoljnu fleksibilnost elektroenergetske mreže** i ograničene kapacitete za skladištenje energije, što otežava balansiranje varijabilnih izvora poput sunca i vetra;
- **nedostatak pouzdanih lokalnih meteoroloških podataka** i odsustvo integrisanih sistema za kratkoročno i dugoročno predviđanje proizvodnje energije;
- **ograničenu primenu naprednih metoda veštačke inteligencije** u analizi podataka, modelovanju i optimizaciji rada energetskeg postrojenja;
- **nedovoljno razvijene digitalne modele** (*digital twins*), koji bi omogućili dinamičko praćenje performansi i optimizaciju proizvodnje u realnom vremenu.

Ovi izazovi istovremeno predstavljaju i ključne pravce daljeg razvoja ka integraciji savremenih informacionih tehnologija, digitalizaciji elektroenergetskeg sistema i većoj upotrebi metoda mašinskog učenja u predviđanju i upravljanju energetskeg tokovima. Potrebni su tačni, adaptivni i pouzdani modeli predviđanja proizvodnje energije iz PV sistema, koji bi doprineli efikasnijem planiranju investicija, stabilnijem radu mreže i bržoj integraciji Srbije u regionalno i evropsko energetskeg tržište.



Slika 1.5: Mapa GHI za Srbiju: prosečne godišnje vrednosti prema bazi PVGIS (2005-2022) [20].

1.3 Motivacija i značaj istraživanja

PV sistemi danas predstavljaju jedan od ključnih stubova globalne tranzicije ka održivim izvorima energije. Njihova primena ubrzano raste zahvaljujući smanjenju troškova proizvodnje i cene PV modula, razvoju naprednih materijala i širenju tržišta obnovljive energije. Ipak, uprkos značajnom tehnološkom napretku, tačno predviđanje proizvodnje energije PV sistema i dalje predstavlja jedan od najvećih izazova u procesu integracije obnovljivih izvora u elektroenergetske mreže.

Motivacija

Proizvodnja električne energije iz PV sistema direktno je zavisna od promenljivih meteoroloških uslova: GHI, difuzne i direktne komponente zračenja, temperature okoline i PV modula, brzine vetra i albeda površine. Ove veličine su prostorno i vremenski nestabilne, što dovodi do značajnih oscilacija u generisanoj izlaznoj snazi PV sistema i otežava pouzdano planiranje i predviđanje proizvedene energije i njihovu integraciju u elektroenergetsku mrežu. Tradicionalni pristupi predviđanju proizvodnje PV sistema zasnivaju se na:

- korišćenju tipičnih meteoroloških godina (TMY) iz baza kao što su PVGIS i Meteonorm;
- fizičkim i empirijskim modelima implementiranim u softverskim alatima poput PVsyst-a;
- klasičnim statističkim metodama, kao što su linearna i višestruka regresija, ARIMA

modeli i eksponencijalno izravnavanje [21].

Iako ovi pristupi daju zadovoljavajuće rezultate u dugoročnim analizama, njihova tačnost je ograničena u kratkoročnim prognozama, posebno na satnom i višesatnom horizontu (od jednog do nekoliko sati), koje su ključne za operativno upravljanje sistemom i tržišno planiranje. Pored toga, većina komercijalnih softverskih rešenja ne omogućava integraciju višestrukih izvora podataka i primenu naprednih metoda veštačke inteligencije (VI) i mašinskog učenja (ML).

U okviru klasičnih statističkih pristupa, posebno mesto zauzimaju linearni i višestruki regresioni modeli, vremenski serijski modeli tipa ARIMA, kao i metode eksponencijalnog izravnavanja. Regresioni modeli polaze od pretpostavke linearne zavisnosti između izlazne veličine (snage ili energije PV sistema) i odabranih meteoroloških parametara, kao što su globalna horizontalna irradiance, temperatura vazduha i brzina vetra, i često se koriste kao referentni modeli zbog svoje jednostavnosti i interpretabilnosti.

Vremenski serijski modeli, poput ARIMA pristupa [21], fokusirani su na modelovanje autokorelacije u istorijskim podacima, pri čemu se buduće vrednosti procenjuju isključivo na osnovu prethodnih posmatranja. Iako ovi modeli mogu ostvariti zadovoljavajuće performanse u vrlo kratkoročnim horizontima predviđanja, njihova primenljivost u kontekstu PV sistema je ograničena, jer ne omogućavaju eksplicitnu integraciju fizičkih i meteoroloških uzroka naglih promena proizvodnje, naročito u uslovima prolazne oblačnosti [22].

Metode eksponencijalnog izravnavanja dodatno pojednostavljaju proces predviđanja dodeljivanjem veće težine novijim podacima, čime se obezbeđuje numerička stabilnost i robusnost modela. Međutim, zbog izraženog nelinearnog i nestacionarnog karaktera sunčevog zračenja i PV izlaza, ove metode imaju ograničenu sposobnost da prate brze promene, što ih čini pogodnim prvenstveno za bazna poređenja, ali ne i za precizno operativno predviđanje generisane energije PV sistema.

Navedena ograničenja klasičnih statističkih metoda jasno ukazuju na potrebu za primenom naprednijih pristupa koji mogu da sagledaju nelinearne odnose, višedimenzionalne ulazne podatke i vremensku dinamiku meteoroloških procesa, što predstavlja osnovnu motivaciju za primenu veštačkih neuronskih mreža i hibridnih modela u ovom istraživanju. Zbog toga se javlja potreba za razvojem novih metodoloških pristupa koji povezuju analizu meteoroloških parametara i predviđanje pomoću neuronskih mreža i hibridnih modela, uz jasno definisane referentne (baseline) metode poređenja.

U skladu sa navedenim ograničenjima tradicionalnih i klasičnih statističkih pristupa, u ovoj disertaciji usvojen je višemodelski koncept zasnovan na veštačkim neuronskim mrežama, koji obuhvata tri komplementarna prediktivna modela (M1–M3), prilagođena različitim inženjerskim i eksploatacionim scenarijima. Model M1 namenjen je proceni solarnog potencijala i podršci projektovanju PV sistema u fazi planiranja, oslanjajući se pretežno na dugoročne meteorološke i satelitske podatke. Model M2 fokusiran je na

end-to-end kratkoročno predviđanje izlazne snage PV sistema na satnom i višesatnom horizontu, uz korišćenje lokalnih meteoroloških merenja i vremenskih lagova. Model M3 razmatra scenario ograničene dostupnosti ulaznih podataka, sa ciljem obezbeđivanja robusne prognoze u uslovima kada ne postoje eksperimentalni mereni podaci ili oslanjanja na indirektnu izvore informacija. Ovakva struktura omogućava sistematsko poređenje sa konvencionalnim metodama u svakom od razmatranih scenarija i jasno kvantifikovanje doprinosa pristupa baziranih na primeni veštačkih neuronskih mreža (ANN - *Artificial Neural Network*) u kontekstu tačnosti, stabilnosti i primenljivosti predviđanja.

Značaj istraživanja

Cilj ovog istraživanja jeste razvoj i validacija integrisanog metodološkog okvira za projektovanje, simulaciju i predviđanje performansi PV sistema, koji objedinjuje tri međusobno povezana istraživačka segmenta:

1. **Fizičko i matematičko modelovanje PV ćelija i modula** — zasnovano na relevantnim IEC standardima (IEC 60891), rezultatima numeričkih simulacija (PC1D) i kalibraciji prema eksperimentalnim merenjima;
2. **Analizu i sintezu više izvornih meteoroloških podataka** — integraciju lokalnih merenja sa područja Niša sa satelitskim i reanaliznim bazama podataka (Meteosat, PVGIS, ERA5) koje predstavljaju prostorno i vremenski homogenizovane meteorološke podatke dobijene kombinovanjem merenja i numeričkog modelovanja atmosfere;
3. **Primenu metoda veštačke inteligencije** — razvoj, obuku i evaluaciju ANN modela za satno i višesatno predviđanje proizvodnje PV sistema, uz sistematsko poređenje sa konvencionalnim pristupima.

U okviru disertacije primenjen je višemodelski pristup zasnovan na skupu komplementarnih ANN modela (M1–M3), pri čemu svaki model adresira različite nivoe dostupnosti ulaznih podataka i različite inženjerske scenarije. Model M1 namenjen je proceni solarnog potencijala i podršci fazi planiranja PV sistema, model M2 realizuje *end-to-end* kratkoročnu operativnu prognozu energetskog izlaza, dok je model M3 usmeren na predviđanje u uslovima ograničene mernosti radiometrijskih veličina. Ovakva struktura omogućava dosledno poređenje sa referentnim metodama u svakom od razmatranih scenarija, kao i kvantifikovanje doprinosa ANN pristupa korišćenjem standardizovanih metrika greške (RMSE, nRMSE, nMBE), uključujući sezonsku i dnevnu analizu performansi.

Očekivani rezultati istraživanja doprinose:

- povećanju tačnosti kratkoročnog predviđanja proizvodnje električne energije iz PV sistema;
- unapređenju metodologije projektovanja solarnih postrojenja u realnim klimatskim uslovima Republike Srbije i šireg regiona;

- razvoju smernica za integraciju višezvornih meteoroloških podataka i adaptivnih modela u operativnim scenarijima.

Pored navedenog, u disertaciji se definiše i konceptualni okvir za digitalnog blizanca (*Digital Twin*) PV sistema kao pravac budućih istraživanja. Ovaj koncept predstavlja osnovu za kasniju integraciju prediktivnih modela sa dijagnostičkim i kontrolnim funkcijama, uključujući detekciju odstupanja, analizu degradacije i podršku upravljanju u bliskom realnom vremenu.

Šira relevantnost istraživanja

Razvoj pouzdanih i adaptivnih modela za predviđanje proizvodnje električne energije iz obnovljivih izvora predstavlja jedan od ključnih preduslova za uspešnu realizaciju ciljeva definisanih u okviru *Zelene agende za Zapadni Balkan* i *Strategije energetskeog razvoja Republike Srbije do 2050. godine* [23]. U tom kontekstu, rezultati ovog istraživanja omogućavaju:

- optimizaciju rada postojećih i planiranih PV elektrana;
- unapređenje stabilnosti elektroenergetskog sistema kroz preciznije dnevne i intradnevne prognoze proizvodnje;
- povećanje energetske efikasnosti i smanjenje emisije CO₂;
- jačanje kapaciteta domaćih istraživačkih i industrijskih aktera u oblasti digitalizacije energetike.

Na taj način, ovo istraživanje poseduje ne samo izražen naučni doprinos, već i značajan praktični i društveni uticaj, jer doprinosi ubrzanju energetske tranzicije Republike Srbije i jačanju integracije lokalnih kapaciteta u savremene evropske i globalne energetske tokove.



2. Pregled literature

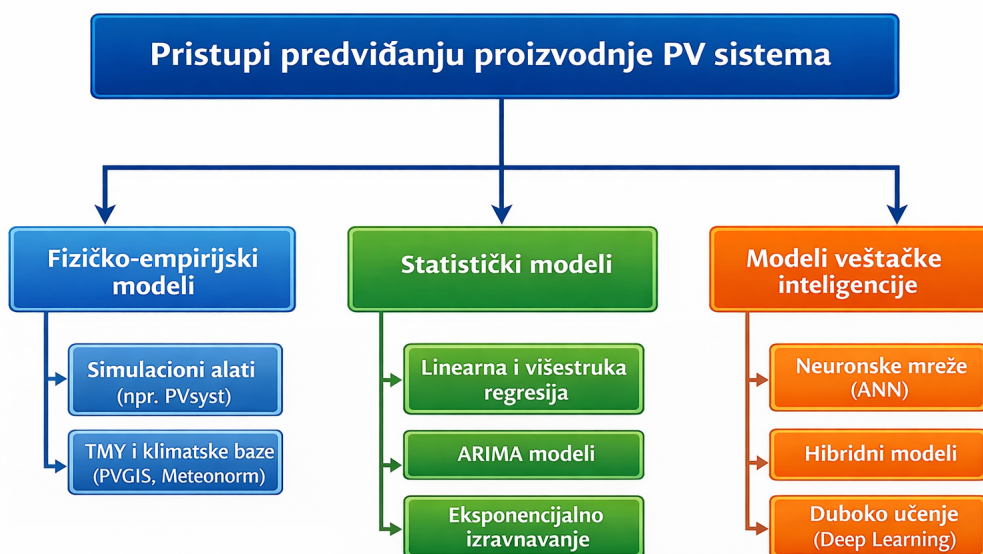
U ovom poglavlju je dat sistematski pregled važnijih dosadašnjih istraživanja u oblasti PV sistema, sa fokusom na modelovanje karakteristika, metode projektovanja i savremene pristupe predviđanju proizvodnje električne energije. Poseban akcenat je stavljen na evoluciju metodologija, od klasičnih fizičkih i empirijskih modela, preko statističkih i data-driven pristupa, do savremenih hibridnih koncepata koji integrišu veštačku inteligenciju i digitalne blizance.

Imajući u vidu rastući udeo PV sistema u elektroenergetskim mrežama, tačnost modelovanja i prognoziranja izlazne snage postaje ključni faktor za pouzdano planiranje, upravljanje i optimizaciju rada sistema. Zbog toga savremena istraživanja teže prelasku sa statičkih, determinističkih proračuna ka adaptivnim i prediktivnim modelima koji mogu da obuhvate vremensku dinamiku meteoroloških uslova, degradaciju komponenti i kompleksne nelinearne odnose između ulaznih i izlaznih veličina.

Na osnovu analize relevantne literature, mogu se identifikovati tri dominantna istraživačka pravca (slika 2.1):

- razvoj i unapređenje fizičkih i empirijskih modela performansi PV ćelija, modula i sistema, sa ciljem preciznog proračuna njihovih karakteristika u realnim radnim uslovima;
- primena metoda mašinskog učenja i veštačkih neuronskih mreža u predviđanju solarne iradijacije i proizvodnje električne energije, naročito u kratkoročnim i višehorizonskim prognozama;
- uvođenje koncepta digitalnog blizanca (*Digital Twin*) u projektovanje, nadzor i optimizaciju PV sistema, kroz integraciju fizičkih modela, merenja i prediktivnih algoritama.

Pregled literature obuhvata radove publikovane u relevantnim međunarodnim časopisima i konferencijskim zbornicima, indeksiranim u bazama *Scopus*, *IEEE Xplore*, *ScienceDirect* i



Slika 2.1: Hijerarhija modela predikcije karakteristika PV sistema.

Web of Science, u periodu od 2010. do 2024. godine. Pretraga je sprovedena korišćenjem ključnih pojmova: *photovoltaic modeling*, *solar forecasting*, *machine learning for PV systems*, *digital twin in solar energy* i *PV system design optimization*.

Struktura poglavlja prati logičan tok, od osnovnih principa i klasičnih modela ka naprednim i integrisanim pristupima. Najpre se razmatraju osnove PV tehnologija i uticaj radnih uslova na karakteristike PV modula, zatim fizički i empirijski modeli koji predstavljaju temelj tradicionalnog projektovanja. Konačno, analiziraju se modeli bazirani na podacima, metode mašinskog učenja i hibridni pristupi, sa posebnim osvrtom na njihovu primenu u predviđanju proizvodnje i razvoju digitalnih blizanaca. Na kraju poglavlja identifikuju se ključna ograničenja postojećih rešenja i istraživačke praznine koje motivišu originalni doprinos ove disertacije.

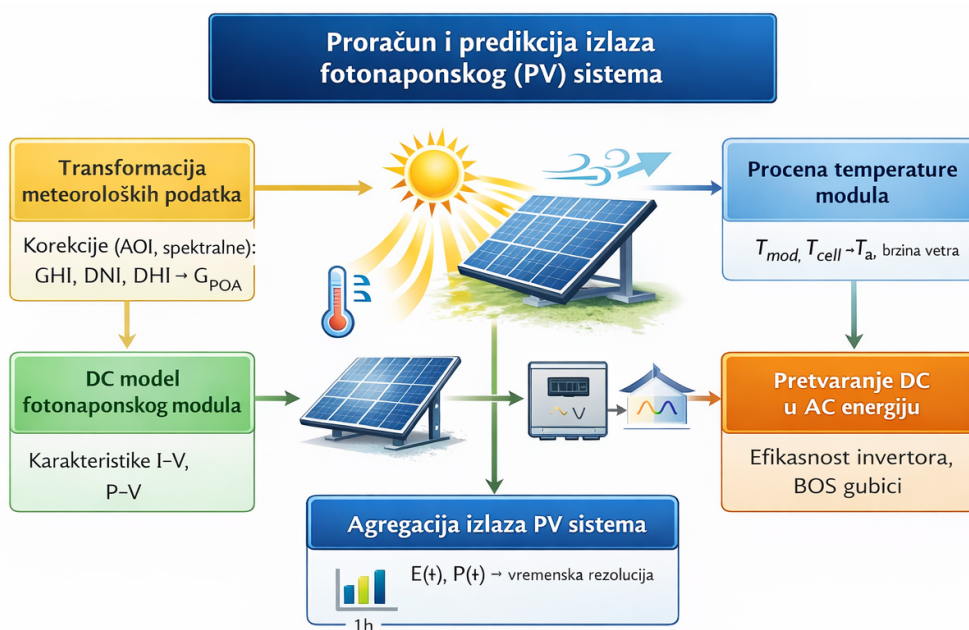
2.1 Fotonaponske (PV) tehnologije

PV konverzija u solarnoj ćeliji zasniva se na interakciji elektromagnetnog zračenja i poluprovodničkog materijala sa formiranim P-N spojem, pri čemu apsorpcija fotona dovodi do generisanja parova elektron-šupljina i pojave električne struje u spoljašnjem kolu. U kontekstu modelovanja PV sistema i prognoziranja proizvodnje energije, razumevanje osnovnih karakteristika PV ćelija i modula predstavlja polaznu tačku za izbor odgovarajuće strukture modela, ulaznih promenljivih i evaluacionih metrika.

U praksi se proračun i predikcija izlaza PV sistema najčešće realizuju kroz niz međusobno povezanih podmodela (slika 2.2):

1. transformacija meteoroloških veličina (GHI , DNI , DHI) u solarno zračenje na ravan modula G_{POA} (POA - *plane-of-array*) uz korekcije upadnog ugla (AOI) i spektralne promene;
2. procena temperature modula i/ili solarne ćelije (T_{mod} , T_{cell}) na osnovu G_{POA} , temperature ambijenta i brzine vetra;
3. DC model modula (npr. jednodiodni/dvodiodni) i proračun $I-V$ i $P-V$ karakteristika;
4. pretvaranje DC u AC energiju uz uzimanje u obzir efikasnosti invertora i sistemskih gubitaka (BOS);
5. agregacija podataka na željenu vremensku rezoluciju, koja podrazumeva ujednačavanje vremenskog koraka i predstavljanje izlaza PV sistema kao srednje snage $P(t)$ ili proizvedene energije $E(t)$ po intervalu, u cilju uporedive analize, verifikacije modela i kratkoročnog predviđanja.

Ovakva dekompozicija na podmodule omogućava jasno razdvajanje fizičkih i empirijskih komponenti i predstavlja prirodan okvir za kasniju integraciju data-driven i hibridnih modela.




Slika 2.2: Proces proračuna i predikcije karakteristika PV sistema.

2.1.1 Princip rada i karakteristike solarnih ćelija

Solarna ćelija radi na principu unutrašnjeg fotoelektričnog efekta u poluprovodniku sa P-N spojem [24]. Kada se foton čija je energija veća od energije koja odgovara širini zabranjene zone poluprovodnika (E_g) apsorbira, generiše se par nosilaca naelektrisanja elektron-šupljina. Unutrašnje električno polje u oblasti osiromašenja oko P-N spoja ra-

zdvaja generisane nosioce naelektrisanja, i na taj način se generiše električna struja koja protiče kroz priključeni potrošač (slika 2.3).

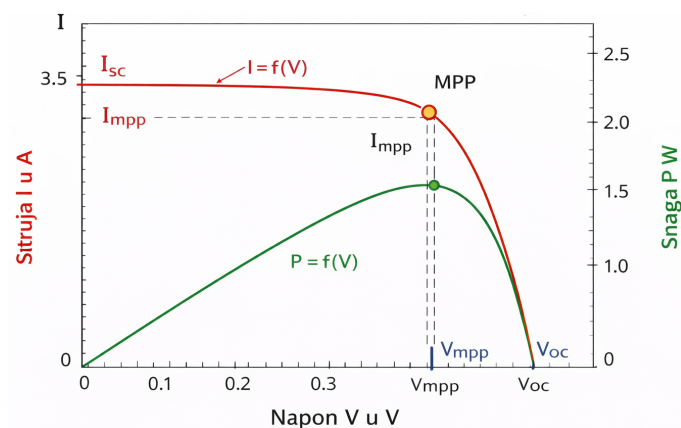


Slika 2.3: Šematski prikaz principa rada solarne ćelije.

Nelinearno ponašanje PV ćelije se u inženjerskoj praksi najčešće opisuje jednodiodnim ekvivalentnim modelom [25], koji uključuje izvor fotostruje I_{ph} , diodu, redni otpor R_s i paralelnu otpornost R_{sh} (slika 2.5):

$$I_{pv} = I_{ph} - I_0 \left(e^{\frac{q(V + I_{pv}R_s)}{nkT}} - 1 \right) - \frac{V_d + I_{pv}R_s}{R_{sh}}. \quad (2.1)$$

U (2.1) I_0 je struja zasićenja diode, n faktor idealnosti diode, q elementarno naelektrisanje, k Bolcmanova konstanta i T apsolutna temperatura. Iz modela se dobijaju karakteristične tačke karakteristika $I - V$ i $P - V$: struja kratkog spoja I_{sc} , napon otvorenog kola V_{oc} i tačka maksimalne snage MPP, definisana kao $P_{MPP} = V_{mpp}I_{mpp}$ (slika 2.4). U realnim uslovima rada, položaj ovih tačaka je funkcija iradijance na ravni modula G_{POA} , temperature solarne ćelije T_{cell} , gubitaka usled serijskih/paralelnih otpornosti i parcijalnog senčenja [26].



Slika 2.4: Karakteristika c-Si solarne ćelije ($I - V$ i $P - V$) sa označenim karakterističnim tačkama.

2.1.2 Tipovi solarnih ćelija i PV modula

Savremene PV tehnologije se, prema materijalu i tehnologiji izrade, mogu grupisati u tri dominantne klase:

1. **Kristalni silicijum (c-Si)** – monokristalne i polikristalne ćelije/moduli, koji dominiraju tržištem zbog tehnološke zrelosti, dugoročnih garancija i visokih komercijalnih efikasnosti (tipično 18-23% na nivou modula).
2. **Tankoslojne tehnologije** – amorfni silicijum (a-Si), CdTe i CIGS, koje generalno nude niže komercijalne efikasnosti (oko 10-15%), ali često bolju toleranciju na difuzno zračenje, niže temperaturne koeficijente i povoljnije performanse pri slabijem osvetljenju.
3. **Nove generacije i napredne konfiguracije** – perovskitne, tandem (npr. perovskit-Si) i bifacijalne tehnologije, kod kojih se očekuje dalje popravljjanje karakteristika kroz povećanje apsorpcije spektra i bolju upotrebu raspoložive površine.

Iz ugla modelovanja i prognoziranja karakteristika, tip tehnologije utiče na temperaturne koeficijente, osetljivost na spektar solarnog zračenja i AOI, degradacione mehanizme, kao i na strukturu gubitaka (npr. LID/LeTID kod c-Si, ili specifične promene parametara pri slabom osvetljenju kod tankoslojnih modula). Zbog toga izbor tehnologije predstavlja relevantan deo definisanja pretpostavki simulacionog modela i interpretacije grešaka prognoze.

2.1.3 Uticaj radnih uslova na karakteristike PV modula

Karakteristike solarnih ćelija i PV modula značajno zavise od spoljašnjih uslova rada, pre svega od intenziteta solarnog zračenja na ravan modula G_{POA} , temperature ćelije T_{cell} , spektralnog sastava solarnog zračenja i upadnog ugla. Porast temperature ima dominantno negativan uticaj na izlaznu snagu, prvenstveno kroz smanjenje V_{oc} i pomeranje radne tačke, što se u praksi opisuje temperaturnim koeficijentom snage γ_p . Tipične vrednosti za c-Si module su reda veličine -0.35 do $-0.45\%/^{\circ}C$, pri čemu konkretna vrednost zavisi od tehnologije i konstrukcije PV modula.

U realnim instalacijama dodatno su prisutni efekti koji odstupaju od idealnih, laboratorijskih, uslova:

- **Parcijalno senčenje** uzrokuje pojavu više lokalnih maksimuma na $P - V$ krivi, povećava rizik od lokalnog pregrevanja (engl. *hot-spot* efekata) i može dovesti do značajnih gubitaka energije čak i pri senčenju malog dela niza.
- **Neusklađenost modula** (engl. *mismatch*) usled tolerancija, degradacije ili neuniformnog osvetljenja uvodi dodatne gubitke na nivou stringa i polja.
- **Zagađenost vazduha i prljanje površine PV modula** (engl. *soiling*) menja efektivnu apsorpciju i uvodi sezonsku komponentu gubitaka.
- **Spektralne i AOI korekcije** postaju posebno bitne pri niskim solarnim elevacijama

i promenljivoj oblačnosti, što je tipično za zimske i prelazne periode. Zbog navedenih efekata, moderni PV sistemi koriste algoritme praćenja tačke maksimalne snage (MPPT - *Maximum Power Point Tracking*) (npr. *perturb-and-observe*, *incremental conductance* i njihove adaptivne varijante) radi kontinuiranog praćenja optimalne radne tačke [27], [28], [29]. U okviru validacije i poređenja performansi, od posebnog značaja je usklađivanje proračuna i merenja sa preporukama relevantnih standarda (IEC 61724-1:2017 [30], IEC 60891:2009 [31]), posebno pri korekciji rezultata na referentne uslove i pri definisanju energetskih pokazatelja i grešaka prognoze.

2.2 Fizički i empirijski modeli PV sistema

Modelovanje karakteristika PV sistema predstavlja osnovu za procenu proizvodnje električne energije, analizu gubitaka i projektovanje pouzdanih energetskih postrojenja. U literaturi su tokom poslednjih decenija razvijeni brojni modeli koji se razlikuju po nivou detalja, potrebnim ulaznim podacima i oblasti primene. Ovi modeli se mogu podeliti na fizičke i empirijske, pri čemu oba pristupa imaju značajnu ulogu u inženjerskoj praksi.

Fizički modeli polaze od fundamentalnih zakona fizike poluprovodnika i termodinamike, dok empirijski modeli koriste statističke i regresione relacije između meteoroloških veličina i izlazne snage sistema. U kontekstu predviđanja proizvodnje i integracije sa savremenim metodama mašinskog učenja, razumevanje prednosti i ograničenja ovih klasičnih pristupa predstavlja neophodan korak ka razvoju naprednih hibridnih modela.

2.2.1 Fizički modeli


Fizički modeli imaju za cilj da verno opišu ponašanje PV ćelija i modula na osnovu poznatih materijalnih i električnih parametara [32]. Njihova osnovna prednost leži u fizičkoj interpretabilnosti, jer omogućavaju analizu uticaja pojedinačnih parametara (temperatura, iradijansa, redne i paralelne otpornosti) na oblik $I - V$ i $P - V$ karakteristika.

Najčešće korišćeni fizički modeli (slika 2.5) uključuju:

- **Jednodiodni model (Single-Diode Model, SDM)** - predstavlja standardni pristup u simulaciji PV ćelija i modula. Model opisuje osnovne mehanizme generacije i rekombinacije nosilaca i široko se primenjuje u komercijalnim i istraživačkim softverskim alatima [33], [34].
- **Dvodiodni model (Two-Diode Model, TDM)** - proširenje SDM-a koje uključuje dodatnu diodu radi preciznijeg opisa rekombinacionih procesa, naročito pri niskim nivoima iradijanse i povišenim temperaturama. Iako daje veću tačnost, zahteva veći broj parametara i složeniju numeričku implementaciju [35], [36].
- **Parametarski modeli modula** - kao što su De Soto i SANDIA modeli, koji koriste kombinaciju fizičkih relacija i empirijskih koeficijenata za korekciju performansi u

zavisnosti od temperature, spektra i ugla upada zračenja [37].

- **Termalni modeli** - namenjeni proceni temperature PV modula i ćelije na osnovu ambijentalnih uslova, pri čemu se često koriste pojednostavljeni izrazi (npr. Faimanov ili NOCT model) radi praktične primene [38].



Slika 2.5: Najčešće korišćeni fizički modeli.


Fizički modeli su naročito pogodni za analizu pojedinačnih PV modula, projektovanje PV sistema i validaciju merenja prema standardnim uslovima. Međutim, njihova primena u realnim operativnim uslovima ograničena je dostupnošću preciznih parametara i nemogućnošću da uzimaju u obzir kompleksne nelinearne efekte izazvane oblačnošću, parcijalnim senčenjem i degradacijom karakteristika tokom vremena.

2.2.2 Empirijski modeli

Empirijski modeli zasnivaju se na eksperimentalno utvrđenim relacijama između meteoroloških veličina i izlazne snage ili energije PV sistema [39]. Za razliku od fizičkih modela, oni ne zahtevaju detaljno poznavanje unutrašnje strukture ćelija, već koriste statističke zavisnosti dobijene regresijom nad istorijskim podacima. Najpoznatiji empirijski pristupi (slika 2.6) su:

- **PVUSA model** - jedan od najranijih i najpoznatijih empirijskih modela, koji povezuje izlaznu snagu sa globalnom iradijansom i temperaturom ambijenta kroz polinomni izraz [40], [41].
- **Linearni i kvazi-linearni modeli snage** - u kojima se pretpostavlja proporcionalnost između iradijance i izlazne snage, uz temperaturnu korekciju pomoću konstantnog koeficijenta [37], [42].

- **Empirijski modeli implementirani u komercijalnim alatima** - kao što su SAM i PVsyst, gde se koriste kombinacije empirijskih korekcija za gubitke usled temperature, prljanja, mismatch-a i degradacije [43], [44].



Slika 2.6: Najčešće korišćeni empirijski modeli.

Glavna prednost empirijskih modela je njihova jednostavnost i mala računaska složenost, što ih čini pogodnim za brze procene i dugoročne energetske analize. Međutim, njihova tačnost je jako zavisna od kvaliteta ulaznih podataka i pravilne kalibracije, dok se sposobnost generalizacije značajno smanjuje u uslovima koji odstupaju od onih u kojima je model formiran.

2.2.3 Uporedna analiza i ograničenja klasičnih pristupa

Uporedne analize iz literature pokazuju da fizički modeli generalno pružaju veću tačnost i bolju interpretabilnost, ali uz cenu veće složenosti i zahteva za parametrima. Empirijski modeli, s druge strane, omogućavaju jednostavnu implementaciju i brze proračune, ali često ne uspevaju da adekvatno opišu nelinearne i vremenski promenljive fenomene u realnim uslovima rada PV sistema. Zajednička ograničenja oba pristupa uključuju:

- statički karakter modela i ograničenu vremensku dinamiku;
- oslanjanje na prosečne ili idealizovane meteorološke uslove;
- smanjenu tačnost pri brzom menjanju oblačnosti i parcijalnom senčenju;
- ograničenu mogućnost adaptacije na degradaciju i promene u PV sistemu.

Zbog navedenih ograničenja, klasični fizički i empirijski modeli sve češće se koriste kao referentni ili pomoćni modeli, dok savremena istraživanja teže razvoju prediktivnih i adaptivnih pristupa zasnovanih na analizi vremenskih serija i mašinskom učenju. Ovi pristupi predstavljaju most ka modelima baziranim na podacima i hibridnim metodama, koje se razmatraju u narednim poglavljima. U Tabeli 2.1 je dat prikaz osnovnih karakteristika

najčešće korišćenih modela u literaturi.

Tabela 2.1: *Uporedni prikaz fizičkih i empirijskih modela performansi PV sistema.*

Model	Tip modela	Ključne karakteristike	Primena
De Soto [33]	Fizički	Parametarski pristup; korekcija I_{sc} i V_{oc} prema G i T	PVLib, MATLAB
SANDIA [37]	Poluempirijski	Empirijski koeficijenti; ugao upada i spektralna korekcija	PVsyst, SAM
Faiman [38]	Termalni	Model temperature modula u realnim uslovima	Terenska merenja
PVUSA [40]	Empirijski	Regresioni odnos $P(G, T)$	Dugoročne analize
SAM [45], [46]	Empirijski/polufizički	Kombinovani pristup, više tehnologija	Energetske simulacije

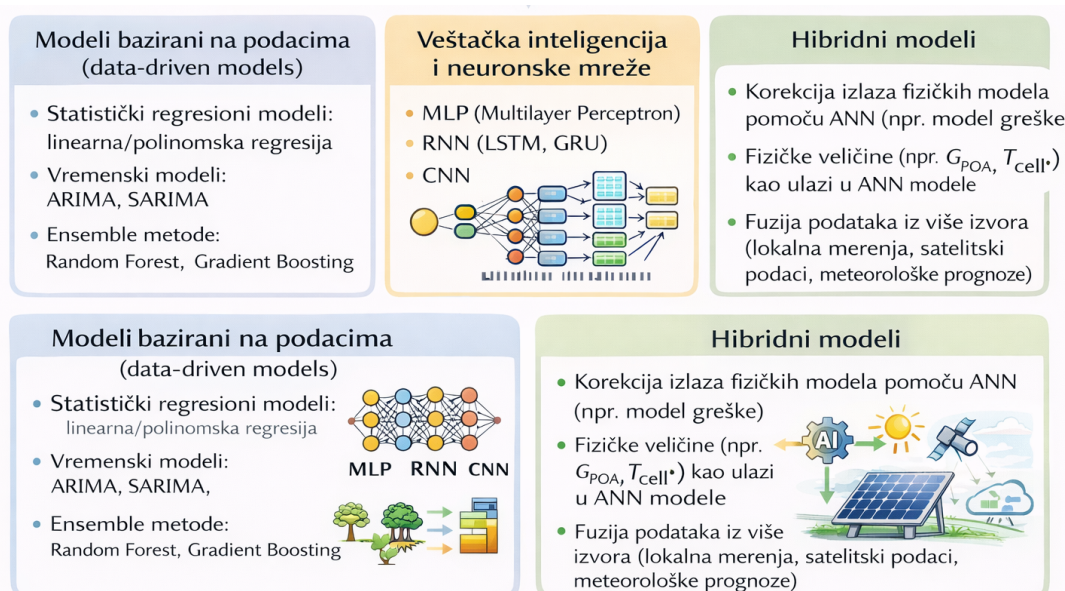
2.3 Prediktivni i hibridni modeli PV sistema

Analiza fizičkih i empirijskih modela pokazuje da, iako ovi pristupi pružaju solidnu osnovu za proračun performansi PV sistema, njihova primenljivost postaje ograničena u uslovima izražene vremenske varijabilnosti meteoroloških parametara, parcijalnog senčenja i nelinearnog ponašanja sistema [39], [42]. Posebno u kontekstu kratkoročnog i višehorizontskog predviđanja proizvodnje energije, klasični modeli teško mogu da obuhvate brze promene iradijance, temperature i oblačnosti koje direktno utiču na izlaznu snagu PV sistema [22].

Zbog toga savremena istraživanja sve više prelaze ka prediktivnim modelima zasnovanim na vremenskim serijama i metodama mašinskog učenja, kao i ka hibridnim pristupima koji kombinuju fizičke principe sa ANN i drugim metodama mašinskog učenja [47], [48], [49], [50]. Ovi modeli omogućavaju adaptivno ponašanje, učenje iz podataka i poboljšanu tačnost predviđanja u realnim operativnim uslovima, naročito u prisustvu nelinearnih i nestacionarnih ulaznih veličina.

Posebno značajnu ulogu u savremenim prediktivnim okvirima imaju modeli sa vremenskom memorijom, kao što su rekurentne neuronske mreže (RNN), LSTM i GRU arhitekture, koje omogućavaju implicitno modelovanje dinamike sistema i višehorizontsku prognozu proizvodnje električne energije iz PV sistema [51]. Na slici 2.7 grafički je prikazana evolucija različitih pristupa modelovanju i predviđanju performansi PV sistema, počev od klasičnih fizičkih i empirijskih modela, preko prediktivnih modela zasnovanih na vremenskim serijama, do savremenih hibridnih pristupa. Fizički i empirijski modeli, iako

pogodni za analizu stacionarnih i dugoročnih uslova rada, pokazuju izražena ograničenja u prisustvu brze vremenske varijabilnosti i nelinearnih efekata, što je u skladu sa diskusijom u ovom poglavlju.



Slika 2.7: Evolucija modela za predviđanje performansi PV sistema: od fizičkih i empirijskih ka prediktivnim i hibridnim pristupima.

Prediktivni modeli zasnovani na mašinskom učenju koriste istorijske podatke i vremensku zavisnost ulaznih veličina kako bi poboljšali tačnost kratkoročnih i višehorizontskih prognoza, dok hibridni modeli integrišu fizičke relacije kao ograničenja, regularizacione članove ili početne uslove u procesu učenja. Na taj način ostvaruje se kompromis između fizičke interpretabilnosti i adaptivne sposobnosti modela, što predstavlja osnovu savremenih pristupa predviđanju izlazne snage i energije PV sistema [52].

2.3.1 Modeli bazirani na podacima

Modeli bazirani na podacima (engl. *data-driven*) zasnivaju se na analizi istorijskih vremenskih serija meteoroloških i energetskih podataka, bez eksplicitnog uvođenja detaljnih fizičkih parametara PV modula i sistema. Osnovna pretpostavka ovih pristupa jeste da se nelinearna zavisnost između ulaznih promenljivih (iradijansa, temperatura, vreme, indeks oblačnosti, itd.) i izlazne veličine (snaga ili energija PV sistema) može naučiti direktno iz podataka [47], [48]. Najčešće korišćeni data-driven modeli uključuju:

- **Statističke regresione modele** - linearne i polinomske regresije koje predstavljaju najjednostavniji oblik data-driven pristupa [53];
- **Vremenske modele** - kao što su ARIMA i SARIMA, koji eksplicitno modeluju autokorelaciju i sezonalnost vremenskih serija [54], [55];
- **Ensemble metode** - poput Random Forest i Gradient Boosting algoritama, dodatno

poboljšavaju robustnost predviđanja kombinovanjem više baznih modela [49], [56]. Iako data-driven modeli mogu nadmašiti klasične empirijske pristupe u određenim uslovima, njihova sposobnost generalizacije ostaje ograničena pri promenama režima rada ili ulaznih podataka, što motiviše primenu adaptivnih metoda zasnovanih na neuronskim mrežama [22], [48].

2.3.2 Veštačka inteligencija (VI) i veštačke neuronske mreže (ANN)

Veštačke neuronske mreže predstavljaju centralni alat savremenih prediktivnih modela u oblasti PV sistema, zahvaljujući svojoj sposobnosti aproksimacije složenih nelinearnih zavisnosti između ulaznih i izlaznih promenljivih [47], [57]. U literaturi se najčešće koriste MLP arhitekture za kratkoročne prognoze, kao i rekurentne neuronske mreže, naročito LSTM i GRU modeli, koji efikasno opisuju vremensku zavisnost podataka [49], [58], [59]. U novijim istraživanjima, konvolucione i hibridne CNN–LSTM arhitekture primenjuju se na višekanalne i prostorne ulaze, uključujući satelitske podatke, čime se dodatno poboljšava tačnost kratkoročnih prognoza [48], [60], [61].

ANN modeli su se pokazali naročito efikasnim u kratkoročnim prognozama (1–24 časova unapred), gde postižu značajno niže vrednosti grešaka (RMSE, nRMSE, MAPE) u poređenju sa klasičnim fizičkim i empirijskim modelima. Međutim, njihova primena zahteva pažljiv izbor ulaznih promenljivih, pravilnu normalizaciju podataka i rigoroznu validaciju kako bi se izbegla prenaučenosť i degradacija performansi [62].

Tabela 2.2 daje sintezni uporedni prikaz najčešće korišćenih ANN arhitektura u kontekstu kratkoročne prognoze performansi PV sistema, sa posebnim osvrtom na njihovu ulogu u predloženoj metodologiji ove disertacije. Prikaz pokazuje da se MLP (Multi-Layer Perceptron) arhitektura, zahvaljujući relativno jednostavnoj strukturi, dobroj sposobnosti aproksimacije nelinearnih zavisnosti i niskoj računarskoj složenosti, može efikasno koristiti za modelovanje odnosa između meteoroloških parametara i izlazne snage PV sistema. U predloženoj metodologiji upravo MLP predstavlja osnovu svih razvijenih modela, uključujući modele grupe M1 (M1–A1, M1–A1b i M1–A2), kao i unapređeni model M2. Uvođenjem vremenskih lag varijabli u ulazni skup podataka omogućeno je implicitno modelovanje vremenske dinamike sistema, čime se postiže značajno poboljšanje tačnosti predviđanja bez povećanja strukturne složenosti modela.

Rekurentne arhitekture tipa LSTM i GRU, koje omogućavaju eksplicitno modelovanje vremenske memorije u sekvencijalnim podacima, široko su zastupljene u savremenoj literaturi o prognozi solarne energije. Slično tome, hibridni CNN–LSTM modeli kombinuju prostornu ekstrakciju karakteristika i vremensku analizu sekvenci i često postižu vrlo visoke performanse kada su dostupni višekanalni ili satelitski podaci. Međutim, takvi pristupi zahtevaju znatno veće skupove podataka i veću računarsku složenost, pa su u ovoj disertaciji razmatrani pretežno kao literaturni referentni modeli.

Tabela 2.2: Pregled ANN arhitektura relevantnih za kratkoročnu prognozu solarne energije i njihova uloga u predloženim modelima M1 i M2.

Arhitektura	Struktura memorije	Tip ulaznih podataka	Računarska složenost	Uloga u disertaciji
MLP (Multi-Layer Perceptron)	Nema eksplicitnu memoriju; vremenska dinamika može se modelovati pomoću ulaznih lag varijabli	Trenutni meteorološki parametri i/ili vremenski lagovi merenih veličina	Niska	Osnovna arhitektura korišćena u svim predloženim modelima (M1–A1, M1–A1b, M1–A2 i M2). Omogućava nelinearnu aproksimaciju odnosa između meteoroloških parametara i izlazne snage PV sistema.
LSTM / GRU	Rekurentna struktura sa eksplicitnom vremenskom memorijom	Vremenske serije meteoroloških i energetske podataka	Srednja do visoka	Razmatrani kao referentni pristupi u savremenoj literaturi za prognozu solarne energije. U ovom radu nisu direktno implementirani, već služe kao konceptualni referentni model.
CNN–LSTM	Kombinovana prostorno-vremenska obrada (CNN ekstrakcija karakteristika + LSTM vremenska memorija)	Višekanalni podaci (npr. satelitske slike, prostorna polja zračenja ili oblaka)	Visoka	Predstavlja napredni pristup koji se koristi u literaturi kada su dostupni prostorni ili satelitski podaci. U ovoj disertaciji korišćeni su isključivo lokalni meteorološki podaci, pa ovaj pristup nije implementiran.

Na osnovu ovog poređenja, izabrana metodologija zasniva se na optimizovanoj MLP arhitekturi, čime se postiže povoljan kompromis između tačnosti predviđanja, interpretabilnosti modela i računarske efikasnosti, što je od posebnog značaja za praktičnu primenu u realnim operativnim uslovima.

Poseban doprinos ove disertacije ogleda se u razvoju metodološkog pristupa koji kombinuje relativno jednostavnu, ali pažljivo optimizovanu MLP arhitekturu sa informativno bogatim ulaznim skupom podataka i implicitnim modelovanjem vremenske dinamike putem lag promenljivih, čime se postiže visok nivo tačnosti predviđanja uz zadržavanje dobre interpretabilnosti i računarske efikasnosti modela.


2.3.3 Hibridni modeli: integracija fizičkih i AI pristupa

Hibridni modeli predstavljaju kompromis između fizičke interpretabilnosti klasičnih modela i adaptivne moći veštačke inteligencije. U ovim pristupima, fizički modeli se koriste kao osnovni okvir ili referenca, dok se ANN ili drugi ML algoritmi primenjuju za korekciju sistematskih grešaka, učenje nelinearnih odnosa ili predviđanje rezidualnih odstupanja.

Najčešći hibridni koncepti uključuju:

- korekciju izlaza fizičkih modela pomoću ANN (model greške);
- korišćenje fizičkih veličina (npr. G_{POA} , T_{cell}) kao ulaza u ANN modele;
- fuziju podataka iz više izvora (lokalna merenja, satelitski podaci, meteorološke prognoze).

Ovakvi modeli omogućavaju veću robusnost, bolju generalizaciju i lakšu integraciju u operativne sisteme za nadzor i upravljanje. Ujedno, oni predstavljaju prirodan prelaz ka konceptu digitalnog blizanca, gde se fizički sistem, merenja i prediktivni modeli objedinjuju u jedinstven adaptivni okvir.



Slika 2.8: Osnovni princip koncepta digitalnog blizanca PV sistema.

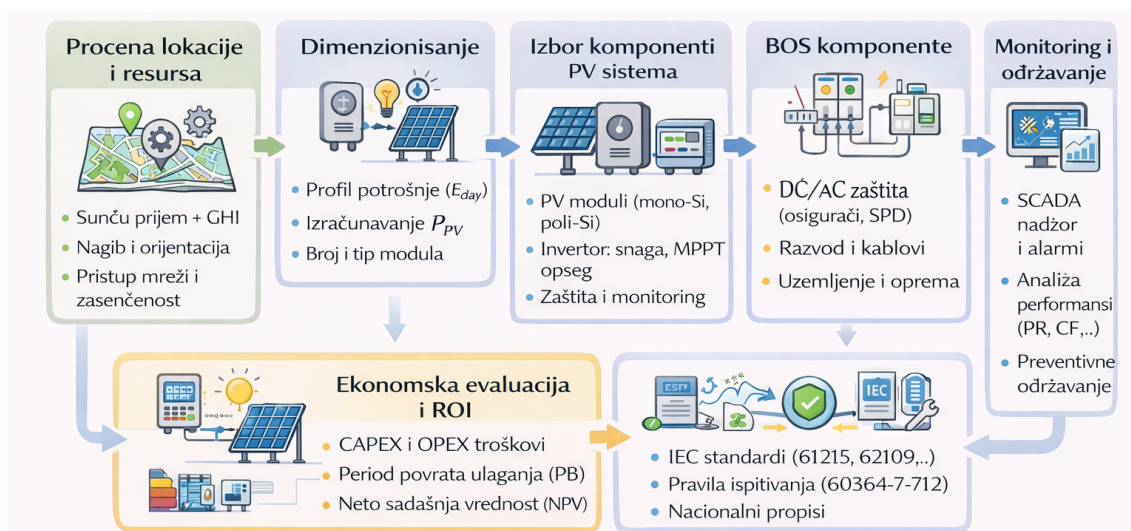
Na slici 2.8 je prikazan koncept *digitalnog blizanca* PV (PV) sistema, koji ilustruje paralelno postojanje fizičkog sistema i njegovog virtuelnog modela. Leva strana slike predstavlja realni PV sistem, koji obuhvata PV module, invertor i merni podsistem za akviziciju ključnih operativnih veličina, kao što su sunčeva irradiansa, temperatura i izlazna snaga. Ovi podaci se u realnom vremenu ili sa kratkim vremenskim kašnjenjem prenose ka digitalnom sloju.

Desna strana slike prikazuje digitalnog blizanca PV sistema, realizovanog u računarskom okruženju, gde se na osnovu prikupljenih mernih i meteoroloških podataka izvršava simulacija i prediktivna analiza ponašanja sistema. Digitalni blizanac omogućava procenu trenutnih i budućih performansi PV sistema, identifikaciju odstupanja od nominalnog rada, kao i evaluaciju različitih scenarija rada bez intervencije na fizičkom postrojenju. Dvosmerna veza između fizičkog sistema i digitalnog blizanca omogućava kontinuiranu razmenu podataka i predstavlja osnovu za napredne funkcije nadzora, predviđanja, optimizacije i buduću integraciju dijagnostičkih i upravljačkih algoritama.

Prediktivni i hibridni modeli zasnovani na veštačkoj inteligenciji predstavljaju ključni iskorak u modelovanju i prognoziranju performansi PV sistema. Njihova sposobnost da integrišu više-izvorne podatke, uče iz vremenskih serija i prilagođavaju se promenljivim uslovima čini ih pogodnim za primenu u realnim sistemima i naprednim konceptima upravljanja. Ovi pristupi direktno motivišu razvoj modela koji će biti predstavljeni u narednim poglavljima disertacije, gde se ANN modeli primenjuju na različite nivoe dostupnosti podataka, vremenske horizonte i inženjerske scenarije, uz kvantitativnu evaluaciju njihove tačnosti i robusnosti.

3. Metode projektovanja PV sistema

Projektovanje PV sistema predstavlja višefazni proces koji obuhvata analizu lokacije i solarnih resursa, izbor i dimenzionisanje komponenti, kao i ekonomsku evaluaciju sistema. Tradicionalno, ovaj proces se zasniva na determinističkim inženjerskim pristupima, dok savremene metode uvode optimizacione i prediktivne modele koji integrišu stvarne meteorološke i tehničke podatke, kao i zahteve standarda, monitoringa i dugoročnog održavanja sistema. U ovom poglavlju analiziraju se tri osnovna pristupa: (1) tradicionalni inženjerski pristupi, (2) softverski alati i simulacioni modeli, i (3) ograničenja konvencionalnih metoda.



Slika 3.1: Postupak projektovanja PV sistema: od procene lokacije i dostupnih resursa do tehničke i ekonomske evaluacije.

3.1 Tradicionalne metode projektovanja

Projektovanje PV sistema zahteva pažljivo planiranje i analizu kako bi se obezbedila sigurna, pouzdana i dugotrajna eksploatacija [63], [64]. Tradicionalne metode predstavljaju osnovu inženjerskog pristupa u projektovanju PV postrojenja i zasnivaju se na primeni standardnih procedura, matematičkih modela i komercijalno dostupnih softverskih alata [24].

Ovaj pristup podrazumeva sekvencijalnu realizaciju više međusobno povezanih faza: procenu lokacije i dostupnih solarnih resursa, dimenzionisanje sistema i izbor komponenti, ekonomsku analizu i procenu vremena potrebnog za povratak ulaganja, kao i proveru usklađenosti sa tehničkim i bezbednosnim propisima [65], [66]. Cilj je da se obezbedi efikasna, stabilna i isplativa proizvodnja električne energije iz solarnih izvora, uz optimalnu upotrebu resursa i minimizaciju gubitaka tokom eksploatacije.

U nastavku su prikazane ključne faze tradicionalnog projektovanja PV sistema, koje predstavljaju referentnu osnovu za kasniju primenu naprednih modela i inteligentnih metoda optimizacije.

3.1.1 Procena lokacije

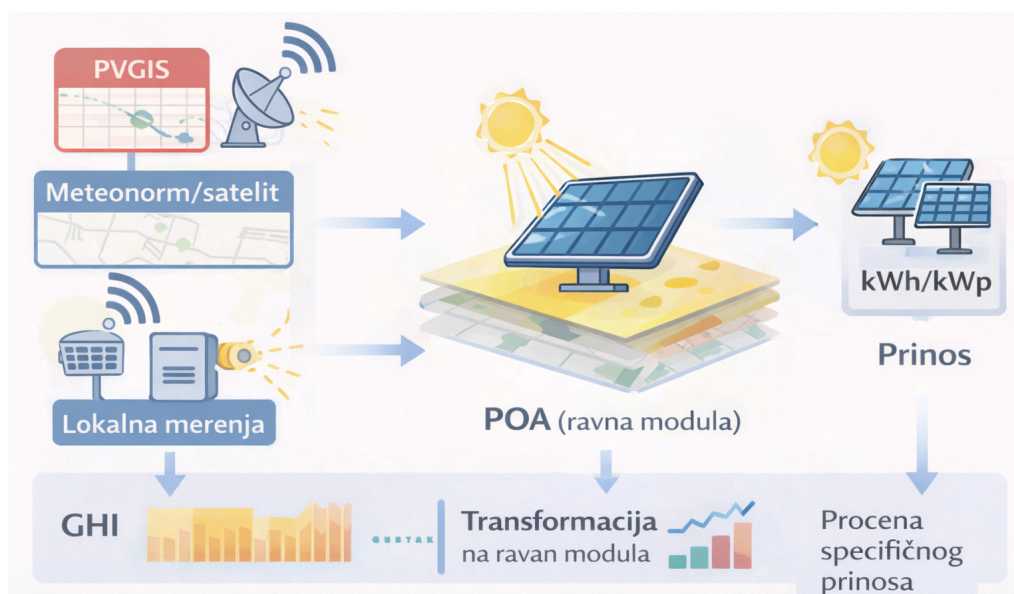
Procena lokacije predstavlja jedan od ključnih koraka u procesu projektovanja PV sistema jer u velikoj meri određuje energetska efikasnost, pouzdanost i ekonomsku isplativost investicije. Izbor lokacije mora biti zasnovan na detaljnoj analizi geografskih, klimatskih i mikro-lokalnih faktora koji zajedno utiču na raspoloživu količinu sunčeve energije, termalne gubitke i potencijalna zasenčenja tokom godine.

U prvoj fazi sprovodi se analiza geografskih koordinata (dužine i širine) koje direktno utiču na upadni ugao sunčevog zračenja i trajanje insolacije tokom dana i godine. Na osnovu njih definiše se optimalna orijentacija (najčešće prema jugu za severnu hemisferu) i nagib panela koji omogućava maksimalno iskorišćenje direktnog i difuznog zračenja. Za teritoriju Srbije, optimalni nagib se kreće između 30° i 35° , dok preciznija vrednost zavisi od geografske širine lokacije i planiranog režima rada sistema (sezonski ili celogodišnji rad).

Sledeći korak obuhvata analizu klimatskih uslova, sa fokusom na prosečan broj sunčanih sati, godišnju količinu padavina i učestalost ekstremnih vremenskih pojava. Ovi parametri imaju značajan uticaj na energetska prinos, ali i na pouzdanost i životni vek opreme. Na primer, visoka relativna vlažnost i česte padavine mogu povećati rizik od korozije PV modula i priključnih kutija, dok ekstremne temperature zahtevaju odgovarajuće postupke termičkog projektovanja PV sistema.

Merenje i procena raspoloživog solarnog zračenja (insolacije) predstavlja centralni deo procene lokacije. U praksi se koristi kombinacija satelitskih baza podataka (npr. PV-

GIS, NASA-SSE, Meteonorm) i lokalnih meteoroloških merenja, pri čemu se procenjene vrednosti GHI transformišu na ravan modula (POA) uz uvažavanje orijentacije, nagiba i sistemskih gubitaka, kako bi se dobio očekivani specifični prinos PV sistema izražen u kWh/kWp [20], [63]. Postupak transformacije solarnog resursa u očekivani energetski prinos šematski je prikazan na slici 3.2.



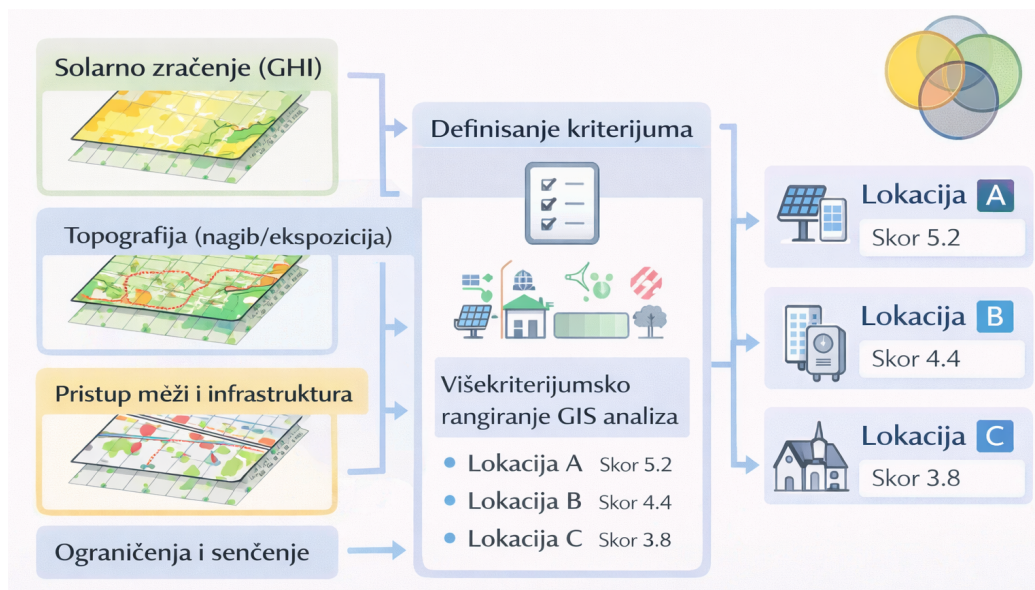
Slika 3.2: Povezanost solarnog resursa i specifičnog prinosa PV sistema.

Na ovaj način obezbeđuje se konzistentna veza između procene solarnog potencijala i dimenzionisanja PV sistema u narednim fazama projektovanja.

Konačno, posebnu pažnju treba posvetiti analizi zasenčenja izazvanog okolnim objektima kao što su drveće, zgrade, stubovi ili terenske nepravilnosti. Ova analiza se sprovodi metodama geometrijskog modelovanja (npr. korišćenjem alata poput *PVsyst*, *SketchUp* ili *Helioscope*) kako bi se identifikovali periodi delimičnog ili potpunog zasenčenja tokom dana i godine. Čak i delimično senčenje jednog niza može izazvati značajne gubitke energije zbog neusklađenih strujno-naponskih karakteristika PV modula u stringu ¹.

Dobijeni rezultati svih pomenutih analiza objedinjeni su u okviru GIS (Geographic Information System) alata, koji omogućava višekriterijumsku analizu pogodnosti lokacije integracijom meteoroloških, topografskih, infrastrukturnih i ograničavajućih faktora u jedinstveni indeks pogodnosti [13], [67]. Konceptualni okvir ove analize prikazan je na slici 3.3.

¹string predstavlja osnovnu strukturnu jedinicu PV sistema, formiranu serijskim povezivanjem modula radi postizanja odgovarajućeg naponskog nivoa za rad invertora.



Slika 3.3: GIS-bazirana višekriterijumska procena pogodnosti lokacije za PV sisteme.

3.1.2 Dimenzionisanje PV sistema - procena profila potrošnje

Proces dimenzionisanja PV sistema započinje detaljnom analizom potrošnje električne energije korisnika, jer se upravo na osnovu energetske potrebe određuju veličina, konfiguracija i režim rada sistema. Cilj ovog koraka je da se obezbedi optimalno usklađivanje proizvodnje električne energije iz PV sistema sa zahtevima potrošnje tokom dana, meseca i godine, uz minimalne gubitke i maksimalnu isplativost.


Prvi korak podrazumeva analizu trenutne i buduće procenjene potrošnje električne energije. U okviru ove analize prikupljaju se podaci o troškovima električne energije u prethodnom periodu, satnim ili mesečnim merenjima iz brojila, kao i o planiranom rastu potrošnje usled proširenja objekta, povećanja broja uređaja ili promene režima korišćenja. Na osnovu dobijenih vrednosti određuje se prosečna i maksimalna dnevna potrošnja (E_{avg} i E_{max}), izražena u kWh.

U sledećoj fazi se vrši pregled i kategorizacija potrošača energije, što uključuje identifikaciju svih uređaja, aparata i mašina koji troše električnu energiju. Za svaki uređaj se definišu nazivna snaga P_i [W], prosečno vreme rada t_i [h/dan] i faktor korišćenja f_i . Ukupna dnevna potrošnja energije tada se može izraziti kao:

$$E_{day} = \sum_{i=1}^n P_i \cdot t_i \cdot f_i. \quad (3.1)$$

Ovaj proračun omogućava precizno sagledavanje raspodele potrošnje po satima, što je od izuzetne važnosti za dimenzionisanje kapaciteta PV sistema i eventualnog baterijskog skladišta. Upoređivanjem dobijenog profila potrošnje sa očekivanim profilom proizvodnje PV sistema moguće je identifikovati deo proizvedene električne energije koji se koristi

direktno na mestu proizvodnje (self-consumption), kao i periode kada postoji višak energije, koji se može iskoristiti za predaju u elektrodistributivnu mrežu ili skladištenje, odnosno periode deficita koji se pokrivaju iz mreže ili pomoćnih izvora (npr. vetro turbine, dizel generator, itd.), što je prikazano na slici 3.4.



Slika 3.4: Uporedni dnevni profili potrošnje i proizvodnje PV sistema [68].

Na osnovu dobijenih vrednosti pristupa se određivanju potrebne instalirane snage PV sistema (P_{PV}), čime se obezbeđuje zadovoljenje energetske potrebe korisnika u prosečnim uslovima osunčanosti. Procena se vrši korišćenjem izraza [63]:

$$P_{PV} = \frac{E_{day}}{H_T \cdot \eta_{sys}}, \quad (3.2)$$

gde je H_T prosečno dnevno globalno zračenje na ravni modula [kWh/m^2], a η_{sys} ukupna efikasnost sistema (uključujući inverter, gubitke u kablovima i temperaturne gubitke). Ovakvim pristupom se određuje minimalna potrebna snaga PV sistema u kilovatima (kW).

U sledećem koraku definiše se broj i tip PV modula, koji zavise od izabrane tehnologije (mono-Si, poli-Si, PERC, HJT, itd.), snage pojedinačnog modula P_m i konfiguracije stringova. Broj modula N_{mod} računa se prema relaciji:

$$N_{mod} = \frac{P_{PV}}{P_m}. \quad (3.3)$$

Pri tome je potrebno voditi računa o naponskoj usklađenosti PV modula sa ulaznim karakteristikama invertora (DC ulazni opseg i maksimalna struja).

Na kraju, vrši se razvijanje dnevnog, mesečnog i godišnjeg profila potrošnje. Ovi profili omogućavaju analizu sezonskih varijacija i prepoznavanje perioda maksimalnog

opterećenja, što je posebno važno u hibridnim sistemima sa baterijskim skladištem ili dodatnim izvorima (npr. mreža, agregat). Kroz upoređivanje profila potrošnje i očekivane proizvodnje PV sistema dobija se vremenska usklađenost između proizvodnje i potrošnje, čime se može odrediti optimalna veličina sistema, potreban kapacitet baterija i stepen energetske nezavisnosti korisnika.

Rezultati analize profila potrošnje i proizvodnje predstavljaju ključni ulaz za softverske alate za simulaciju i optimizaciju PV sistema, kao što su *PVsyst* [69], gde se na satnom nivou analizira energetski bilans, stepen sopstvene potrošnje i ekonomski efekti sistema. Takođe, analiza energetskog bilansa, optimalne konfiguracije PV sistema i ekonomske isplativosti može se sprovesti korišćenjem softverskog alata *HOMER Pro* [70]. Numerička analiza, modelovanje i simulacija PV sistema, kao i razvoj prediktivnih i optimizacionih algoritama, realizovani su u okruženju *MATLAB* [71].

3.1.3 Izbor komponenata PV sistema

Izbor komponenata PV sistema predstavlja jednu od najvažnijih faza u procesu projektovanja, jer direktno utiče na energetsku efikasnost, pouzdanost rada i dugoročne troškove eksploatacije. Ključni elementi sistema obuhvataju PV module, invertore, nosače (konstrukciju), zaštitnu i spojnu opremu, kao i merni i nadzorni sistem. U ovoj fazi se posebna pažnja posvećuje tehničkim karakteristikama, kompatibilnosti komponenti i njihovoj usklađenosti sa međunarodnim standardima, kao što su IEC 61215 [72], IEC 61730 [73] i IEC 62109 [74].

Izbor PV modula

Izbor PV modula zasniva se na analizi više kriterijuma: efikasnosti pretvaranja sunčeve energije u električnu, nazivnoj snazi (izraženoj u W_p), temperaturnom koeficijentu, pouzdanosti u realnim uslovima rada i odnosu cena-performanse. U savremenim sistemima najčešće se koriste mono-Si (monokristalni silicijum) PV moduli zbog veće efikasnosti (20-23 %), dok poli-Si PV moduli i dalje nalaze primenu u ekonomičnijim rešenjima [24], [75].

Ključni parametri koji se razmatraju pri izboru PV modula su:

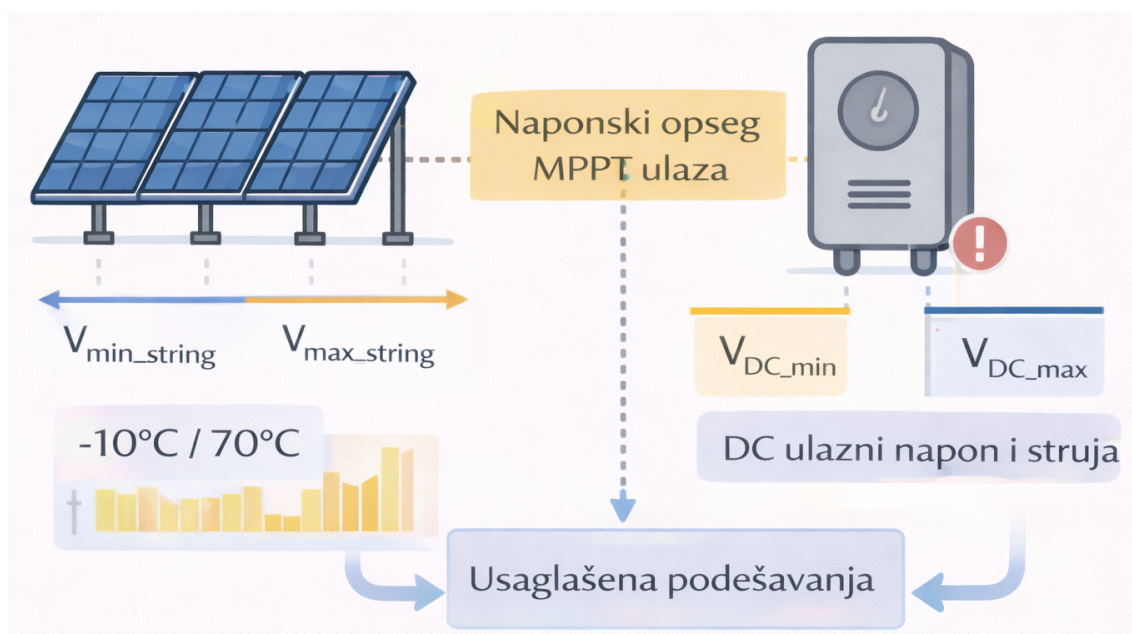
- *Nazivna snaga modula* P_m (u W_p), koja direktno utiče na ukupnu instaliranu snagu sistema.
- *Naponske i strujne karakteristike* (V_{oc} , I_{sc} , V_{mp} , I_{mp}), neophodne za usklađivanje sa ulaznim opsegom invertora.
- *Temperaturni koeficijent snage* (γ_p), koji pokazuje pad izlazne snage sa porastom temperature (tipično -0.35 do $-0.45\%/^{\circ}C$).
- *Otpornost na degradaciju i mehaničke uslove*, prema IEC 61215 (otpornost na vlagu, UV zračenje, vetar i sneg).

U praksi se izbor modula često vrši i prema dostupnosti na tržištu, garanciji (tipično 12-15 godina za proizvod i 25 godina za performanse) i kompatibilnosti sa konstrukcijom i invertorom. Za potrebe preciznog modelovanja u softverima kao što su *PVsys* ili *MATLAB/Simulink*, koristi se detaljan električni model PV modula (npr. jednodioni ili dvo-diodni model) koji uključuje parametre kao što su redna (R_s) i paralelna otpornost (R_{sh}), kao i temperaturu ćelija prema Faimanovom ili NOCT modelu [32], [38].

Izbor invertora

Izbor invertora je jednako važan kao i izbor modula, jer inverter predstavlja „srce“ PV sistema, s obzirom da pretvara jednosmernu struju (DC) koju generišu PV moduli u naizmeničnu struju (AC), koja se koristi u domaćinstvima ili se prosleđuje u elektroenergetsku mrežu. Osnovni kriterijumi za izbor invertora su:

- *Nominalna snaga* (P_{inv}), koja treba da bude približno jednaka ili manja od ukupne snage PV generatora (P_{PV}), uz dozvoljeno odstupanje od $\pm 10\%$.
- *Ulazni DC napon i opseg MPPT*, koji mora obuhvatiti naponske karakteristike niza modula (slika 3.5). Naponski opseg MPPT ulaza mora obuhvatiti radni napon PV stringa u realnim temperaturnim uslovima, dok se maksimalni DC napon i maksimalna struja ne smeju prekoračiti.
- *Efikasnost pretvaranja* (η_{inv}), koja kod savremenih invertora dostiže 97-99 %.
- *Broj MPPT ulaza*, koji omogućava optimalno praćenje tačke maksimalne snage za nezavisne nizove panela različite orijentacije.
- *Vrsta invertora: string, centralni ili mikroinvertori*, u zavisnosti od veličine sistema i konfiguracije PV polja.



Slika 3.5: Ilustracija usklađivanja PV stringa i invertora.

Posebna pažnja se posvećuje pouzdanosti i zaštitnim funkcijama invertora, uključujući prenaponsku, strujnu i termičku zaštitu, kao i mogućnost rada u mrežnom (*on-grid*) ili autonomnom (*off-grid*) režimu. U sistemima sa baterijskim skladištenjem energije koriste se hibridni invertori koji omogućavaju dvosmerni tok energije (punjenje i pražnjenje baterija) [76].

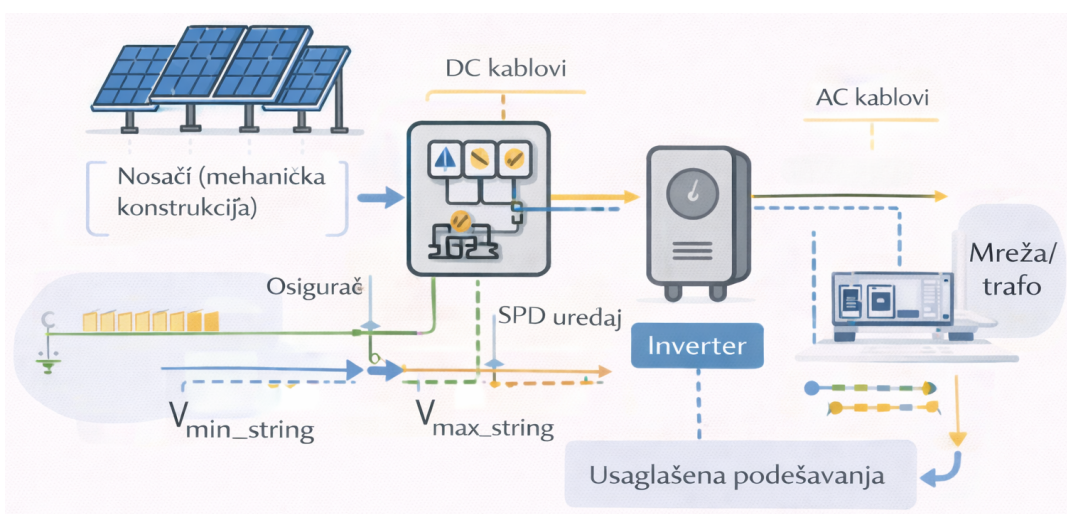
Pored osnovnih komponenti, u projektovanju se mora obratiti pažnja i na:

- *DC i AC zaštitnu opremu* (osigurači, prekidači, SPD uređaji),
- *nosače i konstrukciju* (fiksni ili sa praćenjem sunca – *tracking* sistemi),
- *kablovske vodove i konektore* (npr. MC4, sa UV i IP68 zaštitom),
- *sistem monitoringa i daljinskog nadzora* (SCADA, Modbus, RS485, Wi-Fi komunikacija).

Primenom standardizovanog pristupa izboru komponenti, zasnovanog na tehničkim specifikacijama, električnom usklađivanju i dugoročnoj pouzdanosti, obezbeđuje se optimalna performansa i stabilan rad PV sistema tokom celog životnog ciklusa [76], [77]. Takođe, na ovaj način se obezbeđuje optimalna efikasnost i minimalni troškovi održavanja sistema, čime se omogućava stabilna i predvidiva proizvodnja električne energije tokom celog životnog ciklusa PV sistema.

3.1.4 BOS - prateće mehaničke i električne komponente sistema

Pored osnovnih elemenata kao što su PV moduli i invertori, izuzetno važan deo svakog PV sistema čine prateće mehaničke i električne komponente - BOS (*Balance of System*). Ove komponente obezbeđuju fizičku stabilnost, električnu povezanost i bezbedan rad PV sistema tokom celog njegovog životnog veka, pri čemu njihov kvalitet i pravilno dimenzionisanje imaju direktan uticaj na ukupne gubitke, pouzdanost i dugoročnu eksploataciju [64], [76]. Struktura i međusobni odnosi ključnih BOS komponenti u okviru PV sistema prikazani su na slici 3.6.



Slika 3.6: Pregled osnovnih BOS (*Balance of System*) komponenti u PV sistemu.

Mehaničke komponente

Mehaničke komponente obuhvataju nosače (montažne strukture) na koje se PV moduli postavljaju. Njihov izbor i dizajn pre svega zavisi od tipa instalacije, da li se radi o krovnom PV sistemu, PV instalaciji na nadstrešnici ili u okviru fasade objekta. Na kraju poseban tip mehaničkih komponentata se koristi za PV sisteme montirane na zemlji tzv. zemaljske (ground-mounted) instalacije. Osnovni zadatak konstrukcije jeste da obezbedi optimalan nagib i orijentaciju panela, kao i njihovu stabilnost u različitim vremenskim uslovima. Strukture se izrađuju od aluminijuma ili pocinkovanog čelika zbog otpornosti na koroziju i malog odnosa mase i čvrstoće konstrukcije. Prilikom projektovanja konstrukcije, potrebno je izvršiti proračune opterećenja u skladu sa Eurokod standardima EN 1991-1-4 [78] i EN 1991-1-3 [79], dok se u sistemima velikih razmera sve češće primenjuju jedno- i dvoosni sistemi za praćenje sunca, koji omogućavaju povećanje godišnjeg prinosa uz cenu veće mehaničke složenosti i održavanja [63]. Postupak izbora mehaničkih komponentata uključuje sledeće faktore:

- maksimalnu brzinu vetra u regionu i pritisak koji deluje na površinu modula;
- opterećenje snegom i statičku otpornost konstrukcije;
- otpornost na vibracije, temperaturne dilatacije i eventualne seizmičke efekte;
- trajnost i održavanje spojeva, vijaka i sidrišta.

U sistemima velikih razmera (solarni parkovi) često se koriste *tracking sistemi* (jedno- ili dvoosni), koji povećavaju godišnji prinos energije za 15-25 %, ali zahtevaju složeniju mehaniku i periodično održavanje.

Električne komponente

Električne komponente BOS-a obuhvataju sve elemente koji omogućavaju prenos električne energije od PV modula do invertora, a zatim ka mreži ili baterijskom sistemu. Glavni elementi električnog dela BOS sistema su:

- *DC kablovi* koji povezuju PV module u stringove i stringove sa DC razvodnim ormarima. Izrađeni su od UV-otpornih i dvoslojnih izolacija, obično preseka od 4-10 mm²;
- *AC kablovi* koji vode struju od invertora ka razvodnom ormanu ili mreži, dimenzionisani prema maksimalnoj struji i dozvoljenom padu napona ($\Delta U < 1.5\%$);
- *prekidači i osigurači* na DC i AC strani, koji obezbeđuju selektivnost zaštite i mogućnost servisnog isključenja;
- *prenaponska zaštita* (SPD tip 1+2) prema standardu IEC 61643-31 [80], koja štiti od udara groma i prenapona indukovanih u mreži;
- *sistem uzemljenja i izjednačenja potencijala*, koji obezbeđuje sigurnost korisnika i zaštitu od električnih udara.

Dodatno, BOS obuhvata i projektovanje električne šeme sistema, gde se definiše način

povezivanja stringova, lokacija razvodnih ormana, tipovi prekidača, kao i položaj komunikacionih linija za monitoring. Ovo mora biti u potpunosti usklađeno sa zahtevima standarda IEC 60364-7-712 [81], kako bi se obezbedila električna bezbednost, selektivnost zaštite i otpornost sistema na prenaponske pojave.

Ukoliko je u PV sistemu planirano baterijsko skladište energije, neophodno je projektovati dvosmerni energetski tok između invertora i baterijskog sistema, kao i dodatne zaštite za DC/DC pretvarače, temperaturne senzore i BMS (Battery Management System). Svi elementi moraju biti projektovani tako da obezbede minimalne gubitke i visoku efikasnost prenosa energije ($\eta_{BOS} > 98\%$).

Kvalitetno projektovan BOS predstavlja osnovu dugotrajnog i stabilnog rada PV sistema, jer omogućava minimizaciju gubitaka, povećanje operativne pouzdanosti i smanjenje troškova održavanja tokom celog projektovanog životnog ciklusa postrojenja.

3.1.5 Ekonomska opravdanost i povratak ulaganja (ROI)

Evaluacija ekonomske opravdanosti PV sistema predstavlja ključni korak u procesu planiranja i donošenja investicione odluke [82]. Ova analiza obuhvata procenu inicijalnih investicionih troškova, operativnih troškova tokom eksploatacije, kao i određivanje finansijskih pokazatelja koji kvantifikuju dugoročnu isplativost sistema.

Početni investicioni troškovi

Početni investicioni troškovi (*Capital Expenditure - CAPEX*) obuhvataju troškove projektovanja, nabavke i realizacije PV sistema. U ovu grupu spadaju troškovi PV modula i invertora, prateće opreme (BOS), instalacije i priključenja na elektroenergetsku mrežu. Tipične vrednosti investicionih troškova za male i srednje sisteme u Evropi u poslednjim godinama kreću se u opsegu 700–1200 €/kW_p, u zavisnosti od veličine sistema i tržišnih uslova [83], [84].

Ukupan investicioni trošak može se izraziti kao:

$$C_{total} = C_{PV} + C_{BOS} + C_{inst} + C_{grid}, \quad (3.4)$$

gde C_{PV} predstavlja troškove modula i invertora, C_{BOS} troškove prateće opreme, C_{inst} troškove instalacije, a C_{grid} troškove priključenja na mrežu. Kod većih sistema dolazi do izražaja efekat ekonomije obima, pa investicioni trošak po instaliranom kW_p opada sa porastom snage sistema.

Operativni troškovi

Operativni troškovi (*Operational Expenditure - OPEX*) uključuju troškove redovnog održavanja, nadzora sistema, čišćenja modula, osiguranja, kao i periodične zamene komponenti (npr. invertora na svakih 10-12 godina). Godišnji OPEX tipično iznosi 1-2 % početne

investicije, dok se degradacija snage PV modula kreće u opsegu 0.3-0.5 % godišnje [85]. Primena sistema nadzora i prediktivnog održavanja može dodatno smanjiti rizik neplaniranih zastoja i produžiti efektivni radni vek sistema.

Period povratka ulaganja

Period povrata ulaganja (*Payback Period - PB*) predstavlja vreme potrebno da kumulativne godišnje uštede nadmaše početnu investiciju. U najjednostavnijem obliku definiše se kao:

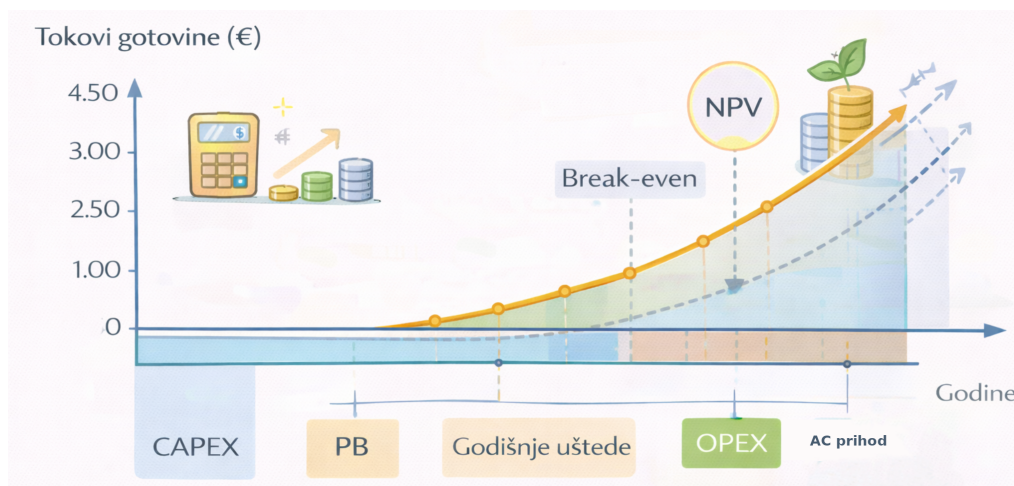
$$PB = \frac{C_{total}}{S_{year}}, \quad (3.5)$$

gde je S_{year} prosečna godišnja finansijska korist ostvarena proizvodnjom električne energije iz PV sistema. U prisustvu subvencija, poreskih olakšica ili garantovanog otkupa energije, vrednost S_{year} se povećava, čime se period povratka značajno skraćuje.

Za sveobuhvatniju procenu koristi se metoda neto sadašnje vrednosti (*Net Present Value - NPV*), zasnovana na diskontovanju novčanih tokova [82]:

$$NPV = \sum_{t=1}^n \frac{S_t - O_t}{(1+r)^t} - C_{total}, \quad (3.6)$$

gde su S_t godišnja finansijska korist, O_t operativni troškovi, r diskontna stopa, a n životni vek sistema (tipično 25-30 godina). Pozitivna vrednost NPV ukazuje na finansijsku opravdanost projekta (slika 3.7).



Slika 3.7: Diskontovani tokovi gotovine PV sistema: početni troškovi - CAPEX, godišnje koristi i operativni troškovi - OPEX.

Nivelisani trošak električne energije

Nivelisani trošak električne energije (*Levelized Cost of Electricity - LCOE*) predstavlja standardni pokazatelj ekonomske konkurentnosti energetskih tehnologija [82], [84]. Definiše se kao odnos ukupnih diskontovanih troškova i ukupne diskontovane proizvedene

energije tokom radnog veka sistema:

$$LCOE = \frac{C_{total} + \sum_{t=1}^n \frac{O_t}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^t}} \quad (3.7)$$

Niža vrednost LCOE ukazuje na veću konkurentnost sistema u poređenju sa alternativnim izvorima energije ili tržišnom cenom električne energije.

Unutrašnja stopa profitabilnosti

Dodatni pokazatelj predstavlja unutrašnja stopa profitabilnosti (*Internal Rate of Return - IRR*), definisana kao diskontna stopa pri kojoj je $NPV = 0$. Projekat se smatra prihvatljivim ukoliko je $IRR > r_{min}$, gde je r_{min} minimalna prihvatljiva stopa povratka investicija.

Sveobuhvatna analiza dugoročne isplativosti uključuje razmatranje različitih scenarija, uključujući promene cena električne energije, degradaciju modula, zamenu ključnih komponenti, kao i modele neto merenja (engl. *net-metering*) u okviru sistema podsticajnih otkupnih cena (engl. *feed-in tariff*) [68]. Za razliku od sistema neto merenja, gde se proizvedena energija koristi za umanjeње sopstvene potrošnje, sistem podsticajnih otkupnih cena podrazumeva prodaju proizvedene energije po unapred definisanoj tarifi. Rezultat predstavlja skup ključnih indikatora (PB , NPV , IRR , $LCOE$), na osnovu kojih se donosi informisana investiciona odluka.

Detaljan numerički primer proračuna LCOE za reprezentativne uslove u Republici Srbiji, zajedno sa analizom osetljivosti na diskontnu stopu, investicioni trošak i godišnji energetske prinos, prikazan je u Dodatku A.

3.1.6 Bezbednosni standardi i propisi

Bezbednost PV sistema predstavlja fundamentalni zahtev u svim fazama njegovog životnog ciklusa - od projektovanja i instalacije, do eksploatacije i održavanja. Usklađenost sa važećim zakonskim aktima i međunarodnim tehničkim standardima obezbeđuje pouzdan rad sistema, zaštitu korisnika i servisnog osoblja, kao i stabilnu integraciju u elektroenergetsku mrežu.

Regulatorni okvir u Republici Srbiji definiše pravne i tehničke uslove za izgradnju i priključenje PV sistema. Ključni dokumenti su Zakon o energetici, Zakon o obnovljivim izvorima energije, kao i tehnički uslovi distributivnog operatera za priključenje na mrežu. U zavisnosti od snage i lokacije PV sistema, mogu biti neophodne građevinske i ekološke saglasnosti u skladu sa važećim propisima.

Tehnički standardi čine osnovu bezbednosnog projektovanja PV sistema. Njihova primena obuhvata sledeće nivoe:

- *Kvalitet i pouzdanost modula* — IEC 61215 (ispitivanje trajnosti) i IEC 61730 (bezbednosni zahtevi modula).
- *Bezbednost energetskih pretvarača* — IEC 62109.
- *Projektovanje i instalacija niskonaponskih PV sistema* — IEC 60364-7-712.
- *Prenaponska i gromobranska zaštita* — IEC 61643-31 i EN 62305.
- *Verifikacija i dokumentacija instalacije* — EN 62446-1.
- *Praćenje performansi* — IEC 61724-1:2021.

Ovi standardi sistematizuju zahteve u pogledu električne sigurnosti (zaštita od strujnog udara, kratkog spoja i prenapona), mehaničke otpornosti konstrukcije na vetar i sneg (u skladu sa EN 1991), zaštite od požara, kao i uzemljenja i izjednačenja potencijala.

Operativna bezbednost podrazumeva primenu odgovarajućih procedura tokom instalacije i održavanja, uključujući obuku i sertifikaciju osoblja, periodične inspekcije, termografske analize, ispitivanje izolacije i vođenje tehničke dokumentacije u skladu sa EN 62446-1. Dosledna primena regulatornog i normativnog okvira ne samo da smanjuje tehničke i bezbednosne rizike, već doprinosi dugoročnoj pouzdanosti sistema i njegovoj finansijskoj održivosti.

3.1.7 Testiranje, puštanje u rad, monitoring i održavanje PV sistema

Završna faza realizacije PV sistema obuhvata niz aktivnosti usmerenih na verifikaciju ispravnosti instalacije, potvrdu tehničkih performansi i implementaciju sistema za nadzor i održavanje. Ove aktivnosti su od suštinskog značaja za bezbedan rad, pouzdanost i ostvarenje očekivanih energetskih pokazatelja tokom životnog veka postrojenja.

Testiranje i verifikacija sistema

Testiranje i verifikacija sistema sprovode se neposredno pre puštanja u rad i imaju za cilj da potvrde da svi elementi sistema rade u skladu sa projektom i relevantnim standardima (IEC 62446-1, IEC 60364-7-712, IEC 61730). Postupak obuhvata sledeće korake:

- *vizuelna inspekcija* svih komponenti, uključujući PV module, nosače, kablove, konektore i razvodne ormare;
- provera momenta zatezanja spojeva i mehaničke stabilnosti konstrukcije;
- merenje napona otvorenog kola (V_{oc}) i struje kratkog spoja (I_{sc}) svakog stringa radi potvrde električnog kontinuiteta i pravilne polarizacije;
- test izolacije DC kola i uzemljenja prema EN 62446-1;
- termografski pregled PV polja radi detekcije tzv. „hot-spot“ efekata i nepravilnih spojeva;
- funkcionalno testiranje invertora, MPPT praćenja i zaštitnih uređaja (osigurači, SPD, prekidači).

Svi rezultati testiranja dokumentuju se u *izveštaju o verifikaciji sistema*, koji predstavlja

obavezni deo tehničke dokumentacije i preduslov za izdavanje upotrebne dozvole. Ovim dokumentom potvrđuje se da sistem zadovoljava zahteve bezbednosti, zaštite i performansi predviđenih projektom.

Puštanje u rad

Puštanje u rad (komisioniranje) predstavlja formalni postupak kojim se sistem zvanično uključuje u radni režim. Tokom ove faze proverava se ispravnost sinhronizacije invertora sa mrežom, stabilnost napona i frekvencije, kao i zaštitni mehanizmi u slučaju nestanka napona u mreži (*anti-islanding protection*). Parametri se upoređuju sa proračunatim vrednostima iz softverskih simulacija (npr. PVsyst, MATLAB/Simulink) kako bi se potvrdila očekivana energetska proizvodnja. Nakon uspešnog testiranja, sistem se predaje korisniku uz komplet tehničke dokumentacije, garantne listove i uputstva za održavanje.

Monitoring i analiza performansi

Monitoring i analiza performansi sprovode se kontinuirano tokom eksploatacije PV sistema i predstavljaju osnovu za evaluaciju njegovog rada. Savremeni PV sistemi integrišu merni i komunikacioni hardver koji omogućava automatsko prikupljanje podataka u realnom vremenu:

- merenje napona i struje po stringovima;
- praćenje izlazne snage, faktora snage i efikasnosti invertora;
- registraciju temperature modula, ambijentalne temperature i solarne iradijance;
- prenos podataka putem RS485, Ethernet ili Wi-Fi protokola ka SCADA sistemu.

Analiza performansi se vrši u skladu sa standardom **IEC 61724-1:2021**, koji definiše metodologiju izračunavanja ključnih pokazatelja kao što su:

- *Performance Ratio (PR)* - odnos između stvarne i teoretske proizvodnje energije;
- *Capacity Factor (CF)* - iskorišćenost instaliranog kapaciteta tokom godine;
- *Availability (A)* - vreme u kojem je sistem bio operativan u odnosu na ukupno vreme rada.

Sistemi za monitoring omogućavaju detekciju anomalija (pad napona, pregrevanje, zastoji invertora) i pokreću alarmne procedure, čime se smanjuje rizik od zastoja i gubitaka energije. Pored tehničkih analiza, monitoring omogućava i izračunavanje ekonomskih pokazatelja kao što su mesečna ušteda, generisana energija i procenjeni ROI u realnom vremenu.

Održavanje PV sistema

Održavanje PV sistema ima presudan uticaj na dugovečnost i stabilnost rada postrojenja. U skladu sa preporukama proizvođača i standardom *EN 62446-2*, održavanje obuhvata:

- periodične vizuelne inspekcije i čišćenje PV modula radi uklanjanja prašine, polena i snega;

- provere napona, konektora, uzemljenja i DC razvodnih ormana;
- zamenu invertora, osigurača i SPD uređaja po isteku radnog veka;
- ažuriranje softverskih modula i arhiviranje podataka sa sistema nadzora.

Preporučuje se godišnja verifikacija performansi PV sistema (tzv. *annual performance check*) i revizija električnih spojeva kako bi se sprečilo degradiranje kontakata i povećanje otpora. Pravilno sprovedeno održavanje omogućava da sistem zadrži više od 85-90 % početne efikasnosti i produži radni vek na više od 25 godina.

Kombinacijom preciznog testiranja, automatizovanog monitoringa i redovnog održavanja obezbeđuje se visok stepen pouzdanosti i stabilnosti PV sistema, što predstavlja ključni preduslov za ostvarivanje predviđenih energetske, ekonomske i ekološke benefita tokom celokupnog perioda eksploatacije.

3.2 Softverski alati i simulacioni modeli

Tokom poslednje dve decenije razvijen je niz softverskih alata koji omogućavaju modeliranje, simulaciju i optimizaciju PV sistema. Ovi alati integrišu fizičke, empirijske i ekonomske modele radi procene performansi, gubitaka, proizvodnje energije i finansijske isplativosti sistema. Njihova primena omogućava sistematsku analizu različitih projektnih scenarija u zavisnosti od geografskih, meteoroloških i tehničkih uslova.

U okviru ove disertacije, program *PVsyst* korišćen je kao referentni fizičko–empirijski model za simulaciju energetske performansi PV sistema. *PVsyst* se zasniva na standardizovanim procedurama proračuna energetske bilansa i u skladu je sa smernicama IEC 61724-1 za praćenje i evaluaciju performansi PV sistema. Njegova primena omogućava detaljnu analizu svih komponenti energetske lanca - od solarne iradijacije, preko konverzije u PV modulu i invertoru, do isporuke energije u mrežu.

Rezultati dobijeni simulacijom u *PVsyst*-u korišćeni su kao referentne vrednosti za validaciju modela razvijenih u okviru ove disertacije, uključujući modele zasnovane na ANN implementirane u okruženju MATLAB/Simulink. Takav pristup omogućava kvantifikaciju odstupanja između determinističkog fizičkog modela i adaptivnog modela zasnovanog na podacima, čime se obezbeđuje metodološki rigorozna komparativna evaluacija.

Pored poređenja sa *PVsyst* simulacijama, rezultati prediktivnih modela upoređeni su i sa raspoloživim eksperimentalnim podacima, čime je uspostavljen trostepeni okvir verifikacije: (1) fizičko–empirijska simulacija (*PVsyst*), (2) model zasnovan na veštačkoj inteligenciji, i (3) mereni podaci. Ovakav validacioni pristup omogućava objektivnu procenu tačnosti i pouzdanosti predloženih modela, kao i identifikaciju njihovih ograničenja.

U Tabeli 3.1 dat je uporedni pregled najčešće korišćenih softverskih paketa za projektovanje i simulaciju PV sistema.

Tabela 3.1: *Uporedni pregled najčešće korišćenih softverskih alata za projektovanje i simulaciju PV sistema.*

Alat	Tip modela	Prednosti	Ograničenja	Izvor
PVsyst	Fizičko-empirijski	Detaljna analiza gubitaka i senčenja; standardizovan prema IEC 61724; korisnički interfejs i detaljan energetska bilans	Zatvoren kod; ograničena mogućnost integracije sa AI/ML algoritmima	[86], [87]
SAM (NREL)	Fizičko-ekonomski	Energetska i finansijska analiza; otvoren API; mogućnost izrade složenih scenarija	Osetljiv na kvalitet meteoroloških podataka i lokalne ekonomske parametre	[45], [46]
MATLAB/Simulink	Matematički/simulacioni	Visoka fleksibilnost; podrška za ANN, fuzzy i optimizacione algoritme; mogućnost modelovanja Digital Twin sistema	Zahteva dobro poznavanje sistema i programiranja; duže vreme simulacije	[88], [89]
HOMER Pro	Energetsko planiranje	Simulacija hibridnih sistema (PV-vetar-baterije-dizel); optimizacija troškova i konfiguracija	Ograničena vremenska rezolucija i uprošćeni meteorološki modeli	[70], [90]

PVsyst predstavlja profesionalni softverski alat zasnovan na fizičko–empirijskim modelima konverzije energije i detaljnom modelovanju gubitaka u PV sistemima. Uključuje baze podataka komponenti (moduli, invertori), meteorološke baze (Meteonorm, PVGIS) i 3D modele senčenja.

U ovoj disertaciji, PVsyst je korišćen za simulaciju referentnih scenarija proizvodnje električne energije, pri čemu su dobijeni rezultati služili kao validaciona osnova za poređenje sa ANN modelima i eksperimentalnim podacima. Na taj način, PVsyst je funkcionisao kao standardizovani referentni model za evaluaciju predloženog istraživačkog pristupa.

SAM (System Advisor Model) je razvijen od strane Nacionalne laboratorije za obnovljivu energiju (NREL, SAD). SAM kombinuje energetske i ekonomske modele i koristi se za analizu isplativosti projekata OIE. Alat omogućava unos lokalnih meteoroloških podataka, definisanje finansijskih scenarija i simulaciju ponašanja PV sistema u zavisnosti od tržišnih cena električne energije. Njegove prednosti su otvoreni API, jednostavna integracija sa Python skriptama i bogat skup predefinisanih tehnologija (PV, vetar, biomasa, geotermalna energija). Glavni nedostatak je zavisnost od tačnosti ulaznih podataka i složenost pri modelovanju lokalnih troškova i subvencija.

MATLAB/Simulink predstavlja naučno-istraživački standard za modelovanje i simulaciju dinamičkih sistema. U oblasti PV sistema omogućava razvoj sopstvenih fizičkih, matematičkih i AI modela (npr. MLP, LSTM, CNN-LSTM, XGBoost). Prednost MATLAB-a je potpuna fleksibilnost, podrška za digitalne blizance (*Digital Twin*) i integracija sa eksperimentalnim podacima iz laboratorija. Nedostatak je zahtev za naprednim poznavanjem programiranja i duže vreme simulacije u kompleksnim scenarijima.

HOMER Pro je softverski alat za energetske planiranje i optimizaciju hibridnih sistema koji kombinuju PV, vetrogeneratore, dizel generatore i baterijska skladišta. Fokusira se na ekonomsku optimizaciju i pronalaženje najisplativije konfiguracije sistema uz zadate energetske zahteve i resurse. Prednost HOMER-a je jednostavna integracija više izvora energije i precizna finansijska analiza, dok su glavni nedostaci ograničena vremenska rezolucija i uprošćeni meteorološki modeli.

Integracijom navedenih softverskih alata sa savremenim metodama VI i optimizacije (npr. genetski algoritmi, neuronske mreže i fuzzy sistemi), moguće je značajno unaprediti tačnost prognoza i efikasnost projektovanja PV sistema, čime se prelazi sa tradicionalnih determinističkih na adaptivne i inteligentne pristupe modeliranju.

3.3 Ograničenja konvencionalnih metoda

Iako su konvencionalne metode projektovanja PV sistema široko prihvaćene u inženjerskoj praksi i predstavljaju osnovu komercijalnih softverskih rešenja, one pokazuju niz ograničenja koja postaju sve izraženija u savremenim uslovima dinamičkog upravljanja energijom i povećanog udela obnovljivih izvora u elektroenergetskim mrežama. Njihova statička

priroda i ograničena mogućnost prilagođavanja promenljivim meteorološkim i operativnim uslovima često dovode do smanjene tačnosti simulacija i otežavaju primenu u sistemima za nadzor u realnom vremenu.

Glavna ograničenja konvencionalnih metoda mogu se svesti na:

- **Statička priroda modela** - većina komercijalnih softvera koristi prosečne mesečne ili godišnje vrednosti globalne solarne iradijacije i temperature, čime se zanemaruje vremenska varijabilnost i gube informacije o kratkoročnim fluktuacijama solarne energije (npr. oblačnost, senčenje, promene albeda).
- **Nedostatak prediktivnih komponenti** - konvencionalni pristupi ne uključuju analizu vremenskih serija niti algoritme ML za prognozu meteoroloških parametara ili izlazne snage PV sistema. Time se ograničava njihova primena u dinamičkim sistemima upravljanja i planiranju rada mreže.
- **Nepotpuna integracija podataka** - ulazni podaci iz različitih izvora (npr. lokalne meteorološke stanice, Meteosat, ERA5 reanalize) često se koriste nezavisno, bez međusobne validacije i fuzije, što dovodi do nesigurnosti u izlaznim rezultatima i smanjene robustnosti modela.
- **Ograničena validacija modela** - simulacioni rezultati se najčešće porede sa idealizovanim proračunima ili standardnim testnim uslovima (STC), dok su poređenja sa realnim merenjima (field data) i performansama u režimu radne temperature modula (NOCT) retka i ograničena.
- **Neadekvatna primenljivost za pametne bidirekzione mreže** - većina postojećih softverskih paketa ne podržava dvosmernu komunikaciju sa sistemima merenja i nadzora (SCADA/EMS), niti omogućava implementaciju adaptivnog upravljanja i optimizacije u realnom vremenu.

Zbog ovih ograničenja, savremena istraživanja u oblasti PV sistema sve više teže integrisanim i prediktivnim modelima koji kombinuju klasične fizičke proračune sa naprednim VI algoritmima, optimizacije performansi i *Digital Twin* konceptima. Ovakvi pristupi omogućavaju preciznije predviđanje proizvodnje, automatsku dijagnostiku i adaptivno upravljanje PV elektranama u okviru pametnih mreža nove generacije.



4. Metodologija istraživanja

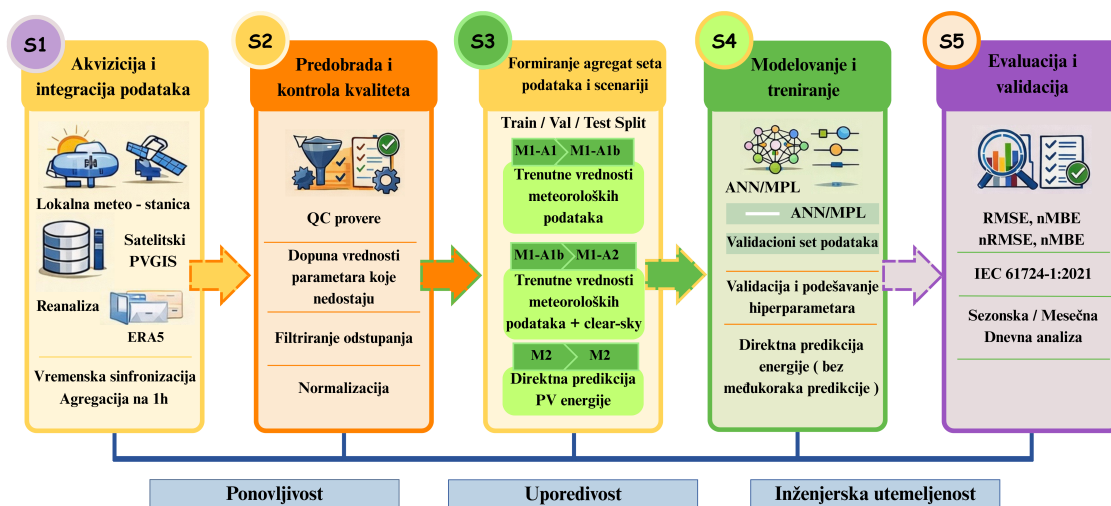
Metodologija istraživanja u ovoj doktorskoj disertaciji organizovana je kao sekvencijalni, ali iterativni proces, osmišljen tako da obezbedi konzistentnu integraciju heterogenih izvora podataka, sistematsko generisanje prediktivnih modela i objektivnu evaluaciju njihovih performansi.

Ovo poglavlje detaljno definiše metodološki okvir primenjen u istraživanju, uključujući strukturu i harmonizaciju podataka, postupke predprocesiranja i normalizacije podataka, eksperimentalno okruženje, protokol treniranja i testiranja prediktivnih modela, kao i kriterijume evaluacije i validacije u skladu sa relevantnim IEC smernicama. Metodologija je koncipirana tako da obezbedi ponovljivost, uporedivost i inženjersku konzistentnost rezultata, uz jasno razdvajanje eksperimentalnih scenarija u zavisnosti od dostupnosti ulaznih podataka.

4.1 Integrisani okvir istraživanja

Integrisani okvir istraživanja zasnovan je na višeslojnom, sistematskom pristupu koji povezuje akviziciju i integraciju podataka, prethodnu obradu i formiranje skupa podataka, razvoj i treniranje prediktivnih modela, kao i evaluaciju performansi u skladu sa IEC-orientisanim kriterijumima. Ovaj okvir predstavlja metodološku osnovu disertacije i omogućava konzistentno razmatranje različitih scenarija dostupnosti ulaznih podataka i modelskih pristupa.

Principijelni prikaz integrisanog okvira dat je na slici 4.1, gde je metodologija istraživanja i generisanja prediktivnih modela organizovana u pet međusobno povezanih faza (S1-S5), koje se u nastavku poglavlja analiziraju pojedinačno.



Slika 4.1: Principijelni prikaz metodološkog okvira istraživanja (S1-S5).

S1 - Akvizicija i integracija podataka

Početa faza metodološkog okvira je usmerena na formiranje konzistentne i vremenski usklađene baze podataka koja objedinjuje heterogene izvore meteoroloških, radiometrijskih i energetske informacije. Cilj ove faze nije samo prikupljanje podataka, već njihova sistematska verifikacija, strukturno usklađivanje i priprema za dalju analitičku obradu.

U okviru S1 objedinjeni su: (i) lokalna in-situ meteorološka i energetska merenja sa eksperimentalnog PV sistema, (ii) satelitsko-modelirani podaci, (iii) reanalizni meteorološki skupovi podataka, kao i (iv) rezultati PV_{sys} simulacija korišćeni u validacionom kontekstu. S obzirom na razlike u prostornoj reprezentativnosti i vremenskoj rezoluciji navedenih izvora, posebna pažnja posvećena je postupku vremenske sinhronizacije i agregacije, pri čemu je formiran jedinstveni satni skup podataka kao referentna osnova za naredne faze metodologije (S2-S5).

Detaljna struktura izvora, njihova klasifikacija i postupak integracije prikazani su u Odeljku 4.3.

S2 - Predprocesuiranje i kontrola kvaliteta podataka

Druga faza metodološkog okvira usmerena je na pripremu integriranog skupa podataka za modelovanje, uz obezbeđivanje fizičke konzistentnosti, numeričke stabilnosti i metodološke korektnosti eksperimentalnog protokola.

U ovoj fazi izvršena je kontrola kvaliteta podataka, identifikacija i tretman nedostajućih i filtriranje fizički nerealnih vrednosti, kao i definisanje evaluacione dnevne maske u skladu sa preporukama standarda IEC 61724-1 [65]. Posebna pažnja posvećena je skaliranju ulaznih promenljivih i sprečavanju curenja informacija između trening, validacionog i

test skupa. Rezultat faze S2 predstavlja fizički validiran, statistički homogen i numerički stabilan skup podataka, spreman za konstrukciju ulazno–izlaznih parova i formiranje eksperimentalnih konfiguracija u fazi S3.

Detaljan opis primenjenih procedura predobrade i normalizacije dat je u Odeljku 4.4.

S3 - Formiranje skupa podataka i definisanje eksperimentalnih konfiguracija

Treća faza metodološkog okvira predstavlja prelaz između predobrade podataka (S2) i razvoja prediktivnih modela (S4). U ovoj fazi formirani su ulazno–izlazni parovi, definisane eksperimentalne konfiguracije modela i uspostavljen vremenski konzistentan protokol podele skupa podataka.

Nadgledani skup podataka konstruisan je u obliku parova (\mathbf{x}_k, y_{k+H}) , gde \mathbf{x}_k predstavlja ulazni vektor u trenutku k , dok je y_{k+H} ciljna promenljiva predviđena H sati unapred. Definicija ulazne strukture zavisi od razmatrane konfiguracije modela, što je konceptualno prikazano na slikama 5.5 i 5.24. U ovoj fazi formalizovane su dve konceptualno različite strategije modelovanja: indirektni pristup (M1), zasnovan na predikciji *GHI* i naknadnoj proceni energije, i direktni pristup (M2), koji realizuje mapiranje meteoroloških veličina direktno na energetska izlazna promenljiva.

Detaljan opis vremenske podele skupa podataka, konstrukcije nadgledanog skupa i eksperimentalnih konfiguracija dat je u Odeljku 4.5.

S4 - Modelovanje i treniranje prediktivnih modela

Četvrta faza metodološkog okvira obuhvata implementaciju, parametrizaciju i treniranje prediktivnih modela definisanih u fazi S3. U ovoj fazi realizovana je aproksimacija nelinearne zavisnosti između ulaznih meteoroloških promenljivih i ciljne veličine (iradijacija ili energija), primenom data-driven modela.

U zavisnosti od eksperimentalne konfiguracije, model realizuje preslikavanje oblika

$$\hat{y}_{k+H} = f_{\theta}(\mathbf{x}_k), \quad (4.1)$$

odnosno, u slučaju vremenski proširenog ulaza,

$$\hat{y}_{k+H} = f_{\theta}(\mathbf{X}_L(k)), \quad (4.2)$$

gde θ predstavlja skup parametara na kojima se trenira mreža. U ovoj fazi izvršena je sistematska optimizacija hiperparametara¹, primena regularizacionih tehnika i kontrola

¹Hiperparametri veštačke neuronske mreže predstavljaju unapred definisane parametre koji se ne uče tokom procesa treniranja, već se određuju pre početka obuke modela. Oni uključuju, između ostalog, arhitek-

preinačenosti, dok je konačna evaluacija modela ostavljena za završnu fazu metodologije (S5).

Detaljna matematička formulacija, struktura modela i protokol treniranja prikazani su u Odeljku 4.6.

S5 - Evaluacija, validacija i interpretacija performansi

Završna faza metodološkog okvira obuhvata nezavisnu kvantitativnu evaluaciju, komparativno poređenje i inženjersku interpretaciju performansi razvijenih modela. Evaluacija je sprovedena isključivo na test skupu, koji nije korišćen tokom treniranja niti pri izboru hiperparametara, čime je obezbeđena objektivnost dobijenih rezultata.

U ovoj fazi primenjen je konzistentan skup metrika tačnosti i pristrasnosti (bias), uz dodatnu analizu strukture greške na različitim vremenskim skalama (dnevnoj, mesečnoj i sezonskoj). Za indirektno konfiguracije modela iz grupe M1 sprovedena je i energetska validacija primenom PR-baziranog fizičkog modela, uz poređenje sa rezultatima PVsyst simulacija i dostupnim merenim podacima. Nasuprot tome, kod modela M2 evaluacija energetskih veličina realizovana je direktno, budući da model neposredno predviđa proizvedenu električnu energiju PV sistema.

Detaljan opis metrika, IEC-orijentisanog pristupa evaluaciji i protokola validacije dat je u Odeljcima 4.7 i 4.8.

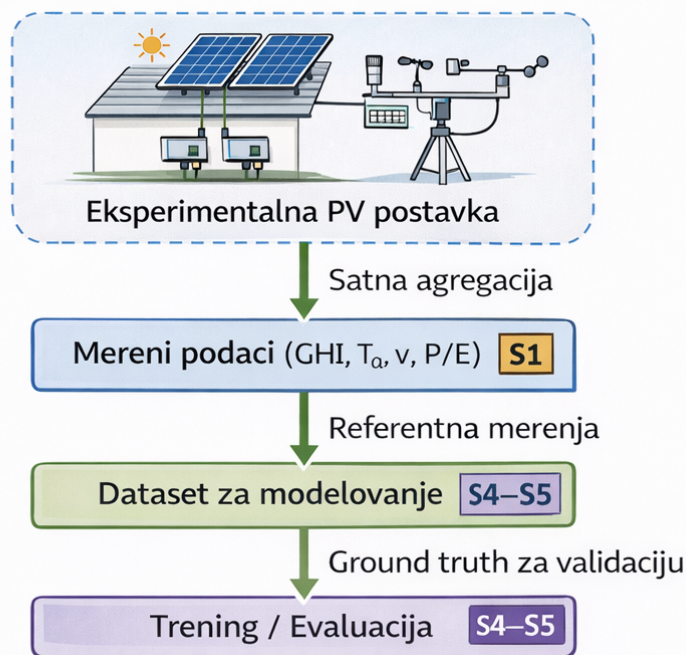
4.2 Eksperimentalno okruženje

Eksperimentalni deo istraživanja realizovan je na Elektronskom fakultetu Univerziteta u Nišu, u okviru laboratorije, kroz implementaciju modularnog PV sistema male snage, konceptualno projektovanog kao mrežno povezan (on-grid) sistem. Međutim, sistem nije fizički priključen na distributivnu elektroenergetsku mrežu, već je veza sa mrežom realizovana simulaciono, čime je omogućena kontrolisana laboratorijska analiza bez stvarnog injektovanja energije u mrežu.

Primarna uloga eksperimentalne postavke (slika 4.2) nije proizvodnja električne energije, već obezbeđivanje referentnih merenih podataka za fazu akvizicije i integracije podataka (S1), kao i nezavisne validacije i evaluacije prediktivnih modela u završnoj fazi metodologije (S5).

Eksperimentalni sistem obezbeđuje satno agregirane merene veličine (GHI, temperatura vazduha, AC snaga i energija), koje predstavljaju referentni izvor za poređenje sa rezultatima ANN modela i PR-baziranih energetskih procena.

turu mreže (broj slojeva i neurona), izbor algoritma treniranja, stopu učenja, broj epoha i regularizacione parametre, i imaju ključni uticaj na performanse i sposobnost generalizacije modela.



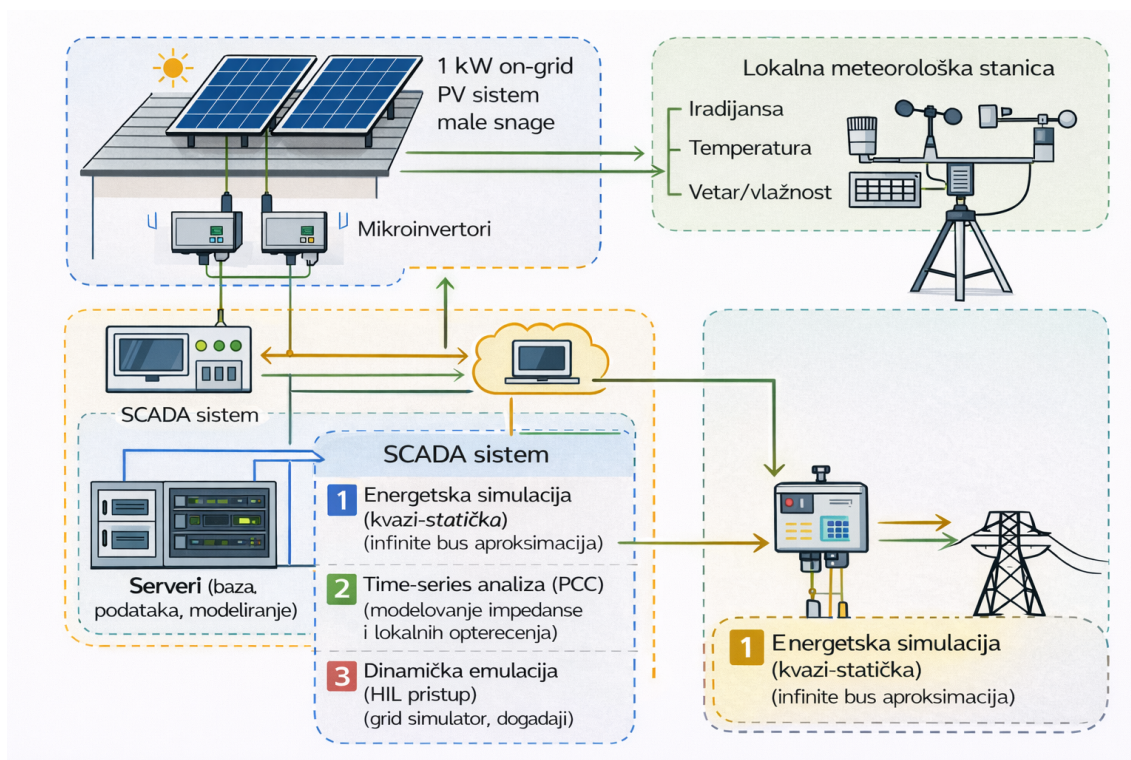
Slika 4.2: Uloga eksperimentalnog PV sistema u okviru metodološkog okvira disertacije. Sistem obezbeđuje referentne merene podatke za faze S1 i S5.

4.2.1 Konfiguracija PV sistema i merni podsistemi

Eksperimentalna postavka sastoji se od sledećih funkcionalnih podsistema:

- **PV podsistem:** dva monokristalna modula nazivne snage 500 W (ukupno 1 kW), orijentisana ka jugu uz nagib približno optimalan za geografsku lokaciju Niša. Svaki modul povezan je na zaseban mikroinverter, čime je obezbeđen nezavisan MPPT po modulu.
- **Meteorološki podsistem:** lokalna merna stanica sa kontinuiranim merenjem GHI, temperature vazduha T_a , brzine vetra v i relativne vlažnosti (RH).
- **SCADA sloj:** sistem za vremensku sinhronizaciju, prikupljanje i centralizovano skladištenje podataka sa PV sistema i meteoroloških senzora.
- **Analitički sloj:** serverska infrastruktura za predobradu podataka, formiranje skupa podataka i razvoj prediktivnih modela.

Detaljna tehnička arhitektura eksperimentalne postavke, sa prikazom energetske i informacione tokove između PV podsistema, meteorološke stanice, SCADA infrastrukture, analitičkog sloja i priključne tačke na mrežu, data je na slici 4.3. Šema obuhvata i konceptualne nivoe simulacije/emulacije mrežnog priključenja razmatrane u okviru ovog istraživanja. Specifikacija eksperimentalnog PV sistema je data u Tabeli 4.1.



Slika 4.3: Šematski prikaz eksperimentalnog 1 kW on-grid PV sistema sa mikroinvertorskom arhitekturom, SCADA slojem i konceptualnim nivoima simulacije/emulacije mrežnog priključenja.

Tabela 4.1: Specifikacija eksperimentalnog PV sistema.

Komponenta	Specifikacija	Opis	Napomena
PV moduli	2 × 500 W (mono-Si)	1 kW ukupno	Krov laboratorije, Niš
Mikroinvertori	2 × mikroinverter	MPPT po modulu	Modul-po-modul arhitektura
Orijentacija / nagib	jug / $\approx 35^\circ$	blisko optimalnom	Lokacija Niš
Meteorološki senzori	GHI, T_a , v , RH	uzorkovanje 1–10 min	Lokalna stanica
Povezivanje na mrežu	on-grid	bez skladištenja	Kvazi-statička simulacija

4.2.2 Simulacija i emulacija priključenja na mrežu

S obzirom da je sistem male snage (1 kW) nije priključen na niskonaponsku distribucionu mrežu, postavlja se pitanje mogućnosti simulacije ili emulacije mrežnog priključenja u kontrolisanom laboratorijskom okruženju. U kontekstu ove disertacije razmatrana su tri konceptualna nivoa:

1. **Energetska (kvazi-statička) simulacija:** mreža se modeluje kao idealni izvor napona (infinite bus aproksimacija), a analiza se svodi na vremensku seriju AC snage i energije. Ovaj pristup je u potpunosti kompatibilan sa PR i PR_T modelima korišćenim u metodologiji.
2. **Time-series mrežna analiza (PCC model):** modelovanje priključne tačke (impedansa voda, lokalna opterećenja, naponske varijacije), pri čemu inverter funkcioniše kao PQ izvor. Ovaj nivo omogućava analizu uticaja lokalnih naponskih prilika na proizvodnju.
3. **Dinamička emulacija (HIL pristup):** upotreba programabilnog mrežnog emulatora i PV simulatora radi testiranja dinamičkog ponašanja invertora (PLL, zaštite, anti-islanding).

U okviru ovog istraživanja primenjen je prvi pristup, budući da je primarni cilj energetska validacija i evaluacija prediktivnih modela, dok detaljna elektromrežna dinamika nije predmet analize.

Napomena o reprezentativnosti sistema male snage

Iako eksperimentalni sistem ima relativno malu instalisanu snagu (1 kW), njegova reprezentativnost za validaciju prediktivnih modela proizilazi iz činjenice da se dominantne nelinearne zavisnosti između meteoroloških parametara i izlazne snage određuju atmosferskim uslovima, temperaturom i dinamikom oblačnosti, a ne apsolutnom instalisanom snagom sistema.

Mikroinvertorska arhitektura dodatno obezbeđuje visoku vremensku rezoluciju merenja, nezavisni MPPT po modulu i povećanu robusnost sistema u uslovima parcijalnog osenčenja, što doprinosi kvalitetu referentnih podataka.

4.2.3 Računarska infrastruktura i softverski alati

Analiza podataka, treniranje i evaluacija prediktivnih modela izvedeni su na lokalnoj radnoj stanici, čija konfiguracija obezbeđuje dovoljnu računarsku snagu za obradu višegodišnjih vremenskih serija, implementaciju neuronskih mreža i izvođenje opsežnih eksperimentalnih analiza. Hardverska konfiguracija korišćena u istraživanju data je u nastavku:

- **CPU:** Intel Core i7-12700K
- **GPU:** NVIDIA GeForce RTX 4070 (12 GB)
- **RAM:** 64 GB DDR5

- **Hard disk:** SSD NVMe 2 TB
- **Operativni sistemi:** Windows 11 Pro

Softverski alati i okruženja korišćeni u okviru istraživanja izabrani su tako da omoguće pouzdanu predobradu podataka, fleksibilnu implementaciju prediktivnih modela i transparentnu evaluaciju rezultata:

- **MATLAB/Simulink:** korišćen za predobradu podataka, analizu vremenskih serija, implementaciju ANN modela, kao i pomoćne numeričke proračune i vizuelizaciju rezultata;
- **PVsys:** korišćen za referentne simulacije i komparativnu analizu u slučajevima kada je takvo poređenje metodološki opravdano;
- **PVGIS API:** korišćen za preuzimanje satnih meteoroloških i radiometrijskih podataka (GHI, DNI, DHI, temperatura vazduha i prateće veličine) u cilju dopune i upoređivanja sa lokalnim merenjima;
- **GIS alati (po potrebi):** korišćeni za prostorne provere, pripremu lokacijskih ulaza i verifikaciju geografskih parametara sistema.

Kombinacija navedene hardverske i softverske infrastrukture omogućila je konzistentnu implementaciju metodološkog okvira, ponovljivost eksperimenata i efikasno poređenje različitih modelskih scenarija u skladu sa zahtevima disertacije.

Opisano eksperimentalno okruženje, zajedno sa računarskom i softverskom infrastrukturom, obezbeđuje pouzdanu osnovu za prikupljanje, sinhronizaciju i skladištenje merenih podataka, kao i za njihovu dalju analizu i obradu. Na ovaj način stvoren je konzistentan skup ulaznih informacija koji se u nastavku rada koristi u fazi akvizicije, integracije i strukturiranja podataka u okviru metodološke celine S1. U sledećem odeljku detaljno se razmatraju izvori korišćenih podataka, postupci njihove integracije i način formiranja ulaznih skupova za različite eksperimentalne scenarije.

4.3 Izvori, integracija i struktura podataka

U okviru metodološke faze akvizicije i integracije podataka (S1), korišćeni su podaci iz više komplementarnih izvora, pri čemu svaki izvor obezbeđuje specifične meteorološke, radiometrijske ili energetske informacije relevantne za modelovanje i predviđanje izlaza PV sistema. Pored lokalnih in-situ merenja, u analizu su uključeni i satelitski i reanalizni meteorološki podaci (engl. *reanalysis weather data*), koji predstavljaju vremenske serije rekonstruisane kombinacijom istorijskih merenja, numeričkih modela i asimilacije podataka. Na taj način obezbeđen je prostorno i vremenski homogen skup parametara pogodan za dugoročno treniranje i nezavisnu evaluaciju modela.

U kontekstu PV sistema, raspoloživost i varijabilnost solarnog zračenja predstavljaju dominantan spoljašnji faktor koji određuje kratkoročne promene izlaza, dok meteorološki parametri (poput temperature vazduha, relativne vlažnosti i brzine vetra) utiču na termalno

stanje modula i posredno na energetska efikasnost sistema. Zbog toga je u okviru faze S1 izvršena integracija više izvora podataka u jedinstvenu, vremenski usklađenu satnu bazu, koja predstavlja osnovu za formiranje ulazno–izlaznih parova definisanih u fazi S3.

Ključne ulazne veličine. U ovom istraživanju centralnu ulogu imaju radiometrijski parametri (GHI, a gde je dostupno i DNI i DHI), uz prateće meteorološke veličine (T_a , RH, v) i izvedene referentne (*clear-sky*) komponente. Ove veličine čine osnovu ulaznog prostora u eksperimentalnim konfiguracijama M1 i M2, pri čemu je GHI definisan kao ciljna veličina u indirektnom pristupu (M1), dok se u direktnom pristupu (M2) meteorološke i radiometrijske veličine mapiraju neposredno na energetska izlaznu promenljivu.

4.3.1 Pregled i klasifikacija izvora podataka

U okviru istraživanja korišćene su tri komplementarne klase izvora podataka, koje se razlikuju prema nivou prostorne reprezentativnosti, vremenskoj rezoluciji i fizičkoj verodostojnosti:

1. **Lokalna in-situ merenja** sa eksperimentalnog PV sistema i meteorološke stanice,
2. **Satelitski i hibridni meteo podaci** dostupni putem javnih servisa (npr. PVGIS),
3. **Reanalizni meteorološki podaci**, dobijeni kombinacijom istorijskih merenja, numeričkih modela i asimilacije podataka.

Lokalna merenja predstavljaju referentni izvor (*ground truth*) za validaciju modela, budući da obezbeđuju podatke visoke vremenske rezolucije direktno sa lokacije sistema. Satelitski i hibridni podaci omogućavaju prostorno kontinuiranu procenu radijacionih i meteoroloških parametara, dok reanalizni podaci obezbeđuju vremenski homogen skup meteoroloških parametara za duge višegodišnje periode (2005-2022. godine), što je od značaja za treniranje i testiranje modela na proširenim vremenskim serijama. Osnovne karakteristike korišćenih izvora prikazane su u Tabeli 4.2.

Tabela 4.2: Klasifikacija i osnovne karakteristike izvora podataka korišćenih u istraživanju.

Izvor	Parametri	Vremenska rezolucija	Prostorna rezolucija	Period
Lokalna meteo-stanica + PV sistem	GHI, T_a , RH, v , P/E	1-10 min, 1 h (lokacija sistema)	tačkasto	2017–2022.
Satelitski / hibridni proizvodi (PVGIS)	GHI, DNI, DHI, T_a	1 h	~1 km	2017–2022.
Reanaliza (ERA5 i sl.)	meteorološki parametri	1 h	10–50 km red veličine	2005–2022.

4.3.2 Lokalna merenja kao referentni izvor podataka

Podaci dobijeni od lokalne meteorološke stanice u Nišu (slika 4.4), koja se nalazi u neposrednoj blizini Elektronskog fakulteta tako da lokalna merenja sa eksperimentalne PV postavke predstavljaju referentni izvor podataka u istraživanju, budući da direktno odlikavaju stvarno ponašanje sistema u datim meteorološkim uslovima. Ovi podaci koriste se kao referentni izvor za validaciju prediktivnih modela, kao i za proveru konzistentnosti i kvaliteta satelitskih i reanaliznih izvora.



Slika 4.4: Meteorološka stanica u Nišu koja se nalazi Tvrđavi u okolini Elektronskog fakulteta.

Merenja se inicijalno prikupljaju sa višom vremenskom rezolucijom (1-10 minuta), a zatim se agregiraju na satni vremenski korak, čime se obezbeđuje kompatibilnost sa ostalim izvorima i doslednost u kasnijoj evaluaciji modela.

4.3.3 Satelitski i reanalizni izvori podataka

Satelitski i reanalizni izvori podataka korišćeni su radi obezbeđivanja kontinuiranih i dugoročnih vremenskih serija meteoroloških i radiometrijskih parametara, naročito u periodima kada lokalna in-situ merenja nisu dostupna ili kada je potrebno proširiti vremenski opseg analize.

U okviru istraživanja korišćeni su satelitsko-modelirani (hibridni) skupovi podataka, poput NSRDB baze [91], koja obezbeđuje satne vrednosti globalnog horizontalnog zračenja (GHI), direktne normalne komponente (DNI), difuzne horizontalne komponente (DHI), kao i odgovarajuće *clear-sky* veličine (GHI_{cs} , DNI_{cs} , DHI_{cs}). Tipična prostorna rezolucija NSRDB podataka iznosi približno 4 km, što omogućava relativno detaljan prostorni prikaz radijacionih uslova u odnosu na klasične reanalizne skupove podataka. Pored radiometrijskih parametara, dostupni su i prateći meteorološki podaci (temperatura vazduha

T_a , tačka rose, tip oblaka i dr.), čime se omogućava formiranje proširenog skupa ulaznih karakteristika za ANN modele.

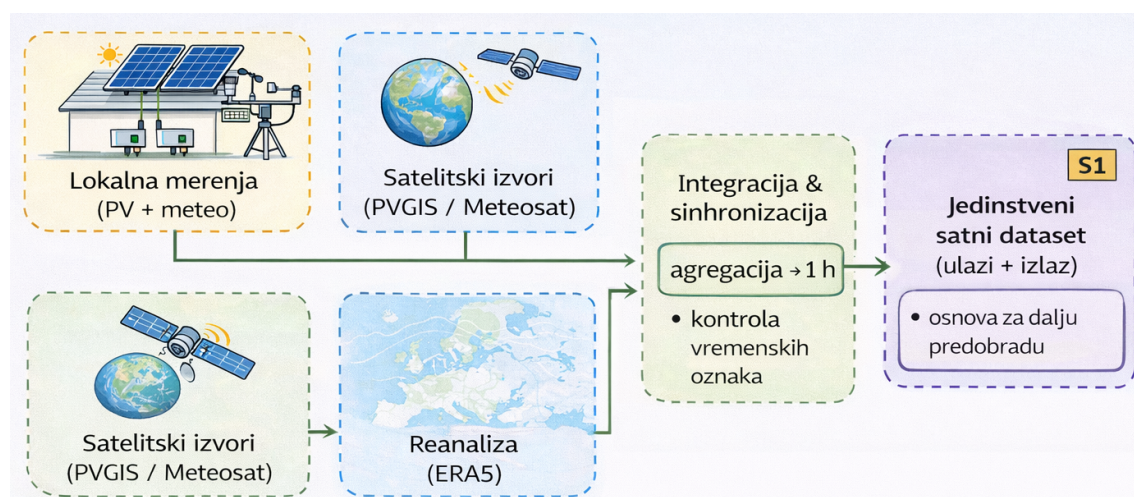
Reanalizni podaci, s druge strane, predstavljaju meteorološke vremenske serije rekonstruisane kombinacijom istorijskih merenja, numeričkih modela atmosfere i asimilacije podataka, čime se obezbeđuje prostorno i vremenski homogen skup parametara za duge višegodišnje periode. Ovakvi skupovi podataka posebno su pogodni za treniranje modela na dugim vremenskim serijama (2005-2022.) i za procenu njihove robusnosti u različitim klimatskim uslovima.

Iako se satelitski i reanalizni izvori razlikuju po prostornoj rezoluciji i metodologiji generisanja, njihova uloga u okviru metodološke faze S1 jeste obezbeđivanje konzistentnih, vremenski usklađenih i strukturno homogenih ulaznih podataka koji se mogu objediniti sa lokalnim merenjima u jedinstvenu bazu pogodnu za dalju obradu i modelovanje.

Napomena o opsegu procene solarnih resursa

Iako se u klasičnim analizama solarnih resursa često sprovode postupci poput transpozicije zračenja na nagnutu ravan i formiranja TMY, u ovoj disertaciji satne vremenske serije radiometrijskih i meteoroloških parametara koriste se prvenstveno kao ulazi za kratkoročnu predikciju. Energetska interpretacija rezultata realizovana je kroz PR-bazirani kvazi-statički model (M1) i/ili direktnu predikciju energije (M2), uz PVsyst kao referentni simulacioni okvir gde je primenljivo.

4.3.4 Integracija i vremenska sinhronizacija podataka



Slika 4.5: Integracija heterogenih izvora podataka u fazi S1 i formiranje jedinstvenog satnog skupa podataka.

Proces integracije podataka, šematski prikazan na Slici 4.5, obuhvata vremensko poravnanje, agregaciju i objedinjavanje lokalnih in-situ merenja, satelitsko–modeliranih meteoroloških podatak i reanaliznih meteoroloških vremenskih serija u jedinstvenu strukturu podataka. S obzirom na različitu vremensku rezoluciju (1-10 min za lokalna merenja,

1 h za satelitske i reanalizne izvore) i prostornu reprezentativnost, svi podaci su sinhronizovani prema jedinstvenoj vremenskoj osi i agregirani na satni vremenski korak. Time je obezbeđeno konzistentno poravnanje vremenskih oznaka i minimizovan uticaj eventualnih vremenskih pomeranja ili interpolacionih postupaka.

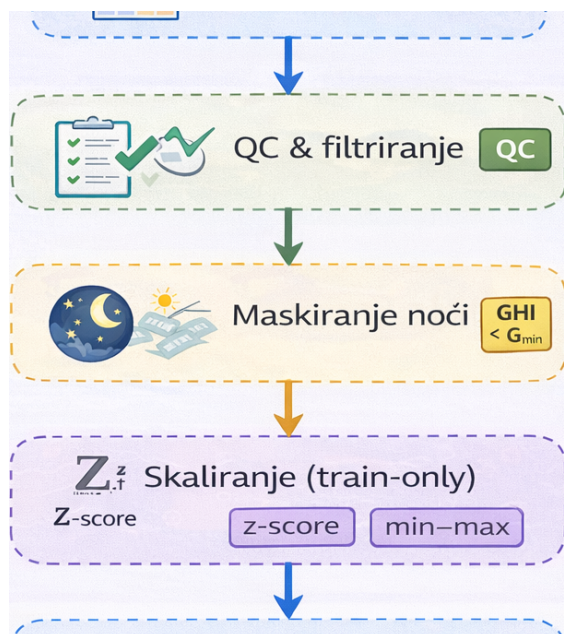
Rezultat ovog procesa je metodološki homogen, vremenski usklađen satni skupa podataka, koji predstavlja osnovu za dalju predobradu, definisanje ulazno-izlaznih parova i formiranje eksperimentalnih scenarija za treniranje i evaluaciju prediktivnih modela.

Napomena o nedostajućim vrednostima

Tokom procesa integracije izvršena je kontrola nedostajućih i nekonzistentnih meteo podataka. Kraći prekidi u lokalnim merenjima tretirani su linearnom interpolacijom ili agregacijom na satni nivo, dok su duži periodi bez podataka isključivani iz analize kako bi se izbeglo uvođenje sistematske greške. Kod satelitskih i reanaliznih izvora nedostajuće vrednosti su identifikovane i filtrirane pre formiranja konačnog skupa podataka, čime je obezbeđena numerička stabilnost u fazi treniranja modela.

4.4 Predobrada, kontrola kvaliteta i normalizacija

Nakon faze akvizicije i integracije podataka (S1), sprovedena je sistematska predobrada skupa podataka sa ciljem da se obezbede numerički stabilni, fizički konzistentni i metodološki korektni ulazni podaci za treniranje i razvoj prediktivnih modela. Faza S2 obuhvata kontrolu kvaliteta, tretman nedostajućih i nekonzistentnih podataka, maskiranje intervala bez informativnog sadržaja, kao i skaliranje promenljivih, pri čemu su sve procedure definisane tako da se spreči curenje informacija između trening, validacionog i test skupa. Tok postupka predobrade podataka je šematski prikazan na slici 4.6.



Slika 4.6: Tok predobrade podataka (S2).

4.4.1 Kontrola kvaliteta i obrada nedostajućih vrednosti

Kontrola kvaliteta obuhvata identifikaciju i uklanjanje podataka koji su fizički nerealni, statistički anomalni ili nepotpuni. Najpre su primenjene sledeće procedure:

- Detekcija nedostajućih vrednosti i isključenje vremenskih intervala bez kompletnog skupa ključnih ulaznih ili izlaznih promenljivih;
- Detekcija ekstremnih odstupanja primenom robustnih statističkih kriterijuma i fizički utemeljenih granica (npr. $GHI \geq 0$, koristi se samo nenegativna insolacija);
- Logičke i fizičke provere konzistentnosti, uključujući međusobnu usklađenost radijacionih i meteoroloških veličina.

Intervali sa izraženim nekonzistentnostima u podacima (npr. nagli skokovi, nedostajuće vrednosti ili neslaganje između merenih i simulacionih veličina) isključuju se iz dalje analize kako bi se sprečilo uvođenje sistematskih grešaka u proces treniranja i evaluacije modela. Na ovaj način obezbeđuje se da model uči isključivo iz reprezentativnih i pouzdanih uzoraka, čime se unapređuje njegova sposobnost generalizacije i smanjuje rizik od pristrasnih procena performansi.

4.4.2 Maskiranje noćnih sati i niskih iradijacija

Zbog izražene dnevne periodičnosti PV proizvodnje, intervali sa zanemarljivom dostupnom solarnom energijom nemaju informativni značaj za evaluaciju modela. Zbog toga se uvodi prag minimalne relevantne iradijacije G_{\min} , pri čemu su časovi za koje važi:

$$GHI < G_{\min}, \quad (4.3)$$

maskirani pri izračunavanju metrika. Maskiranje ne menja izvorne podatke, već isključivo utiče na evaluaciju karakteristika modela, čime se izbegava veštačko uvećavanje relativnih grešaka i narušavanje interpretacije dnevnih, mesečnih i sezonskih profila greške.

4.4.3 Normalizacija i skaliranje ulaznih promenljivih

Radi obezbeđivanja numeričke stabilnosti i efikasne konvergencije algoritama učenja, kontinuirane ulazne promenljive skalirane su pre treniranja modela. U zavisnosti od eksperimentalnog scenarija, primenjene su standardne procedure:

- **Z-score standardizacija:**

$$x^* = \frac{x - \mu_x}{\sigma_x}, \quad (4.4)$$

gde su:

- x - realizacija ulazne promenljive,
- μ_x - empirijska srednja vrednost promenljive x ,
- σ_x - empirijska standardna devijacija promenljive x ,
- x^* - standardizovana vrednost promenljive, važi $\mathbb{E}[x^*] = 0$ i $\text{Var}(x^*) = 1$.

- **Min-max normalizacija:**

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}}. \quad (4.5)$$

gde su:

- x - realizacija ulazne promenljive,
- x_{\min} i x_{\max} - empirijske minimalna i maksimalna vrednost promenljive x ,
- x^* - normalizovana vrednost promenljive, za koju važi $x^* \in [0, 1]$.

Parametri skaliranja određeni su isključivo na trening skupu, a zatim primenjeni na validacioni i test skup, čime je obezbeđena metodološki korektna evaluacija bez curenja informacija.

Kodiranje cikličnih vremenskih promenljivih

S obzirom na periodičnu prirodu vremenskih komponenti (sat u danu, dan u godini), na njih nije primenjivana linearna normalizacija, jer bi dovela do veštačkog diskontinuiteta (npr. prelaz 23 h \rightarrow 0 h). Umesto toga, ciklične promenljive transformisane su korišćenjem sinusno-kosinusnog kodiranja:

$$h_{\sin} = \sin\left(\frac{2\pi h}{24}\right), \quad h_{\cos} = \cos\left(\frac{2\pi h}{24}\right), \quad (4.6)$$

gde je h sat u danu.

Analogno, za dan u godini (d) se koristi:

$$d_{\sin} = \sin\left(\frac{2\pi d}{365}\right), \quad d_{\cos} = \cos\left(\frac{2\pi d}{365}\right). \quad (4.7)$$

Ovakav pristup predstavlja standardnu praksu u modelovanju vremenskih serija podataka i ML, jer omogućava očuvanje kontinuiteta periodičnih promjenljivih i poboljšava sposobnost modela da uči sezonske i dnevne obrasce [92].

4.4.4 Normalizacija grešaka i IEC-orijentisan pristup

Pored apsolutnih metrika greške (MAE, RMSE i MBE), u analizi su korišćene i normalizovane metrike $nRMSE$ i $nMBE$, radi obezbeđivanja uporedivosti rezultata kroz različite sezone, nivoe iradijacije i obime proizvodnje.

Normalizacija je izvršena u odnosu na referentnu veličinu Y_{ref} , definisanu kao srednja merena vrednost posmatranog izlaza u odgovarajućem skupu podataka:

$$nRMSE = \frac{RMSE}{Y_{\text{ref}}}, \quad nMBE = \frac{MBE}{Y_{\text{ref}}}. \quad (4.8)$$

Ovakva definicija omogućava skaliranje greške u odnosu na karakteristični nivo proizvodnje, čime se izbegava sezonski bias i omogućava objektivno poređenje modela sa različitim energetske profilima.

Primena normalizovanih metrika usklađena je sa principima standarda IEC 61724-1:2021 i omogućava jasno razdvajanje sistematskog bias-a i disperzije greške, uz interpretaciju rezultata u inženjerski relevantnom kontekstu.

4.5 Podele skupa podataka i konfiguracije modela

Treća faza metodološkog okvira (S3) obuhvata: (i) formiranje nadgledanog skupa podataka, (ii) vremenski konzistentnu podelu skupa podataka i (iii) formalno definisanje eksperimentalnih konfiguracija modela. Ova faza predstavlja vezu između predobrade podataka (S2) i razvoja prediktivnih modela (S4).

4.5.1 Vremenski konzistentna podela skupa podataka

Podela skupa podataka izvršena je vremenski konzistentno, kako bi se simulirao realan operativni scenario primene modela. Skup podataka obuhvata period 2005–2022. godina i podeljen je na (slika 4.7):

- trening skup (2005–2020),
- validacioni skup (2021),
- test skup (2022).



Slika 4.7: Vremenski konzistentna podela skupa podataka na trening, validacioni i test skup (2005–2022).

Podela je realizovana na osnovu vremena ciljne promenljive y_{k+H} , čime je sprečeno preklapanje informacija između skupova i obezbeđena metodološka korektnost evaluacije. Svi postupci koji zavise od statističkih karakteristika podataka (npr. skaliranje) definisani su isključivo na trening skupu, a zatim dosledno primenjeni na validacioni i test skup.

4.5.2 Formiranje nadgledanog skupa podataka

Nakon sprovedenih procedura kontrole kvaliteta, filtriranja i skaliranja podataka, formiran je nadgledani skup podataka namenjen obuci ML modela. Konstrukcija skupa realizovana je u obliku parova (\mathbf{x}_k, y_{k+H}) , gde \mathbf{x}_k predstavlja ulazni vektor karakteristika u trenutku k , dok je y_{k+H} ciljna promenljiva koju je potrebno predvideti H vremenskih koraka unapred.

S obzirom da je analizirani skup podataka organizovan kao vremenski niz sa satnom rezolucijom, indeks k označava diskretni vremenski trenutak, dok je H horizont prognoze izražen u satima. Na primer, za $H = 1$ model generiše prognozu za naredni sat (*one-step-ahead forecasting*), dok veće vrednosti parametra H odgovaraju višehorizontskim prognozama.

Ulazni vektor \mathbf{x}_k definisan je kao skup odabranih meteoroloških i izvedenih karakteristika dostupnih u trenutku k , odnosno:

$$\mathbf{x}_k = [x_{1,k}, x_{2,k}, \dots, x_{p,k}]^T, \quad (4.9)$$

gde p predstavlja broj ulaznih promenljivih. Struktura ovog vektora zavisi od razmatrane konfiguracije modela i može uključivati trenutne meteorološke veličine, vremenske indikatore, kao i eventualne vremenski pomerene vrednosti (*lag* promenljive) koje omogućavaju modelu da implicitno uzme u obzir vremensku dinamiku posmatranog procesa.

Ciljna promenljiva y_{k+H} odgovara vrednosti veličine od interesa u trenutku $k + H$. U okviru ovog rada to može biti GHI ili izlazna snaga PV sistema, u zavisnosti od razmatranog modela i faze eksperimenta. Formiranjem parova (\mathbf{x}_k, y_{k+H}) dobija se nadgledani skup uzoraka koji se može zapisati u obliku:

$$\mathcal{D} = \{(\mathbf{x}_1, y_{1+H}), (\mathbf{x}_2, y_{2+H}), \dots, (\mathbf{x}_N, y_{N+H})\}, \quad (4.10)$$

gde N označava ukupan broj raspoloživih uzoraka nakon primene svih prethodnih koraka

obrade podataka.

Ovakva formulacija omogućava konzistentno modelovanje problema kratkoročne prognoze u realnom operativnom režimu, pri čemu model u svakom trenutku koristi samo informacije dostupne do trenutka k , dok se ciljna promenljiva odnosi na budući vremenski trenutak $k + H$. Time se obezbeđuje metodološki korektna konstrukcija nadgledanog skupa i izbegava potencijalno informaciono curenje (*data leakage*) između ulaznih i ciljnih promenljivih.

4.5.3 Konfiguracije modela M1 i M2

U istraživanju su razmatrana dva konceptualno različita pristupa modelovanju izlaza PV sistema:

- **Indirektni pristup (M1):** prvo se predviđa $GHI(k + H)$, nakon čega se proizvodnja energije procenjuje primenom PR-baziranog modela:

$$\mathbf{x} \rightarrow GHI \rightarrow E. \quad (4.11)$$

- **Direktni pristup (M2):** ulazne meteorološke promenljive se mapiraju direktno na energetska izlaznu veličinu:

$$\mathbf{x} \rightarrow E. \quad (4.12)$$

U okviru grupe **M1** modela (slika 5.5), razmatrane su sledeće konfiguracije:

- **M1-A1:** trenutne meteorološke i vremenske promenljive bez eksplicitne vremenske memorije;
- **M1-A1b:** proširenje modela M1-A1 uvođenjem clear-sky referentnih parametara;
- **M1-A2:** vremenski prošireni ulazni vektor

$$\mathbf{X}_L(k) = [\mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_{k-L}], \quad (4.13)$$

čime se uvodi eksplicitna vremenska memorija.

Model **M2** (slika 5.24) realizuje direktno mapiranje meteoroloških veličina na energetska izlaznu promenljivu, bez međukoraka predikcije GHI. Ovakva formulacija omogućava sistematsko poređenje indirektnog i direktnog pristupa u identičnim eksperimentalnim uslovima.

Napomena o transparentnosti i reproduktivnosti

Jasno definisane konfiguracije modela (M1-A1, M1-A1b, M1-A2 i M2), uz njihov grafički prikaz (slike 5.5 i 5.24), obezbeđuju transparentnost eksperimentalnog protokola i reproduktivnost rezultata prikazanih u nastavku.

4.6 Arhitektura modela i postupak treniranja

U okviru faze S4 realizovana je implementacija i optimizacija prediktivnih modela definisanih u Odeljku 4.5. Ovaj deo se odnosi na operativni opis arhitekture MLP modela, postupka optimizacije i podešavanja hiperparametara i protokola treniranja, uz strogo poštovanje vremenski konzistentne podele skupa podataka.

4.6.1 Arhitektura MLP modela

U ovom istraživanju korišćene su višeslojne perceptronske mreže (*Multilayer Perceptron - MLP*) tipa feed-forward, koje realizuju nelinearno preslikavanje između ulaznog vektora karakteristika i ciljne promenljive. Model generiše prognozu buduće vrednosti procesa na osnovu informacija dostupnih u trenutku k .

Za osnovnu konfiguraciju modela prognoza se može zapisati kao:

$$\hat{y}_{k+H} = f_{\theta}(\mathbf{x}_k), \quad (4.14)$$

gde \hat{y}_{k+H} predstavlja procenjenju vrednost ciljne promenljive u trenutku $k + H$, dok je $f_{\theta}(\cdot)$ nelinearna funkcija aproksimirana neuronskom mrežom sa skupom parametara θ koji obuhvata sve težine i pomeraje neurona.

Kako bi se modelu omogućilo da uzima u obzir vremensku zavisnost posmatranog procesa, u određenim konfiguracijama koristi se prošireni ulazni vektor koji uključuje vremenski pomerene vrednosti ulaznih promenljivih (*lag* promenljive). Prošireni ulaz definisan je kao:

$$\hat{y}_{k+H} = f_{\theta}(\mathbf{X}_p(k)), \quad (4.15)$$

gde je:

$$\mathbf{X}_p(k) = [\mathbf{x}_k, \mathbf{x}_{k-1}, \dots, \mathbf{x}_{k-p}], \quad (4.16)$$

gde p označava broj obuhvaćenih vremenskih pomeraja. Ovakav pristup omogućava da model implicitno aproksimira vremensku dinamiku procesa koristeći informacije iz prethodnih vremenskih koraka.

Razmatrana MLP mreža sastoji se od ulaznog sloja, L skrivenih slojeva i izlaznog sloja. Ulazni vektor definisan je kao:

$$\mathbf{x} \in \mathbb{R}^n, \quad (4.17)$$

gde n predstavlja broj ulaznih karakteristika. Forward propagacija kroz mrežu može se

zapisati kao:

$$\mathbf{h}^{(1)} = \phi\left(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}\right), \quad (4.18)$$

ili ako se radi o verziji mreže koja koristi vremenski pomerene ulazne parametre:

$$\mathbf{h}^{(l)} = \phi\left(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}\right), \quad l = 2, \dots, L, \quad (4.19)$$

$$\hat{y} = \mathbf{W}^{(L+1)}\mathbf{h}^{(L)} + \mathbf{b}^{(L+1)}. \quad (4.20)$$

Funkcija $\phi(\cdot)$ predstavlja nelinearnu aktivacionu funkciju neurona u skrivenim slojevima. U ovom radu korišćena je tangentno-sigmoidna aktivacija (`tansig`), dok je izlazni sloj realizovan linearnom funkcijom (`purelin`), što je standardni izbor za regresione probleme prognoze kontinualnih veličina.

Ukupan broj parametara koji se koristi u postupku treniranja mreže (težina i pomeraja) može se izraziti kao:

$$N_{\text{param}} = \sum_{l=1}^{L+1} (n_l \cdot n_{l-1} + n_l), \quad (4.21)$$

gde $n_0 = n$ predstavlja broj ulaznih promenljivih, n_l označava broj neurona u sloju l , dok L predstavlja broj skrivenih slojeva mreže. Prvi član $n_l \cdot n_{l-1}$ odgovara broju težina između slojeva $l-1$ i l , dok drugi član n_l predstavlja broj pomeraja (bias) neurona u sloju l .

4.6.2 Optimizacija hiperparametara

U kontekstu neuronskih mreža razlikuju se dve grupe parametara. *Parametri modela* (težine i pomeraji neurona) koji se određuju tokom procesa treniranja optimizacijom funkcije greške, dok *hiperparametri* predstavljaju unapred definisane konfiguracione veličine koje određuju strukturu modela i način njegovog treniranja. Tipični hiperparametri obuhvataju arhitekturu mreže, izbor algoritma treniranja, veličinu vremenskog prozora ili horizont predikcije. Njihove vrednosti ne određuju se direktno u postupku učenja, već se biraju kroz postupak validacije i eksperimentalne optimizacije.

U cilju identifikacije optimalne konfiguracije neuronske mreže primenjena je sistemska pretraga hiperparametara (*grid-search* pristup). Sve konfiguracije evaluirane su na validacionom skupu, dok je izbor finalne konfiguracije vršen na osnovu kriterijuma validacionih performansi (definisano u Sekciji 4.7), uz dodatnu proveru pristrasnosti (bias-a) i stabilnosti dobijenog rešenja. Optimizacija je obuhvatala:

- **Strukturu mreže:** broj skrivenih slojeva (1–3) i broj neurona po sloju;

- **Algoritam treniranja:** različite funkcije treniranja opisane u Prilogu B, uključujući Levenberg–Marquardt (LM, `trainlm`), skalirani konjugovani gradijent (SCG, `trainscg`) i Bayesian regularizacija (BR, `trainbr`);
- **Vremenski prozor L :** kod konfiguracija sa eksplicitnom vremenskom memorijom, menjana je dužina lag prozora L ;
- **Horizont predikcije H :** razmatrani su jednočasovni i višehorizontski scenariji, pri čemu se sa porastom H povećava složenost modela.

4.6.3 Funkcija cilja, regularizacija i kriterijumi zaustavljanja

Proces učenja realizovan je minimizacijom srednje kvadratne greške na trening skupu, uz paralelno praćenje performansi na validacionom skupu. U opštem slučaju, optimizacija se može predstaviti minimizacijom regularizovane funkcije cilja:

$$J(\mathbf{W}) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i(\mathbf{W}))^2 + \lambda \|\mathbf{W}\|_2^2, \quad (4.22)$$

gde je \mathbf{W} vektor svih težinskih koeficijenata, a λ regularizacioni parametar. Drugi član uvodi L2 penalizaciju i kontroliše složenost modela. L2 penalizacija uvodi dodatni član u funkciju greške koji zavisi od kvadrata težinskih koeficijenata, čime se ograničava njihova veličina i kontroliše složenost modela. Na ovaj način se smanjuje rizik od preprilagođavanja (overfitting), a model dobija bolju sposobnost generalizacije. Kod Bayesian Regularization algoritma, parametar λ se adaptivno procenjuje tokom procesa učenja, čime se automatski postiže optimalan kompromis između tačnosti i složenosti modela. Kod BR algoritma parametar λ se adaptivno procenjuje tokom učenja.

Treniranje se zaustavlja primenom kombinovanog kriterijuma konvergencije i generalizacije:

- dostizanje minimalne promene funkcije greške ($\Delta MSE < \varepsilon$) između dve uzastopne epohe;
- dostizanje maksimalnog broja epoha definisanog u okviru grid-search konfiguracije;
- *early stopping* mehanizam zasnovan na validacionom skupu, pri čemu se učenje prekida ukoliko validaciona greška ne pokazuje poboljšanje tokom unapred definisanog broja iteracija (*validation patience*);
- implicitna regularizacija kod `trainbr` algoritma, gde se optimizuje kompromis između greške i veličine težina.

Primena validacionog nadzora i regularizacije omogućava kontrolu prenaučivosti i obezbeđuje stabilnu generalizacionu sposobnost modela na nezavisnom test skupu.

4.6.4 Reproductivnost i robusnost treniranja

Radi smanjenja uticaja slučajne inicijalizacije, svaka konfiguracija trenirana je više puta sa različitim početnim vrednostima težina, a konačne performanse određene su na osnovu validacionih rezultata (prosečnih ili najboljih). Parametri skaliranja iz faze S2 primenjeni su dosledno na sve podskupove, uz striktno poštovanje vremenske podele skupa podataka, bez mešanja informacija između trening, validacionog i test skupa.

Rezultat faze S4 predstavlja skup optimizovanih modela sa jasno definisanim hiperparametrima i kontrolisanim rizikom preučenja, spremnih za nezavisnu evaluaciju u fazi S5.

4.7 Metrike performansi i evaluacija

Evaluacija performansi modela je sprovedena u fazi S5 sa ciljem kvantifikacije tačnosti, bias-a i stabilnosti predikcije u okviru definisanih eksperimentalnih konfiguracija. Izbor metrika izveden je tako da obezbedi inženjerski relevantnu interpretaciju i sezonsku uporedivost rezultata, u skladu sa principima standarda IEC 61724-1:2021.

Detaljne matematičke definicije korišćenih metrika date su u Prilogu C. Ovde je dat metodološki okvir njihove primene i način interpretacije.

Apsolutne metrike greške - RMSE, MAE i MBE su korišćene kao osnovni pokazatelji odstupanja između predviđenih i referentnih vrednosti. RMSE jače penalizuje veće greške i osetljiva je na ekstremna odstupanja, MAE predstavlja robusniju meru tipične greške, dok MBE omogućava identifikaciju sistematskog bias-a.

Normalizovane metrike i sezonska uporedivost - zbog objektivnog poređenja performansi u periodima sa različitim nivoima iradijacije i proizvodnje, apsolutne metrike su, gde je relevantno, normalizovane u odnosu na referentnu vrednost Y_{ref} definisanu kao karakteristični nivo izlaza u posmatranom skupu podataka. Na ovaj način dobijene su normalizovane metrike (nRMSE, nMBE), pogodne za sezonsku i međumodelsku uporedivost.

4.7.1 IEC-orijentisana interpretacija

Prilikom izračunavanja metrika dosledno je primenjen tretman intervala sa zanemarljivom proizvodnjom, kako je definisano u Odeljku 4.4.2, što je posebno važno za zimskie i prelazne periode.

U indirektnom pristupu (M1) energetska evaluacija se zasniva na PR-baziranom modelu (Prilog D), dok se korekcije električnih karakteristika, gde je primenjivo, oslanjaju na preporuke standarda IEC 60891.

4.8 Validacija i poređenje modela

Validacija i poređenje modela realizovani su nad nezavisnim test skupom, uz primenu metrika opisanih u Odeljku 4.7. Cilj je procena tačnosti, generalizacione sposobnosti i stabilnosti modela u vremenu, kao i identifikacija razlika između indirektnog (M1) i direktnog (M2) pristupa.

Proces validacije obuhvata više komplementarnih nivoa:

- **Interna validacija:** analiza konvergencije tokom treniranja, ponašanja validacionog gubitka i mehanizama kontrole preučenja (early stopping, regularizacija), radi procene stabilnosti optimizacije;
- **Test validacija:** kvantitativna evaluacija performansi na test skupu, koji nije učestvovao u treniranju, kao ni u izboru hiperparametara;
- **Poređenje sa referentnim modelima:** upoređivanje razmatranih modelskih pristupa u identičnim eksperimentalnim uslovima, radi identifikacije razlika u tačnosti i robusnosti;
- **Analiza strukture greške:** ispitivanje mesečnih, sezonskih i dnevnih (diurnal) profila performansi, uz razdvajanje sistematskog bias-a i varijabilnosti greške.

Ovako definisan višeslojni pristup omogućava da se performanse modela ne procenjuju isključivo na osnovu agregiranih metrika, već i kroz analizu njihove stabilnosti i konzistentnosti u različitim operativnim režimima.



5. Rezultati istraživanja

U ovom poglavlju prikazani su i sistematski analizirani rezultati eksperimentalne evaluacije prediktivnih ANN modela definisanih u metodološkim fazama S3 do S5. Rezultati su organizovani u skladu sa dva konceptualno različita pristupa modelovanju izlaza (proizvedene električne energije) PV sistema: **indirektni pristup (M1)** i **direktni pristup (M2)**.

Svi prikazani rezultati se primarno odnose na nezavisni test skup (podaci iz 2022. godine), u skladu sa vremenski konzistentnim protokolom podele skupa podataka definisanim u Odeljku 4.5. Evaluacija je sprovedena primenom apsolutnih i normalizovanih metrika greške, u skladu sa IEC-orijentisanim pristupom opisanim u Odeljku 4.7 i Prilogu C.

Metodološki pristup M1

Metodološki pristup **M1** se zasniva na dvostepenoj strukturi predikcije, u okviru koje se najpre vrši satno predviđanje GHI, a zatim se predviđena vrednost koristi kao ulazni podatak za energetske model PV sistema. Na taj način se statistički model prognoze solarnog zračenja i fizičko-energetski model sistema tretiraju kao konceptualno odvojene celine.

Struktura modela M1 može se formalno prikazati kao:

$$\mathbf{x}(k) \longrightarrow \widehat{GHI}(k+H) \longrightarrow \widehat{E}(k+H), \quad (5.1)$$

gde vektor ulaza $\mathbf{x}(k)$ predstavlja meteorološke i vremenske promenljive u trenutku k , dok se procena proizvedene energije $\widehat{E}(k+H)$ dobija primenom PR-baziranog energetskog modela (Prilog D) na predviđenu vrednost zračenja. Ovakva dekompozicija omogućava razdvojenu analizu greške predikcije solarnog zračenja i greške energetskog modelovanja, čime se povećava interpretabilnost dobijenih rezultata.

U okviru metodologije M1 analizirane su sledeće konfiguracije modela, pri fiksiranom

horizontu predviđanja $H = 1$ h:

- **M1–A1** – osnovni *feed-forward* ANN model za predviđanje $GHI(k + H)$, zasnovan na trenutnim meteorološkim i vremenskim ulaznim veličinama, bez eksplicitne vremenske memorije;
- **M1–A1b** – optimizovana varijanta modela M1–A1, dobijena sistematskim pretraživanjem prostora hiperparametara (npr. broj neurona i broj skrivenih slojeva, algoritam učenja `trainscg/trainbr/trainlm`, broj ponavljanja), pri čemu je kriterijum izbora minimalni validacioni nRMSE;
- **M1–A2** – napredna konfiguracija koja uvodi vremenska kašnjenja ulaznih promenljivih (implicitnu vremensku memoriju) radi modelovanja dinamičkih atmosferskih promena, uz proširen ulazni prostor u odnosu na model M1–A1.

Modeli iz grupe M1 evaluirani su kroz dve komplementarne grupe metrika:

1. direktne metrike tačnosti predviđanja GHI (MAE, RMSE, MBE i njihove normalizovane forme), pri čemu je evaluacija ograničena na dnevne (daytime) uzorke radi eliminacije trivijalnih noćnih režima;
2. metrike tačnosti posredno procenjene električne energije/prinosa PV sistema, dobijene propagacijom predviđenog GHI kroz isti PR-bazirani energetski model, uz poređenje sa eksperimentalnim merenjima koja su dostupna za period 2018. do 2022. godine, i sa determinističkim referentnim rezultatima PVsyst simulacije za period 2005–2022. Test metrike se izvršavaju za 2022. godinu

Referentni modeli u okviru M1.

Pored predloženih ANN modela, u analizu su uključeni i referentni modeli (*baseline models*) koji predstavljaju jednostavne predikcione metode i služe kao polazna tačka za evaluaciju performansi naprednijih ML modela. U literaturi o kratkoročnoj prognozi solarnog zračenja baseline modeli se koriste kako bi se kvantifikovalo stvarno poboljšanje koje donose složeniji pristupi.

U okviru metodologije M1 razmatrana su dva standardna referentna pristupa (Prilog E):

- **Persistence model** – pretpostavlja da će vrednost solarnog zračenja u narednom vremenskom koraku biti jednaka poslednjoj izmerenoj vrednosti,
- **Scaled persistence model** – proširena varijanta persistence pristupa koja uvodi korekciju dnevne dinamike solarnog zračenja putem odgovarajućeg skalirajućeg faktora.

Oba referentna modela definisana su u GHI domenu, nakon čega su njihove prognoze propagirane kroz isti PR-bazirani energetski model. Na taj način obezbeđuje se metodološki konzistentno poređenje performansi u energetskom domenu, pri čemu razlike u rezultatima potiču isključivo iz razlika u kvalitetu prognoze GHI.

Referentni model zasnovan na podacima

Pored autoregresivnih referentnih pristupa, u okviru metodologije M1 razmatran je i dodatni

referentni model zasnovan na podacima, implementiran primenom **XGBoost regresionog algoritma** (Prilog F). Za razliku od persistence modela, koji predstavljaju jednostavne fizički motivisane aproksimacije, ovaj pristup pripada klasi savremenih data-driven metoda mašinskog učenja.

Uloga ovog modela je da posluži kao *referentni model* za poređenje sa ANN pristupom, odnosno da pruži referentni nivo performansi koji se može postići primenom modernih algoritama za učenje nad istim skupom ulaznih podataka.

XGBoost model je treniran nad identičnim skupom ulaznih karakteristika i uz istu hronološku podelu podataka (train/validation/test) kao i ANN model. Na ovaj način obezbeđeno je fer i metodološki konzistentno poređenje performansi u domenu predikcije GHI, a zatim i u energetsom domenu nakon propagacije kroz isti PR-bazirani model.

Metodološki pristup M2

Metodološki pristup **M2** realizuje direktno mapiranje meteoroloških i vremenskih promenljivih na energetska izlaznu veličinu PV sistema, bez eksplicitne predikcije iradijacionih veličina:

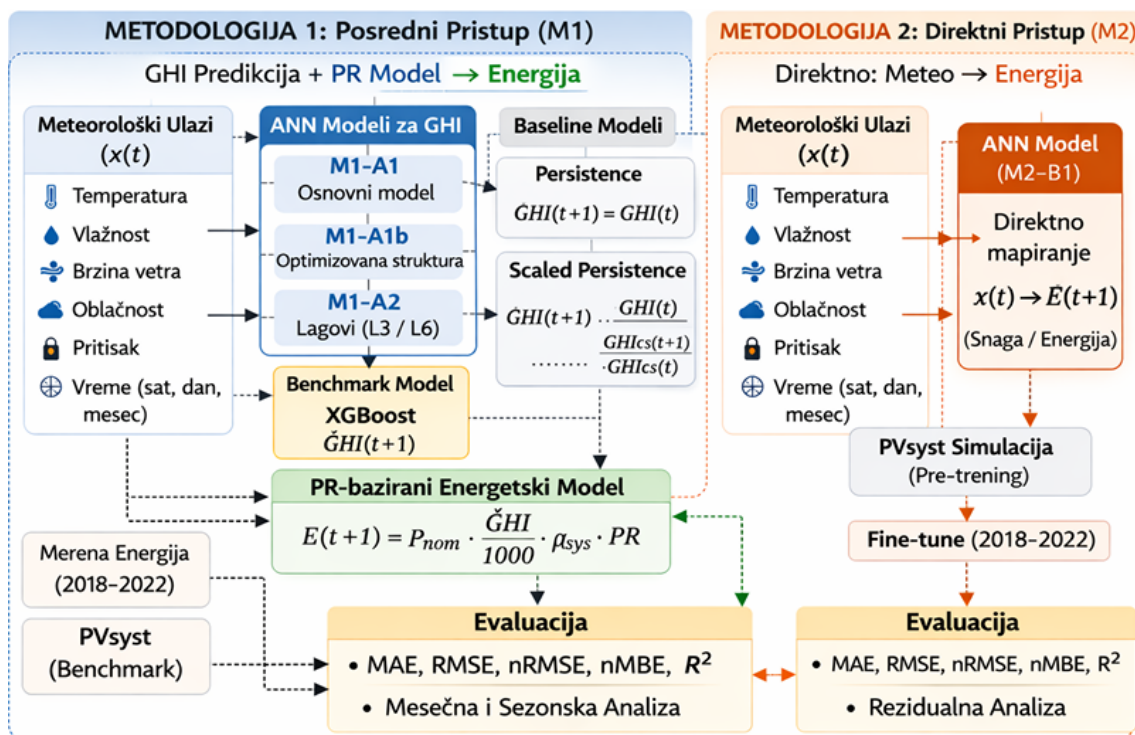
$$\mathbf{x}(k) \longrightarrow \hat{y}(k+H), \quad (5.2)$$

gde \hat{y} predstavlja direktnu predikciju izlaza PV sistema (snage P u kW, odnosno energije u kWh, u zavisnosti od konkretne M2 varijante). U ovom pristupu se ne uvodi poseban fizički model transpozicije i PR-korekcije, već statistički model implicitno aproksimira kompletan lanac konverzije: od atmosferskih uslova do izlazne električne veličine.

Za razliku od M1, gde je moguće razdvojeno analizirati grešku predikcije zračenja i grešku energetskog modela, kod M2 pristupa se celokupna nelinearna transformacija ulaznih promenljivih u izlaz aproksimira jedinstvenim ANN modelom. Time se postiže strukturno pojednostavljenje i smanjenje računске složenosti, uz ograničenu fizičku interpretabilnost dobijenih rezultata. Ovakva formulacija odgovara operativnim scenarijima u kojima je cilj brzo i robusno predviđanje očekivane proizvodnje PV sistema. Konceptualni prikaz metodologija M1 i M2 prikazan je na slici 5.1.

Zbog preglednosti i transparentnosti, ovo poglavlje je organizovano na sledeći način:

- najpre su prikazani dobijeni rezultati istraživanja i detaljna analiza modela iz grupe M1 (A1, A1b i A2), uključujući poređenje sa autoregresivnim baseline modelima (persistence i scaled persistence), data-driven referentni model pristupom zasnovanim na XGBoost algoritmu, kao i referentnim PVsyst izlazom u energetsom domenu;
- zatim slede rezultati istraživanja i analiza direktnog modela M2;
- konačno je dato sintezno poređenje modela M1 i M2 u pogledu tačnosti, stabilnosti i operativne primenljivosti.



Slika 5.1: Usporedni konceptualni prikaz metodologija M1 i M2 za predviđanje izlaza PV sistema na osnovu meteoroloških podataka.

5.1 Skupovi podataka, evaluacija i referentni modeli

U istraživanju su korišćena tri komplementarna skupa podataka: (i) dugoročna meteorološka baza, (ii) eksperimentalna merenja realnog PV sistema i (iii) determinističke simulacije generisane u softveru PVsyst.

Meteorološka baza (2005–2022)

Ulazni meteorološki skup obuhvata period od 1. januara 2005. do 31. decembra 2022. godine, sa satnom vremenskom rezolucijom ($\Delta t = 1$ h). Ukupan broj zapisa iznosi približno $N \approx 18 \times 8760 = 157680$ časova (uz korekciju za prestupne godine). Skup obuhvata meteorološke parametre (GHI, temperaturu vazduha, relativnu vlažnost, brzinu i smer vetra), kao i dodatne atmosfenske indikatore izvedene iz Meteosat satelitskih posmatranja (npr. indeks oblačnosti, difuzna komponenta, zenitni ugao Sunca).

Pre samog procesa generisanja modela sprovedeno je:

- vremensko poravnanje svih serija na jedinstvenu vremensku osu u lokalnom standardnom vremenu, uz harmonizaciju formata vremenskih oznaka;
- uklanjanje fizički nemogućih vrednosti (npr. negativno zračenje tokom dnevnog perioda);
- filtriranje odstupanja na osnovu fizičkih pragova i statističke detekcije ekstremnih vrednosti;

- interpolacija kraćih prekida u merenju (do unapred definisanog vremenskog praga), dok su duži prekidi eliminisani iz procesa treniranja.

Ekperimentalna merenja parametara PV sistema (2018–2022)

Ekperimentalna baza obuhvata period od 2018. do 2022. godine, sa satnim podacima o energiji proizvedenoj na realnom, eksperimentalnom PV sistemu koji je opisan u Odeljku 4.2. Ukupan broj dostupnih podataka iznosi približno $N \approx 5 \times 8760 = 43\,800$ časova. Sistem nadzora implementiran je u skladu sa preporukama IEC 61724-1:2021 standarda (klasifikacija mernog sistema, validacija energetske tokova, kontrola kvaliteta podataka).

Pre evaluacije modela izvršena je:

- agregacija i verifikacija energetske tokova,
- eliminacija perioda zastoja sistema i planiranog održavanja,
- ograničavanje negativnih ili nerealnih vrednosti energije na fizički prihvatljiv opseg.

Ovaj skup predstavlja referentnu eksperimentalnu osnovu za validaciju i nezavisno testiranje modela u energetske domenu.

PVsyst simulacije (2005–2022)

Rezultati simulacije eksperimentalnog PV sistema su generisani korišćenjem softverske paketa PVsyst, za isti vremenski period (2005–2022. godina), uz korišćenje podataka iz iste meteorološke baze, tačno definisane geometrije sistema (nagib, azimut), instalisane snage i modelovanje gubitaka (temperaturni koeficijenti, omski gubici, neusklađenost, degradacija i ostali sistemski faktori).

Rezultati simulacije predstavljaju fizički konzistentan referentni energetske scenario i korišćeni su:

- kao deterministički referentni model u energetske domenu,
- za poređenje sa ANN i XGBoost modelima,
- za analizu odstupanja između fizičkog i data-driven pristupa.

U metodologiji M1 meteorološki podaci koriste se za regresiju GHI (ili drugih atmosferske veličina), dok se prelazak u energetske domen vrši primenom PR-bazirane formulacije i/ili poređenjem sa PVsyst rezultatima. U metodologiji M2 ulazni meteorološki parametri direktno se mapiraju na izlaznu energetske veličinu, pri čemu se mereni rezultati koriste za validaciju i testiranje, dok se PVsyst simulacije koriste kao dodatni referentni sloj za dugoročnu stabilnost i konzistentnost modela.

Ovakva struktura baza omogućava: (i) dugoročno treniranje modela u klimatske reprezentivnom okruženju, (ii) strogu hronološku validaciju, (iii) nezavisno eksperimentalno testiranje i (iv) paralelno poređenje sa fizičkim determinističkim modelom.

Radi preglednosti i jasnog razlikovanja uloga pojedinih baza, u Tabeli 5.1 dat je sumarni prikaz vremenskog obuhvata, rezolucije, obima i metodološke funkcije svakog korišćenog skupa podataka.

Tabela 5.1: Sumarni prikaz korišćenih skupova podataka i njihove uloge u metodologijama M1 i M2.

Skup podataka	Period	Rez.	Broj zapisa	Sadržaj / veličine	Uloga (M1 / M2)
Meteorološka baza	2005–2022	1 h	~157 680	GHI, T_{air} , RH, v_{wind} , smer vetra, satelitski indikatori (Meteosat)	M1: regresija GHI M2: direktni energetski ulaz
PV merenja	2018–2022	1 h	~43 800	Izmerena satna energija sistema, validirana prema IEC 61724-1:2021	Validacija i nezavisni test (M1 i M2)
PVsyst simulacije	2005–2022	1 h	~157 680	Simulirana satna energija (fizički model sistema, definisani gubici)	Deterministički referentni model Referentni energetski scenario

Hronološka podela

U cilju metodološki korektno evaluacije i sprečavanja prenosa informacija iz budućih u prethodne vremenske intervale (tzv. *data leakage*), podaci su podeljeni isključivo hronološki, bez nasumičnog mešanja vremenskih nizova.

Period 2005–2020 korišćen je kao trening skup (\mathcal{D}_{train}), koji obuhvata približno 16 godina podataka ($N \approx 140\,000$ satnih zapisa). Ovaj skup je korišćen za optimizaciju parametara modela (težine neuronske mreže, hiperparametri, regularizacioni koeficijenti).

Godina 2021. izdvojena je kao validacioni skup (\mathcal{D}_{val}) i korišćena je za:

- izbor optimalne arhitekture mreže,
- podešavanje hiperparametara,
- primenu kriterijuma ranog zaustavljanja (early stopping),
- analizu stabilnosti generalizacije.

Godina 2022. korišćena je isključivo kao nezavisni test skup (\mathcal{D}_{rest}), bez ikakvog uticaja na proces treniranja ili izbora modela. Rezultati prikazani za 2022. godinu predstavljaju konačnu i objektivnu procenu performansi modela u uslovima koji simuliraju realnu operativnu primenu (*out-of-sample evaluacija*).

Normalizacija i skaliranje

Svi ulazni parametri normalizovani su primenom transformacije isključivo na trening skupu, odnosno parametri skaliranja (srednja vrednost i standardna devijacija kod z-score normalizacije, ili minimalna i maksimalna vrednost kod min–max transformacije) određeni

su samo na \mathcal{D}_{train} :

$$x^* = \frac{x - \mu_{train}}{\sigma_{train}}. \quad (5.3)$$

Dobijeni parametri zatim su primenjeni bez izmene na \mathcal{D}_{val} i \mathcal{D}_{test} skupovima. Na ovaj način je sprečeno implicitno unošenje informacija iz budućeg perioda u proces treniranja, čime je obezbeđena stroga vremenska kauzalnost i metodološka konzistentnost.

Ovakav *strict split* pristup posebno je značajan u energetskim i meteorološkim vremenskim serijama, gde sezonske, među-godišnje i klimatske varijacije mogu dovesti do preoptimističnih rezultata ukoliko se primeni nasumična podela. Primena stroge hronološke podele omogućava realističnu procenu sposobnosti modela da generalizuje na buduće, do tada neviđene atmosferske uslove.

Formalizacija skupovne notacije.

Neka je kompletan vremenski skup podataka definisan kao uređeni vremenski niz:

$$\mathcal{D} = \{(\mathbf{x}_t, y_t) \mid t = 1, 2, \dots, T\}, \quad (5.4)$$

gde je $\mathbf{x}_t \in \mathbb{R}^m$ vektor ulaznih meteoroloških parametara u trenutku t , dok je y_t ciljna veličina (GHI ili energija PV sistema, u zavisnosti od metodologije M1 ili M2).

Skup \mathcal{D} podeljen je na tri vremenski disjunktna podskupa:

$$\mathcal{D}_{train} = \{(\mathbf{x}_t, y_t) \mid t \in [2005, 2020]\}, \quad (5.5)$$

$$\mathcal{D}_{val} = \{(\mathbf{x}_t, y_t) \mid t \in [2021]\}, \quad (5.6)$$

$$\mathcal{D}_{test} = \{(\mathbf{x}_t, y_t) \mid t \in [2022]\}, \quad (5.7)$$

pri čemu važi:

$$\mathcal{D}_{train} \cap \mathcal{D}_{val} = \mathcal{D}_{train} \cap \mathcal{D}_{test} = \mathcal{D}_{val} \cap \mathcal{D}_{test} = \emptyset \quad (5.8)$$

i

$$\mathcal{D}_{train} \cup \mathcal{D}_{val} \cup \mathcal{D}_{test} = \mathcal{D} \quad (5.9)$$

Uz to, zbog vremenske kauzalnosti, dodatno važi:

$$t_{train} < t_{val} < t_{test}, \quad (5.10)$$

čime je obezbeđena stroga hronološka separacija i realistična simulacija operativnog predviđanja.

Metodološko poređenje podela skupa podataka

U klasičnim regresionim problemima često se primenjuje nasumična podela (random split), pri kojoj se uzorci raspodeljuju u trening i test skup bez obzira na njihov vremenski redosled. Takav pristup implicitno pretpostavlja nezavisnost i identičnu raspodelu podataka (i.i.d. uslov). Međutim, meteorološke i energetske vremenske serije ne zadovoljavaju i.i.d. pretpostavku zbog:

- sezonske periodičnosti,
- autokorelacije u vremenu,
- među-godišnje klimatske varijabilnosti,
- sporih trendova i promena režima.

Nasumična podela u takvom kontekstu dovodi do preklapanja statističkih karakteristika između trening i test skupa, što kao rezultat može imati preoptimističnu procenu performansi modela, odnosno implicitnim curenjem informacija iz budućnosti.

Slično tome, standardna k-fold unakrsna validacija, iako metodološki robusna za statičke skupove podataka, nije adekvatna za vremenske serije, jer remeti temporalnu strukturu i narušava kauzalnost sistema.

Primena striktnog hronološkog pristupa u ovom istraživanju omogućava:

1. realnu i objektivnu procenu performansi modela u uslovima budućih, nepoznatih atmosferskih režima,
2. izbegavanje informacionog curenja,
3. objektivno poređenje data-driven modela sa determinističkim PVsyst referentnim scenarijem,
4. verodostojnu analizu stabilnosti modela na međugodišnjem nivou.

Ovakav protokol validacije usklađen je sa savremenim preporukama za modelovanje energetske i klimatske vremenske serije i predstavlja konzervativniji, ali metodološki korektniji pristup u odnosu na nasumične tehnike podele podataka.

Generalizaciona formulacija

Ako je cilj učenja aproksimacija nepoznate funkcije preslikavanja $f : \mathbb{R}^m \rightarrow \mathbb{R}$ takva da je $\hat{y}_t = \hat{f}(\mathbf{x}_t; \theta)$, gde je θ skup parametara modela (ANN ili XGBoost), za zadatu funkciju gubitka $\ell(\cdot)$ (npr. kvadratna greška), *očekivani rizik* (generalizaciona greška) definisan je kao:

$$\mathcal{R}(\hat{f}) = \mathbb{E}_{(\mathbf{x}, y) \sim \mathcal{D}_{test}} [\ell(\hat{f}(\mathbf{x}), y)]. \quad (5.11)$$

Pošto je raspodela \mathcal{P}_{test} nepoznata, u praksi se procena generalizacione greške vrši na nezavisnom test skupu \mathcal{D}_{test} :

$$\widehat{\mathcal{R}}_{test}(\hat{f}) = \frac{1}{|\mathcal{D}_{test}|} \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}_{test}} \ell(\hat{f}(\mathbf{x}_i), y_i). \quad (5.12)$$

U okviru primenjenog *strict split* protokola, \mathcal{D}_{test} (2022) predstavlja uzorke koji vremenski slede nakon trening i validacionih godina, čime je $\widehat{\mathcal{R}}_{test}$ konzervativna, ali metodološki ispravna procena operativnih performansi (*out-of-sample*). Takođe, proces treniranja se može posmatrati kao minimizacija *empirijskog rizika* na trening skupu uz regularizaciju:

$$\hat{\theta} = \arg \min_{\theta} \left[\frac{1}{|\mathcal{D}_{train}|} \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}_{train}} \ell(\hat{f}(\mathbf{x}_i; \theta), y_i) + \lambda \Omega(\theta) \right], \quad (5.13)$$

gde $\Omega(\theta)$ predstavlja regularizacioni član (npr. L_2 penalizaciju ili *BR* kod ANN), a λ njegov intenzitet.

Statistička analiza raspodela

Kod meteoroloških i energetske vremenskih serija često se uočava međugodišnja promena raspodele ulaznih veličina, poznata kao *covariate shift*. U formalnom smislu to znači da distribucija ulaznog vektora tokom trening perioda nije identična distribuciji u test periodu, tj.:

$$\mathcal{P}_{train}(\mathbf{x}) \neq \mathcal{P}_{test}(\mathbf{x}), \quad \text{pretpostavka da je } \mathcal{P}(y | \mathbf{x}) \text{ približno stabilna.} \quad (5.14)$$

Drugim rečima, fizička veza između ulaznih promenljivih i ciljne veličine ostaje približno ista, dok se sama raspodela meteoroloških uslova može menjati iz godine u godinu usled klimatske varijabilnosti ili specifičnih sezonskih anomalija. Zbog toga je, pored standardne evaluacije greške modela, sprovedena i statistička analiza sličnosti distribucija ulaznih promenljivih između skupova \mathcal{D}_{train} (2005–2020), \mathcal{D}_{val} (2021) i \mathcal{D}_{test} (2022). Cilj ove analize bio je da se kvantifikuje stepen međugodišnje varijabilnosti ulaznog prostora i proceni da li eventualna degradacija performansi u test godini potiče od promene distribucija, a ne od prenaučnosti modela. Analiza obuhvata sledeće korake:

1. **Deskriptivna statistika.** Za svaku ulaznu promenljivu $x^{(k)}$ izračunate su srednja vrednost μ , standardna devijacija σ , medijana, interkvartilni opseg (IQR), kao i percentili (P5, P95)¹ za svaki od skupova \mathcal{D}_{train} , \mathcal{D}_{val} i \mathcal{D}_{test} .
2. **Testovi jednakosti distribucija.** Sprovedeni su neparametarski testovi razlike raspo-

¹ Interkvartilni opseg (IQR = $Q_3 - Q_1$) predstavlja raspon centralnih 50% podataka i daje robusnu meru disperzije, dok percentili P5 i P95 definišu interval koji obuhvata 90% posmatranih vrednosti, omogućavajući analizu promena u ekstremnim, ali reprezentativnim režimima distribucije.

dela: (i) Kolmogorov–Smirnov (KS) test ² za poređenje kumulativnih distribucija i (ii) Mann–Whitney U test ³ kao dopunska provera razlike u centralnoj tendenciji (medijani). Ovi testovi su odabrani jer ne zahtevaju pretpostavku normalnosti.

3. **Efekat veličine razlike.** Pored p-vrednosti, razmatrana je i veličina efekta kako bi se izbegla pogrešna interpretacija statističke značajnosti kod velikih uzoraka. Kao praktična mera razlike korišćena je apsolutna razlika u srednjim vrednostima normalizovana trening standardnom devijacijom:

$$\Delta^{(k)} = \frac{|\mu_{test}^{(k)} - \mu_{train}^{(k)}|}{\sigma_{train}^{(k)}}. \quad (5.15)$$

4. **Analiza sezonskih distribucija.** Pošto se promene režima često manifestuju sezonski, poređenje distribucija sprovedeno je i po mesecima (npr. distribucija GHI u januaru 2022 vs. januar u trening periodu), čime je omogućena preciznija interpretacija performansi modela u specifičnim atmosferskim uslovima.

Rezultati ovih analiza korišćeni su kao dopunska interpretativna osnova pri objašnjenju razlika u tačnosti modela između godina, odnosno za identifikaciju slučajeva u kojima degradacija performansi nije posledica samo modela, već i promene statističkog režima ulaza.

5.2 Matematička analiza metrika

Greška predikcije se definiše kao:

$$e_t = \hat{y}_t - y_t, \quad (5.16)$$

gde su \hat{y}_t i y_t predviđena i referentna vrednost u trenutku t . Posmatraju se dva režima evaluacije: (i) bez filtriranja (*all-samples*) i (ii) sa daylight maskom $M_t \in \{0, 1\}$.

Metrike bez maske dnevnog režima (svi uzorci)

Za T uzoraka:

$$\text{MAE}_{all} = \frac{1}{T} \sum_{t=1}^T |e_t|, \quad \text{RMSE}_{all} = \sqrt{\frac{1}{T} \sum_{t=1}^T e_t^2}, \quad \text{MBE}_{all} = \frac{1}{T} \sum_{t=1}^T e_t. \quad (5.17)$$

²Kolmogorov–Smirnov (KS) test je neparametarski test koji meri maksimalnu razliku između empirijskih kumulativnih distribucija dva uzorka i proverava da li potiču iz iste distribucije.

³Mann–Whitney U test je neparametarski test zasnovan na rangovima, kojim se proverava da li dve nezavisne grupe imaju statistički različite centralne tendencije.

Evaluacija metrika uz primenu maske dnevnog režima

U cilju metodološki korektno i objektivno evaluacije performansi ANN modela u režimu dnevne proizvodnje, uvedena je binarna maska dnevnog režima (engl. *daylight*) $M_t \in \{0, 1\}$, definisana kao:

$$M_t = \begin{cases} 1, & \text{ako je } GHI_t > 0 \\ 0, & \text{inače} \end{cases} \quad (5.18)$$

Ako je ukupan broj uzoraka T , skup dnevnih uzoraka je definisan kao:

$$\mathcal{D} = \{t \in [1, T] \mid M_t = 1\}, \quad (5.19)$$

pa je onda broj dnevnih uzoraka:

$$T_d = |\mathcal{D}| \quad (5.20)$$

Sve evaluacione metrike u daylight režimu računaju se isključivo nad podskupom \mathcal{D} i normalizuju brojem T_d , a ne ukupnim brojem uzoraka T . Na taj način obezbeđuje se konzistentna interpretacija greške u režimu aktivnog rada PV sistema. Metrike sa daylight maskom su sada:

$$\text{MAE}_{\text{day}} = \frac{1}{T_d} \sum_{t \in \mathcal{D}} |\hat{y}_t - y_t| \quad (5.21)$$

$$\text{RMSE}_{\text{day}} = \sqrt{\frac{1}{T_d} \sum_{t \in \mathcal{D}} (\hat{y}_t - y_t)^2} \quad (5.22)$$

i nRMSE, u slučaju da se normalizuje srednjom vrednošću:

$$\text{nRMSE}_{\text{day}} = \frac{\text{RMSE}_{\text{day}}}{\frac{1}{T_d} \sum_{t \in \mathcal{D}} y_t} \cdot 100\% \quad (5.23)$$

ili ako se normalizuje maksimalnom vrednošću:

$$\text{nRMSE}_{\text{day}} = \frac{\text{RMSE}_{\text{day}}}{\max_{t \in \mathcal{D}} y_t} \cdot 100\% \quad (5.24)$$

Normalizacija metrika brojem T_d sprečava veštačko umanjeње greške usled prisustva noćnih uzoraka ($M_t = 0$) i omogućava korektno poređenje kvaliteta PV modela u režimu realne PV proizvodnje.

Analičko razmatranje sistematskog odstupanja

Ukupan broj uzoraka može se razložiti na dnevni i noćni deo:

$$T = T_d + T_n. \quad (5.25)$$

Najpre se definišu srednje apsolutne greške nad dnevnim i noćnim podskupom:

$$\text{MAE}_{day} = \frac{1}{T_d} \sum_{t \in \mathcal{D}} |\hat{y}_t - y_t|, \quad (5.26)$$

$$\text{MAE}_{night} = \frac{1}{T_n} \sum_{t \in \mathcal{N}} |\hat{y}_t - y_t|. \quad (5.27)$$

Tada se ukupna metrika bez daylight filtriranja može zapisati kao:

$$\text{MAE}_{all} = \frac{T_d}{T} \text{MAE}_{day} + \frac{T_n}{T} \text{MAE}_{night}. \quad (5.28)$$

U PV sistemima tokom noći važi:

$$y_t \approx 0, \quad \hat{y}_t \approx 0, \quad (5.29)$$

pa je:

$$\text{MAE}_{night} \approx 0. \quad (5.30)$$

Zamenom u prethodnu relaciju 5.28 se dobija:

$$\text{MAE}_{all} \approx \frac{T_d}{T} \text{MAE}_{day}. \quad (5.31)$$

Kako je odnos $\frac{T_d}{T} < 1$, sledi:

$$\text{MAE}_{all} < \text{MAE}_{day}. \quad (5.32)$$

Znači, uključivanje noćnih uzoraka sistematski redukuje agregiranu vrednost metrike i dovodi do preoptimistične procene tačnosti modela u režimu realne proizvodnje. Ova razlika ne predstavlja numeričku slučajnost, već strukturalnu posledicu ponderisanja grešaka odnosom $\frac{T_d}{T}$. Dakle, radi se o analitički determinisanom odstupanju, a ne o statističkoj fluktuaciji. Detaljna analitička demonstracija sistematskog odstupanja agregiranih metrika bez daylight filtriranja sa realnim odnosom dan/noć za lokaciju u Nišu data je u Prilogu G.

Uticaj na normalizovane metrike.

Normalizovana greška definiše se kao:

$$\text{nRMSE} = \frac{\text{RMSE}}{y_{\text{ref}}} \cdot 100\%. \quad (5.33)$$

Ako se referentna skala računa nad svim uzorcima, tada zbog noćnih vrednosti važi:

$$\bar{y}_{\text{all}} < \bar{y}_{\text{day}}. \quad (5.34)$$

Pošto tipično važi

$$\text{RMSE}_{\text{all}} < \text{RMSE}_{\text{day}} \quad \text{i} \quad \bar{y}_{\text{all}} < \bar{y}_{\text{day}}, \quad (5.35)$$

efekat na nRMSE nije zanemarljiv. Međutim, daylight filtriranje obezbeđuje da i bro-jilac i imenilac reflektuju realne operativne uslove proizvodnje, čime se postiže fizički konzistentna interpretacija rezultata.

U skladu sa ovom analizom preporučuje se:


- primena daylight maske pre računanja metrika,
- računanje referentne skale y_{ref} nad istim maskiranim skupom $\mathcal{D}_{\text{eval}}$.

Na slici 5.2 prikazana je raspodela GHI za test period (2022. godina). Prag $GHI_{\text{thr}} = 20 \text{ W/m}^2$ razdvaja dnevne i noćne/tranzicione uzorke u skladu sa standardom IEC 61724-1:2021 [65]. Uzorci ispod praga se isključuju iz evaluacije. Korišćeni skupovi podataka, sumirani vremenski opsezi, broj podataka u skupu, sadržaj i uloge skupova podataka korišćenih u evaluaciji su dati u Tabeli 5.1. Slika 5.3 prikazuje vremensku seriju referentne energije, predikcije i binarne maske M_t . Evaluacija metrika vrši se samo za $M_t = 1$.

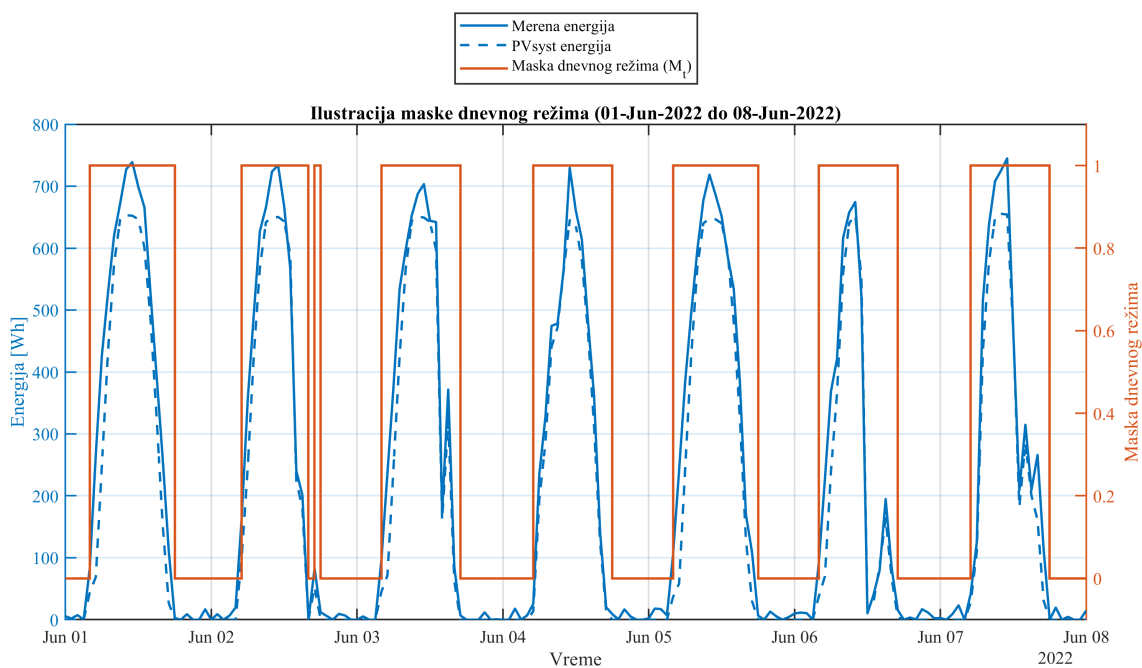
Rezultati iz Tabele 5.2 jasno potvrđuju teorijsku analizu: uključivanje noćnih uzoraka gotovo prepolovljuje MAE i značajno smanjuje RMSE. Ovo potvrđuje da evaluacija bez daylight filtriranja daje sistematski optimistične procene performansi generisanog modela.

Tabela 5.2: Daylight parametri i efekat na metrike (2018–2022).

Parametar	Vrednosti	
	All	Daylight
GHI_{thr}	20 W/m ²	
Broj uzoraka	43 824	18 351
Udeo daylight uzoraka	41.9%	
MAE [Wh]	27.465	60.038
RMSE [Wh]	58.409	89.876
MBE [Wh]	4.278	15.715



Slika 5.2: Histogram GHI sa označenim daylight pragom.



Slika 5.3: Primena maske dnevnog režima na reprezentativnom intervalu.

XGBoost kao referentni model

Pored MLP/ANN modela (Prilog H), u okviru komparativne analize razmatran je i XGBoost regresor kao predstavnik savremenih *tree-ensemble* metoda zasnovanih na gradijentnom pojačavanju stabala odlučivanja. Uloga XGBoost modela nije bila da zameni neuronski pristup, već da posluži kao nezavisan algoritamski referentni model drugačije strukturne paradigme učenja. Na taj način omogućena je procena da li ostvarena poboljšanja performansi potiču iz same informativnosti ulaznog prostora i metodološke postavke problema, ili su isključivo posledica specifične ANN arhitekture.

Radi metodološke konzistentnosti, XGBoost je treniran nad identičnim skupom ulaznih promenljivih, uz istu hronološku podelu podataka (trening, validacija, test) i evaluiran korišćenjem istih metrika u energetsom domenu. Time je obezbeđena objektivna i direktna uporedivost sa MLP/ANN modelima.

Detaljna teorijska i matematička formulacija XGBoost algoritma, uključujući regularizacionu funkciju cilja i postupak sekvencijalnog dodavanja stabala, data je u Prilogu F.

Persistence i scaled persistence modeli

Radi objektivne evaluacije razvijenih ANN i XGBoost modela, korišćeni su standardni referentni pristupi: (i) klasični persistence model i (ii) njegova unapređena varijanta, scaled persistence model.

Persistence model polazi od pretpostavke kratkoročne stacionarnosti atmosferskih uslova, odnosno da je najbolja procena buduće vrednosti GHI jednaka trenutno izmerenoj vrednosti. Uprkos svojoj jednostavnosti, ovaj pristup predstavlja izuzetno snažan i pouzdan referentni kriterijum za satne horizonte prognoze zbog izražene autokorelacije iradijance.

Scaled persistence model uvodi korekciju determinističke komponente Sunčeve geometrije skaliranjem trenutne vrednosti odnosom clear-sky referentnih nivoa u trenucima t i $t + H$. Na taj način se eliminiše dominantni dnevni trend, dok se implicitno pretpostavlja približno konstantan clear-sky indeks u kratkom vremenskom intervalu. Ovaj model predstavlja stroži referentni model u odnosu na klasični persistence pristup.

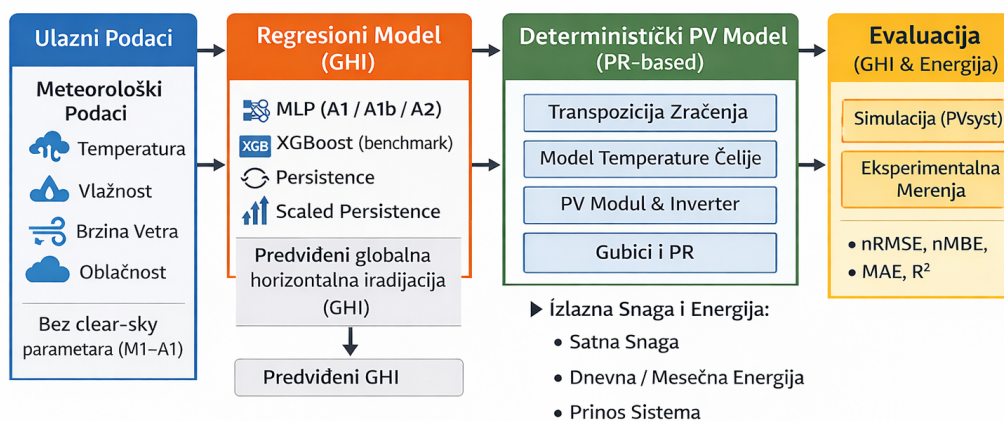
Radi metodološke konzistentnosti, prognoze oba referentna modela propagirane su u energetsom domenu primenom istog PR-zasnovanog konverzionog modela koji je korišćen i kod naprednih metoda. Time je obezbeđeno da razlike u performansama odražavaju isključivo kvalitet prognoze GHI, a ne razlike u fizičkoj transformaciji u energiju. Detaljna matematička formulacija oba modela, uključujući clear-sky aproksimaciju i numeričke zaštite, data je u Prilogu E.

5.3 Rezultati: modeli M1 metodologije

Metodologija M1 realizuje *posredni* pristup predviđanju izlaznih karakteristika PV sistema, u okviru koga se najpre vrši satna regresija GHI, a zatim se predviđena vrednost GHI

mapira u energetska veličinu sistema primenom PR-zasnovanog, fizički interpretabilnog modela (Prilog D).

Ovakva dvostepena formulacija omogućava analizu performansi u dva komplementarna domena: (i) meteorološkom (tačnost predikcije GHI) i (ii) energetsom (tačnost procene proizvedene PV energije). Na taj način razdvajaju se izvori greške koji potiču iz regresione aproksimacije solarnog zračenja od onih koji proizlaze iz fizičkog mapiranja u energetsom domenu. U okviru grupe M1 razmatrane su tri varijante ANN modela (M1–A1, M1–A1b i M1–A2), kao i dva autoregresivna baseline pristupa (persistence i scaled persistence). Pored toga, radi procene algoritamske robusnosti i ispitivanja uticaja izbora regresione arhitekture, implementiran je i dodatni data-driven referentni model zasnovan na XGBoost algoritmu (slika 5.4). Svi modeli trenirani su nad identičnim skupom ulaznih promenljivih i uz striktno hronološku podelu podataka, čime je obezbeđeno metodološki konzistentno i fer poređenje.



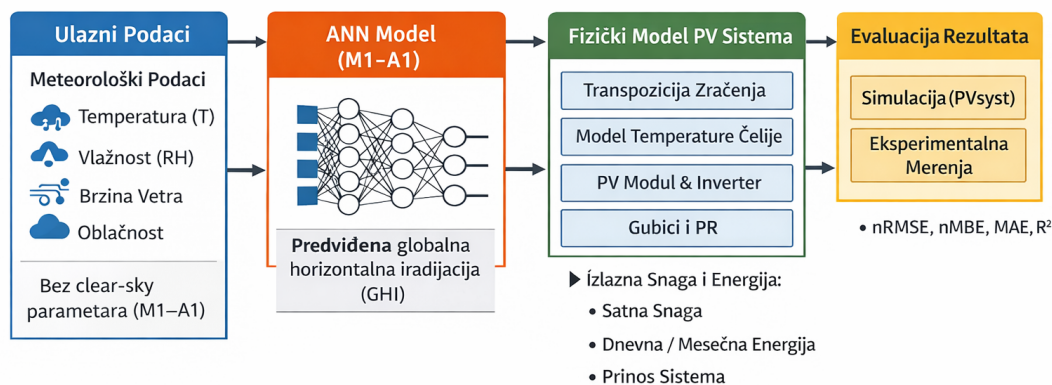
Slika 5.4: Konceptualni tok obrade podataka kod metodologije M1 (predikcija GHI i PR-bazirano mapiranje u energiju).

5.3.1 Model M1–A1: osnovni ANN model (bez optimizacije)

Model M1–A1 predstavlja polaznu ANN konfiguraciju u okviru grupe M1 i služi kao osnovni referentni model za analizu performansi bez sprovedene sistematske optimizacije hiperparametara. Njegova uloga je da obezbedi početnu tačku za procenu mogućnosti ANN pristupa u kratkoročnoj prognozi GHI, kao i da omogući kasnije poređenje sa unapređenim i optimizovanim varijantama modela.

U ovoj fazi analiza je sprovedena za jednočasovni horizont prognoze ($H = 1$ h), pri čemu se najpre evaluiraju performanse modela u domenu prognoze GHI, a zatim se dobijene vrednosti propagiraju kroz isti PR-bazirani energetska model radi procene uticaja greške prognoze na procenu izlazne energije eksperimentalnog PV sistema. Konceptualni tok obrade podataka i evaluacije modela prikazan je na slici 5.5. Prikazana šema obuhvata

formiranje ulaznog prostora, ANN predikciju GHI, konverziju u energetske domen primenom PR-zasnovanog modela i konačnu evaluaciju u iradiacionom i energetskom domenu.



Slika 5.5: Konceptualni tok obrade podataka kod modela M1-A1: ANN predikcija GHI ($H = 1$ h), propagacija kroz PR-zasnovani fizički model i evaluacija u energetskom domenu.

5.3.1.1 Osnovna konfiguracija M1-A1

Pre analize dobijenih rezultata, neophodno je precizno definisati osnovne postavke baznog modela M1-A1, koji u ovom radu predstavlja početnu referentnu ANN konfiguraciju bez dodatne optimizacije hiperparametara. Kompletna implementacija modela data je u Prilogu I, dok su u nastavku izdvojene ključne metodološke i arhitekturne karakteristike ovog modela.

Model M1-A1 formulisan je kao problem jednočasovne kratkoročne prognoze globalnog horizontalnog zračenja, pri čemu se iz ulaznog vektora formiranog u trenutku k predviđa vrednost GHI_{k+H} za horizont prognoze $H = 1$ h. Na taj način, bazna konfiguracija odgovara standardnom *one-step-ahead* režimu prognoze.

Skup ulaznih promenljivih je formiran kombinovanjem meteoroloških i vremenskih karakteristika. Ulazni prostor obuhvata ukupno 16 karakteristika, i to: četiri ciklički kodirane vremenske promenljive (sin i cos reprezentacije dana u godini i časa u danu), kao i sledeće meteorološke veličine: temperaturu vazduha, brzinu vetra, relativnu vlažnost, atmosferski pritisak, precipitabilnu vodu, albedo, zenitni ugao Sunca, azimut Sunca, tip oblačnosti, direktno normalno zračenje (DNI), difuzno horizontalno zračenje (DHI) i *clear-sky* komponentu globalnog horizontalnog zračenja. Ciljna promenljiva modela je mereno globalno horizontalno zračenje (GHI).

U cilju obezbeđenja fizički smislenog skupa za učenje, nadgledani uzorci formirani su tek nakon vremenskog pomeranja ciljne promenljive za $H = 1$ h i primene dnevne maske u ciljnom trenutku. Kao dnevni ciljevi zadržani su samo oni uzorci za koje važi $GHI_{k+H} > 20 \text{ W/m}^2$ i $GHI_{k+H}^{cs} > 20 \text{ W/m}^2$, dok je dodatno, kada je podatak dostupan, primenjen i uslov da zenitni ugao bude manji od 85° . Na ovaj način iz analize su isključeni noćni i

granični uslovi sa zanemarljivim nivoom zračenja, čime je postupak učenja fokusiran na operativno relevantan dnevni režim.

Arhitektura baznog M1–A1 modela realizovana je kao feed-forward MLP mreža sa dva skrivena sloja. Broj neurona u skrivenim slojevima postavljen je na [20 10], odnosno prvi skriveni sloj sadrži 20 neurona, dok drugi sadrži 10 neurona. U skrivenim slojevima korišćena je tangentno–sigmoidna aktivaciona funkcija, dok je izlazni sloj linearan, što odgovara regresionom karakteru problema prognoze GHI.

Postupak treniranja realizovan je primenom SCG algoritma (`trainscg`). Ovaj algoritam izabran je kao bazna opcija zbog povoljnog kompromisa između računске efikasnosti, stabilnosti treniranja i memorijskih zahteva, posebno u poređenju sa LM algoritmom, koji može biti zahtevniji u pogledu memorije, i BR pristupom, koji obično daje robusna rešenja ali uz duže vreme treniranja. Maksimalan broj epoha postavljen je na 500, dok je kriterijum ranog zaustavljanja definisan parametrom `max_fail = 15`, odnosno treniranje se prekida ukoliko tokom 15 uzastopnih epoha ne dođe do poboljšanja validacione greške.

Podela podataka izvršena je strogo hronološki, bez nasumičnog mešanja uzoraka, kako bi se očuvala vremenska struktura problema i izbeglo informaciono curenje. Skup za treniranje obuhvata period 2005–2020, validacioni skup čini 2021. godina, dok je test skup formiran od podataka iz 2022. godine. Ovakva podela omogućava realističnu procenu sposobnosti generalizacije modela na budućem, neviđenom periodu.

Normalizacija ulaznih promenljivih izvršena je korišćenjem srednje vrednosti i standardne devijacije izračunatih isključivo na trening skupu. Dobijeni parametri skaliranja potom su primenjeni i na validacioni i test skup. Na taj način sprečeno je curenje informacija iz budućih perioda ka procesu obuke, što je od suštinske važnosti za korektnu evaluaciju vremenskih modela prognoze.

Pored ANN modela, u istoj eksperimentalnoj postavci implementirani su i referentni modeli za poređenje: standardni *persistence* model, *scaled persistence* model, kao i dodatni referentni model zasnovan na podacima (XGBoost/LSBoost regresioni ansambl stabala). Svi modeli evaluirani su nad istim ciljnim uzorcima i uz identičnu hronološku podelu podataka, čime je obezbeđeno fer i metodološki konzistentno poređenje u domenu prognoze zračenja.

Nakon prognoze GHI, dobijene vrednosti dalje su propagirane kroz isti PR-bazirani energetska model radi procene satne proizvodnje eksperimentalnog PV sistema. Na taj način model M1–A1 nije evaluiran samo u iradijacionom domenu, već i u energetskom domenu, što omogućava sagledavanje praktične vrednosti prognoze sa stanovišta procene proizvodnje električne energije.

Na osnovu navedenih postavki, model M1–A1 predstavlja početnu, strukturno jednostavnu ali metodološki korektno definisanu ANN konfiguraciju, koja služi kao polazna tačka za dalju analizu, poređenje sa referentnim pristupima i kasniju optimizaciju hiper-

parametara u unapređenim varijantama modela. Osnovne karakteristike baznog modela M1–A1 sumirane su u Tabeli 5.3.

Tabela 5.3: Osnovne karakteristike baznog modela M1–A1

Karakteristika	Postavka
Tip modela	Feed-forward MLP
Horizont prognoze	$H = 1$ h
Ulazni prostor	16 karakteristika
Ciljna promenljiva	GHI_{k+1}
Skriveni slojevi	2
Broj neurona	[20 10]
Aktivacija skrivenih slojeva	tansig
Izlazna aktivacija	purelin
Algoritam treniranja	trainscg
Maksimalan broj epoha	500
Early stopping	max_fail=15
Podela podataka	train: 2005–2020; val: 2021; test: 2022
Normalizacija	na osnovu trening skupa
Dnevna maska	$GHI > 20$ W/m ² , $GHI^{cs} > 20$ W/m ² , $\theta_z < 85^\circ$
Referentni modeli	persistence, scaled persistence, XGBoost/LSBoost
Energetska evaluacija	PR-bazirani model

5.3.1.2 Rezultati u GHI domenu.

Numeričke performanse modela u iradijacionom domenu su prikazane u tabeli 5.4. Na

Tabela 5.4: Performanse modela M1–A1 i referentnim modela u GHI domenu (daytime uzorci, $H = 1$ h).

Model	Split	MAE [W/m ²]	RMSE [W/m ²]	MBE [W/m ²]	nRMSE [%]	nMBE [%]
M1–A1	Train	57.92	92.10	-0.43	24.52	-0.12
	Val	56.22	91.93	0.66	23.68	0.17
	Test	56.03	90.51	6.01	23.06	1.53
Persistence	Test	121.98	151.88	-8.81	38.70	-2.24
Scaled persistence	Test	56.30	104.47	-7.58	26.62	-1.93
XGBoost	Test	56.06	91.36	6.08	23.28	1.55

test skupu model M1-A1 ostvaruje vrednost $nRMSE = 23.06\%$, uz nizak sistematski pomak ($nMBE = 1.53\%$). Razlika između trening, validacionih i test metrika je minimalna ($\Delta nRMSE < 1.5\%$), što ukazuje na stabilnu konvergenciju i dobru generalizaciju modela.

U poređenju sa modelom perzistencije, koji implicitno pretpostavlja lokalnu vremensku stacionarnost ($\widehat{GHI}(t+1) = GHI(t)$), ostvareno je značajno smanjenje greške, pri čemu RMSE opada sa 151.88 W/m^2 na približno 90 W/m^2 , što odgovara relativnom poboljšanju od oko 40%.

Uvođenje skalirane perzistencije, koja uključuje determinističku geometrijsku korekciju, dodatno unapređuje performanse u odnosu na osnovni persistence model ($nRMSE = 26.62\%$), ali i dalje zaostaje za ANN modelom M1-A1, što potvrđuje da neuronska mreža uspešno aproksimira nelinearne komponente atmosferske dinamike koje nisu obuhvaćene jednostavnim determinističkim pristupima.

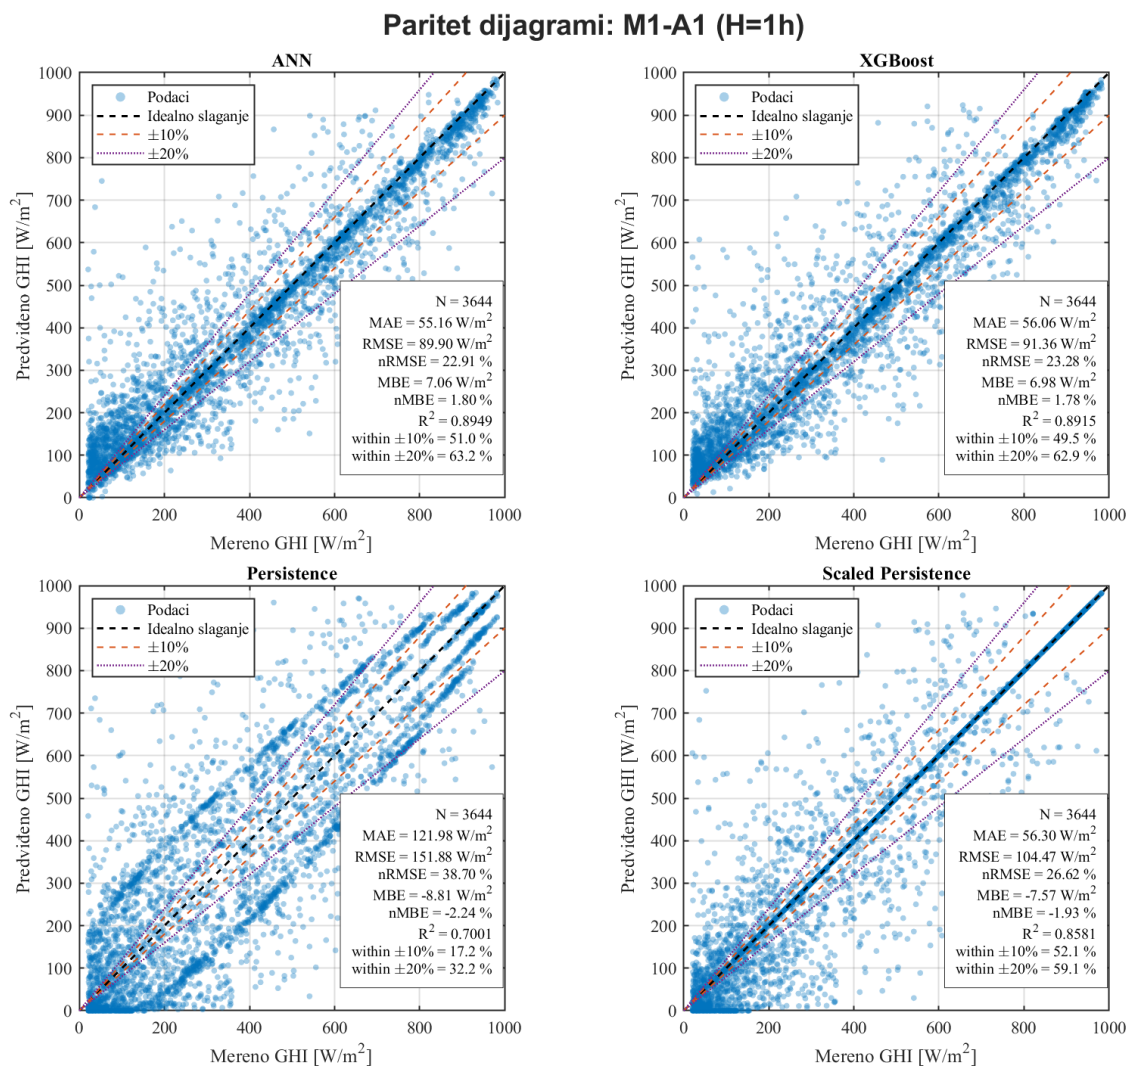
Radi nezavisne validacije rezultata, primenjen je i XGBoost regresioni model kao algoritamski različit referentni model. Dobijene vrednosti ($nRMSE = 23.28\%$, $RMSE = 91.36 \text{ W/m}^2$) praktično su izjednačene sa performansama ANN modela ($nRMSE = 22.91\%$), uz minimalnu razliku od svega $\Delta nRMSE \approx 0.37$ procentnih poena. Ovakva podudarnost ukazuje da ostvareno poboljšanje nije posledica specifične arhitekture modela, već adekvatne reprezentacije ulaznih meteoroloških karakteristika i striktno hronološke validacije.

Paritet dijagrami na slici 5.6 prikazuju uporedni pregled performansi četiri modela u GHI domenu za test skup ($H = 1 \text{ h}$): ANN modela M1-A1, XGBoost modela, modela perzistencije i skalirane perzistencije. Uočava se da model perzistencije pokazuje izraženo rasipanje predikcija i karakteristične paralelne strukture, posebno u tranzicionim atmosferskim režimima ($200\text{--}500 \text{ W/m}^2$), što rezultuje većim vrednostima greške i slabijim koeficijentom determinacije ($R^2 = 0.7001$).

Primena skalirane perzistencije smanjuje rasipanje i poboljšava slaganje sa merenjima ($R^2 = 0.8581$), ali i dalje ne dostiže performanse naprednih modela. ANN model M1-A1 obezbeđuje najkompaktnije grupisanje tačaka oko idealne dijagonale, posebno u domenu srednjih i visokih iradijansi, dok XGBoost pokazuje vrlo sličan obrazac sa blago većom disperzijom u srednjem opsegu.

Za sve modele prisutan je obrazac povećanog rasipanja u tranzicionim režimima, što ukazuje na inherentnu kompleksnost modelovanja naglih promena atmosferskih uslova. Nasuprot tome, u režimima dominantno direktnog zračenja (visoke vrednosti GHI), predikcije su znatno stabilnije i bliže idealnoj dijagonali.


Sezonska analiza prikazana na slici 5.7 potvrđuje da se ostvareno smanjenje greške u odnosu na persistence pristup održava tokom cele godine, uz izraženu zavisnost od godišnjeg doba. U poređenju sa persistence modelom ($nRMSE = 38.70\%$), ANN ostvaruje relativno smanjenje greške od približno 40% ($nRMSE = 23.06\%$), pri čemu su najveća



Slika 5.6: Paritet dijagrami u GHI domenu za test skup ($H = 1$ h): (a) ANN model M1-A1, (b) model perzistencije, (c) skalirana perzistencija i (d) XGBoost model.

poboljšanja uočena tokom prolećnih i letnjih meseci, kada je raspoloživa solarna energija veća i signal stabilniji.

Kriva ANN modela je gotovo identična XGBoost rezultatu, pri čemu razlika u globalnoj metrici iznosi $\Delta nRMSE \approx 0.22$ procentna poena (23.06% naspram 23.28%). Ovakva podudarnost ukazuje da ograničenje performansi nije dominantno uslovljeno izborom algoritma učenja, već inherentnom varijabilnošću atmosferskih procesa i ograničenjima informativnosti ulaznih promenljivih. Dodatno, scaled persistence model dosledno ostvaruje niže greške u odnosu na klasični persistence, ali i dalje značajno zaostaje za modelima zasnovanim na mašinskom učenju, što potvrđuje da uključivanje dodatnih meteoroloških ulaza omogućava superiorno modelovanje kratkoročne dinamike GHI. Varijacije u mesečnim vrednostima nRMSE delimično su povezane i sa brojem raspoloživih uzoraka pri čemu manji broj uzoraka u zimskim mesecima doprinosi većoj varijabilnosti performansi.



Slika 5.7: Mesečne vrednosti $nRMSE$ u GHI domenu (test godina, $H = 1 h$).

5.3.1.3 Rezultati u energetsom domenu.

Prognozirane vrednosti GHI propagirane su u energetska domenu primenom PR-zasnovanog fizičkog modela, u skladu sa relacijom:

$$E(t) = PR \cdot GHI(t) \cdot A_{\text{eff}} \cdot \eta_{\text{ref}}, \quad (5.36)$$

gde PR predstavlja efektivni faktor performansi, dok su A_{eff} i η_{ref} konstantni parametri PV sistema. Kalibracijom na osnovu merenih podataka dobijena je medijana $PR = 0.909$, čime su implicitno obuhvaćeni temperaturni i sistemski gubici. Numerički rezultati u odnosu na merenu proizvodnju tokom 2022. godine prikazani su u tabeli 5.5. Model zadržava relativno smanjenje $nRMSE$ od približno 38% u odnosu na persistence pristup (25.19% prema 40.52%), što je u skladu sa poboljšanjem ostvarenim u GHI domenu. U poređenju sa PVsyst simulacijom, ANN pristup ostvaruje globalno nižu grešku (25.19% prema 27.70%), što ukazuje da data-driven regresija, kombinovana sa PR propagacijom, može reprodukovati realne uslove barem jednako uspešno kao deterministički PVsyst simulacioni model.

XGBoost referentni model pokazuje gotovo identične performanse ($nRMSE = 25.35\%$), uz minimalnu razliku $\Delta nRMSE \approx 0.16$ procentnih poena. Ova podudarnost potvrđuje algoritamsku konzistentnost rezultata i sugerise da ograničenje performansi dominantno potiče od inherentne meteorološke varijabilnosti, a ne od izbora konkretne mašinsko-učeće arhitekture.

Paritet dijagrami na slici 5.8 prikazuju uporednu analizu performansi različitih modela u energetsom domenu za 2022. godinu. Uočava se da referentni model perzistencije poka-

Tabela 5.5: Energetske performanse (satni nivo, 2022) u odnosu na merenu proizvodnju.

Model	MAE [Wh]	RMSE [Wh]	MBE [Wh]	nRMSE [%]	nMBE [%]
PR(pred GHI)	54.24	80.13	7.91	25.19	2.49
XGBoost (PR)	54.44	80.66	8.71	25.35	2.74
PVsyst E_{Grid}	59.45	88.12	12.25	27.70	3.85
Persistence	103.01	128.90	-4.22	40.52	-1.33
Scaled persistence	59.18	91.18	-3.20	28.66	-1.01

zuje izraženo rasipanje predikcija i značajno odstupanje od idealne dijagonale, naročito u srednjem opsegu energija, što potvrđuju visoke vrednosti grešaka i nizak koeficijent determinacije ($R^2 = 0.6504$). Uvođenjem skalirane perzistencije postiže se vidljivo poboljšanje, ali performanse i dalje zaostaju za naprednijim modelima.

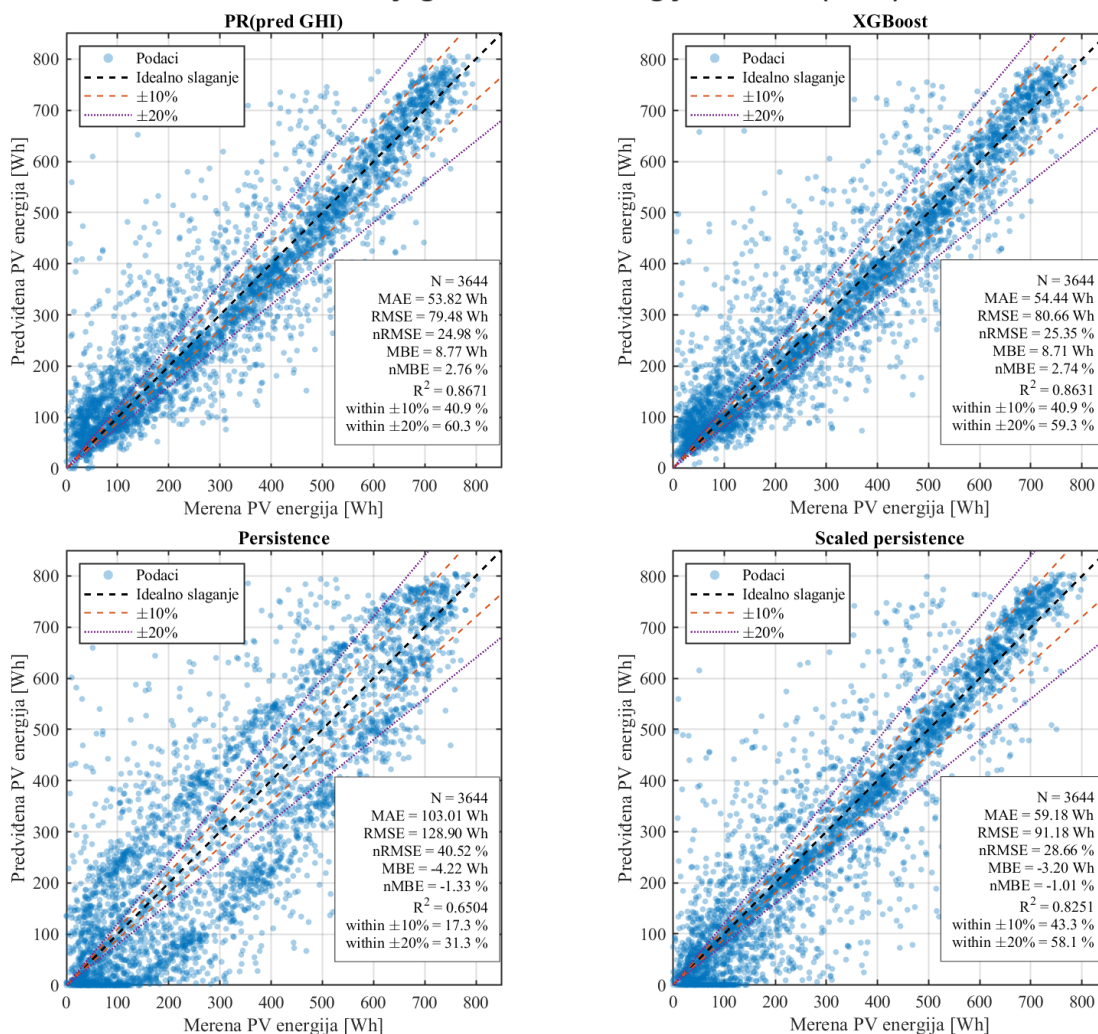
ANN model M1–A1 (PR-baziran pristup) i XGBoost model ostvaruju znatno bolje slaganje sa merenjima, uz dominantno grupisanje tačaka duž idealne dijagonale i značajno niže vrednosti grešaka. Performanse ova dva modela su međusobno vrlo bliske, pri čemu ANN model pokazuje blagu prednost u pogledu niže vrednosti RMSE i veće koncentracije tačaka unutar $\pm 10\%$ opsega.

Heteroskedastičnost je prisutna kod svih razmatranih modela, pri čemu se manifestuje povećanjem disperzije reziduala u srednjem opsegu energija (200–500 Wh), dok su u visokoenergetskom režimu predikcije stabilnije i kompaktnije raspoređene. Kvantitativna analiza potvrđuje ovu pojavu: varijansa greške u srednjem opsegu energija je približno 1.5–2 puta veća u odnosu na visokoenergetski režim, što ukazuje na nelinearnu zavisnost između intenziteta signala i nesigurnosti predikcije. Dodatno, rezultati testova na heteroskedastičnost (npr. Breusch–Pagan [93], [94]) ukazuju na statistički značajno odstupanje od hipoteze o konstantnoj varijansi ($p < 0.05$). Ovi nalazi potvrđuju da se tačnost modela ostvarena u GHI domenu uspešno prenosi u energetski domen, uz dodatni uticaj nelinearnosti u procesu konverzije iradijance u proizvedenu energiju.


Mesečna analiza na slici 5.9 potvrđuje stabilnost modela tokom cele godine. Relativna greška je očekivano viša u zimskim mesecima zbog nižeg nivoa apsolutne proizvodnje, dok su tokom letnjih meseci odstupanja minimalna. Podudarnost sezonskog profila ANN i XGBoost modela dodatno potvrđuje algoritamsku konzistentnost rezultata.

Konzistentnost rezultata između iradijacionog i energetskog domena potvrđuje metodološku koherentnost predloženog pristupa: unapređenje u GHI regresiji direktno se preslikava na poboljšanje energetskih metrika, bez potrebe za dodatnim empirijskim korekcijama. Rezultati modela M1–A1 ukazuju na stabilnu konvergenciju, dobru sposobnost generalizacije i jasno unapređenje u odnosu na referentne (baseline) pristupe, kako u GHI, tako i u energetskom domenu. Ipak, analiza reziduala, naročito u tranzicionim atmosferskim

Paritet dijagrami satne energije: M1--A1 (2022)



Slika 5.8: Paritet dijagrami satne energije za 2022. godinu: (a) PR-bazirani ANN model M1-A1, (b) XGBoost model, (c) model perzistencije i (d) skalirana perzistencija.



Slika 5.9: Mesečne sume energije tokom 2022. godine.

režimima, ukazuje na preostalu varijansu koju je moguće dodatno smanjiti.

S obzirom da ANN i XGBoost pristupi ostvaruju gotovo identične performanse, dalja poboljšanja nisu primarno uslovljena izborom algoritma učenja, već finijom optimizacijom arhitekture, hiperparametara i procesa treniranja postojećeg modela. Kompletan MATLAB skript modela, kao i detaljniji prikaz rezultata simulacije, dati su u Prilozima I i J.

5.3.2 Optimizacija strukture i procesa učenja modela M1-A1

U cilju obezbeđivanja objektivne i metodološki korektne osnove za poređenje različitih varijanti modela M1, sprovedena je sistematska optimizacija strukture i procesa učenja osnovnog ANN modela M1-A1. Cilj ove procedure bio je da se identifikuje konfiguracija neuronske mreže (broj skrivenih slojeva, broj neurona po sloju i algoritam učenja) koja ostvaruje najbolji kompromis između tačnosti predviđanja, stabilnosti procesa učenja i sposobnosti generalizacije, pri fiksiranim ulaznim promenljivim i identičnom eksperimentalnom protokolu.

Eksperimentalni protokol je strogo fiksiran:

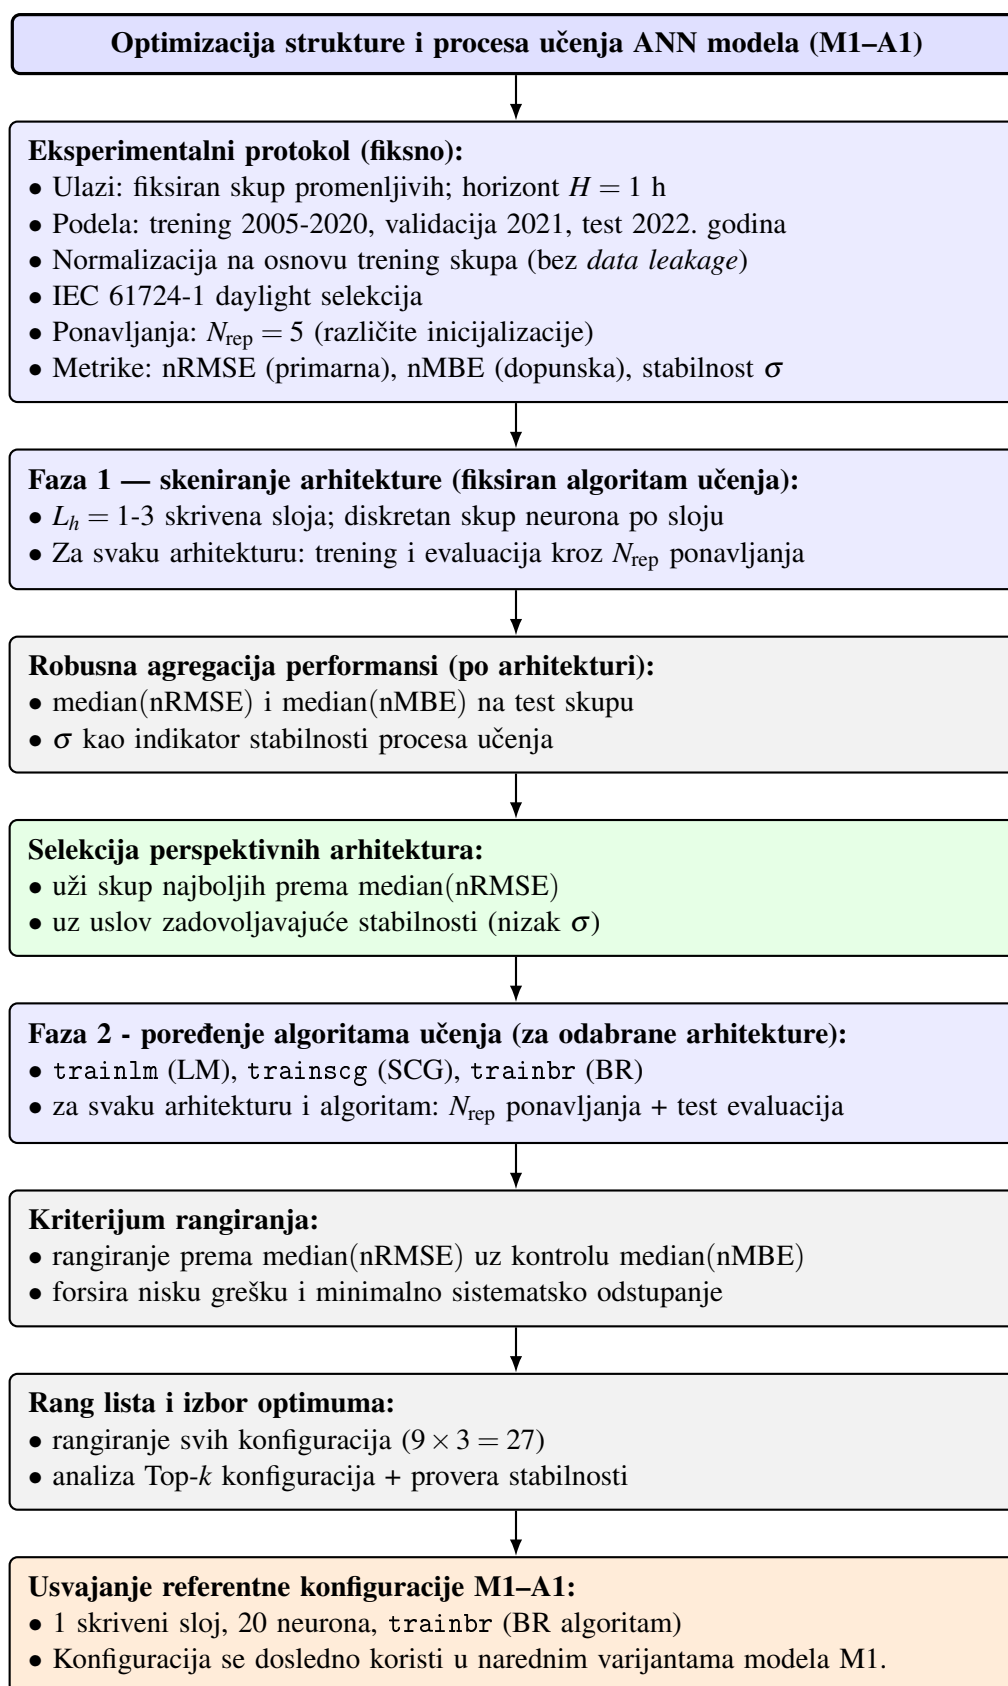
- fiksiran skup promenljivih i horizont predviđanja $H = 1$ h,
- hronološka podela podataka: trening (2005–2020), validacija (2021) i nezavisni test (2022),
- normalizacija isključivo na osnovu trening skupa (bez informacionog curenja),
- IEC 61724-1 daylight selekcija uzoraka na ciljnom vremenskom trenutku,
- $N_{\text{rep}} = 5$ ponavljanja po konfiguraciji (različite inicijalizacije težina),
- primarna metrika: nRMSE na test skupu, dopunska: nMBE, uz analizu stabilnosti kroz standardnu devijaciju.

Postupak optimizacije, čiji je blok dijagram prikazan na slici 5.10, sproveden je u dve faze: **Faza 1** je obuhvatila sistematsko skeniranje arhitekture kroz varijacije broja skrivenih slojeva (1-3) i diskretni skup broja neurona po sloju (5, 10, 15, 20, 30, 40 i višeslojne kombinacije). Algoritam učenja u ovoj fazi bio je fiksiran, a performanse su agregirane korišćenjem median vrednosti nRMSE i nMBE na test skupu.

Faza 2 je obuhvatila analizu tri algoritma učenja: LM (`trainlm`), SCG (`trainscg`) i BR (`trainbr`), za uži skup perspektivnih arhitektura.

Ukupno je razmotreno 27 konfiguracija (9 arhitektura \times 3 algoritma), pri čemu je rangiranje izvršeno na osnovu median test nRMSE vrednosti, uz dodatni uslov niske varijabilnosti kroz ponavljanja. Rezultati optimizacije ukazuju da BR algoritam konzistentno ostvaruje najniže median vrednosti nRMSE, uz stabilno ponašanje kroz inicijalizacije.

Na osnovu sistematske optimizacije strukture i algoritma učenja, kao referentna konfiguracija modela M1-A1 usvojena je jednoslojna MLP mreža sa 20 neurona u skrivenom sloju, trenirana BR algoritmom (`trainbr`). Ova konfiguracija je ostvarila najnižu median vrednost normalizovane greške na test skupu (nRMSE = 22.936%) i najniži kompozit-



Slika 5.10: Šematski prikaz procedure optimizacije strukture i procesa učenja ANN modela M1-A1.

ni skor $J = 23.420$, uz izuzetno malu standardnu devijaciju (niska varijabilnost između ponavljanja), što ukazuje na stabilan proces učenja i dobru sposobnost generalizacije.

Dodatno povećanje broja neurona ili uvođenje dubljih arhitektura nije dovelo do statistički značajnog poboljšanja performansi, što potvrđuje da je odabrana konfiguracija optimalan kompromis između tačnosti, stabilnosti i kompleksnosti modela. Na osnovu rangiranja svih validnih konfiguracija prema kompozitnom kriterijumu:

$$J = \text{median}(\text{nRMSE}_{\text{test}}) + 0.3 |\text{median}(\text{nMBE}_{\text{test}})|, \quad (5.37)$$

prvorangirana konfiguracija (20 neurona, `trainbr`) je usvojena kao referentna i zatim dosledno primenjena u svim narednim varijantama modela M1, čime je obezbeđena objektivna i metodološki korektna komparativna analiza. Uočeno je da povećanje dubine mreže (2 i 3 skrivena sloja) ne donosi sistematsko poboljšanje performansi, dok složenije konfiguracije pokazuju veću varijabilnost i potencijalnu sklonost ka preučavanju.

Tabela 5.6: Najbolje rangirane konfiguracije ANN modela M1–A1 za horizont $H = 1$ h.

Rang	L_h	Hidden	Alg.	med nRMSE [%]	std nRMSE [%]	J
1	1	20	<code>trainbr</code>	22.936	0.0364	23.420
2	1	30	<code>trainbr</code>	22.974	0.0838	23.474
3	1	15	<code>trainbr</code>	22.978	0.0103	23.485
4	2	40–20	<code>trainscg</code>	23.030	0.1010	23.488
5	2	10–5	<code>trainbr</code>	22.971	0.0527	23.521

Najbolje rangirane konfiguracije prikazane su u Tabeli 5.6. Date su median vrednosti i standardna devijacija nRMSE na test skupu (2022. godina) kroz $N_{\text{rep}} = 5$ ponavljanja. Kompletan dizajn-matrica i analitička interpretacija rezultata optimizacije su u [Prilogu K](#). Sa aspekta principa parsimonije (Occamov princip [95], [96])⁴, dobijeni rezultati potvrđuju da je jednoslojna mreža sa umerenim brojem neurona optimalan kompromis između tačnosti, stabilnosti i kompleksnosti modela. Ovakav izbor je metodološki opravdan, jer omogućava transparentnu interpretaciju i objektivno poređenje u svim narednim varijantama modela M1, bez uvođenja nepotrebne dubine ili parametarske redundanse.

5.3.3 Model M1–A1b: optimizovana konfiguracija

Model M1–A1b predstavlja optimizovanu varijantu osnovne M1–A1 arhitekture. Dok je referentni model realizovan sa dva skrivena sloja sa 20 i 10 neurona, i algoritmom `trainscg`, optimizacija je pokazala da jednostavnija arhitektura sa jednim skrivenim

⁴podrazumeva da, između više modela koji imaju slične performanse, treba preferirati onaj sa manjim brojem pretpostavki ili parametara, ukoliko dodatna složenost ne donosi suštinsko poboljšanje objašnjenja ili predikcije.

slojem i 20 neurona, u kombinaciji sa algoritmom trainbr, ostvaruje stabilnije i blago preciznije rezultate.


Zadržana je identična struktura ulaznih promenljivih i hronološka podela podataka (2005–2020 trening, 2021 validacija, 2022 test), čime je omogućeno izolovano ispitivanje uticaja arhitekture i algoritma treniranja na performanse modela.

5.3.3.1 Rezultati optimizacije.

Na test skupu ostvarena je vrednost $nRMSE = 22.936\%$, uz $RMSE = 89.904 \text{ W/m}^2$. U poređenju sa referentnim M1–A1 modelom ($nRMSE = 23.06\%$), ostvareno je smanjenje greške od $\Delta nRMSE \approx 0.12$ procentnih poena ($\approx 0.5\%$ relativnog poboljšanja).

Tabela 5.7: Poređenje referentne i optimizovane konfiguracije (test skup, $H = 1 \text{ h}$).

Model	Hidden slojevi	Algoritam	RMSE	nRMSE [%]
M1–A1	20–10	trainscg	90.51	23.06
M1–A1b	20	trainbr	89.90	22.94



Slika 5.11: Boxplot poređenje $nRMSE$ vrednosti na test skupu (2022) za modele M1–A1 i M1–A1b kroz više ponavljanja treniranja. Prikazane su median vrednosti i raspon varijacije.

Rezultati prikazani na slici 5.11 ukazuju na jasno razdvajanje karakteristika između referentnog modela M1–A1 i optimizovane varijante M1–A1b. Uočava se sistematsko

pomeranje median vrednosti nRMSE ka nižim vrednostima kod optimizovanog modela, uz istovremeno smanjenje rasipanja rezultata kroz ponavljanja treniranja, što ukazuje na veću stabilnost procesa učenja.

Dobijena vrednost Wilcoxon rank-sum testa ($p = 0.016$) [97] potvrđuje da uočena razlika nije posledica slučajnih varijacija, već predstavlja statistički značajno poboljšanje karakteristika. Smanjenje median greške od $\Delta nRMSE = 0.224$ procentna poena dodatno ukazuje da jednostavnija arhitektura sa jednim skrivenim slojem, u kombinaciji sa Bayesovom regularizacijom, omogućava bolju generalizaciju u odnosu na dublju referentnu konfiguraciju. Ovakav rezultat je u skladu sa principom parsimonije, prema kome modeli niže složenosti mogu ostvariti uporedive ili bolje performanse kada je informativnost ulaznog prostora ograničena.

Dobijeni rezultati pokazuju da povećanje dubine mreže ne doprinosi daljem smanjenju greške, dok primena Bayesove regularizacije omogućava stabilniju generalizaciju uz istovremeno pojednostavljenje arhitekture. Međutim, ostvareno poboljšanje ostaje umerno, što ukazuje da je performansni limit statičke regresione formulacije bez vremenske memorije u velikoj meri dostignut.

Analiza modela M1-A1 i njegove optimizovane varijante M1-A1b pokazuje da arhitekture bez eksplicitne vremenske memorije ostvaruju stabilne i reproduktivne rezultate, uz ograničen prostor za dalje unapređenje performansi kroz isključivo strukturnu optimizaciju. Minimalna razlika između konfiguracija potvrđuje da preostala greška nije posledica nedovoljnog kapaciteta modela, već ograničene informativnosti ulaznog vektora.

Struktura reziduala, naročito u tranzicionim atmosferskim režimima, dodatno ukazuje da je ključni nedostatak odsustvo informacije o prethodnom stanju sistema. U tom kontekstu, naredni metodološki korak predstavlja proširenje ulaznog prostora uvođenjem vremenskih kašnjenja, čime se omogućava eksplicitno modelovanje kratkoročne atmosferske dinamike i vremenske korelacije GHI signala.

Model M1-A2 stoga zadržava feed-forward regresionu strukturu, ali prelazi sa statičke na kvazi-dinamičku formulaciju problema, čime se otvara prostor za dalje smanjenje varijanse predikcije.

5.3.4 Model M1-A2: formulacija sa vremenskim kašnjenjem

Analiza modela M1-A1 i njegove optimizovane varijante M1-A1b pokazala je da statička feed-forward regresiona formulacija bez eksplicitne vremenske memorije dostiže prirodni performansni limit, uprkos optimizaciji arhitekture i algoritma učenja. Struktura reziduala i izražena autokorelacija GHI signala ukazuju da preostala greška potiče zbog odsustva informacije o prethodnom stanju sistema.

U cilju prevazilaženja ovog ograničenja, model M1-A2 uvodi vremenska kašnjenja (lagove) u ulazni prostor, čime se problem formuliše kao kvazi-dinamička regresija uz

zadržavanje feed-forward strukture mreže. Ovakav pristup omogućava učenje kratkoročne temporalne dinamike meteoroloških, satelitskih i astronomskih promenljivih relevantnih za GHI.

5.3.4.1 Matematička formulacija

Osnovni statički ANN modeli, razmatrani do sada, se mogu zapisati kao:

$$\hat{y}(t) = f(\mathbf{x}(t)), \quad (5.38)$$

gde je $\mathbf{x}(t)$ vektor meteoroloških i vremenskih promenljivih u trenutku t .

Za razliku od njih, model M1-A2 širi ulazni prostor definisanjem vektora sa vremenskim kašnjenjem ili tzv. lagovanog vektora:

$$\mathbf{X}_L(t) = [\mathbf{x}(t), \mathbf{x}(t-1), \mathbf{x}(t-2), \dots, \mathbf{x}(t-L)], \quad (5.39)$$

pa u ovom slučaju regresiona relacija poprima sledeći oblik:

$$\hat{y}(t) = f(\mathbf{X}_L(t)). \quad (5.40)$$

Na ovaj način model zadržava MLP arhitekturu, ali implicitno modeluje kratkoročnu vremensku dinamiku bez uvođenja rekurentnih struktura.

5.3.4.2 Analiza vremenske zavisnosti i izbor lag-prozora

Izbor dužine lag-prozora L zasnovan je na kombinovanoj analizi statističkih svojstava GHI vremenske serije i empirijskih karakteristika modela. Polazna osnova predstavlja autokorelaciona funkcija (ACF), koja omogućava kvantifikaciju stepena zavisnosti između trenutne vrednosti solarnog zračenja i njegovih prethodnih realizacija. Analiza ACF pokazuje izraženu kratkoročnu autokorelaciju na satnom nivou, sa dominantnim doprinosom prvog vremenskog kašnjenja, dok se za veće lagove korelacija rapidno smanjuje i postaje statistički manje značajna.

Na osnovu ovih uvida razmatrane su vrednosti lag-prozora $L \in \{1, 2, 3, 4, 6\}$, pri čemu se ulazni vektor modela proširuje na $(L+1) \cdot D_0$ dimenzija, gde D_0 predstavlja broj osnovnih ulaznih promenljivih. Povećanje L direktno utiče na rast broja slobodnih parametara neuronske mreže, čime se povećava njena reprezentaciona moć, ali istovremeno i rizik od prenaučivosti. Izbor optimalne vrednosti L sproveden je kao kompromis između nekoliko međusobno suprotstavljenih kriterijuma:

- **smanjenje greške** - procenjeno kroz validacioni i test $nRMSE$, sa ciljem minimizacije greške predviđanja,
- **stabilnost treninga** - analizirana kroz varijansu rezultata između ponavljanja treniranja i konvergenciju optimizacionog algoritma,

- **kontrola prenaučivosti** - procenjena kroz razliku između trening i validacionih performansi, kao i kroz regularizaciona svojstva modela,
- **računska složenost** - koja raste sa dimenzionalnošću ulaznog prostora i brojem parametara mreže.

Empirijski rezultati pokazuju da uvođenje prvog vremenskog kašnjenja ($L = 1$) donosi značajno poboljšanje karakteristika, dok dodatni lagovi ne doprinose daljem smanjenju greške. Naprotiv, za $L \geq 3$ uočava se blago pogoršanje, što se može pripisati povećanoj kolinearnosti ulaznih promenljivih i rastu složenosti modela bez adekvatnog povećanja informativnosti ulaza.

Ovakvo ponašanje je u skladu sa fizičkom prirodom GHI signala, gde je kratkoročna dinamika dominantno određena neposredno prethodnim stanjem atmosfere, dok starije vrednosti imaju ograničen dodatni doprinos. Stoga se izbor $L = 1$ pokazuje kao optimalan u smislu principa parsimonije, omogućavajući postizanje visoke tačnosti uz minimalnu kompleksnost modela.

5.3.4.3 Arhitektura i režim treniranja

Radi obezbeđivanja fer i objektivnog poređenja sa referentnim modelom M1–A1b, u ovoj fazi su zadržane sve ključne komponente arhitekture i režima treniranja, uz izmenu isključivo u domenu ulaznog prostora (uvođenje vremenske memorije). Konkretno, usvojene su sledeće postavke:

- **hronološka podela podataka** ostaje identična: period 2005–2020 koristi se za treniranje, 2021 za validaciju, dok se 2022 koristi kao potpuno nezavisan test skup,
- **algoritam treniranja** je `trainbr` (Bayesian regularization), čime se obezbeđuje implicitna kontrola složenosti modela i smanjenje rizika od prenaučivosti,
- **horizont predviđanja** je fiksiran na $H = 1$ h, kako bi se fokus analize zadržao na kratkoročnoj prognozi.

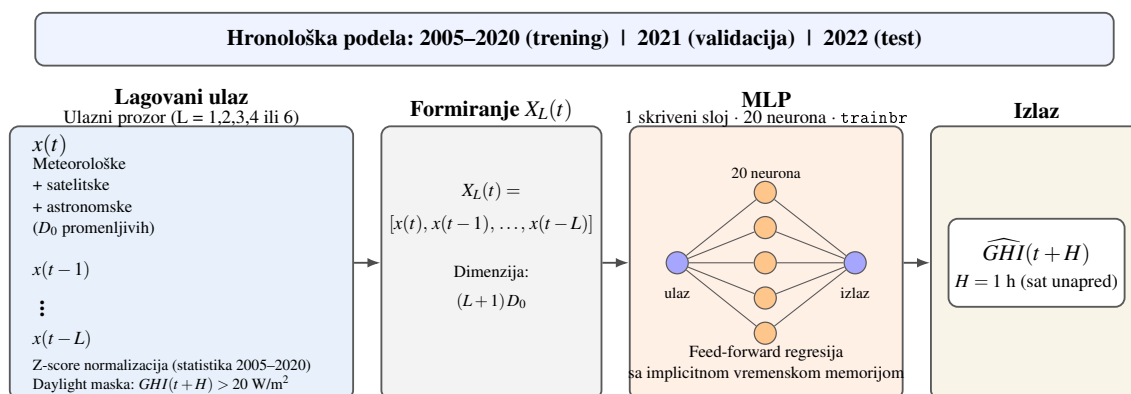
Dodatno, zadržana je ista osnovna MLP arhitektura u smislu broja slojeva i raspodele neurona, pri čemu se jedina promena odnosi na proširenje ulaznog vektora uključivanjem vremenski pomerenih vrednosti ulaznih promenljivih. Na taj način se povećava dimenzionalnost ulaznog prostora, ali bez izmene strukture same neuronske mreže.

Ovako definisan eksperimentalni okvir omogućava izolaciju efekta uvođenja vremenske memorije, tako da se sve uočene promene u karakteristikama modela mogu direktno pripisati izboru lag-prozora L . Time se obezbeđuje konzistentna i metodološki ispravna komparacija između statičkog modela (M1–A1b) i modela sa vremenskom zavisnošću (M1–A2).

5.3.4.4 Konceptualni pipeline modela

Konceptualni pipeline modela je prikazan na slici 5.12 i on uključuje: (1) formiranje lagovanog ulaznog matriksa, (2) hronološku podelu, (3) trening MLP mreže, (4) evaluaciju

u GHI i PR-zasnovanom energetskom domenu.



Slika 5.12: Konceptualni tok obrade u modelu M1–A2: formiranje lagovanog ulaznog vektora i MLP regresija za prognozu GHI za $H = 1 \text{ h}$ unapred (generička struktura za $L \in \{1, 6\}$).

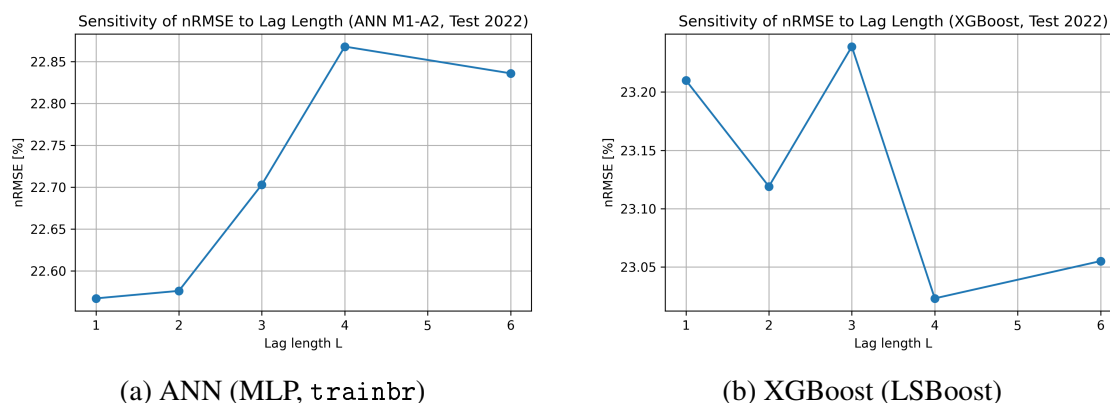
5.3.4.5 Određivanje optimalne dužine lag-prozora

Razmatrane su vrednosti $L \in \{1, 2, 3, 4, 6\}$, pri čemu se optimalna vrednost određuje na osnovu performansi na nezavisnom test skupu 2022 (tabela 5.8). Analiza osetljivosti modela M1–A2 na dužinu lag-prozora L pokazuje da minimalna vrednost normalizovane greške $nRMSE$ u GHI domenu (test godina 2022) iznosi 22.567% za $L = 1$. Povećanje broja vremenskih kašnjenja ne dovodi do daljeg smanjenja greške; naprotiv, za $L \geq 3$ uočava se postepeno povećanje varijanse predikcije i blago pogoršanje performansi. Razlika između $L = 1$ i $L = 2$ iznosi svega 0.009 procentnih poena, što je ispod praga praktičnog značaja i ukazuje da dodatno uključivanje drugog vremenskog kašnjenja ne doprinosi informativnosti ulaznog prostora.

Tabela 5.8: Uticaj dužine lag-prozora L na performanse modela M1–A2 (GHI domen, test skup 2022).

L	RMSE [W/m^2]	nRMSE [%]	nMBE [%]
1	88.572	22.567	1.561
2	88.607	22.576	1.309
3	89.106	22.703	1.874
4	89.755	22.868	2.001
6	89.629	22.836	1.464

Ovakvo ponašanje modela može se objasniti visokom kratkoročnom autokorelacijom GHI signala na satnom nivou, pri čemu je dominantna informacija o evoluciji zračenja sadržana neposredno u prethodnom satu. Uvođenje dodatnih lagova povećava dimenzionalnost ulaznog vektora na $(L+1) \cdot D_0$, pri čemu raste broj parametara i potencijal



Slika 5.13: Osetljivost $nRMSE$ na dužinu lag-prozora L za model M1–A2 (GHI domen, test 2022).


kolinearosti između ulaznih promenljivih. Posledica toga je povećanje složenosti modela bez proporcionalnog dobitka u generalizacionoj sposobnosti, što se manifestuje blagim rastom $nRMSE$ i sistematske greške $nMBE$ za veće vrednosti L (slika 5.13(a)). Rezultati XGBoost regresora potvrđuju sličan trend: promene u $nRMSE$ sa porastom L ostaju unutar uskog opsega (23.0–23.2%), bez jasnog sistematskog poboljšanja (slika 5.13(b)). Time se pokazuje da izostanak dobitka pri povećanju lag-prozora nije specifičnost MLP arhitekture, već predstavlja svojstvo same informacione strukture problema.

Dobijeni rezultati ukazuju da je za satni horizont prognoze ($H = 1$ h) eksplicitno uključivanje samo jednog vremenskog kašnjenja dovoljno da se zahvati dominantna kratkoročna dinamika atmosferskih promena. Dalje povećanje lag-prozora uvodi redundantne informacije i povećava rizik od prenaučivosti bez realnog doprinosa smanjenju greške. Sa aspekta principa parsimonije, optimalan kompromis između tačnosti i kompleksnosti ostvaruje se za $L = 1$, čime model M1–A2 zadržava jednostavnu feed-forward strukturu uz minimalnu vremensku memoriju.

Dodatni uvid u značaj uvođenja minimalne vremenske memorije dat je na slici 5.14, gde je izvršeno direktno poređenje karakteristika optimizovanog statičkog modela M1–A1b i modela M1–A2 sa $L = 1$. Uočava se konzistentno smanjenje greške u oba posmatrana domena: za 0.369 procentnih poena u GHI domenu i 0.573 procentnih poena u energetskom domenu. Ovi rezultati potvrđuju da čak i minimalno proširenje ulaznog prostora vremenskom komponentom omogućava modelu da bolje aproksimira kratkoročnu dinamiku atmosferskih promena. Istovremeno, izostanak dodatnog poboljšanja za veće vrednosti L ukazuje da je dominantna informacija sadržana u neposredno prethodnom vremenskom koraku, čime se dodatno potvrđuje optimalnost izbora $L = 1$.

5.3.4.6 Evaluacija modela u GHI domenu

Slika 5.15 prikazuje paritet dijagrama različitih modela za predikciju globalnog horizontalnog zračenja (GHI) na test skupu (2022) za horizont prognoze od jednog sata ($H = 1$ h, $L = 1$). Vizuelna analiza ukazuje da ANN model ostvaruje najkompaktniju distribuciju



Slika 5.14: Poređenje performansi modela bez vremenske memorije (M1-A1b) i modela sa jednim vremenskim kašnjenjem (M1-A2, $L = 1$) u GHI i energetskom domenu za test godinu 2022.

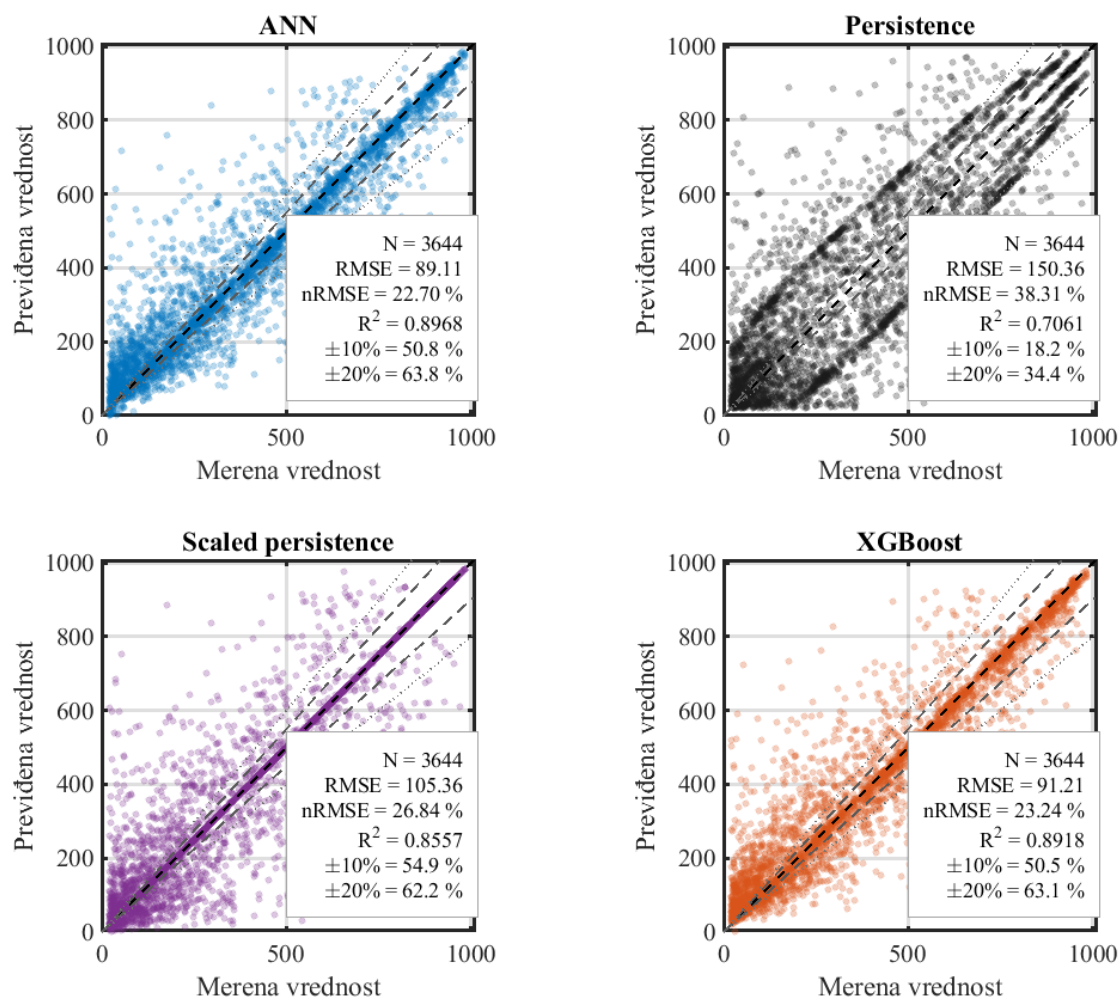
tačkaka oko idealne dijagonale, što potvrđuje visoku tačnost i dobru sposobnost reprodukcije celokupnog opsega vrednosti zračenja. XGBoost model pokazuje sličan obrazac, ali sa nešto izraženijim rasipanjem, naročito u srednjem opsegu vrednosti GHI.

Nasuprot tome, persistence model karakterišu jasno uočljive paralelne strukture, koje proizilaze iz njegove determinističke prirode i odsustva adaptivnog modelovanja vremenske dinamike. Kao posledica toga javljaju se značajna odstupanja od idealnog slaganja. Skalirana persistence metoda delimično redukuje sistematsku grešku osnovnog persistence pristupa, ali i dalje pokazuje povećano rasipanje i ograničenu preciznost.

Kvantitativni pokazatelji dodatno potvrđuju ove nalaze: ANN model ostvaruje najniže vrednosti RMSE i nRMSE, kao i najviši koeficijent determinacije ($R^2 \approx 0.90$), dok persistence model beleži značajno lošije performanse (nRMSE $\approx 38\%$, $R^2 \approx 0.70$). Udeo tačkaka unutar $\pm 10\%$ i $\pm 20\%$ intervala dodatno naglašava superiornost ANN i XGBoost modela u odnosu na referentne pristupe.

5.3.4.7 Sezonska i mesečna stabilnost karakteristika

Radi procene robusnosti modela tokom godišnjeg ciklusa, analizirane su mesečne i sezonske vrednosti nRMSE u GHI domenu za test godinu 2022 (slika 5.16). Prikaz mesečnih rezultata (slika 5.16a) dodatno uključuje i broj dostupnih uzoraka po mesecima, čime se omogućava pouzdanija interpretacija varijacija greške. Uočava se izražena sezonska




Slika 5.15: Paritet dijagrami (predikcija naspram merenja) za modele M1–A2 u GHI domenu za test godinu 2022 i horizont prognoze $H = 1$ h ($L = 1$).

zavisnost performansi svih modela. Najveće vrednosti $nRMSE$ prisutne su u zimskim mesecima (novembar–februar), gde dominiraju difuzni režimi zračenja, česta oblačnost i veća varijabilnost atmosferskih uslova. U ovim periodima modeli zasnovani na učenju (ANN i XGBoost) i dalje zadržavaju značajnu prednost u odnosu na referentne pristupe, ali uz primetno povećanje greške. Nasuprot tome, tokom prolećnih i letnjih meseci (mart–avgust) dolazi do značajnog smanjenja $nRMSE$, pri čemu se minimalne vrednosti ostvaruju u kasnom proleću i ranom letu (maj–jul). Ovaj period karakterišu stabilniji meteorološki uslovi i veća dominacija direktne komponente sunčevog zračenja, što olakšava modelovanje i dovodi do boljeg slaganja sa merenjima.

Sezonska agregacija (slika 5.16b) dodatno potvrđuje ove nalaze: najniže greške ostvaruju se u JJA (jun-juli-avgust) sezoni, dok su najveće vrednosti prisutne u DJF (decembar-januar-februar) periodu. ANN i XGBoost modeli pokazuju vrlo slične performanse kroz sve sezone, sa blagom prednošću ANN modela, dok persistence model značajno zaostaje u svim režimima. Skalirana persistence metoda redukuje sistematsku grešku u odnosu na

osnovni persistence pristup, ali i dalje ne dostiže tačnost modela zasnovanih na učenju.

Važno je istaći da varijacije u $nRMSE$ delimično koreliraju i sa brojem raspoloživih uzoraka po mesecima (slika 5.16a), pri čemu manji broj uzoraka u zimskim mesecima dodatno doprinosi povećanoj nesigurnosti procene. Ipak, dominantan uticaj ima fizička priroda atmosferskih uslova, a ne sama veličina skupa podataka. Dobijeni rezultati potvrđuju da model M1–A2 zadržava stabilne performanse tokom čitave godine, uz očekivano pogoršanje u složenijim zimskim režimima, ali bez degradacije koja bi ugrozila njegovu praktičnu primenu.



(a) Mesečne vrednosti $nRMSE$

(b) Sezonska analiza $nRMSE$


Slika 5.16: Analiza $nRMSE$ u GHI domenu tokom test godine 2022.

Na slici 5.17 su prikazane mesečne vrednosti $nRMSE$ u GHI domenu za test godinu 2022, uz paralelni prikaz srednje mesečne merene vrednosti \overline{GHI}_{meas} (desna osa). Uočava se očekivana sezonalnost: tokom proleća i leta (maj–avgust), kada je \overline{GHI}_{meas} najveći, ANN i XGBoost ostvaruju najmanje greške, dok su zimski meseci (novembar–februar) povezani sa većim $nRMSE$, što je konzistentno sa difuzno-dominantnim i meteorološki promenljivijim uslovima. U svim mesecima, oba data-driven modela značajno nadmašuju persistence baseline, dok scaled-persistence delimično smanjuje sistematsko potcenjivanje, ali i dalje zaostaje za ANN/XGB naročito u zimskom režimu. Linija \overline{GHI}_{meas} dodatno potvrđuje da porast relativne greške u zimskim mesecima nije posledica “lošeg skaliranja” već realno težih režima sa nižim apsolutnim nivoima zračenja i većom relativnom varijabilnošću.

5.3.4.8 PR-bazirana energetska evaluacija

Radi fizički interpretabilne validacije, prognozirane vrednosti GHI propagirane su u energetske domen primenom istog PR-baziranog modela korišćenog u okviru M1 grupe, pri čemu je PR kalibrisan na osnovu merenih podataka. Na ovaj način omogućena je indirektna procena tačnosti modela u smislu proizvodnje električne energije, uz očuvanje konzistentnosti metodologije.

Mesečna analiza greške u energetskom domenu prikazana je na slici 5.18, gde su pored vrednosti $nRMSE$ prikazani i brojevi raspoloživih uzoraka po mesecima. Ovakav



Slika 5.17: Mesečni $nRMSE$ u GHI domenu (test 2022) za M1-A2 ($L = 1$): ANN, XGBoost, persistence i scaled-persistence; desna osa prikazuje GHI_{meas} .

prikaz omogućava istovremenu procenu sezonske varijabilnosti performansi i pouzdanosti evaluacije.

Rezultati pokazuju da se obrasci uočeni u GHI domenu u velikoj meri prenose i na energetski domen. Najniže vrednosti $nRMSE$ ostvaruju se tokom prolećno-letnjeg perioda (maj–jul), dok se najveće greške javljaju u zimskim mesecima (novembar–februar), što je posledica povećane varijabilnosti atmosferskih uslova i izraženijeg uticaja difuzne komponente zračenja.


Modeli zasnovani na učenju (ANN(PR) i XGBoost(PR)) zadržavaju konzistentnu prednost u odnosu na referentne pristupe kroz sve mesece. ANN(PR) ostvaruje blago niže vrednosti $nRMSE$ u većini perioda, dok XGBoost(PR) pokazuje vrlo slične performanse sa minimalnim odstupanjima. Nasuprot tome, persistence(PR) model karakterišu značajno veće greške i izražena sezonska varijabilnost, sa maksimumima tokom zimskih meseci. Skalirana persistence(PR) metoda smanjuje sistematsku grešku osnovnog persistence modela, ali i dalje ne dostiže nivo tačnosti modela zasnovanih na učenju.

Važno je istaći da transformacija iz GHI u energetski domen dodatno amplifikuje uticaj grešaka u proceni zračenja, budući da se one propagiraju kroz PR model. Uprkos tome, relativni odnosi između modela ostaju očuvani, što potvrđuje robusnost predloženog pristupa i njegovu primenljivost u realnim energetskim analizama.

5.3.4.9 Analiza reprezentativnih dana

Radi kvalitativne procene dinamičkog ponašanja modela, prikazani su primeri reprezentativnih vedrih dana (slika 5.19) i dana sa izraženom promenljivošću oblačnosti (slika 5.20). Ovakav pristup omogućava detaljan uvid u sposobnost modela da reprodukuje različite režime varijacije GHI signala, koji su ključni za razumevanje strukture ukupne greške.

Kod vedrih dana (slika 5.19) uočava se vrlo dobro slaganje između merenih i predvi-




Slika 5.18: Mesečne vrednosti $nRMSE$ u PR-baziranom energetsom domenu (merena PV energija, test 2022). Prikazana je i raspodela broja uzoraka po mesecima (N).

denih vrednosti GHI. Model M1–A2 uspešno reprodukuje glatku, približno sinusoidalnu dnevnu trajektoriju zračenja, sa minimalnim odstupanjima u oblasti maksimalnih vrednosti oko podneva. Ovakvo ponašanje ukazuje na dobru sposobnost modela da aproksimira determinističku komponentu sunčevog zračenja u stabilnim atmosferskim uslovima, pri čemu je uticaj slučajnih fluktuacija minimalan.


Nasuprot tome, u danima sa izraženom promenljivošću oblačnosti (slika 5.20) dolazi do značajno složenije dinamike GHI signala, karakterisane brzim i naglim promenama intenziteta zračenja. U ovim uslovima model i dalje uspeva da prati opšti trend promene, ali su uočljiva odstupanja u trenucima naglih padova i skokova zračenja, koji su posledica prolazne oblačnosti. Ove diskrepancije ukazuju na ograničenja modela u hvatanju visokofrekventnih komponenti signala, koje su inherentno stohastičke prirode i teško predvidive na osnovu dostupnih ulaznih promenljivih.

Važno je istaći da su upravo ovakvi promenljivi režimi dominantni izvor ukupne greške, što je u skladu sa prethodno analiziranim sezonskim rezultatima. Uprkos tome, model M1–A2 zadržava stabilno ponašanje i ne pokazuje sistematska odstupanja, već su greške lokalizovane u vremenskim intervalima sa izraženom meteorološkom neizvesnošću.

Ova analiza potvrđuje da uvođenje minimalne vremenske memorije ($L = 1$) omogućava modelu da bolje prati kratkoročnu dinamiku zračenja, ali i da su preostale greške pre svega posledica inherentne nepredvidivosti atmosferskih procesa, a ne nedostatka modela. Rezultati prikazani u Tabeli 5.9 ukazuju na izraženu zavisnost performansi modela od režima neba. U uslovima vedrih dana svi modeli ostvaruju znatno niže vrednosti greške, pri čemu ANN i XGBoost modeli postižu $nRMSE$ ispod 4%, dok skalirana persistence metoda dostiže i ispod 3%. Nasuprot tome, u režimu promenljive oblačnosti dolazi do značajnog pogoršanja performansi, gde $nRMSE$ za ANN i XGBoost raste na oko 23%, dok



Slika 5.19: Primer dana sa izraženom promenljivošću oblačnosti (test 2022): poređenje merenog i predviđenog GHI za model M1-A2 ($L = 1$).



Slika 5.20: Primer dana sa izraženom promenljivošću oblačnosti (test 2022): struktura greške modela M1-A2 ($L = 1$).

persistence model dostiže gotovo 39%.

Ova razlika dodatno je kvantifikovana u Tabeli 5.10, gde se uočava porast greške od približno 20 procentnih poena za ANN i XGBoost modele. Time se jasno potvrđuje da su dani sa izraženom promenljivošću oblačnosti dominantan izvor ukupne greške, dok u stabilnim atmosferskim uslovima modeli mogu veoma precizno reprodukovati dnevni tok globalnog horizontalnog zračenja.

Tabela 5.9: Uporedne karakteristike modela u GHI domenu za vedre i promenljive/oblačne dane (test skup 2022).

Režim	Model	N	MAE	RMSE	nRMSE [%]	MBE	nMBE [%]	R^2
Vedri	ANN	104	12.12	18.78	3.42	-3.07	-0.56	0.995
	XGBoost	104	12.76	20.09	3.65	-7.24	-1.32	0.994
	Persistence	104	118.41	132.71	24.13	-4.38	-0.80	0.758
	Scaled persistence	104	2.63	12.95	2.35	1.33	0.24	0.998
Promenljivi	ANN	3540	55.83	90.35	23.29	7.66	1.98	0.893
	XGBoost	3540	56.92	92.48	23.84	7.52	1.94	0.888
	Persistence	3540	119.16	150.85	38.89	0.11	0.03	0.702
	Scaled persistence	3540	56.37	106.87	27.55	1.83	0.47	0.850


Slika 5.21 vizuelno ilustruje prethodno kvantifikovane razlike u performansama modela između vedrih i promenljivih dana. Jasno se uočava stabilno ponašanje ANN i XGBoost

Tabela 5.10: Promena nRMSE u zavisnosti od režima neba (test 2022).

Model	nRMSE (vedri) [%]	nRMSE (promenljivi) [%]	Δ [%]
ANN	3.42	23.29	19.88
XGBoost	3.65	23.84	20.19
Persistence	24.13	38.89	14.76
Scaled persistence	2.35	27.55	25.20

modela u oba režima, uz relativno mali međusobni jaz, dok persistence model pokazuje izrazitu degradaciju tačnosti u uslovima promenljive oblačnosti. Skalirana persistence metoda ostvaruje najnižu grešku u vedrim uslovima, ali pokazuje značajan pad performansi u složenijim atmosferskim režimima.

Ovakvo ponašanje ukazuje da je dominantan izvor greške povezan sa kratkoročnim fluktuacijama GHI signala usled prolazne oblačnosti, što predstavlja ključni izazov u modelovanju solarnih resursa i motiviše dalje unapređenje modela u pravcu boljeg hvatanja vremenske dinamike. Ovi rezultati ukazuju da je potencijal za dalje unapređenje modela


**Slika 5.21:** Uporedni prikaz vrednosti nRMSE u GHI domenu za različite modele u zavisnosti od režima neba (test skup 2022).

pre svega vezan za bolje hvatanje kratkoročnih fluktuacija GHI signala, što predstavlja otvoren izazov u kontekstu visoko-promenljivih atmosferskih uslova.

Dodatni uvid u dinamičko ponašanje modela tokom više uzastopnih dana prikazan je na slici 5.22. Vremenski niz omogućava direktno poređenje merenog GHI sa predikcijama ANN i XGBoost modela, kao i sa referentnim persistence i skaliranom persistence metodom. Uočava se da data-driven modeli znatno bolje reprodukuju dnevni profil solar-

nog zračenja, uključujući i vršne vrednosti, u odnosu na persistence pristupe. Skalirana persistence metoda delimično ublažava sistematsko potcenjivanje i fazno kašnjenje karakteristično za osnovni persistence model, ali i dalje pokazuje izraženiju inerciju u uslovima brzih promena oblačnosti.

Višednevni prikaz potvrđuje stabilno ponašanje ANN modela u tipičnim režimima zračenja, uz istovremeno jasno isticanje perioda u kojima dominiraju tranzijentni atmosferski uslovi i dolazi do povećanja greške kod svih modela.




Slika 5.22: Višednevni prikaz GHI (test 2022, $H = 1$ h, $L = 1$): Measured vs ANN, XGBoost, persistence i scaled-persistence.

5.3.4.10 Poređenje sa M1–A1b (GHI i energetski domen)

Direktno poređenje optimizovanog statičkog modela M1–A1b i optimalne M1–A2 konfiguracije ($L = 1$) dato je u tabeli 5.11. Rezultati pokazuju da uvođenje minimalne vremenske memorije ($L = 1$) dovodi do konzistentnog poboljšanja performansi u oba evaluaciona domena. U GHI domenu ostvareno je smanjenje $nRMSE$ sa 22.936% na 22.567% ($\Delta = -0.369$ p.p.), dok je u energetskom domenu smanjenje sa približno 25.3% na 24.727% ($\Delta \approx -0.57$ p.p.). Ovakav rezultat potvrđuje da informacija o prethodnom stanju zračenja ima realan fizički značaj i da se njeno uključivanje pozitivno reflektuje i nakon propagacije kroz PR-bazirani energetski model. Poboljšanje u energetskoj domeni je čak izraženije nego u GHI domenu, što ukazuje na stabilizaciju predikcione varijanse pri transformaciji zračenja u energiju, pri čemu je dobitak u energetskom domenu metodološki posebno značajan jer potvrđuje fizičku konzistentnost modela. Slika 5.23 daje sažet pregled dva uzastopna koraka unapređenja modela M1. U prvom koraku, optimizacija arhitekture i prelazak sa konfiguracije M1–A1 na M1–A1b doveli su do statistički značajnog, ali relativno umerenog poboljšanja performansi u GHI domenu, uz istovremeno smanjenje varijabilnosti između ponavljanja treniranja. U drugom koraku, uvođenje minimalne vremenske memorije kod modela M1–A2 ($L = 1$) omogućilo je dodatno smanjenje greške, i to kako

Tabela 5.11: Poređenje M1-A1b i optimalnog M1-A2 modela (GHI i PR-bazirana energetska domena, test skup 2022).

Model	GHI domen		Energetski domen	
	RMSE [W/m^2]	nRMSE [%]	RMSE [Wh]	nRMSE [%]
M1-A1b	89.904	22.936	80.9	25.3
M1-A2 ($L = 1$)	88.572	22.567	78.668	24.727

**Slika 5.23:** Vizuelni pregled unapređenja modela M1 kroz dve uzastopne faze.

u GHI, tako i u energetskom domenu. Posebno je značajno što je poboljšanje izraženije u energetskom domenu, što potvrđuje da uključivanje informacije o prethodnom stanju zračenja ne doprinosi samo boljoj aproksimaciji GHI signala, već i stabilnijoj propagaciji predikcije ka izlaznoj energetskoj veličini.

Rezime modela M1 tehnologije

Analiza modela iz grupe M1 pokazuje da su karakteristike ANN arhitektura za predviđanje GHI dominantno zavise od informativnosti ulaznih parametara, a ne od povećanja dubine ili kompleksnosti neuronske mreže. Optimizovana statička konfiguracija M1-A1b, zasnovana na jednom skrivenom sloju sa 20 neurona i Bayesovoj regularizaciji, ostvaruje stabilne i reproduktivne rezultate, pri čemu dodatno povećanje dubine ne donosi značajna poboljšanja. Time je potvrđeno da je dostignut limit statičke regresione formulacije.

Uvođenje minimalne vremenske memorije u modelu M1-A2 ($L = 1$) omogućilo je dodatno smanjenje greške u GHI domenu, uz konzistentno poboljšanje i u PR-baziranoj energetskoj evaluaciji. Rezultati pokazuju da je dominantna kratkoročna informacija o dinamici zračenja sadržana neposredno u prethodnom satu. Povećanje dužine lag-prozora ne doprinosi daljem smanjenju greške i može dovesti do blagog pogoršanja generalizacionih

karakteristika. Na taj način potvrđena je metodološka opravdanost prelaska sa statičke na kvazi-dinamičku formulaciju problema. Izbor konačnog skupa ulaznih promenljivih izvršen je tako da se očuva parsimonija modela, odnosno da se zadrži minimalan broj varijabli koje pružaju dovoljnu prediktivnu informaciju bez uvođenja nepotrebne kompleksnosti.

5.4 Model M2: direktno predviđanje karakteristika PV sistema

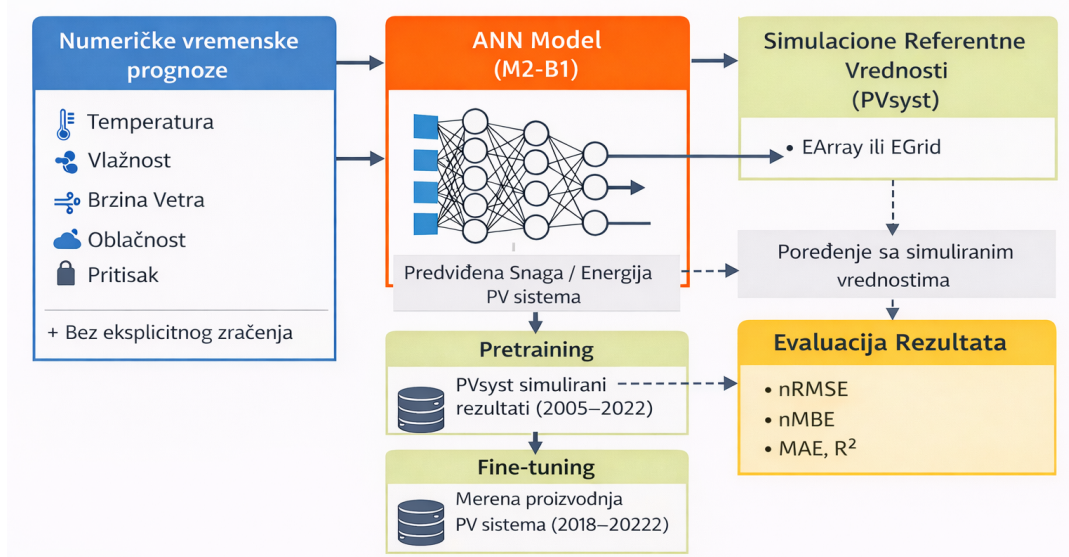
Model M2 predstavlja alternativni pristup predviđanju proizvodnje PV sistema zasnovan na direktnom preslikavanju prognostički dostupnih meteoroloških veličina i proizvedene izlazne energije PV sistema. Za razliku od modela iz grupe M1, kod kojih se najpre predviđa GHI, a zatim se energetski prinos sistema procenjuje primenom fizičkog modela PV sistema, model M2 realizuje jedinstveni *data-driven* pristup u kojem se odnos između meteoroloških podataka i izlazne proizvodnje PV sistema uči direktno uz pomoć veštačke neuronske mreže.

Osnovna ideja M2 pristupa jeste aproksimacija ponašanja referentnog fizičkog simulacionog modela PV sistema realizovanog u softverskom alatu *PVsyst*. Kao što je prikazano na slici 5.24, ANN model (M2–B1) koristi meteorološke ulaze iz numeričkih vremenskih prognoza (temperatura, vlažnost, brzina vetra, oblačnost i pritisak), bez eksplicitnog uvođenja zračenja, čime se simulira realan scenario operativne prognoze. U fazi *pretraining*-a, neuronska mreža uči funkcionalnu zavisnost između meteoroloških ulaza i izlazne snage/energije PV sistema generisane u *PVsyst*-u, pri čemu su simulacije realizovane korišćenjem *Meteonorm* baze podataka za period 2005–2022. Na ovaj način ANN aproksimira ponašanje detaljnog fizičkog modela, uz značajno smanjenje računarske složenosti.

Nakon toga, u fazi finog podešavanja, model se dodatno prilagođava korišćenjem merenih podataka sa eksperimentalnog PV sistema snage 1 kW za period 2018–2022, čime se uvodi korekcija na realne radne uslove i smanjuje razlika između simulacionog i stvarnog sistema. Evaluacija modela vrši se kroz poređenje sa referentnim *PVsyst* vrednostima (npr. E_{Array} ili E_{Grid}), kao i sa merenim podacima, primenom standardnih metrika tačnosti ($nRMSE$, $nMBE$, MAE i R^2). Ovakva dvostepena strategija učenja omogućava kombinovanje prednosti fizički zasnovanih i *data-driven* pristupa, čime se obezbeđuje visok nivo tačnosti i robusnosti modela u različitim meteorološkim uslovima.

5.4.1 M2 metodološki okvir

Model M2 predstavlja *data-driven* pristup za direktnu procenu izlazne energije fotonaponskog (PV) sistema na osnovu meteoroloških ulaza, bez eksplicitnog modelovanja međukoraka (npr. zračenje \rightarrow DC \rightarrow AC). Osnovna ideja zasniva se na aproksimaciji referentnog fizičkog modela realizovanog u softverskom alatu *PVsyst*, uz naknadnu adaptaciju



Slika 5.24: Konceptualni pipeline modela M2–B1.

na realne merene podatke.

Formalna definicija modela

Model se može zapisati kao nelinearna funkcija:

$$\hat{y}(t) = f_{\theta}(\mathbf{z}(t)), \quad (5.41)$$

gde $\mathbf{z}(t) \in \mathbb{R}^d$ predstavlja ulazni vektor meteoroloških promenljivih, $\hat{y}(t)$ procenjenu izlaznu veličinu sistema, a θ skup parametara neuronske mreže. Multilayer perceptron (MLP) koristi se kao univerzalni aproksimator ove funkcije [57].

Arhitektura modela

Model M2 realizovan je kao višeslojna perceptronska neuronska mreža (MLP) sa dve skrivene slojne strukture definisane konfiguracijom $\mathbf{h} = [30, 15]$. Mreža aproksimira nelinearnu funkcionalnu zavisnost između meteoroloških podataka i izlazne snage odnosno energije PV sistema, i može se zapisati u opštem obliku:

$$\hat{y}(t) = f_{\theta}(\mathbf{z}(t)), \quad (5.42)$$

gde $\mathbf{z}(t)$ predstavlja ulazni vektor, $\hat{y}(t)$ izlaz modela, a θ skup parametara neuronske mreže.

Arhitektura mreže sastoji se od:

- ulaznog sloja dimenzije $d = 5$ (meteorološki podaci),
- dva skrivena sloja sa 30 i 15 neurona,
- izlaznog sloja sa linearnom aktivacionom funkcijom.

Za treniranje mreže koristi se algoritam Bayesian regularization (`trainbr`), uz funkciju

greške definisanu kao srednja kvadratna greška (MSE). Maksimalan broj epoha postavljen je na 500, uz eksplicitno definisanu podelu na trening i validacioni skup (hold-out pristup), realizovanu korišćenjem `divideind` strategije u MATLAB okruženju [98].

Ulazni podaci se prethodno standardizuju primenom z -transformacije (na osnovu trening skupa), čime se obezbeđuje numerička stabilnost i brža konvergencija tokom učenja. Specifičnost M2 pristupa ogleda se u dvostepenoj strategiji treniranja:

- **Pretraining:** mreža se inicijalno trenira na simuliranim podacima dobijenim iz *PVsyst* modela (period 2005–2021),
- **Fino podešavanje** (engl. *Fine-tuning*): prethodno naučeni parametri se dodatno prilagođavaju korišćenjem merenih podataka (2018–2021), pri čemu se zadržava ista arhitektura i inicijalne težine.

U fazi finog podešavanja koristi se smanjen broj epoha (tipično ≈ 150), kako bi se izbeglo prenaučavanje na ograničenom skupu merenih podataka, dok se standardizacija ulaza preuzima iz faze predtreniranja radi očuvanja konzistentnosti ulaznog prostora. Ovakva konfiguracija omogućava efikasno balansiranje između složenosti modela i njegove generalizacione sposobnosti, uz očuvanje parsimonije i stabilnosti treninga.

Model se može interpretirati kao oblik transfer learning pristupa [99], gde se znanje stečeno na simulacionim podacima prenosi i adaptira na realne uslove rada sistema. Detaljna definicija ulaznog prostora data je u nastavku.

Ulazni prostor ANN modela

Ulazni vektor modela M2 definisan je isključivo skupom meteoroloških veličina koje su standardno dostupne iz numeričkih vremenskih prognoza, u obliku:

$$\mathbf{z}(t) = [T_{\text{air}}(t), \text{RH}(t), v_{\text{wind}}(t), C(t), p(t)], \quad (5.43)$$

gde T_{air} označava temperaturu vazduha, RH relativnu vlažnost, v_{wind} brzinu vetra, C indikator oblačnosti, a p atmosferski pritisak. Na ovaj način formiran ulazni prostor odražava realne operativne uslove, u kojima su upravo ove veličine dostupne unapred kroz meteorološke prognoze.

Za razliku od pristupa zasnovanih na iradijacionim veličinama, u ovoj konfiguraciji se ne koriste eksplicitni podaci o solarnom zračenju (GHI, DNI, DHI), niti se uvode vremenski lagovi. Time model predstavlja direktan *data-driven* pristup proceni izlazne snage ili energije PV sistema, pri čemu neuronska mreža implicitno uči relaciju između meteoroloških uslova i efektivnog solarnog ulaza.

Ovakva formulacija omogućava veću robusnost i praktičnu primenljivost modela u realnim sistemima, gde visoko-kvalitetna merenja solarnog zračenja često nisu dostupna ili su opterećena dodatnim greškama. Istovremeno, povećava se zahtevnost modelovanja, jer se informacija o solarnom zračenju mora inferirati posredno iz dostupnih meteoroloških

promenljivih. Potencijalna proširenja ulaznog prostora, poput uključivanja satelitskih podataka ili polu-fizičkih indikatora (npr. clear-sky modela), nisu bila predmet istraživanja u okviru ove disertacije, kako bi se izolovao efekat osnovnog meteorološkog skupa ulaza.

Izlaz ANN modela

Izlaz modela M2 predstavlja procenu izlazne snage ili proizvedene energije PV sistema u diskretnom vremenskom koraku t , i definisan je kao:

$$\hat{y}(t) = f_{\text{ANN}}(\mathbf{z}(t)), \quad (5.44)$$

gde $\hat{y}(t)$ označava procenjenju izlaznu veličinu sistema, dok $f_{\text{ANN}}(\cdot)$ predstavlja nelinearnu mapu realizovanu višeslojnom perceptronskom neuronskom mrežom.

U zavisnosti od konfiguracije modela i faze treniranja, izlaz može odgovarati:

- *E_Array* – DC energiji generisanoj na nivou PV polja (PVsyst simulacija),
- *E_Grid* – AC energiji isporučenoj mreži (mereni ili simulirani podaci).

Tokom faze predtreniranja, model uči aproksimaciju izlaza fizičkog PVsyst modela, dok se u fazi finog podešavanja izlaz prilagođava realnim merenim vrednostima, čime se postiže bolja reprezentacija stvarnog ponašanja sistema.

S obzirom na to da se model zasniva isključivo na meteorološkim ulazima, funkcija $f_{\text{ANN}}(\cdot)$ implicitno enkodira složene fizičke procese konverzije sunčevog zračenja u električnu energiju, uključujući efekte temperature, oblačnosti i gubitaka u sistemu.

Na ovaj način, M2 model omogućava direktnu procenu energetskog izlaza bez eksplicitnog modelovanja međukoraka (npr. GHI \rightarrow DC \rightarrow AC), čime se postiže pojednostavljenje modela uz očuvanje visoke tačnosti.

U ovom radu izlaz je definisan na satnom nivou ($\Delta t = 1$ h).

Strategija treniranja

Treniranje modela realizovano je u dve faze:

- **Predtreniranje:** model se trenira na simuliranim PVsyst podacima (2005–2021),
- **Fino podešavanje:** model se dodatno prilagođava merenim podacima (2018–2021), uz zadržavanje inicijalnih težina.

Ovakav pristup može se interpretirati kao oblik transfer learning-a, gde se znanje stečeno na simulacionim podacima prenosi i adaptira na realne uslove rada sistema [99].

Predloženi M2 pristup omogućava direktnu procenu energetskog izlaza PV sistema bez eksplicitnog modelovanja međukoraka, čime se značajno smanjuje računaska složenost i povećava operativna primenljivost. Istovremeno, model implicitno enkodira složene fizičke procese konverzije sunčevog zračenja u električnu energiju, što omogućava visoku tačnost uz očuvanje parsimonije modela.

Referentni i mereni izlazni podaci

U okviru modela M2 koriste se dve komplementarne kategorije izlaznih podataka, koje imaju jasno razdvojene metodološke uloge u procesu razvoja i validacije modela.

Prvu kategoriju čine referentni izlazi dobijeni simulacijom eksperimentalnog PV sistema snage 1 kW u softverskom alatu *PVsyst*. Ovaj skup podataka (*PVsyst_NewData_2005–2022*) obuhvata satne vrednosti proizvedene energije sistema (*E_Array* i/ili *E_Grid*) za period 2005–2022 i koristi se za inicijalnu obuku (*pretraining*) modela. U ovoj fazi neuronska mreža uči funkcionalnu zavisnost između meteoroloških ulaza i izlaza referentnog fizičkog modela.

Drugu kategoriju čine realni mereni podaci proizvodnje istog eksperimentalnog PV sistema, dostupni za period 2018–2022. Ovi podaci koriste se za dodatno prilagođavanje modela i njegovu konačnu evaluaciju u realnim operativnim uslovima.

Na taj način formiran je dvostepeni pristup razvoju modela. U prvoj fazi obezbeđuje se stabilno učenje na dugom i homogenom simulacionom skupu, dok se u drugoj fazi model adaptira na realne uslove rada sistema. Time se kombinuju prednosti fizičkog simulacionog modelovanja i empirijskih merenja, uz smanjenje uticaja ograničene dostupnosti realnih podataka.

5.4.2 Matematička formulacija dvofaznog učenja

Model M2 formulisan je kao nelinearna regresija koja preslikava meteorološke ulaze u izlaznu energiju (ili snagu) PV sistema. Neka je $\mathbf{z}(t) \in \mathbb{R}^d$ ulazni vektor, a $y(t) \in \mathbb{R}$ odgovarajuća izlazna veličina. ANN realizuje preslikavanje

$$\hat{y}(t) = f_{\theta}(\mathbf{z}(t)), \quad (5.45)$$

gde θ označava skup parametara modela.

Predtreniranje na PVsyst referentnom skupu.

Za period 2005–2022 definisan je skup simulacionih uzoraka

$$\mathcal{D}_{\text{sim}} = \{(\mathbf{z}(t), y_{\text{sim}}(t))\}_{t=1}^{N_{\text{sim}}}. \quad (5.46)$$

Parametri modela u fazi predtreniranja određuju se minimizacijom srednje kvadratne greške

$$\theta_0 = \arg \min_{\theta} \frac{1}{N_{\text{sim}}} \sum_{t=1}^{N_{\text{sim}}} (f_{\theta}(\mathbf{z}(t)) - y_{\text{sim}}(t))^2. \quad (5.47)$$

Fino podešavanje na merenom skupu.

Za period 2018–2022 definisan je skup merenih uzoraka

$$\mathcal{D}_{\text{meas}} = \{(\mathbf{z}(t), y_{\text{meas}}(t))\}_{t=1}^{N_{\text{meas}}}. \quad (5.48)$$

Polazeći od inicijalnih parametara θ_0 , fino podešavanje se sprovodi minimizacijom greške u odnosu na merene izlaze

$$\theta^* = \arg \min_{\theta} \frac{1}{N_{\text{meas}}} \sum_{t=1}^{N_{\text{meas}}} (f_{\theta}(\mathbf{z}(t)) - y_{\text{meas}}(t))^2, \quad \theta|_{\text{init}} = \theta_0. \quad (5.49)$$

Regularizacija i očuvanje naučene strukture.

Kako bi se ograničilo prenaučavanje na kraći mereni skup i očuvala struktura naučena tokom predtreniranja, optimizacioni problem može se zapisati i u regularizovanom obliku

$$\theta^* = \arg \min_{\theta} \left[\frac{1}{N_{\text{meas}}} \sum_{t=1}^{N_{\text{meas}}} (f_{\theta}(\mathbf{z}(t)) - y_{\text{meas}}(t))^2 + \lambda \|\theta - \theta_0\|_2^2 \right]. \quad (5.50)$$

Interpretacija.

Faza predtreniranja omogućava modelu da nauči dominantne fizičke zakonitosti sistema implicitno enkodirane u PVsyst simulacijama, dok faza finog podešavanja vrši korekciju sistematskih odstupanja i adaptaciju na realne operative uslove. Dobijeni model sa parametrima θ^* predstavlja kompromis između robusnosti stečene učenjem na dugom simulacionom nizu i tačnosti u reprodukciji realnih merenja.

Na ovaj način M2 pristup se može interpretirati kao oblik transfer learning-a u kome se znanje stečeno na simulacionim podacima prenosi i prilagođava realnim sistemima, čime se postiže poboljšana generalizacija i praktična primenljivost modela.

5.4.3 Optimizacija arhitekture MLP M2 modela

U cilju izbora optimalne konfiguracije MLP ANN mreže za model M2 sprovedena je sistematska optimizacija arhitekture i algoritma treniranja. Postupak optimizacije realizovan je nad skupovima za treniranje i validaciju, dok test skup nije korišćen u fazi izbora arhitekture, čime je obezbeđena korektna procena generalizacionih sposobnosti modela.

Optimizacija je obuhvatila skup jednoslojnih i višeslojnih MLP konfiguracija, pri čemu su razmatrane arhitekture sa 10, 20, 30 i 40 neurona u jednom skrivenom sloju, kao i odabrane dvoslojne konfiguracije [30 15], [25 15] i [30 10]. Za svaku arhitekturu testirani su algoritmi treniranja `trainscg`, `trainlm` i `trainbr`, uz po dva nezavisna ponavljanja treniranja radi smanjenja uticaja slučajne inicijalizacije težinskih koeficijenata. Performanse svake konfiguracije ocenjene su na validacionom skupu korišćenjem standardnih


metrika greške: MAE, RMSE, MBE, kao i normalizovane metrike $nRMSE$. Kao osnovni kriterijum za rangiranje kandidata usvojena je validaciona vrednost metrike $nRMSE$, dok su konačne vrednosti dobijene usrednjavanjem rezultata kroz dva ponavljanja.

Rezultati pokazuju da Bayesova regularizacija (`trainbr`) dosledno ostvaruje bolje performanse od algoritama `trainlm` i `trainscg`. Najbolje rezultate postigla je arhitektura sa dva skrivena sloja [30 15] trenirana algoritmom `trainbr`, sa prosečnim vrednostima

$$MAE = 0.0122 \text{ kW}, \quad RMSE = 0.0158 \text{ kW}, \quad MBE = 0.0001 \text{ kW}, \quad nRMSE = 5.02\%.$$

Dobijena vrednost bias komponente je praktično zanemarljiva, što ukazuje da izabrana konfiguracija ne pokazuje sistematsku tendenciju ni ka potcenjivanju ni ka precenjivanju procenjene izlayne snage/proizvedene energije PV sistema.

Dobijeni rezultati optimizacije prikazani su na slici 5.25, dok su najbolje rangirane konfiguracije i njihove metrike date u Tabeli 5.12. Detaljni rezultati svih testiranih konfiguracija i pojedinačnih ponavljanja prikazani su u Prilogu L.2.



Slika 5.25: Uporedni prikaz srednjih validacionih vrednosti $nRMSE$ za razmatrane konfiguracije MLP arhitekture i algoritme treniranja u okviru optimizacije modela M2.

Tabela 5.12: Najbolje rangirane konfiguracije tokom optimizacije M2 modela na osnovu srednje validacione vrednosti $nRMSE$.

Rang	Konfiguracija	MAE [kW]	RMSE [kW]	MBE [kW]	$nRMSE$ [%]
1	trainbr + [30 15]	0.0122	0.0158	0.0001	5.02
2	trainbr + [25 15]	0.0124	0.0161	0.0001	5.09
3	trainbr + [30 10]	0.0126	0.0162	0.0001	5.14
4	trainbr + 30	0.0128	0.0164	-0.0001	5.23
5	trainbr + 40	0.0129	0.0165	-0.0002	5.26

Analiza rezultata optimizacije.

Rezultati optimizacije pokazuju da su sve najbolje rangirane konfiguracije dobijene primenom algoritma `trainbr`, što potvrđuje da Bayesova regularizacija predstavlja najpogodniji pristup za obučavanje MLP modela u okviru razmatranog problema. U poređenju sa algoritmima `trainlm` i `trainscg`, `trainbr` obezbeđuje niže vrednosti validacionih grešaka i stabilnije ponašanje kroz ponovljena treniranja, što ukazuje na bolju kontrolu složenosti modela i smanjen rizik od preprilagođavanja.

Može se uočiti da prelazak sa jednoslojnih na dvoslojne arhitekture donosi dodatno, iako numerički umereno, poboljšanje tačnosti. Najbolja dvoslojna konfiguracija [30 15] ostvaruje niži $nRMSE$ od svih jednoslojnih mreža, što ukazuje da dodatni skriveni sloj omogućava efikasnije modelovanje nelinearnih zavisnosti između meteoroloških ulaza i izlazne snage PV sistema. Istovremeno, razlike između nekoliko vodećih `trainbr` konfiguracija ostaju relativno male, što potvrđuje da je model dovoljno robustan i da performanse nisu preterano osetljive na umerene izmene arhitekture.

Na osnovu sprovedene optimizacije kao konačna konfiguracija modela M2 usvojena je arhitektura [30 15] trenirana algoritmom `trainbr`. Ova konfiguracija obezbeđuje najpovoljniji kompromis između tačnosti predikcije, stabilnosti kroz ponovljena treniranja i složenosti modela, pa je kao takva korišćena u daljoj fazi modelovanja i završnoj evaluaciji.

5.4.4 Rezultati predtreniranja na PVsyst skupu

U prvoj fazi razvoja modela M2 sprovedena je obuka neuronske mreže na simulacionom skupu podataka generisanom u softverskom alatu *PVsyst*. Ovaj skup obuhvata satne vrednosti meteoroloških ulaza i odgovarajuće izlaze PV sistema za period 2005–2022, čime se dobija veliki broj uzoraka pogodan za stabilno treniranje neuronske mreže.

Cilj ove faze nije direktna reprodukcija realne proizvodnje sistema, već aproksimacija referentnog fizičkog modela PV sistema. Na taj način neuronska mreža uči osnovnu funkcionalnu zavisnost između meteoroloških ulaza i izlaza PV sistema, što predstavlja početnu tačku za kasniju fazu prilagođavanja modela na osnovu realnih merenja.


Performanse modela u ovoj fazi evaluirane su nad test skupom za 2022. godinu, pri čemu su dobijene sledeće metrike:

$$MAE = 0.0177 \text{ kW} \quad RMSE = 0.0371 \text{ kW} \quad MBE = -0.0029 \text{ kW}$$

Relativno mala vrednost bias-a (MBE) ukazuje na odsustvo izraženog sistematskog odstupanja između predikcije neuronske mreže i referentnog *PVsyst* modela.

Konvergencija procesa učenja

Tok procesa treniranja prikazan je na slici 5.26, gde je data evolucija funkcije greške u logaritamskoj skali ($\log MSE$) u zavisnosti od iteracija algoritma učenja tokom predtreniranja.



Slika 5.26: Kriva učenja tokom predtreniranja modela M2 na PVsyst simulacionom skupu podataka.

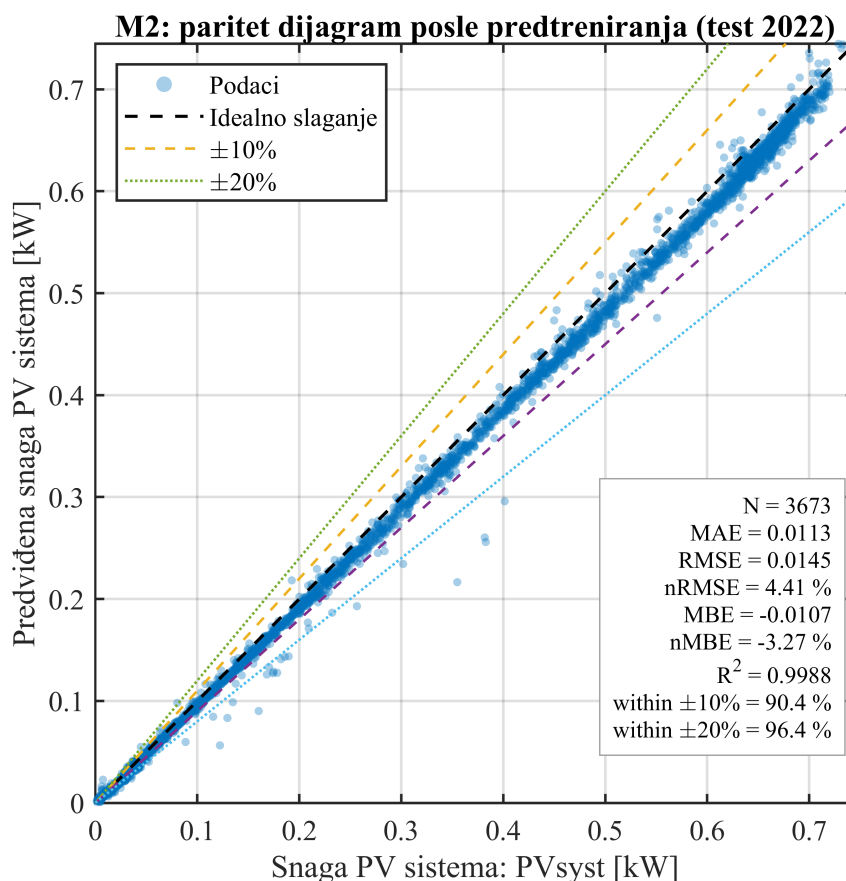
Sa slike se može uočiti monotono opadajući trend funkcije greške, što ukazuje na stabilnu i efikasnu konvergenciju optimizacionog algoritma. U početnim fazama treniranja prisutan je izraženiji pad vrednosti greške, što je karakteristično za inicijalno prilagođavanje težinskih koeficijenata modela, dok se u kasnijim iteracijama uočava postepeno usporavanje konvergencije kako se ANN model približava minimumu funkcije cilja. Posebno je značajno da ne dolazi do pojave izraženih oscilacija ili divergencije, što potvrđuje numeričku stabilnost izabranog algoritma treniranja i adekvatnost podešenih hiperparametara (stopa učenja⁵, broj epoha i regularizacija). Ovakvo ponašanje ukazuje da model ne ulazi u režim prekomernog prilagođavanja (*overfitting*) tokom predtreniranja, već uspešno generalizuje obrasce prisutne u PVsyst simulacionom skupu podataka.

Takođe, odsustvo naglih skokova u vrednosti greške sugeriše da je optimizacioni proces vođen ka glatkom minimumu bez značajnog uticaja lokalnih minimuma ili nestabilnih gradijenata. Stabilna konvergencija u ovoj fazi je od ključnog značaja, jer obezbeđuje kvalitetnu inicijalizaciju modela za kasniju fazu finog podešavanja na realnim merenim podacima. Na osnovu prikazane krive učenja može se zaključiti da je predtreniranje uspešno izvršeno, čime su obezbeđeni stabilni i reprezentativni početni ANN parametri za dalju optimizaciju modela M2.

Paritet: PVsyst model vs. ANN aproksimacija

Paritet dijagram između referentnih izlaza PVsyst modela i ANN predviđanja je prikazan na slici 5.27. Ovaj tip dijagrama predstavlja standardni alat za vizuelnu procenu kvaliteta aproksimacije, jer omogućava direktno poređenje predikovanih i referentnih vrednosti u celom opsegu posmatranih podataka. Raspodela tačaka je dominantno koncentrisana oko

⁵Stopa učenja (*learning rate*, najčešće označena sa η) je hiperparametar koji određuje koliko veliki korak model pravi pri ažuriranju težina tokom treniranja.



Slika 5.27: Paritet dijagram između referentnog izlaza PVsyst modela i predikcije ANN modela nakon predtreniranja, za test skup iz 2022. godine.

linije idealnog slaganja ($y = \hat{y}$), što ukazuje na visoku sposobnost neuronske mreže da aproksimira nelinearno ponašanje referentnog fizičkog modela. Mala disperzija tačaka oko dijagonale sugeriše nizak nivo slučajne greške, dok odsustvo sistematskog odstupanja uočenog kroz nagib raspodele potvrđuje da model ne pokazuje izraženu pristrasnost (*bias*).


Može se uočiti da se odstupanja blago povećavaju u regionima viših vrednosti izlazne snage, što je očekivano s obzirom na povećanu varijabilnost meteoroloških uslova i nelinearne efekte u režimima visokog solarnog zračenja. Ipak, čak i u tim oblastima zadržava se zadovoljavajući nivo slaganja, što potvrđuje robusnost modela. Analiza gustine tačaka ukazuje na to da model posebno dobro aproksimira dominantne radne režime sistema (srednje vrednosti snage), koji imaju najveći uticaj na ukupnu energetska proizvodnju. Ovakvo ponašanje je od posebnog značaja za praktične primene, jer greške u tim regionima najviše utiču na agregirane energetske metrike.

Takođe, prisustvo uskog pojasa tačaka oko linija $\pm 10\%$ i $\pm 20\%$ odstupanja dodatno potvrđuje visoku preciznost modela i njegovu sposobnost da zadrži grešku u prihvatljivim granicama za većinu uzoraka. Na osnovu prikazanog paritet dijagrama može se zaključiti da neuronska mreža, nakon predtreniranja na PVsyst simulacionom skupu podataka, uspešno uči funkcionalnu zavisnost između ulaznih promenljivih i izlazne snage sistema, pri čemu

postiže visok nivo slaganja sa referentnim fizičkim modelom i obezbeđuje pouzdanu osnovu za dalju fazu finog podešavanja na realnim merenjima.

Fizička konzistentnost modela

Na slici 5.28 prikazana je zavisnost izlazne snage PV sistema od GHI za referentni PVsyst model. Ova zavisnost predstavlja jednu od fundamentalnih fizičkih relacija u radu PV sistema, budući da je proizvedena snaga direktno uslovljena intenzitetom upadnog solarnog zračenja. Dobijena raspodela ukazuje na monotono rastuću i približno linearnu



Slika 5.28: Zavisnost izlazne snage PV sistema od globalnog horizontalnog zračenja (GHI) u PVsyst simulacionom skupu.

zavisnost između proizvodnje PV sistema i intenziteta solarnog zračenja, što je u skladu sa osnovnim fizičkim modelima konverzije energije u PV modulima. U idealizovanom slučaju, izlazna snaga sistema može se aproksimirati proporcionalnošću sa efektivnim zračenjem, uz korekcije uslovljene temperaturom modula, gubicima u sistemu i radnim režimom invertera. Odstupanja od linearnog trenda manifestuju se kroz blagu disperziju tačaka i predstavljaju posledicu uticaja sekundarnih faktora, kao što su temperatura ćelija, ugao upada zračenja, spektralne promene i sistemski gubici (omski, konverzioni i efekti senčenja). Ova varijabilnost potvrđuje da PVsyst model verno reprodukuje kompleksnost realnog sistema i generiše podatke sa fizički utemeljenim nelinearnostima.


Sa aspekta treniranja neuronske mreže, ovakva struktura podataka omogućava usvajanje osnovne funkcionalne zavisnosti između ulaznih i izlaznih veličina, čime model ne predstavlja samo statističku aproksimaciju, već implicitno enkodira fizičke zakonitosti sistema. Očuvanje ove konzistentnosti tokom predtreniranja ključno je za postizanje dobre sposobnosti generalizacije, posebno prilikom prenosa modela na realne merene podatke

finog podešavanja. Dodatna validacija modela ostvaruje se kroz kombinovanu analizu sa paritet dijagramom (slika 5.27), koji potvrđuje visok nivo slaganja između predviđenih i referentnih vrednosti u smislu standardnih metrika tačnosti. Saglasnost između statističke preciznosti i fizičke interpretabilnosti ukazuje da model ne pati od prekomernog prilagođavanja, već uspešno usvaja fundamentalne zakonitosti sistema.

Na osnovu prikazane analize može se zaključiti da predtreniranje modela M2 obezbeđuje kvantitativno tačnu i fizički konzistentnu reprezentaciju odnosa između meteoroloških ulaza i izlazne snage, čime se formira pouzdana osnova za dalju optimizaciju i primenu modela.

Sezonska struktura simulacionog skupa

Pored analize pojedinačnih satnih zavisnosti, od posebnog značaja je razmatranje sezonske raspodele proizvodnje energije u simulacionom PVsyst skupu podataka. Na slici 5.29 su prikazane srednje mesečne vrednosti energije dobijene simulacijom za period 2005–2022. godina, čime se obuhvata dugoročna varijabilnost meteoroloških uslova. Prikazana



Slika 5.29: Mesečne vrednosti energije dobijene iz PVsyst simulacionog skupa za period 2005–2022.

raspodela jasno ukazuje na izraženu sezonsku komponentu proizvodnje, sa maksimumima tokom letnjih meseci i minimumima u zimskom periodu. Ovakav obrazac direktna je posledica promena u intenzitetu i trajanju solarnog zračenja, kao i varijacija u visini Sunca i dužini dana tokom godine. Pored toga, sezonske promene temperature dodatno utiču na efikasnost PV modula, doprinoseći ukupnoj varijabilnosti izlazne energije. Značajno je da simulacioni skup obuhvata širok spektar radnih režima, od niskih zimskih vrednosti solarnog zračenja i kratkih dana, do visokih letnjih intenziteta i produženog trajanja osunčanosti. Time se obezbeđuje reprezentativnost podataka u odnosu na realne klimatske uslove posmatrane lokacije, kao i prisustvo različitih kombinacija ulaznih promenljivih koje utiču na rad sistema.

Sa stanovišta treniranja neuronske mreže, ovakva sezonska raznovrsnost ima ključnu ulogu, jer omogućava modelu da u procesu predtreniranja usvoji obrasce ponašanja sistema u različitim klimatskim režimima. Time se smanjuje rizik od pristrasnosti modela ka određenim delovima godine i povećava njegova sposobnost generalizacije kroz vremenske skale. Dodatno, ravnomerna zastupljenost sezonskih obrazaca doprinosi stabilnosti optimizacionog procesa, jer sprečava dominaciju određenih režima u funkciji greške tokom treniranja. Ovo je posebno važno za modele namenjene višehorizontskom predviđanju, gde je neophodno pouzdano modelovati prelaze između sezona i ekstremne uslove.

Na osnovu prikazane analize može se zaključiti da PVsyst simulacioni skup poseduje adekvatnu sezonsku strukturu i varijabilnost, čime obezbeđuje kvalitetnu osnovu za prethodno treniranje modela M2 i formiranje robusne inicijalne aproksimacije koja je primenljiva u širokom spektru meteoroloških uslova.

5.4.5 Rezultati faze finog podešavanja na merenim podacima

Nakon inicijalne obuke neuronske mreže na simulacionom skupu podataka koji je dobio PVsyst simulacijom, sprovedena je dodatna faza prilagođavanja modela na realnim merenim podacima proizvodnje eksperimentalnog PV sistema. Cilj ove faze je da se prevaziđu razlike između simulacionog i stvarnog ponašanja sistema i omogući preciznija reprodukcija izlazne snage u realnim operativnim uslovima.

Fino podešavanje je realizovano nad skupom podataka za period 2018–2022. godine, dok je evaluacija performansi izvršena na nezavisnom test skupu za 2022. godinu. Dobijene vrednosti osnovnih metrika tačnosti iznose:

$$\mathbf{MAE = 0.0106 \text{ kW} \quad RMSE = 0.0139 \text{ kW} \quad MBE = 0.0031 \text{ kW}}$$

Kako bi se dobila realnija procena performansi u režimu aktivne proizvodnje, dodatno je sprovedena evaluacija ograničena na dnevne periode (*daylight* režim). U tom slučaju, normalizovane metrike imaju sledeće vrednosti:


$$\mathbf{nRMSE = 5.99\% \quad nMBE = -0.17\%}$$

Dobijene vrednosti ukazuju na visok nivo tačnosti modela, pri čemu niska vrednost nRMSE potvrđuje dobru aproksimaciju izlazne snage, dok zanemarljiva vrednost nMBE ukazuje na odsustvo izražene sistematske greške. Razlika u znaku između MBE i nMBE posledica je normalizacije i različitog domenskog ograničenja evaluacije, ali u oba slučaja bias ostaje mali i ne utiče značajno na ukupne performanse modela.

Na osnovu navedenih rezultata može se zaključiti da faza finog podešavanja značajno unapređuje sposobnost modela da reprodukuje realno ponašanje PV sistema, uz očuvanje stabilnosti i fizičke konzistentnosti postignute tokom predtreniranja.

Konvergencija tokom faze finog podešavanja

Tok procesa dodatnog treniranja modela prikazan je na slici 5.30, gde je data evolucija logaritamske srednje kvadratne greške (logMSE) tokom iteracija algoritma učenja u fazi finog podešavanja na realnim merenim podacima. Sa slike se može uočiti stabilna i



Slika 5.30: Kriva učenja tokom faze finog podešavanja modela M2 na merenim podacima.

monotono opadajuća konvergencija funkcije greške, bez izraženih oscilacija ili divergencije, što potvrđuje numeričku stabilnost izabrane arhitekture i optimizacionog algoritma. Za razliku od predtreniranja, gde je inicijalni pad greške bio izraženiji, ovde se uočava blaži i postepeniji tok konvergencije, što je očekivano s obzirom na to da model već poseduje kvalitetnu inicijalizaciju težinskih koeficijenata stečenu učenjem na simulacionim podacima. Ovakvo ponašanje ukazuje na efikasan prenos prethodno naučenih reprezentacija (*transfer learning*), pri čemu se tokom fine-tuning faze vrši fino prilagođavanje modela specifičnostima realnih merenih podataka. U tom smislu, proces učenja ne započinje iz nasumične inicijalizacije, već iz već formiranog funkcionalnog modela koji već enkodira osnovne fizičke relacije sistema.


Dodatno, treba imati u vidu da realni mereni podaci sadrže viši nivo šuma, nesavršenosti merenja i neregularnosti u odnosu na simulacione podatke, što se reflektuje kroz nešto sporiju i manje izraženu konvergenciju. Uprkos tome, odsustvo naglih skokova u vrednosti greške ukazuje da model uspešno amortizuje uticaj šuma i zadržava stabilan tok optimizacije.

Takođe, izostanak porasta greške u kasnijim iteracijama sugerise da ne dolazi do prekomernog prilagođavanja (*overfitting*) u ovoj fazi, što je od posebnog značaja imajući u vidu ograničenu količinu i veću varijabilnost realnih podataka. Time se potvrđuje da prethodno treniranje na simulacionom skupu deluje kao efektivna regularizacija modela. Na osnovu prikazane krive učenja može se zaključiti da faza finog podešavanja omogućava

stabilnu adaptaciju modela M2 na realne uslove, uz očuvanje prethodno naučenih fizičkih zakonitosti i postizanje dodatnog poboljšanja u tačnosti predikcije.

Paritet: merene vrednosti vs. ANN predviđanje

Na slici 5.31 prikazan je paritet dijagram između merenih vrednosti proizvodnje eksperimentalnog PV sistema i ANN predikcije nakon faze finog podešavanja. Ovakav prikaz omogućava direktnu procenu kvaliteta modela u realnim uslovima eksploatacije, gde su prisutni šum merenja i dodatne nelinearnosti koje nisu u potpunosti obuhvaćene simulacionim modelom. Raspodela tačaka pokazuje izraženu koncentraciju oko linije idealnog



Slika 5.31: Paritet dijagram između merenih vrednosti proizvodnje PV sistema i predikcije ANN modela nakon faze finog podešavanja, za test skup iz 2022. godine.


slaganja ($y = \hat{y}$), što potvrđuje sposobnost modela da sa visokom tačnošću reprodukuje realnu proizvodnju posmatranog PV sistema. U poređenju sa rezultatima iz predtreniranja, može se uočiti zadržavanje osnovnog obrasca slaganja, uz blago povećanu disperziju, što je očekivano usled prisustva mernog šuma, operativnih neizvesnosti i neidealnosti u realnom radu sistema. Analiza raspodele tačaka ukazuje na odsustvo izražene sistematske greške, što implicira da model ne pokazuje značajnu pristrasnost u proceni izlazne snage. Manja odstupanja su uočljiva u oblastima visokih vrednosti snage, gde dolazi do pojačane varijabilnosti usled dinamičkih promena meteoroloških uslova i nelinearnih efekata u radu sistema (temperatura, zasićenje invertera, gubici).

Dodatno, većina tačaka ostaje unutar pojasa $\pm 10\%$ i $\pm 20\%$ odstupanja, što potvrđuje da ANN model zadovoljava praktične kriterijume tačnosti u kontekstu energetskog predviđanja. Ovakav rezultat je posebno značajan imajući u vidu da se evaluacija vrši na realnim merenim podacima, koji predstavljaju znatno zahtevniji test za model u odnosu na simulacione ulaze. Saglasnost između predviđenih i merenih vrednosti ukazuje da faza finog podešavanja uspešno prilagođava model specifičnostima realnog sistema, pri čemu se očuvavaju prethodno naučene fizičke relacije.

Na osnovu prikazanog paritet dijagrama može se zaključiti da model M2, nakon faze finog podešavanja, postiže visok nivo slaganja sa realnim merenjima i predstavlja robusno rešenje za predviđanje proizvodnje PV sistema u realnim uslovima rada.

Raspodela rezidualne greške

Distribucija rezidualne greške modela prikazana je na slici 5.32. Rezidualna greška definisana je kao razlika između merenih i predviđenih vrednosti izlazne snage, čime predstavlja ključni indikator kvaliteta modela i njegove sposobnosti aproksimacije realnog PV sistema. Prikazana raspodela greške je približno simetrična oko nulte vrednosti, što ukazuje na



Slika 5.32: Histogram rezidualne greške modela M2 nakon faze finog podešavanja na merenim podacima.

odsustvo izraženog sistematskog pomeraja ANN modela, odnosno na zanemarljivu MBE vrednost. Ovakvo ponašanje potvrđuje da model ne pokazuje tendenciju sistematskog preценjivanja ili potcenjivanja izlazne snage.

Većina rezidualnih vrednosti koncentrisana je u relativno uskom intervalu oko nule, što ukazuje na nisku disperziju greške i stabilno ponašanje modela u najvećem broju slučajeva. Ova karakteristika direktno je povezana sa dobrim vrednostima standardnih metrika tačnosti, kao što su MAE i RMSE. Blaga proširenja repova distribucije mogu se pripisati ekstremnim radnim uslovima sistema, kao što su nagle promene solarnog zračenja, prolazak oblaka ili prelazni režimi rada invertora, gde je predikcija inherentno složenija.

Ovakva odstupanja su očekivana u realnim merenim podacima i ne ukazuju na sistematski nedostatak modela.

Oblik distribucije, koji se približava normalnoj raspodeli, sugerise da su greške modela pretežno slučajnog karaktera i da ne postoji dominantna nelinearna struktura koja bi ostala "neuhvaćena" modelom. Time se potvrđuje adekvatnost izabrane arhitekture i uspešnost faze finog podešavanja u prilagođavanju ANN modela realnim uslovima. Na osnovu prikazane analize može se zaključiti da model M2 ostvaruje uravnotežen odnos između bias-a i varijanse greške, pri čemu dominira slučajna komponenta reziduala, što predstavlja poželjnu karakteristiku za modele namenjene operativnoj primeni u predviđanju proizvodnje PV sistema.

Kombinovana analiza paritet dijagrama (slika 5.31) i raspodele rezidualne greške (slika 5.32) omogućava sveobuhvatno sagledavanje performansi modela iz dva komplementarna ugla. Dok paritet dijagram pruža dvodimenzionalni uvid u odnos između predviđenih i merenih vrednosti i omogućava identifikaciju eventualnih sistematskih odstupanja u zavisnosti od nivoa snage, histogram reziduala daje jednodimenzionalni pregled ukupne raspodele greške.

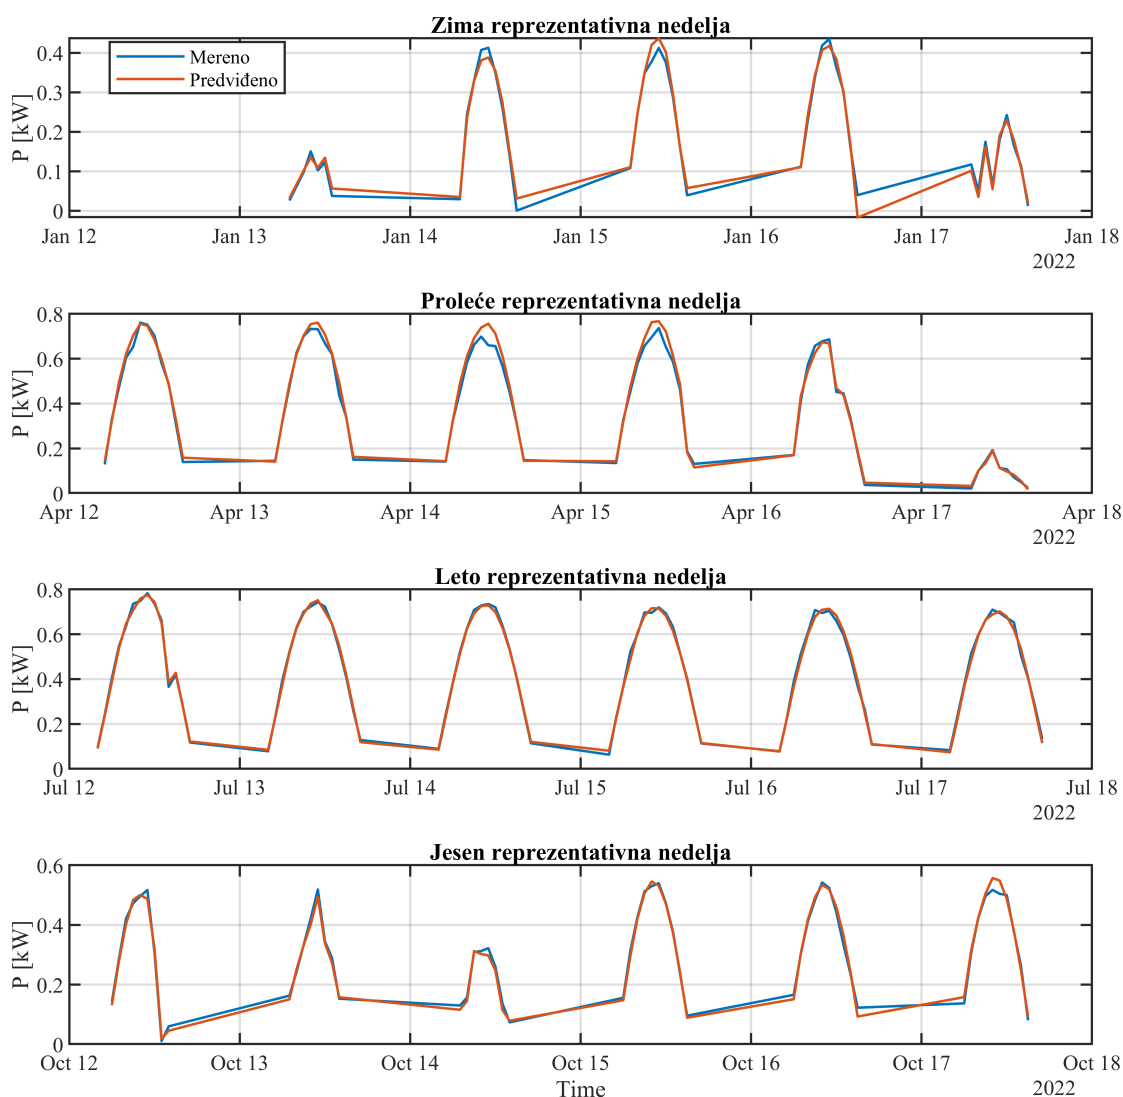
Saglasnost između ova dva prikaza ogleđa se u činjenici da koncentracija tačaka oko linije idealnog slaganja u paritet dijagramu direktno odgovara visokoj koncentraciji reziduala oko nulte vrednosti u histogramu. Istovremeno, blaga disperzija tačaka pri višim vrednostima snage reflektuje se kroz proširenje repova distribucije rezidualne greške, što ukazuje na povećanu varijabilnost u tim režimima.

Vremensko praćenje realne proizvodnje

Pored globalnog paritetnog prikaza, od posebnog značaja je analiza sposobnosti modela da kroz vreme reprodukuje dinamiku realne proizvodnje PV sistema. Na slici 5.33 prikazano je poređenje merenih i predviđenih vrednosti snage za reprezentativne periode iz test godine, koji obuhvataju karakteristične sezonske režime (zima, proleće, leto i jesen). Prikazani rezultati ukazuju na visok stepen slaganja između merenih i predviđenih vremenskih serija, pri čemu model uspešno reprodukuje ne samo maksimalne dnevne vrednosti, već i oblik dnevnih profila proizvodnje. Posebno je značajno da su jasno uhvaćeni karakteristični obrasci kao što su jutarnji porast, podnevni maksimum i večernji pad snage, što potvrđuje sposobnost modela da enkodira osnovnu fizičku dinamiku rada PV sistema.

Analiza po sezonama pokazuje da model zadržava konzistentne karakteristike u različitim meteorološkim uslovima. U letnjem periodu, gde dominiraju stabilni i visoki nivoi zračenja, model gotovo u potpunosti prati glatke i simetrične dnevne krive. U prelaznim sezonama (proleće i jesen), gde su prisutne izraženije fluktuacije usled promenljive oblačnosti, model uspešno reprodukuje promene u obliku krive, uključujući i nagle padove snage. Tokom zimskog perioda, iako su vrednosti snage niže i odnos signal-šum nepovoljniji,

Prikaz merene i predviđene snage tokom reprezentativnih nedelja (2022 test set)



Slika 5.33: Poređenje merenih i predviđenih vrednosti izlazne snage PV sistema tokom reprezentativnih perioda u test godini 2022.

model i dalje zadržava zadovoljavajući nivo slaganja. Manja lokalna odstupanja između merenih i predviđenih vrednosti mogu se uočiti u trenucima brzih promena zračenja, što je posledica ograničene mogućnosti modela da u potpunosti anticipira kratkotrajne stohastičke događaje (npr. prolazak oblaka). Ipak, ova odstupanja su kratkotrajna i ne dovode do značajnog narušavanja ukupnog kvaliteta predikcije.

Za razliku od paritet dijagrama, koji daje globalnu procenu tačnosti, vremenski prikaz omogućava uvid u sekvencijalnu konzistentnost modela, odnosno njegovu sposobnost da održava tačnost kroz kontinualne vremenske intervale. Ova karakteristika je od ključnog značaja za praktične primene, kao što su upravljanje energijom i kratkoročno planiranje proizvodnje.

Na osnovu prikazanih rezultata može se zaključiti da model M2, nakon faze finog

podešavanja, ne samo da postiže visoku tačnost u statističkom smislu, već i verno reprodukuje vremensku dinamiku proizvodnje PV sistema, čime potvrđuje svoju primenljivost u realnim operativnim uslovima.

5.4.6 Detaljna analiza grešaka modela M2


Pored globalnih metrika tačnosti, sprovedena je detaljna analiza grešaka modela M2 sa ciljem identifikacije njihove strukture i zavisnosti od ključnih fizičkih i vremenskih faktora. Ova analiza obuhvata ispitivanje rezidualne greške u funkciji intenziteta zračenja, nivoa proizvodnje, doba dana i sezonskih varijacija.

Za razliku od agregiranih metrika, koje pružaju uvid u ukupni kvalitet ANN modela, ovakav pristup omogućava razlaganje greške na specifične režime rada sistema i identifikaciju potencijalnih slabosti modela u određenim uslovima. Time se dobija dublje razumevanje ponašanja modela u realnim meteorološkim uslovima.

Poseban fokus stavljen je na analizu sistematske i slučajne komponente greške, kao i na njihovu stabilnost kroz različite vremenske skale. Ovakva višedimenzionalna analiza predstavlja ključni korak u proceni robusnosti i pouzdanosti modela, posebno u kontekstu njegove primene u operativnim sistemima za predviđanje proizvodnje PV sistema.

Zavisnost rezidualne greške od intenziteta zračenja

Na slici 5.34 prikazana je rezidualna greška modela u funkciji GHI za test skup iz 2022. godine. Ovakav prikaz omogućava detaljniju analizu performansi modela u različitim režimima rada PV sistema, u zavisnosti od nivoa dostupne solarne energije. Prikazana



Slika 5.34: Rezidualna greška modela M2 u funkciji globalnog horizontalnog zračenja (GHI) za test skup iz 2022. godine.

raspodela pokazuje da su odstupanja modela dominantno grupisana oko nulte vrednosti u širokom opsegu intenziteta zračenja, što ukazuje na odsustvo izraženog sistematskog trenda u zavisnosti od GHI. Time se potvrđuje da model zadržava konzistentnu tačnost kroz različite radne režime sistema. Može se uočiti blago povećanje rasipanja rezidualne greške pri višim vrednostima GHI, što predstavlja tipičan primer heteroskedastičnog ponašanja. Ovaj efekat je očekivan, jer u režimima visoke proizvodnje dolazi do izraženijeg uticaja nelinearnih faktora, kao što su temperaturna zavisnost efikasnosti modula, ograničenja invertera, kao i povećana osetljivost sistema na kratkotrajne promene meteoroloških uslova.

U oblasti niskih vrednosti zračenja, rezidualna greška ostaje relativno mala i stabilna, što ukazuje da model uspešno reprodukuje ponašanje sistema u uslovima slabog osunčanja, gde dominiraju linearni odnosi između ulaza i izlaza. Nasuprot tome, veća disperzija pri visokim GHI vrednostima reflektuje kompleksniju dinamiku sistema, ali bez pojave sistematskog odstupanja.


Važno je istaći da odsustvo jasne funkcionalne zavisnosti reziduala od GHI sugeriše da model ne propušta značajnu nelinearnu komponentu koja bi ostala "neuhvaćena", već da su preostale greške pretežno slučajnog karaktera. Time se dodatno potvrđuje adekvatnost izabrane arhitekture i uspešnost faze finog podešavanja u prilagođavanju modela realnim uslovima. Na osnovu prikazane analize može se zaključiti da model M2 održava stabilne performanse kroz čitav opseg intenziteta zračenja, uz očekivano povećanje varijanse greške u režimima visokog opterećenja, ali bez narušavanja ukupne tačnosti i fizičke konzistentnosti modela.

Mesečna raspodela rezidualne greške

Za procenu sezonske stabilnosti modela, na slici 5.35 je prikazana mesečna raspodela rezidualne greške pomoću boxplot dijagrama. Ovakav prikaz omogućava uvid u centralnu tendenciju (medijanu), disperziju (interkvartilni opseg) i prisustvo ekstremnih vrednosti za svaki mesec u posmatranom periodu. Može se uočiti da je medijana reziduala tokom većine meseci veoma bliska nultoj vrednosti, što potvrđuje odsustvo izražene sistematske greške kroz čitavu godinu. Ovakvo ponašanje ukazuje na stabilan rad modela bez sezonski uslovljenog bias-a.

Širina interkvartilnog opsega (IQR) ostaje relativno ujednačena između meseci, što sugeriše da varijabilnost greške ne zavisi značajno od sezone. Ipak, uočava se blago povećanje rasipanja tokom prelaznih perioda (proleće i jesen), kada su meteorološki uslovi promenljiviji i karakterisani čestim promenama oblačnosti i zračenja. Prisustvo pojedinačnih ekstremnih vrednosti (*outlier-a*) izraženije je u mesecima sa većom dinamikom atmosferskih uslova, što je u skladu sa analizom rezidualne greške u funkciji GHI, gde je takođe uočena povećana varijansa pri složenijim radnim režimima sistema.

Tokom letnjih meseci, raspodela reziduala je uža i simetričnija, što odražava stabilnije




Slika 5.35: Mesečna raspodela rezidualne greške modela M2 prikazana pomoću boxplot dijagrama za test skup iz 2022. godine.

uslove rada sistema sa dominantno vedrim nebom i manjim uticajem kratkotrajnih fluktuacija. Nasuprot tome, zimski period karakterišu niže vrednosti snage i veći relativni uticaj šuma, ali bez značajnog narušavanja centralne tendencije greške. Na osnovu prikazane analize može se zaključiti da model M2 zadržava visok nivo stabilnosti tokom cele godine, uz konzistentno nisku vrednost bias-a i umerenu varijansu greške, što potvrđuje njegovu robusnost u različitim sezonskim uslovima rada PV sistema.

Zavisnost greške od nivoa proizvodnje

Dodatni uvid u strukturu odstupanja modela dobijen je analizom rezidualne greške u funkciji merene izlazne snage PV sistema, što je prikazano na slici 5.36. Ovakav prikaz omogućava procenu performansi modela u različitim režimima opterećenja sistema, od niskih do maksimalnih vrednosti proizvodnje. Rezultati pokazuju da su odstupanja modela raspoređena simetrično oko nulte vrednosti kroz čitav opseg posmatranih snaga, bez izraženog sistematskog trenda precenjivanja ili potcenjivanja. Time se potvrđuje da model održava konzistentnu tačnost u različitim radnim režimima PV sistema.

U oblasti niskih vrednosti snage, rezidualna greška ostaje mala i relativno kompaktna, što ukazuje na stabilno ponašanje modela u uslovima slabog osunčanja, gde dominiraju jednostavniji, približno linearni odnosi između ulaznih i izlaznih veličina. Sa porastom nivoa proizvodnje uočava se blago povećanje rasipanja greške, što je u skladu sa rezultatima dobijenim u analizi u funkciji GHI. Ovaj efekat može se interpretirati kao posledica povećane složenosti PV sistema pri visokim nivoima snage, gde dolazi do izraženijeg uticaja nelinearnih faktora, uključujući temperaturnu zavisnost efikasnosti PV modula, moguće ograničenje invertora, kao i povećanu osetljivost na kratkotrajne promene meteoroloških uslova.



Slika 5.36: Rezidualna greška modela M2 u funkciji merene izlazne snage PV sistema.


Važno je naglasiti da i pored blagog povećanja varijanse, ne dolazi do pojave sistemskog pomeraja srednje vrednosti reziduala, što ukazuje da model ne gubi tačnost u režimima visokog opterećenja. Time se potvrđuje njegova sposobnost da adekvatno modeluje i najznačajnije energetske doprinose, koji se dominantno javljaju upravo pri višim vrednostima snage.

Na osnovu prikazane analize može se zaključiti da model M2 pokazuje stabilne i robusne performanse u celokupnom opsegu rada PV sistema, uz očekivano povećanje varijanse greške u režimima visoke proizvodnje, ali bez narušavanja ukupne tačnosti i fizičke konzistentnosti modela.

Dnevni profil greške

Na slici 5.37 je prikazan dnevni profil MBE i RMSE u funkciji sata u toku dana. Ovakav prikaz omogućava analizu performansi ANN modela u različitim fazama dnevnog ciklusa proizvodnje PV sistema. Može se uočiti da su odstupanja modela izraženija u prelaznim periodima dana, odnosno tokom jutarnjih i večernjih sati, kada dolazi do naglih promena intenziteta zračenja i brzog porasta ili opadanja izlazne snage. U tim režimima, relativni uticaj promena upadnog ugla sunčevog zračenja, senčenja i kratkotrajnih meteoroloških fluktuacija je veći, što povećava složenost procesa predikcije.

Nasuprot tome, u centralnim dnevnim satima, kada PV sistem radi u stabilnijem režimu sa visokim i relativno konstantnim nivoom zračenja, greška modela je manja i ujednačenija. Ovakvo ponašanje ukazuje na to da model uspešno aproksimira dominantne radne režime PV sistema, gde su odnosi između ulaznih i izlaznih veličina stabilniji i manje podložni brzim promenama. Analiza MBE pokazuje da ne postoji izražen sistemski pomeraj



Slika 5.37: Dnevni profil srednje greške (MBE) i RMSE modela M2 u funkciji sata u toku dana.

tokom dana, pri čemu vrednosti ostaju bliske nuli u svim vremenskim intervalima. Ovo potvrđuje odsustvo dnevno uslovljenog bias-a i ukazuje na konzistentno ponašanje modela u različitim fazama proizvodnog ciklusa.


Profil RMSE dodatno ukazuje na povećanu varijabilnost greške u jutarnjim i večernjim satima, što je u skladu sa prethodnim analizama reziduala u funkciji GHI i izlazne snage. Time se potvrđuje da su veća odstupanja povezana sa režimima u kojima sistem prelazi između stanja niske i visoke proizvodnje.

Na osnovu prikazanih rezultata može se zaključiti da model M2 zadržava visok nivo tačnosti tokom većeg dela dana, uz očekivano povećanje greške u tranzicionim periodima, ali bez pojave sistematskih odstupanja. Ovakav obrazac ponašanja je u skladu sa fizičkom prirodom PV sistema i potvrđuje robusnost modela u dinamičkim uslovima rada.

Dnevno–sezonska struktura sistematske greške

Najdetaljniji uvid u strukturu sistematskog odstupanja modela dat je na slici 5.38, gde je prikazana srednja rezidualna greška u funkciji meseca i sata u toku dana. Ovakav dvodimenzionalni prikaz omogućava identifikaciju specifičnih vremenskih i sezonskih režima u kojima dolazi do sistematskih odstupanja modela. Sa slike se može uočiti da je najveći deo sistematskog odstupanja lokalizovan u dnevnim periodima aktivne proizvodnje, dok su noćni sati očekivano bez značajnih odstupanja usled izostanka proizvodnje. U okviru dnevnog ciklusa, izraženiji bias se javlja u jutarnjim i večernjim satima, gde model ima tendenciju blagih odstupanja usled brzih promena intenziteta zračenja i tranzicionih režima rada sistema.

Tokom centralnih dnevnih sati (približno 9–13 h), posebno u prolećnim i letnjim mesecima, može se uočiti blago pozitivno sistematsko odstupanje, što ukazuje na tendenciju modela da u tim uslovima blago precenjuje izlaznu snagu. Ovakvo ponašanje može se povezati sa povećanim uticajem temperaturnih efekata i mogućim ograničenjima invertora



Slika 5.38: Toplotna mapa srednje rezidualne greške modela M2 u funkciji meseca i sata u toku dana.

pri visokim nivoima zračenja.

Sa druge strane, u jutarnjim i večernjim satima prisutan je blago negativan bias, što ukazuje na tendenciju potcenjivanja proizvodnje u režimima niskog upadnog ugla solarnog zračenja i povećane varijabilnosti atmosferskih uslova. Ovi režimi su inherentno teži za modelovanje zbog naglih promena ulaznih veličina i manjeg odnosa signal–šum.

Sa sezonskog aspekta, odstupanja su izraženija tokom prolećnih i letnjih meseci, kada PV sistem radi u režimima viših snaga i većeg dinamičkog opsega. Nasuprot tome, u zimskom periodu, iako su relativne greške potencijalno veće zbog nižih vrednosti snage, apsolutni bias ostaje mali i bez jasnog obrasca. Važno je istaći da, uprkos lokalizovanim odstupanjima, srednja vrednost reziduala ostaje bliska nuli u većini kombinacija mesec–sat, što potvrđuje odsustvo izraženog globalnog sistematskog pomeraja modela. Uočeni obrasci su fizički interpretabilni i dominantno povezani sa režimima brze promene ulaznih veličina.

Na osnovu prikazane analize može se zaključiti da model M2 pokazuje visok nivo stabilnosti bez značajnog globalnog bias-a, dok su lokalna odstupanja ograničena na specifične vremenske i sezonske režime koji su inherentno najzahtevniji za modelovanje.

5.4.7 Završna diskusija dobijenih rezultata

Rezultati prikazani u prethodnim podsekcijama potvrđuju da predloženi model M2 predstavlja efikasan pristup direktnoj proceni proizvodnje PV sistema na osnovu prognostički dostupnih meteoroloških podataka.

U prvoj fazi razvoja modela, neuronska mreža je obučena na simulacionom skupu generisanom pomoću referentnog fizičkog modela PV sistema u softverskom alatu *PVsystem*. Dobijeni rezultati pokazuju da ANN model može sa visokom tačnošću aproksimirati ponašanje simulacionog modela, pri čemu su ostvarene vrednosti greške $MAE = 0.0177$ kW i

RMSE = 0.0371 kW, uz zanemarljiv sistematski bias.

U drugoj fazi razvoja modela sprovedeno je dodatno prilagođavanje (*fine-tuning*) na osnovu realnih merenih podataka proizvodnje eksperimentalnog PV sistema. Ovaj korak omogućava korekciju razlika između simulacionog i realnog ponašanja sistema i značajno poboljšava operativnu primenljivost modela.

Evaluacija modela nad nezavisnim test skupom za 2022. godinu pokazuje da ANN model uspešno reprodukuje realnu proizvodnju PV sistema, pri čemu su dobijene vrednosti MAE = 0.0106 kW i RMSE = 0.0139 kW. Kada se analiza ograniči na dnevne periode sa aktivnom proizvodnjom (*daylight* režim), normalizovana srednja kvadratna greška iznosi približno $nRMSE \approx 6\%$, dok je normalizovani bias praktično zanemarljiv ($nMBE \approx -0.17\%$).

Dodatna analiza mesečnih i sezonskih metrika ukazuje na stabilno ponašanje modela tokom cele godine, bez izraženog sezonskog pomeraja greške. Toplotna mapa bias-a pokazuje da se najveća odstupanja javljaju tokom jutarnjih i večernjih sati, što je očekivano s obzirom na strm nagib proizvodne krive PV sistema u tim periodima.

Posmatrano u celini, model M2 pokazuje da je moguće direktno preslikavanje između meteoroloških ulaza i izlazne proizvodnje PV sistema realizovati uz zadovoljavajući nivo tačnosti primenom relativno jednostavne ANN arhitekture. Takav pristup predstavlja interesantnu alternativu klasičnim metodama zasnovanim na dvostepenom postupku predikcije zračenja i naknadne procene energetskeg prinosa. Istovremeno, rezultati sugerišu da kombinacija dugog simulacionog skupa podataka za inicijalno učenje i ograničenog skupa realnih merenja za naknadno prilagođavanje modela predstavlja efikasan način za izgradnju robusnih modela predikcije proizvodnje PV sistema.

5.4.8 Ograničenja modela M2 i pravci budućeg razvoja

Iako model M2 pokazuje zadovoljavajuće performanse u direktnoj predikciji proizvodnje PV sistema na osnovu prognostički dostupnih meteoroloških podataka, neophodno je sagledati njegova metodološka ograničenja i potencijalne pravce daljeg razvoja. Razmatranje ovih aspekata omogućava preciznije definisanje domena primene modela i identifikaciju mogućnosti za njegovo buduće unapređenje.

Zavisnost od referentnog simulacionog modela

Jedno od osnovnih ograničenja modela M2 proizilazi iz činjenice da se inicijalna faza obuke zasniva na izlazima referentnog simulacionog modela realizovanog u softverskom alatu *PVsyst*. U tom smislu, neuronska mreža u prvoj fazi razvoja ne uči direktno ponašanje realnog PV sistema, već aproksimira odziv fizičkog modela, uključujući njegove pretpostavke i pojednostavljenja.

Ovakav pristup ne predstavlja fundamentalno ograničenje u kontekstu operativne

prognoze, već jasno definiše interpretaciju rezultata. Model M2 se može posmatrati kao brza aproksimacija referentnog simulacionog modela, pogodna za situacije u kojima nije moguće ili nije praktično izvršavati detaljne fizičke simulacije u realnom vremenu.

Ograničenja ulaznih prognostičkih podataka

Performanse modela M2 u značajnoj meri zavise od kvaliteta i prostorno-vremenske rezolucije prognostičkih meteoroloških podataka. Greške i nesigurnosti u numeričkim vremenskim prognozama direktno se reflektuju na tačnost procene proizvodnje PV sistema, što predstavlja inherentno ograničenje svih operativnih modela ovog tipa.

Posebno su izazovni uslovi brzo promenljive oblačnosti, kada prostorna i vremenska rezolucija prognoze nije dovoljna da precizno opiše dinamiku atmosferskih procesa iznad lokacije PV sistema.

Odsustvo eksplicitnih iradijacionih ulaza

Za razliku od pristupa iz grupe M1, model M2 ne koristi eksplicitne komponente solar-nog zračenja (GHI, DNI ili DHI), već se u potpunosti oslanja na prognostički dostupne meteorološke promenljive. Ovakav pristup pojednostavljuje operativnu primenu modela, ali istovremeno može ograničiti maksimalnu tačnost predikcije u situacijama kada su informacije o solarnom zračenju dostupne ili se mogu pouzdano procijeniti iz numeričkih vremenskih prognoza.

Arhitekturna ograničenja modela

Korišćenje relativno jednostavne *feed-forward* neuronske mreže omogućava dobru numeričku stabilnost i jednostavnu implementaciju, ali istovremeno ograničava sposobnost modela da eksplicitno modeluje složene vremenske zavisnosti i sekvencijalne obrasce u ulaznim podacima. Iako se deo vremenske dinamike implicitno nalazi u prognostičkim ulazima, ovakav pristup ne koristi u potpunosti potencijal sekvencijalnih neuronskih arhitektura.

Potencijalni pravci unapređenja

Na osnovu identifikovanih ograničenja mogu se izdvojiti sledeći potencijalni pravci daljeg razvoja modela M2:

- uvođenje sekvencijalnih neuronskih arhitektura (npr. LSTM ili GRU) radi eksplicitnog modelovanja vremenskih zavisnosti u meteorološkim podacima;
- integracija satelitskih podataka za oblačnost i indikatora prostorno-vremenskog kretanja oblaka;
- razvoj modela za višehorizontske prognoze (*multi-horizon forecasting*) u okviru jedinstvene arhitekture;
- proširenje validacije modela na veći broj PV sistema različitih tehnologija i klimat-

skih regiona;

- razvoj hibridnih pristupa koji kombinuju fizičke modele i metode zasnovane na podacima.

Završna napomena

Uprkos navedenim ograničenjima, model M2 predstavlja metodološki konzistentan okvir za direktnu prognozu proizvodnje PV sistema na osnovu prognostički dostupnih meteoroloških podataka. Kombinacija dugog simulacionog skupa za inicijalno učenje i ograničenog skupa realnih merenja za naknadno prilagođavanje modela pokazala se kao efikasan pristup izgradnji robusnih modela predikcije proizvodnje PV sistema, dok identifikovani pravci razvoja predstavljaju osnovu za dalja istraživanja u ovoj oblasti.

5.5 Komparativna analiza modela M1 i M2

U prethodnim sekcijama predstavljena su dva konceptualno različita pristupa modelovanju proizvodnje PV sistema. Modeli iz grupe M1 zasnivaju se na indirektnom pristupu, u kojem se najpre predviđa GHI, nakon čega se energetske prinos sistema određuje primenom fizičkog modela. Nasuprot tome, model M2 realizuje direktno preslikavanje između meteoroloških podataka i izlazne proizvodnje PV sistema primenom jedinstvene neuronske mreže.

Ova dva pristupa odražavaju različite filozofije modelovanja:

- M1 pristup se oslanja na eksplicitno razdvajanje fizičkih procesa,
- M2 integriše sve faze modelovanja u jedinstveni *data-driven* okvir.

Shodno tome, njihovo poređenje omogućava procenu kompromisa između fizičke interpretabilnosti, tačnosti predikcije i operativne složenosti.

U ovoj sekciji daje se sintezna komparativna analiza modela M1 i M2, koja obuhvata: (i) metodološke razlike između pristupa, (ii) kvantitativno poređenje performansi u GHI i energetskom domenu, kao i (iii) diskusiju njihovih prednosti, ograničenja i potencijalne oblasti primene.

5.5.1 Metodološko poređenje pristupa

Tabela 5.13 jasno ilustruje fundamentalne razlike između indirektnog (M1) i direktnog (M2) pristupa modelovanju proizvodnje PV sistema.

Indirektni pristup M1 zasniva se na modularnoj strukturi u kojoj su procesi predikcije solarnog zračenja i procene energetske prinosa eksplicitno razdvojeni. Ovakva dekompozicija omogućava visok nivo interpretabilnosti i direktno povezivanje rezultata sa fizičkim procesima u PV sistemu. Kao posledica, M1 pristup je posebno pogodan za analizu performansi sistema, validaciju modela i razvoj *digital twin* koncepata.

Nasuprot tome, model M2 integriše sve faze modelovanja u jedinstveni *data-driven*

Tabela 5.13: Sintezna komparativna analiza metodoloških pristupa M1 i M2.

Karakteristika	M1 – Indirektni pristup	M2 – Direktni pristup
Struktura modela	Dvostepena: $\mathbf{x} \rightarrow \widehat{GHI} \rightarrow \widehat{E}$	Jednostepena: $\mathbf{x} \rightarrow \widehat{E}$
Ciljna veličina	GHI (posredno: energija)	Izlazna snaga / energija PV sistema
Uloga fizičkog modela	Eksplisitna (PR-bazirani model)	Implicitna (enkodirana u ANN)
Interpretabilnost	Visoka (razdvojena analiza greške)	Ograničena (integrisana greška)
Računska složenost	Viša (ANN + fizički model)	Niža (jedinstveni ANN)
Operativna primena	Analiza i validacija sistema	Operativna prognoza i tržišne aplikacije
Osetljivost na GHI	Visoka	Smanjena (bez eksplicitnog GHI)
Modularnost / Digital Twin	Visoka	Ograničena

okvir, čime se eliminiše potreba za eksplicitnim modelovanjem međukoraka. Ovakav pristup značajno smanjuje računsku složenost i pojednostavljuje implementaciju, što predstavlja ključnu prednost u operativnim uslovima i aplikacijama u realnom vremenu.

Ključna razlika između ova dva pristupa ogleda se u kompromisu između interpretabilnosti i operativne efikasnosti. Dok M1 omogućava detaljan uvid u pojedinačne komponente greške i njihovu fizičku interpretaciju, M2 postiže veću kompaktnost modela i potencijalno bolje ukupne performanse kroz direktno učenje odnosa između ulaza i izlaza. U tom smislu, izbor između M1 i M2 pristupa ne predstavlja striktno pitanje superiornosti jednog modela, već zavisi od konkretne primene: M1 je pogodniji za analitičke i istraživačke svrhe, dok M2 predstavlja efikasnije rešenje za operativne sisteme predviđanja proizvodnje PV energije.

5.5.2 Kvantitativno poređenje performansi

Tabela 5.14: Poređenje performansi modela M1 i M2 na test skupu.

Model	MAE [W]	RMSE [W]	nRMSE [%]	nMBE [%]
M1-A1	56.03	90.51	23.06	1.53
M1-A1b	54.24	80.13	25.19	2.49
M1-A2	53.8	78.29	24.61	1.46
M2-B1	14.70	18.90	5.99	-0.17


Tabela 5.14 prikazuje kvantitativno poređenje performansi modela razvijenih u okviru ovog istraživanja na nezavisnom test skupu. Prikazane metrike omogućavaju direktno poređenje tačnosti različitih modelskih konfiguracija u energetskom domenu.

Rezultati jasno pokazuju da direktni model M2 ostvaruje značajno bolje performanse

u odnosu na sve konfiguracije modela iz grupe M1. Konkretno, vrednost normalizovane srednje kvadratne greške smanjena je sa približno 23–25% kod M1 modela na oko 6% kod modela M2, što predstavlja poboljšanje od približno četiri puta. Istovremeno, sistematska greška kod modela M2 je praktično zanemarljiva ($nMBE \approx -0.17\%$), dok kod M1 modela postoji izraženiji bias.

Dobijeni rezultati ukazuju da direktni pristup omogućava efikasnije učenje odnosa između meteoroloških ulaza i izlazne proizvodnje, bez akumulacije greške karakteristične za dvostepene modele. Na taj način se izbegava propagacija greške iz faze predikcije GHI u fazu procene energetskog prinosa.

Na slici 5.39 prikazan je uporedni pregled više metrika tačnosti, gde se može uočiti konzistentna prednost modela M2 u svim posmatranim kriterijumima. Ova konzistentnost ukazuje na stabilno poboljšanje performansi, a ne na optimizaciju pojedinačne metrike.



Slika 5.39: Uporedni prikaz više metrika tačnosti (MAE, RMSE i nRMSE) za modele M1 i M2 na test skupu.


Radar dijagram sa slike 5.40 omogućava sintetički prikaz ukupnog profila performansi modela. Model M2 karakteriše veća površina poligona, što potvrđuje njegovu superiornost u višekriterijumskom smislu. Za razliku od toga, modeli iz grupe M1 pokazuju ujednačeno slabije performanse kroz sve posmatrane metrike.

Na osnovu sprovedene analize može se zaključiti da direktni pristup modelovanja (M2) ne samo da pojednostavljuje strukturu modela, već istovremeno obezbeđuje i značajno viši nivo tačnosti u odnosu na indirektno pristupe zasnovane na predikciji GHI.

5.5.3 Diskusija komparativnih rezultata

Rezultati prikazani u prethodnim sekcijama ukazuju da oba pristupa, M1 i M2, poseduju specifične prednosti i ograničenja koja zavise od ciljne primene modela i dostupnosti ulaznih podataka.

Indirektni pristup M1 zasniva se na dvostepenoj strukturi modelovanja u kojoj se



Slika 5.40: Radar dijagram normalizovanih performansi modela M1 i M2 na osnovu više metrika greške.

najpre vrši predikcija GHI, a zatim se energija PV sistema procenjuje primenom fizičkog energetskeg modela. Ovakva struktura omogućava visoku interpretabilnost modela, budući da je moguće odvojeno analizirati greške u proceni solarnog zračenja i energetskeg prinosa sistema. Uključivanje fizičkog modela takođe omogućava direktno povezivanje rezultata modela sa fizičkim karakteristikama PV sistema.

Nasuprot tome, model M2 realizuje direktno preslikavanje između meteoroloških ulaza i izlazne proizvodnje sistema. Ovakav pristup omogućava značajno pojednostavljenje strukture modela i smanjenje računskog opterećenja, što može biti od posebnog značaja u operativnim aplikacijama prognoze proizvodnje električne energije i upravljanja energetskeg sistemima.

Sa metodološkog stanovišta, indirektni pristup M1 predstavlja fizički utemeljeniji okvir modelovanja, dok direktni pristup M2 nudi veću fleksibilnost i jednostavniju implementaciju. Izbor optimalnog pristupa stoga zavisi od balansa između zahteva za interpretabilnošću modela i potrebe za računskom efikasnošću i robusnošću u operativnim uslovima.

Posmatrano u celini, rezultati ovog istraživanja pokazuju da oba pristupa predstavljaju validne strategije za modelovanje proizvodnje PV sistema. Indirektni pristup M1 pruža veću fizičku transparentnost i pogodniji je za detaljnu tehničku analizu sistema, dok direktni pristup M2 omogućava jednostavniju strukturu modela i potencijalno bržu operativnu implementaciju u realnim energetskeg aplikacijama.



6. Zaključak

Razvoj pouzdanih metoda za prognozu proizvodnje PV sistema predstavlja jedan od ključnih izazova savremenih elektroenergetskih sistema sa visokim udelom obnovljivih izvora energije. Tačnost predviđanja proizvodnje direktno utiče na stabilnost elektroenergetske mreže, planiranje rada sistema, kao i na ekonomske aspekte tržišta električne energije.

Cilj ove doktorske disertacije bio je razvoj i analiza metoda predikcije proizvodnje PV sistema zasnovanih na savremenim metodama mašinskog učenja, sa posebnim fokusom na veštačke neuronske mreže i integraciju različitih izvora meteoroloških podataka. U okviru istraživanja razvijen je metodološki okvir koji omogućava korišćenje lokalnih meteoroloških merenja, satelitskih podataka i simulacionih modela za dobijanje robusnih modela predviđanja proizvodnje PV sistema.

U radu su analizirana dva konceptualno različita pristupa predikciji proizvodnje PV sistema:

- Prvi pristup, označen kao metodologija **M1**, zasniva se na indirektnoj strategiji u kojoj se najpre vrši predikcija GHI primenom ANN modela, nakon čega se predviđene vrednosti zračenja transformišu u energetska proizvodnja korišćenjem fizičkog modela PV sistema. Ovakav pristup omogućava visoku interpretabilnost modela i jasno razdvajanje grešaka koje potiču iz predikcije zračenja od grešaka energetskog modela.
- Drugi pristup, označen kao metodologija **M2**, zasniva se na direktnoj strategiji u kojoj neuronska mreža direktno predviđa izlaznu snagu ili energiju PV sistema na osnovu dostupnih meteoroloških ulaza. Ovim pristupom postiže se značajno pojednostavljenje strukture modela i smanjenje računске složenosti, što je posebno pogodno za operativne primene u realnom vremenu.

U okviru istraživanja razvijeno je više varijanti ANN modela koje koriste različite kombinacije ulaznih promenljivih, uključujući meteorološke parametre, vremenske indikatore

i informacije o stanju atmosfere. Posebna pažnja posvećena je optimizaciji arhitekture neuronskih mreža i analizi uticaja algoritama treniranja na performanse modela.

Rezultati istraživanja pokazuju da razvijeni modeli postižu visok nivo tačnosti u predikciji proizvodnje PV sistema. U slučaju modela M2, nakon faze finog podešavanja obuke na realnim merenim podacima, ostvarena je normalizovana srednja kvadratna greška reda veličine približno $nRMSE \approx 6\%$ tokom dnevnih perioda aktivne proizvodnje, uz veoma mali sistematski bias modela ($nMBE \approx -0.17\%$). Dobijeni rezultati ukazuju na dobru sposobnost modela da reprodukuje realnu dinamiku proizvodnje PV sistema u različitim meteorološkim uslovima.

Komparativna analiza pristupa M1 i M2 pokazuje da oba modela poseduju specifične prednosti. Indirektni pristup M1 omogućava bolju interpretaciju fizičkih procesa i pogodniji je za detaljnu analizu uticaja meteoroloških parametara na proizvodnju PV sistema. Sa druge strane, direktni pristup M2 obezbeđuje jednostavniju strukturu modela i bržu implementaciju u operativnim sistemima prognoze.

Na osnovu sprovedenih analiza može se zaključiti da kombinovanje fizičkih modela i metoda mašinskog učenja predstavlja veoma perspektivan pristup za razvoj naprednih sistema predikcije proizvodnje PV sistema.

Rezultati ove disertacije doprinose razvoju metodologije za prognozu proizvodnje PV sistema i mogu imati značajnu primenu u planiranju rada elektroenergetskih sistema, integraciji obnovljivih izvora energije i optimizaciji energetske tržišta.

Kao pravci daljih istraživanja izdvajaju se:

- primena naprednih sekvencijalnih modela mašinskog učenja (LSTM, GRU) za eksplicitno modelovanje vremenskih zavisnosti,
- integracija satelitskih i numeričkih meteoroloških prognoza u okviru jedinstvenog hibridnog modela,
- razvoj višehorizontskih modela predikcije proizvodnje PV sistema,
- primena razvijenih metoda u realnim operativnim sistemima prognoze proizvodnje obnovljivih izvora energije.

Razvijeni metodološki okvir predstavlja osnovu za dalji razvoj inteligentnih sistema predikcije proizvodnje obnovljivih izvora energije i doprinosi boljoj integraciji PV sistema u savremene elektroenergetske mreže.

6.1 Originalni naučni doprinosi disertacije

Na osnovu sprovedenog teorijskog i eksperimentalnog istraživanja u okviru ove doktorske disertacije mogu se izdvojiti sledeći originalni naučni doprinosi:

- Razvijen je metodološki okvir za predikciju proizvodnje PV sistema zasnovan na integraciji metoda mašinskog učenja i meteoroloških podataka različitog porekla, uključujući lokalna merenja, simulacione modele i satelitske informacije o stanju

atmosfera.

- Predložen je indirektni model predikcije proizvodnje PV sistema (M1 pristup) zasnovan na dvostepenoj strukturi $\mathbf{x} \rightarrow \widehat{GHI} \rightarrow \widehat{E}$, koji omogućava razdvajanje greške predikcije solarnog zračenja od greške energetskog modela, čime se postiže veća interpretabilnost rezultata i omogućava detaljna analiza uticaja meteoroloških faktora na proizvodnju PV sistema.
- Razvijen je direktni model predikcije proizvodnje PV sistema (M2 pristup) zasnovan na jedinstvenoj ANN arhitekturi koja direktno mapira meteorološke ulaze u proizvodnju električne energije, čime se postiže pojednostavljenije strukture modela i povećava njegova operativna primenljivost u sistemima kratkoročne prognoze.
- Sprovedena je sistematska optimizacija arhitekture neuronske mreže i algoritama treniranja, pri čemu je pokazano da BR algoritam (`trainbr`) obezbeđuje stabilnije performanse i bolju generalizaciju modela u odnosu na alternativne metode treniranja.
- Razvijen je postupak kombinovanja simulacionih i merenih podataka kroz dvostepeni proces obuke modela (*pretraining* na simulacionom skupu i *fine-tuning* na realnim merenjima), čime je omogućeno efikasno korišćenje velikih simulacionih baza podataka uz istovremeno prilagođavanje modela realnom ponašanju PV sistema.
- Izvršena je detaljna analiza performansi razvijenih modela korišćenjem različitih statističkih metrika i dijagnostičkih analiza, uključujući sezonsku, mesečnu i dnevnu strukturu greške, čime je potvrđena stabilnost modela u različitim meteorološkim uslovima.
- Sprovedena je komparativna analiza indirektnog (M1) i direktnog (M2) pristupa predikciji proizvodnje PV sistema, kojom su identifikovane njihove ključne prednosti i ograničenja u pogledu interpretabilnosti, računске složenosti i operativne primenljivosti.

Dobijeni rezultati predstavljaju doprinos razvoju metoda predikcije proizvodnje PV sistema i mogu imati značajnu primenu u planiranju rada elektroenergetskih sistema, integraciji obnovljivih izvora energije i razvoju naprednih sistema prognoze proizvodnje električne energije iz obnovljivih izvora.

Tabela 6.1: Povezanost identifikovanih naučnih doprinosa sa odgovarajućim poglavljima disertacije.

C	Naučni doprinos	Poglavlje disertacije
C1	Razvoj metodološkog okvira za predikciju proizvodnje PV sistema zasnovanog na integraciji meteoroloških podataka, simulacionih modela i metoda mašinskog učenja.	Poglavlja 3 i 4
C2	Razvoj indirektnog modela predikcije proizvodnje PV sistema (M1 pristup) zasnovanog na dvostepenoj strukturi $\mathbf{x} \rightarrow \widehat{GHI} \rightarrow \widehat{E}$.	Poglavlje 5
C3	Razvoj direktnog modela predikcije proizvodnje PV sistema (M2 pristup) zasnovanog na jedinstvenoj ANN arhitekturi za direktnu predikciju izlazne energije.	Poglavlje 6
C4	Optimizacija arhitekture neuronskih mreža i analiza uticaja algoritama treniranja na stabilnost i tačnost predikcije.	Poglavlje 6 i <u>Prilog A</u>
C5	Razvoj postupka kombinovanja simulacionih i merenih podataka kroz dvostepeni proces obuke modela (pretraining i fine-tuning).	Poglavlje 6
C6	Detaljna statistička i dijagnostička analiza performansi predloženih modela u različitim meteorološkim uslovima.	Poglavlja 5 i 6
C7	Komparativna analiza indirektnog (M1) i direktnog (M2) pristupa predikciji proizvodnje PV sistema.	Poglavlje 5

A. Numerički primer proračuna LCOE za PV sistem (Srbija)

U ovom dodatku prikazan je primer proračuna LCOE za mrežno povezani PV sistem u Srbiji (referentna lokacija: region Niša). Proračun je izveden po jedinici instalisane snage 1 kW_p, u skladu sa standardnim pristupom diskontovanih troškova i diskontovane proizvodnje [82], [84]. Godišnji energetske prinos uzet je kao tipična vrednost dobijena na osnovu PVGIS baze [20], dok je degradacija PV modula usvojena prema analitičkom pregledu degradacionih stopa [85]. Opseg CAPEX vrednosti oslanja se na savremene troškovne izveštaje i literaturne preglede [84], [100]. Pretpostavke za proračun su date u Tabeli A.1.

Tabela A.1: Ulazne pretpostavke za proračun LCOE (po 1 kW_p).

Parametar	Vrednost
Životni vek sistema, n	25 godina
Diskontna stopa, r	7%
Početna investicija, C_{total}	900 € / kW _p
Godišnji OPEX	1.5% CAPEX = 13.5 € / god
Zamena invertora	12 godina; 120 € / kW _p
Godišnja proizvodnja, E_1	1250 kWh/kW _p
Degradacija proizvodnje	0.4% / god

Godišnja proizvodnja u godini t modelovana je kao:

$$E_t = E_1(1 - d)^{t-1}, \quad (\text{A.1})$$

gde je d godišnja stopa degradacije. LCOE se računa prema:

$$LCOE = \frac{C_{total} + \sum_{t=1}^n \frac{O_t}{(1+r)^t}}{\sum_{t=1}^n \frac{E_t}{(1+r)^t}}. \quad (\text{A.2})$$

O_t uključuje OPEX i eventualne periodične troškove (npr. zamenu invertora).

Za pretpostavke iz Tabele A.1 dobijeno je:

$$\sum_{t=1}^n \frac{E_t}{(1+r)^t} \approx 14076 \text{ kWh/kW}_p, \quad C_{total} + \sum_{t=1}^n \frac{O_t}{(1+r)^t} \approx 1111 \text{ €/kW}_p. \quad (\text{A.3})$$

Odnosno:

$$LCOE \approx 0.079 \text{ €/kWh}. \quad (\text{A.4})$$

Dobijena vrednost predstavlja reprezentativan pokazatelj dugoročnog prosečnog troška proizvedene električne energije iz PV sistema u posmatranim uslovima. Rezultat je osetljiv na diskontnu stopu, investicioni trošak i godišnji prinos (lokacija, nagib, gubici), pa se u praktičnim studijama preporučuje sprovođenje analize osetljivosti na r , C_{total} i E_1 [82].

Analiza osetljivosti.

U Tabeli A.2 menja se diskontna stopa r i početni godišnji prinos E_1 , uz fiksiran $C_{total} = 900 \text{ €/kW}_p$, dok Tabela A.3 prikazuje zajednički uticaj CAPEX-a i prinosa kada je $r = 7\%$.

Tabela A.2: Osetljivost LCOE na diskontnu stopu r i početni prinos E_1 ($C_{total} = 900 \text{ €/kW}_p$).

r [%]	$E_1 = 1150$	$E_1 = 1250$	$E_1 = 1350$
	LCOE [€/kWh]		
5	0.074	0.068	0.063
7	0.086	0.079	0.073
9	0.098	0.090	0.084

Tabela A.3: Osetljivost LCOE na CAPEX i početni prinos E_1 (fiksno $r = 7\%$).

C_{total} [€/kW _p]	$E_1 = 1150$	$E_1 = 1250$	$E_1 = 1350$
800	0.077	0.071	0.065
900	0.086	0.079	0.073
1100	0.104	0.096	0.089

Rezultati potvrđuju očekivano ponašanje: porast diskontne stope povećava LCOE (usled jačeg “kažnjavanja” buduće proizvodnje), dok veći specifični prinos i niži CAPEX smanjuju LCOE. Ovakav prikaz je pogodan za brzu procenu ekonomskog opsega projekta, pre sprovođenja detaljnije finansijske simulacije [82], [84].



B. Algoritmi učenja

U ovom dodatku je dat kratak pregled algoritama učenja korišćenih za treniranje ANN pri generisanju modela. Iako je primarni fokus istraživanja u ovom radu na analizi uticaja ulaznih promenljivih i vremenske memorije na tačnost predviđanja, izbor algoritma učenja ima značajan uticaj na brzinu konvergencije, stabilnost procesa učenja i sposobnost generalizacije ANN modela. Razmatrana su tri široko prihvaćena algoritma učenja, čije su osnovne karakteristike ukratko opisane u nastavku.

Levenberg–Marquardt algoritam - `trainlm`

Levenberg–Marquardt (LM) algoritam predstavlja kvazi-drugoredni optimizacioni postupak namenjen rešavanju problema nelinearne regresije u smislu najmanjih kvadrata. Iterativna šema algoritma je prikazana na slici B.1. U kontekstu treniranja veštačkih neuronskih mreža, cilj je minimizacija funkcije srednje kvadratne greške oblika:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (\text{B.1})$$

gde je $e_i = y_i - \hat{y}_i(\mathbf{w})$ greška između stvarne i predviđene vrednosti, a \mathbf{w} vektor svih težinskih koeficijenata i bias parametara mreže.

Aproksimacija Hesijan matrice

Za razliku od klasične gradijentne metode, koja koristi samo prvi izvod, LM algoritam koristi aproksimaciju Hesijan matrice funkcije greške. Za probleme najmanjih kvadrata Hesijan se može aproksimirati kao:

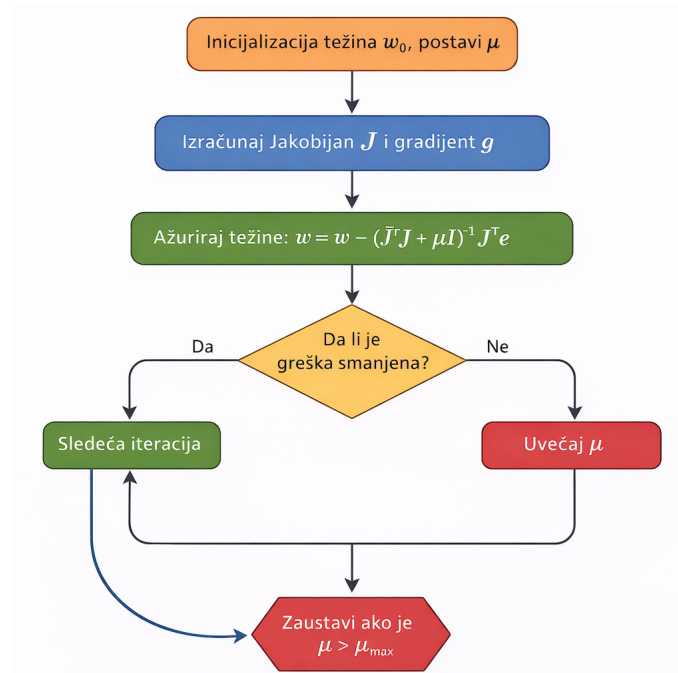
$$\mathbf{H} \approx \mathbf{J}^T \mathbf{J} \quad (\text{B.2})$$

gde je \mathbf{J} Jakobijan matrica parcijalnih izvoda grešaka u odnosu na težine:

$$J_{ij} = \frac{\partial e_i}{\partial w_j} \quad (\text{B.3})$$

Gradijent funkcije greške je tada:

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (\text{B.4})$$



Slika B.1: Iterativna šema Levenberg-Marquardt (LM) algoritma.

Na osnovu toga, iterativno ažuriranje težina ima oblik:

$$\mathbf{w}_{k+1} = \mathbf{w}_k - (\mathbf{J}^T \mathbf{J} + \mu \mathbf{I})^{-1} \mathbf{J}^T \mathbf{e} \quad (\text{B.5})$$

gde je μ parametar prigušenja (damping factor), a \mathbf{I} jedinična matrica.

Interpretacija parametra μ

Parametar μ omogućava adaptivni prelaz između dve optimizacione strategije:

- ako je μ veoma mali, algoritam se ponaša kao Gauss-Newton metoda, sa brzim kvadratnim približavanjem minimumu;
- ako je μ veliki, dominira član $\mu \mathbf{I}$ i algoritam se svodi na gradijentni spust sa malim korakom.

Tokom treninga, vrednost μ se adaptivno menja: ako se greška smanjuje, μ se redukuje (algoritam postaje agresivniji), dok se u slučaju povećanja greške μ povećava, čime se obezbeđuje stabilnost konvergencije.

Numeričke i računarske karakteristike

Glavna prednost LM algoritma jeste veoma brza konvergencija u blizini minimuma funkcije greške, posebno kod mreža sa umerenim brojem parametara (tipično nekoliko stotina do nekoliko hiljada težina).

Međutim, računaska složenost formiranja i inverzije matrice $(\mathbf{J}^T \mathbf{J})$ je reda:

$$\mathcal{O}(n_w^3) \quad (\text{B.6})$$

gde je n_w broj parametara mreže. Takođe, memorijski zahtevi su približno:

$$\mathcal{O}(n_w^2) \quad (\text{B.7})$$

što LM algoritam čini nepraktičnim za veoma duboke mreže ili velike skupove podataka.

Regularizacija i generalizacija

U odsustvu regularizacije, LM algoritam može dovesti do preučavanja, posebno kada je broj parametara uporediv sa brojem trening uzoraka. U MATLAB okruženju (`trainlm`) se često koristi *early stopping* strategija zasnovana na validacionom skupu, čime se ograničava degradacija sposobnosti generalizacije.

Primena u okviru ove disertacije

U okviru sprovedene optimizacije modela M1 i M2, LM algoritam je korišćen kao referentni brzi optimizator za mreže sa malim i srednjim brojem skrivenih neurona. Zbog determinističke prirode i brzine konvergencije, omogućava efikasnu pretragu hiperparametarskog prostora, posebno u grid-search procedurama.

Kod većih konfiguracija i u slučajevima izraženog šuma, zamenjen je Bayesovom regularizacijom, koja pokazuje bolju robusnost u smislu stabilnosti validacionih metrika.

Skalirani konjugovani gradijent - `trainscg`

Algoritam skaliranog konjugovanog gradijenta (SCG) predstavlja metodu optimizacije namenjenu efikasnom treniranju veštačkih neuronskih mreža u problemima nelinearne minimizacije, pri čemu se posebno ističe činjenica da ne zahteva eksplicitnu jednodimenzionu linijsku pretragu (line search) radi određivanja optimalnog koraka u svakoj iteraciji [101]. Time se smanjuje ukupna računarska složenost i povećava numerička stabilnost u odnosu na klasične konjugovane gradijentne varijante.

Osnovna ideja: konjugovani pravci

Polazi se od minimizacije funkcije greške $E(\mathbf{w})$ nad vektorom parametara \mathbf{w} . U iteraciji k koristi se pravac pretrage \mathbf{p}_k koji je konstruisan tako da bude (aproksimativno) *konjugovan* u odnosu na lokalnu kvadratnu aproksimaciju funkcije cilja, čime se izbegava cik-cak ponašanje tipično za najprostiji gradijentni spust.

U najopštijem obliku, ažuriranje parametara glasi:

$$\mathbf{w}_{k+1} = \mathbf{w}_k + \alpha_k \mathbf{p}_k, \quad (\text{B.8})$$

gde je α_k korak (step size), a \mathbf{p}_k pravac pretrage. Kod konjugovanog gradijenta pravac se tipično generiše rekursivno:

$$\mathbf{p}_k = -\mathbf{g}_k + \beta_k \mathbf{p}_{k-1}, \quad (\text{B.9})$$

gde je $\mathbf{g}_k = \nabla E(\mathbf{w}_k)$ gradijent, dok β_k određuje koliki deo prethodnog pravca se prenosi u novu iteraciju.

Ključna razlika: izbegavanje linijske pretrage

Kod standardnih konjugovanih gradijentnih metoda, korak α_k se dobija linijskom pretragom (više evaluacija funkcije cilja duž pravca \mathbf{p}_k), što kod neuronskih mreža može biti škupno"jer svaka evaluacija implicira prolaz kroz mrežu i računanje greške.

SCG uvodi *skaliranje* i koristi aproksimaciju lokalne krivine duž pravca pretrage, oslanjajući se na ideju srodnu trust-region pristupu: umesto eksplicitne pretrage, SCG procenjuje pogodan korak kombinovanjem gradijentne informacije i približne drugoredne informacije (krivine), uz kontrolu stabilnosti.

U praktičnoj implementaciji, krivina duž pravca \mathbf{p}_k se aproksimira izrazom:

$$\kappa_k \approx \mathbf{p}_k^T \mathbf{H}_k \mathbf{p}_k, \quad (\text{B.10})$$

gde je \mathbf{H}_k Hesijan (ili njegova aproksimacija). SCG izbegava eksplicitno formiranje \mathbf{H}_k , već koristi

numeričke/proceduralne procene proizvoda tipa $\mathbf{H}\mathbf{p}$, čime se značajno smanjuju memorijski zahtevi.

Računska složenost i skaliranje

U poređenju sa Levenberg–Marquardt algoritmom, SCG ima znatno niže memorijske zahteve, jer ne zahteva formiranje i inverziju matrice dimenzije $n_w \times n_w$ (gde je n_w broj parametara mreže). Zbog toga je SCG pogodniji za:

- mreže sa većim brojem parametara (više neurona i/ili više slojeva),
- veće skupove podataka,
- situacije kada raspoloživa memorija predstavlja ograničenje.

U praksi, jedna iteracija SCG algoritma često košta približno kao jedna do nekoliko gradijentnih evaluacija, dok LM iteracija može biti višestruko skuplja zbog rešavanja linearnog sistema. Zbog toga SCG često zahteva veći broj iteracija, ali uz povoljniji ukupan odnos resursa (memorija / vreme) kod većih problema.

Konvergenција i numeričke osobine

SCG tipično konvergira sporije od LM algoritma u blizini optimuma, jer LM koristi eksplicitniju drugorednu informaciju (preko $\mathbf{J}^T \mathbf{J}$ aproksimacije), dok SCG koristi implicitnu procenu krivine. Ipak, SCG je često robusniji u smislu stabilnosti i manje je osetljiv na loše uslovljene probleme, posebno kada je funkcija greške “ravna” ili kada postoji značajan šum u podacima [95].

Primena u okviru ove disertacije

U okviru ove disertacije, SCG (`trainscg`) je razmatran kao efikasna alternativa za treniranje modela sa većim brojem parametara i kao kompromis između brzine i računarskih zahteva. Posebno je pogodan u fazama sistematske pretrage hiperparametara (gde je potrebno trenirati veći broj konfiguracija), kao i u situacijama kada LM postaje ograničen memorijskim zahtevima.

Bayesian regularization - `trainbr`

Bayesian regularization (BR) predstavlja proširenje standardnog treniranja neuronskih mreža zasnovano na probabilističkoj interpretaciji problema minimizacije [102], [103]. Za razliku od klasične minimizacije srednje kvadratne greške, ovde se uvodi eksplicitna penalizacija normi težinskih koeficijenata, čime se obezbeđuje kontrola složenosti modela i poboljšava sposobnost generalizacije.

Modifikovana funkcija cilja

U okviru BR pristupa, funkcija cilja definiše se kao:

$$F(\mathbf{w}) = \beta E_D + \alpha E_W \quad (\text{B.11})$$

gde je:

$$E_D = \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (\text{B.12})$$

greška aproksimacije nad podacima, dok je

$$E_W = \frac{1}{2} \sum_{j=1}^{n_w} w_j^2 \quad (\text{B.13})$$

regularizacioni član koji penalizuje velike vrednosti težina. Parametri α i β predstavljaju hiperparametre koji određuju odnos između verodostojnosti podataka i složenosti modela.

Probabilistička interpretacija

Bayesov pristup polazi od pretpostavke da su:

- greške e_i imaju Gaussovu raspodelu sa varijansom σ_D^2 ,
- težine w_j imaju Gaussovu raspodelu sa varijansom σ_W^2 .

U tom slučaju, maksimizacija posteriorne verovatnoće $P(\mathbf{w} | \mathcal{D})$ je ekvivalentna minimizaciji funkcije $F(\mathbf{w})$, pri čemu važi:

$$\alpha = \frac{1}{\sigma_W^2}, \quad \beta = \frac{1}{\sigma_D^2}. \quad (\text{B.14})$$

Ključna prednost BR algoritma jeste to što se α i β adaptivno procenjuju tokom procesa učenja, na osnovu dokaza (evidence framework) koji je razvio MacKay [102]. Na taj način, odnos između prilagođavanja podacima i regularizacije nije unapred fiksiran, već se optimizuje automatski.

Efektivni broj parametara

Jedna od važnih posledica Bayesovog pristupa jeste pojam *efektivnog broja parametara*:

$$\gamma = n_w - 2\alpha \text{tr}(\mathbf{H}^{-1}), \quad (\text{B.15})$$

gde je \mathbf{H} Hesijan funkcije cilja. Vrednost γ predstavlja meru stvarne složenosti modela, odnosno broj parametara koji efektivno doprinose aproksimaciji. U slučaju jake regularizacije, γ može biti znatno manji od ukupnog broja težina n_w .

Numeričke karakteristike

U MATLAB implementaciji (`trainbr`), BR se oslanja na LM optimizacioni mehanizam, ali sa modifikovanom funkcijom cilja. Zbog toga:

- zadržava brzu konvergenciju LM pristupa,
- automatski kontroliše preučavanje,
- ne zahteva eksplicitni validacioni skup za *early stopping*.

Međutim, računaska složenost ostaje visoka, jer je i dalje potrebno formirati aproksimaciju Hesijan matrice. Zbog toga BR može biti sporiji od `trainlm` i znatno sporiji od `trainscg`, posebno kod većih mreža.

Prednosti u energetske i meteorološkim primenama

Kod predikcije meteoroloških i energetske veličina, ulazni podaci često sadrže šum, sezonske varijacije i visoku međusobnu korelaciju promenljivih. U takvim uslovima, klasična minimizacija MSE može dovesti do prekomernog prilagođavanja trening podacima.

BR pokazuje sledeće prednosti:

- stabilnije performanse na nezavisnim skupovima podataka,
- smanjenje varijanse modela,
- robusnost na kolinearnost ulaznih promenljivih.

Primena u okviru ove disertacije

U okviru sprovedenih eksperimenata za modele M1 i M2, algoritam `trainbr` korišćen je u situacijama sa ograničenim brojem uzoraka i povećanom kompleksnošću mreže. U poređenju sa `trainlm`, pokazao je manju osetljivost na šum i stabilnije validacione metrike, uz blago povećanje vremena potrebnog za treniranje.

Zbog balansa između tačnosti i generalizacije, BR predstavlja posebno pogodan izbor za dugoročne energetske prognoze zasnovane na heterogenim meteorološkim podacima.

Komparativna analiza algoritama učenja

Tabela B.1: Komparativna analiza algoritama *trainlm*, *trainscg* i *trainbr*.

Karakteristika	LM (<i>trainlm</i>)	SCG (<i>trainscg</i>)	BR (<i>trainbr</i>)
Red optimizacije	Kvazi-drugoredni (Gauss–Newton aproks.)	Prvoredni (konjugovani pravci)	Drugoredni (LM + Bayes regularizacija)
Hesijan matrica	Aproksimacija $\mathbf{J}^T \mathbf{J}$	Ne formira eksplicitno	Aproksimacija $\mathbf{J}^T \mathbf{J}$
Memorijska složenost	$\mathcal{O}(n_w^2)$	$\mathcal{O}(n_w)$	$\mathcal{O}(n_w^2)$
Brzina konvergencije	Vrlo brza (blizu minimuma)	Umerena	Umerena do brza
Broj iteracija	Mali	Veći	Srednji
Osetljivost na šum	Umerena	Relativno stabilna	Niska (automatska regularizacija)
Rizik od preučavanja	Povišen bez early stopping	Umeren	Nizak
Potreba za validacionim skupom	Da (early stopping)	Da	Ne (nije obavezno)
Pogodnost za veće mreže	Ograničena	Visoka	Ograničena
Tipična primena	Manje/srednje mreže	Veće mreže i skupovi podataka	Problemi sa šumom i ograničenim podacima

U okviru sprovedenih eksperimenata za modele M1 i M2, uočene su jasne razlike u ponašanju algoritama u zavisnosti od kompleksnosti mreže i prirode ulaznih podataka.

Kod modela M1, koji se zasniva na regresiji GHI uz naknadnu PR-baziranu evaluaciju energije, *trainlm* je pokazao najbržu konvergenciju i najniže vrednosti validacionog nRMSE kod manjih i srednjih konfiguracija (npr. dvostruki skriveni sloj sa umerenim brojem neurona). Međutim, kod povećanja broja parametara primećena je veća varijabilnost između ponavljanja, što ukazuje na osetljivost LM pristupa na inicijalizaciju i šum u podacima.

Algoritam *trainscg* pokazao je stabilnije ponašanje kod većih konfiguracija mreže i tokom sistematske grid-search optimizacije, uz nešto sporiju konvergenciju. Zbog nižih memorijskih zahteva, SCG se pokazao pogodnim za testiranje većeg broja arhitektura bez degradacije računarskih performansi.

Kod modela M2, koji integriše simulacione (PVsyst) i merene podatke kroz duži vremenski horizont (2005–2022), *trainbr* je pokazao najstabilnije performanse u smislu generalizacije na nezavisnom test skupu. Automatska adaptacija regularizacionih parametara rezultovala je manjim sezonskim bias-om i nižom varijansom greške u uslovima povećane meteorološke varijabilnosti.

U celini, dobijeni rezultati potvrđuju da ne postoji univerzalno najbolji algoritam, već da izbor zavisi od kompromisa između brzine konvergencije, memorijskih zahteva i stabilnosti generalizacije. U kontekstu ove disertacije, *trainlm* je optimalan za brzu optimizaciju manjih modela, *trainscg* za skalabilnu pretragu hiperparametara, dok *trainbr* pruža najpouzdaniju generalizaciju u energetskim prognozama zasnovanim na heterogenim meteorološkim podacima.



C. Definicije korišćenih metrika

U cilju kvantitativne evaluacije performansi predloženih modela za predikciju GHI i posrednu procenu proizvodnje električne energije PV sistema, u ovom istraživanju korišćen je skup standardnih metričkih pokazatelja greške. Izbor metrika zasnovan je na njihovoj širokoj primeni u relevantnoj literaturi, interpretabilnosti u inženjerskom kontekstu i mogućnosti direktnog poređenja različitih modela i studija.

Srednja apsolutna greška (MAE)

Srednja apsolutna greška (Mean Absolute Error, MAE) definiše se kao aritmetička sredina apsolutnih razlika između predviđenih i referentnih vrednosti:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|, \quad (\text{C.1})$$

gde y_i predstavlja referentnu (merenu) vrednost, \hat{y}_i predviđenu vrednost modela, a N ukupan broj uzoraka.

MAE predstavlja intuitivnu i lako interpretabilnu meru prosečne greške, izraženu u istim fizičkim jedinicama kao i posmatrana veličina (W/m^2 za GHI, odnosno Wh za energiju). Ova metrika je robusna na pojedinačne ekstremne greške i pruža realističnu procenu tipičnog odstupanja modela u svakodnevnim operativnim uslovima.

Srednja kvadratna greška (RMSE)

Srednja kvadratna greška (Root Mean Square Error, RMSE) definiše se kao:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2}. \quad (\text{C.2})$$

Za razliku od MAE, RMSE kvadrira pojedinačna odstupanja, čime daje veću težinu velikim greškama. Zbog toga je RMSE posebno osetljiva na ekstremne greške i korisna za identifikaciju modela koji povremeno generišu značajna odstupanja, što je od posebnog značaja u analizi kratkoročne predikcije solarnog zračenja u uslovima promenljive oblačnosti.

U inženjerskom kontekstu, RMSE se često tumači kao indikator “najgoreg slučaja” u prosečnom smislu, i predstavlja dopunu MAE metričkom pokazatelju.

Srednja greška bias-a (MBE)

Srednja greška bias-a (Mean Bias Error, MBE) definiše se kao:

$$\text{MBE} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i). \quad (\text{C.3})$$

MBE kvantifikuje sistematsku tendenciju modela ka precenjivanju (pozitivna vrednost) ili potcenjivanju (negativna vrednost) referentnih vrednosti. Za razliku od MAE i RMSE, koje mere ukupnu veličinu greške, MBE daje informaciju o smeru greške i od posebnog je značaja u analizi energetskog bilansa, gde čak i mali sistematski bias može dovesti do značajnih odstupanja nakon dugoročne agregacije.

Normalizovane metričke veličine (nMAE, nRMSE, nMBE)

Radi omogućavanja poređenja performansi modela u različitim vremenskim periodima, klimatskim uslovima, kao i sa rezultatima iz literature, u ovom radu korišćene su i normalizovane verzije osnovnih metrika greške:

$$\text{nMAE} = \frac{\text{MAE}}{\bar{y}} \cdot 100\%, \quad \text{nRMSE} = \frac{\text{RMSE}}{\bar{y}} \cdot 100\%, \quad \text{nMBE} = \frac{\text{MBE}}{\bar{y}} \cdot 100\%, \quad (\text{C.4})$$

gde \bar{y} označava srednju vrednost referentne veličine na posmatranom skupu uzoraka.

Normalizacija omogućava izražavanje grešaka u relativnim procentima i olakšava uporednu analizu različitih modela, čak i kada se apsolutne vrednosti zračenja ili energije značajno razlikuju. Međutim, treba napomenuti da normalizovane metrike zavise od izbora referentne skale i skupa uzoraka, pa se u ovom radu uvek interpretiraju u kombinaciji sa apsolutnim metričkim pokazateljima.

Primena metrika u analizi energetskog bilansa

U analizi proizvodnje električne energije, iste metričke veličine (MAE, RMSE, MBE i njihove normalizovane forme) primenjene su na satne, dnevne i mesečne vrednosti proizvedene energije. Ovakav pristup omogućava sagledavanje propagacije grešaka iz domene predikcije solarnog zračenja u energetski domen, kao i analizu efekta vremenske agregacije na smanjenje stohastičke komponente greške.

Posebno je važno istaći da se u ovom radu metričke veličine u energetskom domenu ne koriste isključivo za rangiranje modela, već prvenstveno za analizu fizičke konzistentnosti predloženog modelskog okvira i razumevanje odnosa između greške predikcije GHI i ukupnog energetskog bilansa PV sistema.

Tabela C.1: *Metrike i evaluacioni kriterijumi korišćeni za procenu performansi ANN modela*

Metod / metrika	Definicija	Jedinica	Napomena / standard
MAE	Srednja apsolutna greška između predviđenih i referentnih vrednosti	kWh / W	Intuitivna metrika ukupne greške; preporučena u IEC 61724-1
RMSE	Kvadratni koren srednje kvadratne greške, naglašava veća odstupanja	kWh / W	Osetljiva na ekstreme; pogodna za analizu varijabilnosti
nRMSE	Normalizovana RMSE u odnosu na srednju ili nazivnu vrednost	%	Omogućava poređenje između sistema različitih snaga
MBE (Bias)	Srednja potpisana greška (sistematsko odstupanje)	kWh / W	Indikator sistematskog precenjivanja ili potcenjivanja
nMBE	Normalizovana srednja potpisana greška	%	IEC-kompatibilna metrika za dugoročne analize



D. PR-bazirani model

Naziv *PR-bazirani model* potiče od pojma *Performance Ratio* (PR), koji predstavlja standardni indikator performansi fotonaponskog sistema definisan u međunarodnim standardima (IEC 61724-1). PR opisuje odnos između stvarno proizvedene električne energije sistema i teorijski raspoložive energije koja bi bila proizvedena u idealnim uslovima pri nominalnoj instaliranoj snazi.

Formalno, PR se može zapisati kao:

$$PR = \frac{E_{AC}}{P_{nom} \frac{H_{POA}}{G_{ref}}}, \quad (D.1)$$

gde su:

- E_{AC} – proizvedena električna energija sistema,
- P_{nom} – nominalna instalirana snaga PV sistema,
- H_{POA} – ukupna ozračenost na ravni modula,
- $G_{ref} = 1000 \text{ W/m}^2$ – referentno zračenje pri standardnim testnim uslovima (STC).

PR predstavlja agregirani faktor koji obuhvata ukupne systemske gubitke PV postrojenja, uključujući gubitke usled temperature modula, invertora, kablova, nesavršenog MPPT praćenja, prljanja modula, kao i druge operativne faktore. Tipične vrednosti PR faktora za dobro projektovane sisteme kreću se u opsegu 0.75–0.90.

Na osnovu ove definicije moguće je konstruisati jednostavan empirijsko–fizički model koji povezuje solarno zračenje i izlaznu energiju sistema. U okviru ovog modela najpre se procenjuje trenutna izlazna snaga PV sistema:

$$P_{PV}(t) = PR \cdot P_{nom} \cdot \frac{GHI(t)}{G_{ref}}, \quad (D.2)$$

dok se energija proizvedena u diskretnom vremenskom koraku Δt dobija integracijom snage u posmatranom vremenskom intervalu.

Osnovna formulacija

Energija proizvedena u diskretnom vremenskom koraku Δt može se zapisati kao

$$E_{PV}(t) = PR \cdot P_{nom} \cdot \frac{GHI(t)}{G_{ref}} \cdot \Delta t \quad (D.3)$$

gde je $G_{ref} = 1000 \text{ W/m}^2$.

U ovom radu koristi se GHI kao ulazna veličina, dok parametar PR implicitno apsorbuje razliku između horizontalnog zračenja i zračenja na ravni modula, kao i druge sistemske gubitke. Ovakav pristup omogućava jednostavnu i računski efikasnu konverziju predviđenog $GHI(t)$ u energiju PV sistema.

Temperaturna zavisnost snage PV modula

Efikasnost i izlazna snaga PV modula značajno zavise od temperature solarnih ćelija. Standardni linearni model korekcije snage definisan je kao

$$P(T_c) = P_{STC} [1 + \gamma_P (T_c - T_{ref})] \quad (\text{D.4})$$

gde su:

- T_c – temperatura solarne ćelije [$^{\circ}\text{C}$],
- $T_{ref} = 25^{\circ}\text{C}$ – referentna temperatura (STC),
- γ_P – temperaturni koeficijent snage [$1/^{\circ}\text{C}$],
- P_{STC} – nominalna snaga pri STC uslovima.

Za c-Si PV module tipične vrednosti temperaturnog koeficijenta su: $\gamma_P \approx -0.0035$ do -0.005 K^{-1} .

Procena temperature ćelije

U odsustvu direktnog merenja temperature ćelije koristi se pojednostavljeni NOCT model:

$$T_c(t) = T_a(t) + \frac{NOCT - 20}{800} \cdot GHI(t) \quad (\text{D.5})$$

gde su:

- T_a – temperatura ambijenta [$^{\circ}\text{C}$],
- $NOCT$ – nominalna radna temperatura ćelije [$^{\circ}\text{C}$].

Tipične vrednosti su: $NOCT = 42\text{--}48^{\circ}\text{C}$.

PR model sa temperaturnom korekcijom

Uključivanjem temperaturne korekcije konačni model energije PV sistema postaje:

$$E_{PV}(t) = PR \cdot P_{nom} \cdot \frac{GHI(t)}{G_{ref}} \cdot [1 + \gamma_P (T_c(t) - T_{ref})] \cdot \Delta t \quad (\text{D.6})$$

Za satnu rezoluciju ($\Delta t = 1 \text{ h}$) dobija se:

$$E_{PV}(t) = PR \cdot P_{nom} \cdot \frac{GHI(t)}{1000} \cdot [1 + \gamma_P (T_c(t) - 25)]. \quad (\text{D.7})$$

Ukupna energija u periodu T

$$E_{PV,T} = \sum_{t \in T} PR \cdot P_{nom} \cdot \frac{GHI(t)}{1000} \cdot [1 + \gamma_P (T_c(t) - 25)] \quad (\text{D.8})$$



E. Persistence i Scaled Persistence modeli

U cilju objektivne evaluacije performansi razvijenih modela zasnovanih na ANN, kao referentni modeli korišćeni su klasični *persistence* i *scaled persistence* modeli. Ovi modeli predstavljaju standardne bazne pristupe u kratkoročnom predviđanju solarne iradijancije i proizvodnje PV sistema, posebno za horizonte prognoze reda jednog sata.

Persistence model

Persistence model polazi od pretpostavke da će buduća vrednost GHI biti jednaka trenutno izmerenoj vrednosti. Za horizont prognoze H model se definiše kao:

$$\hat{GHI}_{\text{pers}}(t + H) = GHI(t). \quad (\text{E.1})$$

Za najčešće korišćen horizont $H = 1$ h, relacija se svodi na:

$$\hat{GHI}_{\text{pers}}(t + 1) = GHI(t). \quad (\text{E.2})$$

Ovaj model se često naziva i *naive* ili *last value carried forward* model. Iako je konceptualno jednostavan, persistence model predstavlja izuzetno snažan referentni kriterijum za vrlo kratkoročne prognoze, posebno u stabilnim meteorološkim uslovima.

U energetskom domenu, prognozirana iradijancija se propagira kroz isti PR-zasnovani model konverzije kao i ANN prognoza:

$$\hat{E}_{\text{pers}}(t + H) = P_{\text{nom}} \cdot \frac{\hat{GHI}_{\text{pers}}(t + H)}{1000} \cdot PR \cdot \Delta t, \quad (\text{E.3})$$

čime se obezbeđuje metodološka konzistentnost prilikom poređenja sa naprednim modelima.

Scaled Persistence model

Klasični persistence model ne uzima u obzir promenu položaja Sunca između trenutka t i $t + H$. Zbog toga se u literaturi često koristi tzv. *scaled persistence* model, koji uvodi korekciju zasnovanu na promeni očekivane (clear-sky) iradijancije.

Neka je $GHI_{\text{cs}}(t)$ clear-sky globalna horizontalna iradijancija (određena na osnovu solarne geometrije

i atmosferskog modela). Tada se scaled persistence definiše kao:

$$\hat{GHI}_{sp}(t+H) = GHI(t) \cdot \frac{GHI_{cs}(t+H)}{GHI_{cs}(t)}. \quad (E.4)$$

Na taj način se trenutna izmerena vrednost skaluje u skladu sa promenom teorijski očekivanog clear-sky nivoa zračenja.

U slučajevima kada je $GHI_{cs}(t)$ vrlo mala (npr. tokom izlaska ili zalaska Sunca), uvodi se numerička zaštita:

$$\hat{GHI}_{sp}(t+H) = 0 \quad \text{za} \quad GHI_{cs}(t) < \varepsilon, \quad (E.5)$$

gde je ε mala pozitivna konstanta.

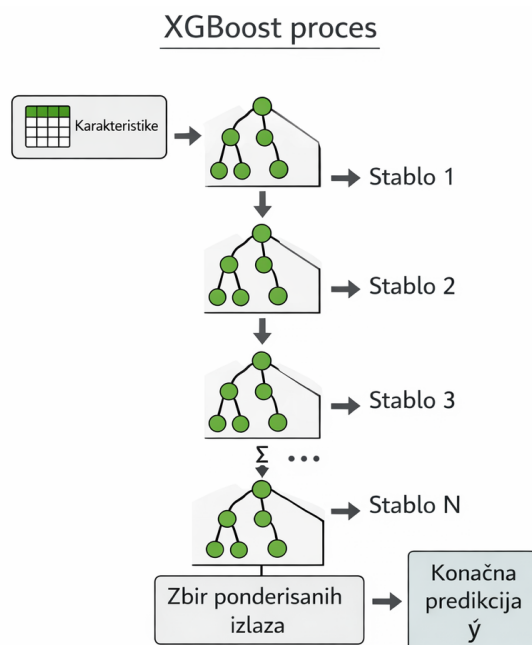
Analogno persistence modelu, scaled persistence prognoza se u energetskom domenu propagira kroz isti PR model konverzije:

$$\hat{E}_{sp}(t+H) = P_{nom} \cdot \frac{\hat{GHI}_{sp}(t+H)}{1000} \cdot PR \cdot \Delta t. \quad (E.6)$$

F. XGBoost model

Ovaj prilog prikazuje formalnu osnovu algoritma *Extreme Gradient Boosting* (XGBoost), koji pripada klasi ansambl metoda zasnovanih na sekvencijalnom pojačavanju (*boosting*) regresionih stabala. U okviru disertacije XGBoost je korišćen kao nezavisni referentni model radi poređenja sa MLP pristupom i provere robusnosti zaključaka.

Ansambl stabala i aditivni model



Slika F.1: Šematski prikaz principa XGBoost modela zasnovanog na sekvencijalnom dodavanju regresionih stabala i aditivnoj kombinaciji njihovih izlaza.

Na slici F.1 prikazan je osnovni princip rada XGBoost algoritma, pri čemu se konačna predikcija formira kao ponderisani zbir izlaza više regresionih stabala, treniranih sekvencijalno uz regularizovanu optimizaciju funkcije gubitka.

Neka je $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^N$ skup podataka. XGBoost formira predikciju kao zbir K regresionih stabala:

$$\hat{y}_i = \sum_{k=1}^K f_k(\mathbf{x}_i), \quad f_k \in \mathcal{F}, \quad (\text{F.1})$$

gde \mathcal{F} označava prostor regresionih stabala. Svako stablo mapira ulaz u jedan od listova, pri čemu list nosi težinu w (skalarni izlaz).

Regularizovana funkcija cilja

XGBoost minimizuje regularizovani cilj:

$$\mathcal{L} = \sum_{i=1}^N l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k), \quad (\text{F.2})$$

gde je $l(\cdot)$ konveksna funkcija gubitka (npr. kvadratna greška za regresiju), a $\Omega(\cdot)$ regularizacioni član koji penalizuje složenost stabla:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2, \quad (\text{F.3})$$

pri čemu je T broj listova stabla, w_j težina j -tog lista, dok γ i λ kontrolišu penalizaciju složenosti i L2 regularizaciju.

Sekvencijalno učenje i Taylorova aproksimacija

Model se gradi iterativno. U iteraciji t , dodaje se novo stablo f_t tako da:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i). \quad (\text{F.4})$$

Ciljna funkcija se aproksimira do drugog reda Taylorove ekspanzije oko $\hat{y}_i^{(t-1)}$:

$$\mathcal{L}^{(t)} \approx \sum_{i=1}^N \left[l(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t(\mathbf{x}_i)^2 \right] + \Omega(f_t), \quad (\text{F.5})$$

gde su g_i i h_i prvi i drugi izvod gubitka:

$$g_i = \left. \frac{\partial l(y_i, \hat{y})}{\partial \hat{y}} \right|_{\hat{y}=\hat{y}_i^{(t-1)}}, \quad h_i = \left. \frac{\partial^2 l(y_i, \hat{y})}{\partial \hat{y}^2} \right|_{\hat{y}=\hat{y}_i^{(t-1)}}. \quad (\text{F.6})$$

Dobitak pri grananju stabla

Za konkretno stablo, uzorci se grupišu po listovima. Za list j definišu se sume gradijenata i Hessiana:

$$G_j = \sum_{i \in I_j} g_i, \quad H_j = \sum_{i \in I_j} h_i, \quad (\text{F.7})$$

gde je I_j skup indeksa uzoraka u listu j . Optimalna težina lista dobija se kao:

$$w_j^* = -\frac{G_j}{H_j + \lambda}. \quad (\text{F.8})$$

Dobitak (*gain*) pri podeli jednog lista na levi i desni potomak iznosi:

$$\text{Gain} = \frac{1}{2} \left(\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda} \right) - \gamma, \quad (\text{F.9})$$

gde indeksi L , R i bez indeksa označavaju leve, desne i roditeljske sume. Podela se prihvata ako je $\text{Gain} > 0$.

Hiperparametri i kontrola složenosti

Performanse i generalizacija XGBoost modela zavise od više hiperparametara, među kojima su:

- `n_estimators` (broj stabala) i `learning_rate` (korak učenja),
- `max_depth` i `min_child_weight` (struktura stabla),
- `subsample` i `colsample_bytree` (stohastičko uzorkovanje),
- λ i γ (regularizacija i penalizacija grananja).

Tipično se koristi validacioni skup i/ili kros-validacija (uz poštovanje vremenske strukture) za izbor optimalne konfiguracije.

Prednosti i ograničenja u kontekstu PV predviđanja

XGBoost je posebno pogodan za modelovanje nelinearnih odnosa i interakcija ulaznih promenljivih, uz visoku robusnost na različite skale ulaza. Međutim, kao i druge ansambl metode, poseduje veći broj hiperparametara i može zahtevati pažljivo podešavanje da bi se izbeglo preprilagođavanje, naročito u prisustvu autokorelisanih vremenskih serija.

U okviru ove disertacije, XGBoost je korišćen kao referentni model, pri čemu su primenjene iste strategije podele podataka i kriterijumi evaluacije kao i za MLP model, čime je obezbeđena objektivna i metodološki konzistentna uporedivost rezultata.



G. Analitička analiza odstupanja metrika bez daylight filtriranja

Formalna dekompozicija agregiranih metrika

Neka je ukupan broj uzoraka T , koji se može razložiti na dnevne i noćne uzorke:

$$T = T_d + T_n, \quad (\text{G.1})$$

gde je:

- T_d – broj uzoraka tokom dnevnog režima ($GHI_t > 0$),
- T_n – broj uzoraka tokom noćnog režima ($GHI_t \approx 0$).

Definišimo podskupove:

$$\mathcal{D} = \{t \mid GHI_t > 0\}, \quad \mathcal{N} = \{t \mid GHI_t \approx 0\}. \quad (\text{G.2})$$

Srednja apsolutna greška nad dnevnim i noćnim režimom definiše se kao:

$$\text{MAE}_{day} = \frac{1}{T_d} \sum_{t \in \mathcal{D}} |\hat{y}_t - y_t|, \quad (\text{G.3})$$

$$\text{MAE}_{night} = \frac{1}{T_n} \sum_{t \in \mathcal{N}} |\hat{y}_t - y_t|. \quad (\text{G.4})$$

Ukupna metrika bez daylight filtriranja ima oblik:

$$\text{MAE}_{all} = \frac{T_d}{T} \text{MAE}_{day} + \frac{T_n}{T} \text{MAE}_{night}. \quad (\text{G.5})$$

Analogno važi i za MSE:

$$\text{MSE}_{all} = \frac{T_d}{T} \text{MSE}_{day} + \frac{T_n}{T} \text{MSE}_{night}. \quad (\text{G.6})$$

Strukturalna (analitička) bias-a

U PV sistemima tokom noći važi:

$$y_t \approx 0, \quad \hat{y}_t \approx 0, \quad (\text{G.7})$$

pa je:

$$\overline{\text{MAE}}_{night} \approx 0, \quad \overline{\text{MSE}}_{night} \approx 0. \quad (\text{G.8})$$

Zamenom u prethodnu relaciju dobija se aproksimacija:

$$\overline{\text{MAE}}_{all} \approx \frac{T_d}{T} \overline{\text{MAE}}_{day}. \quad (\text{G.9})$$

Kako je:

$$\frac{T_d}{T} < 1, \quad (\text{G.10})$$

sledi:

$$\overline{\text{MAE}}_{all} < \overline{\text{MAE}}_{day}. \quad (\text{G.11})$$

Dakle, smanjenje agregirane metrike ne predstavlja posledicu poboljšanja modela, već je determinisano samom strukturom ponderisanja grešaka odnosom $\frac{T_d}{T}$. Ova pojava predstavlja analitički determinisan bias, a ne statističku fluktuaciju.

Numerički ilustrativni primer

Razmotrimo godišnji skup sa satnim uzorkovanjem:

$$T = 8760, \quad T_d = 4380, \quad T_n = 4380. \quad (\text{G.12})$$

Neka su dobijene vrednosti:

$$\overline{\text{MAE}}_{day} = 0.08, \quad \overline{\text{MAE}}_{night} = 0.005. \quad (\text{G.13})$$

Tada:

$$\overline{\text{MAE}}_{all} = \frac{4380}{8760} \cdot 0.08 + \frac{4380}{8760} \cdot 0.005 \quad (\text{G.14})$$

$$= 0.5 \cdot 0.08 + 0.5 \cdot 0.005 = 0.0425. \quad (\text{G.15})$$

Odnos agregirane i dnevne metrike iznosi:

$$\frac{\overline{\text{MAE}}_{all}}{\overline{\text{MAE}}_{day}} = \frac{0.0425}{0.08} \approx 0.53, \quad (\text{G.16})$$

što znači da agregirana metrika daje približno 47% nižu vrednost greške u odnosu na realni režim proizvodnje.



H. Multilayer Perceptron (MLP) model

U prilogu je data sažeta, ali formalno utemeljenu teorijsku i matematičku osnovu *Multilayer Perceptron* (MLP) neuronskih mreža korišćenih u okviru ove disertacije. Ovi se izbegava opterećivanje osnovnog metodološkog poglavlja, a ključne definicije, relacije i aspekti treninga i regularizacije se dostupni na jednom mestu radi reproduktivnosti i jasne interpretacije.

Problem regresije i notacija

Posmatra se nadgledani regresioni problem u kome se, za dati uzorak k , ulazni vektor $\mathbf{x}(k) \in \mathbb{R}^n$ mapira u skalarni izlaz $y(k+H) \in \mathbb{R}$, pri čemu je H horizont predviđanja. Model generiše procenu $\hat{y}(k+H)$ prema mapi:

$$f_{\theta} : \mathbb{R}^n \rightarrow \mathbb{R}, \quad \hat{y}(k+H) = f_{\theta}(\mathbf{x}(k)), \quad (\text{H.1})$$

gde θ označava skup svih parametara (težina i bias).

Arhitektura MLP mreže

Na slici H.1 prikazana je tipična arhitektura MLP mreže koja je korišćena u ovom radu. Mreža je organizovana kao *feedforward* struktura bez povratnih veza, pri čemu se informacije propagiraju isključivo od ulaznog ka izlaznom sloju.

MLP je *feedforward* neuronska mreža sastavljena od ulaznog sloja, jednog ili više skrivenih slojeva i izlaznog sloja. Za mrežu sa L skrivenih slojeva, neka su dimenzije slojeva date sa $n_0 = n$, n_1, \dots, n_L , i $n_{L+1} = 1$. Rekurzivno se definišu aktivacije:

$$\mathbf{a}_0 = \mathbf{x}, \quad (\text{H.2})$$


$$\mathbf{z}_{\ell} = \mathbf{W}_{\ell} \mathbf{a}_{\ell-1} + \mathbf{b}_{\ell}, \quad \ell = 1, \dots, L, \quad (\text{H.3})$$

$$\mathbf{a}_{\ell} = \phi(\mathbf{z}_{\ell}), \quad \ell = 1, \dots, L, \quad (\text{H.4})$$

$$\hat{y} = \mathbf{W}_{L+1} \mathbf{a}_L + b_{L+1}, \quad (\text{H.5})$$

gde su $\mathbf{W}_{\ell} \in \mathbb{R}^{n_{\ell} \times n_{\ell-1}}$ matrice težina, $\mathbf{b}_{\ell} \in \mathbb{R}^{n_{\ell}}$ vektori bias-a, a $\phi(\cdot)$ nelinearna aktivaciona funkcija (npr. *tanh*, *ReLU* ili *sigmoid*). Za regresiju se izlazni sloj tipično uzima linearan.

Multilayer Perceptron (MLP)



Slika H.1: Šematski prikaz strukture višeslojnog perceptrona (MLP) sa ulaznim, skrivenim i izlaznim slojem.

Broj parametara i složenost

Ukupan broj treniranih parametara u MLP mreži sa L skrivenih slojeva iznosi:

$$N_{\text{param}} = \sum_{\ell=1}^{L+1} (n_{\ell} n_{\ell-1} + n_{\ell}), \quad (\text{H.6})$$

što direktno utiče na memorijske zahteve i rizik od preprilagođavanja (*overfitting*), posebno kod velikih ulaznih dimenzija i dubokih mreža.

Funkcija gubitka i trening

Za skup uzoraka $\{(\mathbf{x}_i, y_i)\}_{i=1}^N$, standardna funkcija gubitka za regresiju je srednja kvadratna greška (MSE):

$$\mathcal{L}_{\text{MSE}}(\theta) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (\text{H.7})$$

Trening se sprovodi minimizacijom \mathcal{L} po parametrima θ , pri čemu se gradijenti računaju algoritmom *backpropagation*. U praktičnoj implementaciji mogu se koristiti različiti optimizacioni algoritmi (npr. varijante gradijentnog spusta, konjugovani gradijenti ili Levenberg–Marquardt).

Regularizacija i kontrola generalizacije

Da bi se smanjio rizik od preprilagođavanja, često se uvodi regularizacija. Klasična L2 regularizacija dodaje kazneni član:

$$\mathcal{L}(\theta) = \mathcal{L}_{\text{MSE}}(\theta) + \lambda \|\theta\|_2^2, \quad (\text{H.8})$$

gde $\lambda > 0$ kontroliše jačinu regularizacije. Dodatno, *early stopping* koristi validacioni skup i zaustavlja trening kada se performanse na validaciji više ne poboljšavaju.

Praktične napomene o pripremi podataka

Pre treninga MLP modela tipično se primenjuju:

- standardizacija ili normalizacija ulaza (radi stabilnijeg učenja),
- obrada nedostajućih vrednosti i filtriranje nekonzistentnih uzoraka,
- striktna hronološka podela skupa podataka (trening/validacija/test) radi izbegavanja curenja informacija,
- maskiranje noćnih i niskozračenih perioda u skladu sa definisanim kriterijumima evaluacije.

U disertaciji je MLP korišćen kao bazni nelinearni regresor, a detalji implementacije (skripte, podešavanja i parametri) dati su u odgovarajućem prilogu sa kodom radi potpune reproduktivnosti.

I. Implementacija modela M1-A1 u MATLAB okruženju

U ovom prilogu prikazana kompletna MATLAB skripta korišćena za treniranje i evaluaciju modela M1-A1. Implementacija obuhvata pripremu podataka, formiranje ulaznog vektora, podelu skupa podataka, trening ANN modela, generisanje predikcije i izračunavanje metrika performansi.

```
1 %% =====
2 % ANN M1 - A1 (BASE) : GHI forecasting + PR-based PV energy proxy
3 %
4 % Goal:
5 % 1) Train an ANN forecaster for GHI (W/m^2) with horizon H hours ahead
6 % using meteorological + time-cyclic features from Data_2005_2022.
7 % 2) Convert predicted GHI to PR-based hourly PV energy (Wh) for the
8 % experimental PV system.
9 % 3) Where measured PV data exist (Measured_Data, 2018-2022), evaluate
10 % PR-energy derived from predicted GHI vs measured PV energy.
11 %
12 % Data:
13 % - Meteo (2005-2022): Data_2005_2022.[xlsx|csv] (23 columns)
14 % - Measured PV (2018-2022): any .xlsx/.csv in ./Measured_Data/
15 %
16 % Outputs:
17 % - Figures saved to ./Results_M1_A1/Run_yyyymmdd_HHMMSS/
18 % - .mat with model + metrics + aligned timetables
19 % - .xlsx export of aligned evaluation table (optional)
20 %
21 % Notes:
22 % - Daylight mask is applied at TARGET time (k+H) using GHI & zenith (if available).
23 % - Normalization uses TRAIN ONLY (no leakage).
24 % - This is the BASE A1 model.
25 %
26 %% =====
27
28 clear; clc; close all;
29
30 %% =====
31 % Publication Figure Style
32 %% =====
33 set(groot, 'defaultAxesFontName', 'Times New Roman');
34 set(groot, 'defaultTextFontName', 'Times New Roman');
35 set(groot, 'defaultAxesFontSize', 11);
36 set(groot, 'defaultTextFontSize', 11);
37 set(groot, 'defaultAxesLineWidth', 1);
38 set(groot, 'defaultLineLineWidth', 1.2);
39 set(groot, 'defaultFigureColor', 'w');
40 set(groot, 'defaultAxesBox', 'on');
41 set(groot, 'defaultAxesXGrid', 'on');
42 set(groot, 'defaultAxesYGrid', 'on');
43 set(groot, 'defaultAxesXMinorGrid', 'on');
44 set(groot, 'defaultAxesYMinorGrid', 'on');
45
46 %% =====
47 % CFG (edit here)
48 %% =====
49 CFG = struct();
50
51 % Files / folders
```

```

52 CFG.meteoFile      = 'Data_2005_2022.xlsx';      % or .csv
53 CFG.measuredFile  = 'Mereno_Data_2018_2022.xlsx'; % optional single measured file (preferred)
54 CFG.pvsystFile    = 'PVsyst_NewData_2005_2022.csv'; % optional PVsyst export (hourly)
55
56 % Auto-detect measured/pvsyst files in the current folder if names differ
57 if exist(CFG.measuredFile,'file')~=2
58 d = dir(fullfile(pwd, 'Mereno_Data_2018_2022.*'));
59 if ~isempty(d), CFG.measuredFile = d(1).name; end
60 end
61 if exist(CFG.pvsystFile,'file')~=2
62 d = dir(fullfile(pwd, 'PVsyst_NewData_2005_2022.*'));
63 if ~isempty(d), CFG.pvsystFile = d(1).name; end
64 end
65
66 CFG.measuredFolder = fullfile(pwd, 'Measured_Data'); % folder with measured PV files
67
68 %% =====
69 % 0) INPUT PARAMETERS
70 %% =====
71
72 % Forecast horizon (hours ahead)
73 CFG.H = 1;
74
75 % Time split (strict chronological)
76 CFG.trainYears = [2005 2020];
77 CFG.valYear    = 2021;
78 CFG.testYear   = 2022;
79
80 % Daylight filtering (at target time)
81 CFG.GHI_day_th = 20; % W/m^2
82 CFG.Zen_max    = 85; % deg (if zenith available)
83 CFG.useZenMask = true; % will auto-disable if zenith missing
84
85 % ANN config (BASE A1)
86 CFG.hidden     = [20 10]; % baseline; adjust later
87 CFG.trainFcn   = 'trainscg'; % 'trainbr' often good but slower; 'trainlm' memory-heavy
88 CFG.maxEpoch  = 350;
89 CFG.maxFail    = 15;
90 CFG.rngSeed    = 1;
91
92 % PR-based PV proxy (experimental system)
93 % If you know your system parameters, set them here:
94 CFG.Pnom_W     = 1000; % nominal DC power [W] (set to your experimental PV rating)
95 CFG.eta_sys    = 0.90; % lumped efficiency (optional)
96 CFG.PR_default = 0.80; % default PR if calibration not possible
97 CFG.dt_h       = 1; % hourly sampling -> Wh
98
99 % Optional: calibrate a single effective PR from measured PV (2018-2022)
100 CFG.calibratePR_fromMeasured = true;
101 CFG.PR_clip = [0 1.2]; % physically plausible bounds for estimated PR_eff
102
103 % Measured evaluation window
104 CFG.evalYears = [2018 2022]; % inclusive (used when intersecting measured data)
105
106 % Output directory
107 CFG.outRoot = fullfile(pwd, 'Results_M1_A1');
108 CFG.runTag  = datestr(now, 'yyymmdd_HHMMSS');
109 PLOT_DIR   = fullfile(CFG.outRoot, ['Run_' CFG.runTag]);
110 if ~exist(PLOT_DIR,'dir'); mkdir(PLOT_DIR); end
111 fprintf(['INFO Saving figures to: %s\n', PLOT_DIR]);
112
113 %% =====
114 % 1) Load METEO (Data_2005_2022) -> TTmet timetable (M01..M23)
115 %% =====
116 TTmet = loadMeteo23(CFG.meteoFile);
117
118 fprintf(['OK TTmet: %d samples (%s -> %s)\n', height(TTmet), ...
119 datestr(TTmet.Properties.RowTimes(1)), datestr(TTmet.Properties.RowTimes(end))]);
120
121 % Convenience aliases (based on your established column mapping)
122 % M06 Temp, M09 ClearskyGHI, M10 CloudType, M12 DHI, M13 DNI, M15 GHI,
123 % M16 RH, M17 Zenith, M18 Alb, M19 Press, M20 PW,
124 % M22 WindSpeed, M23 Azimuth
125 hasZen = ismember('M17', string(TTmet.Properties.VariableNames));
126 if ~hasZen
127 CFG.useZenMask = false;
128 fprintf(['WARN Zenith (M17) missing -> disabling zenith mask.\n']);
129 end
130
131 %% =====
132 % 2) Build A1 feature space + supervised mapping X(k)->GHI(k+H)
133 %% =====
134 H = CFG.H;
135 t = TTmet.Properties.RowTimes;
136
137 % Time cyclic features (A1)
138 DOY = day(t, 'dayofyear');
139 Hr = hour(t);

```

```

140
141 DOY_sin = sin(2*pi*DOY/365);
142 DOY_cos = cos(2*pi*DOY/365);
143 Hour_sin = sin(2*pi*Hr/24);
144 Hour_cos = cos(2*pi*Hr/24);
145
146 % Core meteo features (consistent with your older A1 scripts)
147 req = ["M06","M22","M16","M19","M20","M18","M17","M23","M10","M13","M12","M09","M15"];
148 missing = req(~ismember(req, string(TTmet.Properties.VariableNames)));
149 assert isempty(missing) || (numel(missing)==1 && missing=="M17"), ...
150 'TTmet missing required variables: %s', strjoin(missing, ', ');
151
152 Temp = getVar(TTmet,'M06');
153 W_speed = getVar(TTmet,'M22');
154 RH = getVar(TTmet,'M16');
155 Press = getVar(TTmet,'M19');
156 PW = getVar(TTmet,'M20');
157 Alb = getVar(TTmet,'M18');
158 Zen = getVar(TTmet,'M17'); % may be NaN if missing
159 Azi = getVar(TTmet,'M23');
160 CloudType = getVar(TTmet,'M10');
161 DNI = getVar(TTmet,'M13');
162 DHI = getVar(TTmet,'M12');
163 GHI_cs = getVar(TTmet,'M09');
164 GHI_meas = getVar(TTmet,'M15');
165
166 X_all = [ ...
167 DOY_sin, DOY_cos, Hour_sin, Hour_cos, ...
168 Temp, W_speed, RH, Press, PW, Alb, ...
169 Zen, Azi, CloudType, ...
170 DNI, DHI, GHI_cs ...
171 ];
172
173 y_all = GHI_meas;
174
175 % Clean NaN/Inf
176 ok = all(isfinite(X_all),2) & isfinite(y_all) & isfinite(t);
177 X_all = X_all(ok,:); y_all = y_all(ok);
178 t = t(ok);
179 GHI_cs = GHI_cs(ok);
180 Zen = Zen(ok);
181
182 assert(numel(y_all) > H+100, 'Not enough samples after cleaning for H=%d.', H);
183
184 % Supervised shift: X(k) predicts GHI at k+H
185 idx = (1:(numel(y_all)-H))';
186 X = X_all(idx,:);
187 y = y_all(idx+H);
188 t_y = t(idx+H);
189
190 % Daylight mask at target time
191 Zen_y = Zen(idx+H);
192 GHIcs_y = GHI_cs(idx+H);
193
194 isDay = (y > CFG.GHI_day_th) & (GHIcs_y > CFG.GHI_day_th);
195 if CFG.useZenMask
196 isDay = isDay & (Zen_y < CFG.Zen_max);
197 end
198
199 X = X(isDay,:); y = y(isDay); t_y = t_y(isDay);
200
201 fprintf('[OK] Supervised samples (day targets): %d\n', numel(y));
202
203 %% =====
204 % 3) Strict time split
205 %% =====
206 yr = year(t_y);
207 iTr = (yr >= CFG.trainYears(1) & yr <= CFG.trainYears(2));
208 iVa = (yr == CFG.valYear);
209 iTe = (yr == CFG.testYear);
210
211 assert(any(iTr) && any(iVa) && any(iTe), 'Empty split after filtering.');
```

```

228
229     rng(CFG.rngSeed);
230
231     net = fitnet(CFG.hidden, CFG.trainFcn);
232     net.performFcn = 'mse';
233     net.trainParam.epochs = CFG.maxEpoch;
234     net.trainParam.max_fail = CFG.maxFail;
235
236     % Force our split (train + val)
237     net.divideFcn = 'divideind';
238     net.divideParam.trainInd = 1:size(Xtrn,1);
239     net.divideParam.valInd = (size(Xtrn,1)+1):(size(Xtrn,1)+size(Xvan,1));
240     net.divideParam.testInd = [];
241
242     Xcat = [Xtrn; Xvan]';
243     ycat = [ytr; yva]';
244
245     fprintf('[INFO] Training ANN: hidden=%s, trainFcn=%s, epochs=%d\n', mat2str(CFG.hidden),
246           CFG.trainFcn, CFG.maxEpoch);
247     net = train(net, Xcat, ycat);
248
249     %% =====
250     % 5) Predict + GHI metrics
251     %% =====
252     GHI_max_phys = 1400;
253
254     yhat_tr = clamp(net(Xtrn)'), 0, GHI_max_phys);
255     yhat_va = clamp(net(Xvan)'), 0, GHI_max_phys);
256     yhat_te = clamp(net(Xten)'), 0, GHI_max_phys);
257
258     metric_block = @(yt,yp) struct( ...
259         'MAE', mean(abs(yp-yt),'omitnan'), ...
260         'RMSE', sqrt(mean((yp-yt).^2,'omitnan')), ...
261         'MBE', mean(yp-yt,'omitnan'), ...
262         'nMAE_pct', 100*mean(abs(yp-yt),'omitnan')/max(mean(yt,'omitnan'),1e-9), ...
263         'nRMSE_pct', 100*sqrt(mean((yp-yt).^2,'omitnan'))/max(mean(yt,'omitnan'),1e-9), ...
264         'nMBE_pct', 100*mean(yp-yt,'omitnan')/max(mean(yt,'omitnan'),1e-9) ...
265     );
266
267     M_GHI_tr = metric_block(ytr, yhat_tr);
268     M_GHI_va = metric_block(yva, yhat_va);
269     M_GHI_te = metric_block(yte, yhat_te);
270
271     disp('=== M1--A1 metrics (GHI, daytime targets) ===');
272     disp(table( ...
273         ["Train";"Val";"Test"], ...
274         [M_GHI_tr.MAE; M_GHI_va.MAE; M_GHI_te.MAE], ...
275         [M_GHI_tr.RMSE; M_GHI_va.RMSE; M_GHI_te.RMSE], ...
276         [M_GHI_tr.MBE; M_GHI_va.MBE; M_GHI_te.MBE], ...
277         [M_GHI_tr.nRMSE_pct; M_GHI_va.nRMSE_pct; M_GHI_te.nRMSE_pct], ...
278         [M_GHI_tr.nMBE_pct; M_GHI_va.nMBE_pct; M_GHI_te.nMBE_pct], ...
279         'VariableNames', {'Split','MAE','RMSE','MBE','nRMSE_pct','nMBE_pct'}));
280
281     %% =====
282     % 5b) Persistence baseline (GHI) for the same targets (k+H)
283     % Definition: GHI_pers(t_y) = GHI_meas(t_y - H)
284     %% =====
285     % Build persistence prediction aligned with y, then split using the same indices
286     % We must reconstruct the aligned "previous" measured GHI at (t_y - H).
287     % Since y is built from y_all(idx+H) after filtering, we can approximate by using
288     % the measured GHI at idx time (before shift) and then applying the same day-mask.
289
290     % Recompute persistence on the pre-filtered supervised arrays
291     y_pers_all = y_all(idx); % GHI_meas at time k predicts target at k+H
292     y_pers = y_pers_all(isDay); % apply same day-target mask
293
294     % Split persistence predictions
295     yhat_pers_tr = y_pers(iTr);
296     yhat_pers_va = y_pers(iVa);
297     yhat_pers_te = y_pers(iTe);
298
299     % Clamp
300     yhat_pers_tr = clamp(yhat_pers_tr, 0, GHI_max_phys);
301     yhat_pers_va = clamp(yhat_pers_va, 0, GHI_max_phys);
302     yhat_pers_te = clamp(yhat_pers_te, 0, GHI_max_phys);
303
304     M_PERS_tr = metric_block(ytr, yhat_pers_tr);
305     M_PERS_va = metric_block(yva, yhat_pers_va);
306     M_PERS_te = metric_block(yte, yhat_pers_te);
307
308     disp('=== Persistence metrics (GHI, daytime targets) ===');
309     disp(table( ...
310         ["Train";"Val";"Test"], ...
311         [M_PERS_tr.MAE; M_PERS_va.MAE; M_PERS_te.MAE], ...
312         [M_PERS_tr.RMSE; M_PERS_va.RMSE; M_PERS_te.RMSE], ...
313         [M_PERS_tr.MBE; M_PERS_va.MBE; M_PERS_te.MBE], ...

```

```

314 [M_PERS_tr.nRMSE_pct;M_PERS_va.nRMSE_pct;M_PERS_te.nRMSE_pct], ...
315 [M_PERS_tr.nMBE_pct; M_PERS_va.nMBE_pct; M_PERS_te.nMBE_pct], ...
316 'VariableNames', {'Split','MAE','RMSE','MBE','nRMSE_pct','nMBE_pct'}));
317
318 % Improvement (Test)
319 impGHI_nRMSE = 100*(M_PERS_te.nRMSE_pct - M_GHI_te.nRMSE_pct)/max(M_PERS_te.nRMSE_pct,1e-9);
320 impGHI_RMSE = 100*(M_PERS_te.RMSE - M_GHI_te.RMSE )/max(M_PERS_te.RMSE,1e-9);
321 fprintf('[INFO] Test improvement vs persistence: nRMSE %+0.2f%%, RMSE %+0.2f%% (lower is
better)\n', impGHI_nRMSE, impGHI_RMSE);
322
323 % --- Scaled persistence baseline (GHI) ---
324 % Definition (clear-sky scaled persistence):
325 %  $GHI_{sp}(t+H) = GHI(t) * GHI_{cs}(t+H) / GHI_{cs}(t)$ 
326 % Here, GHI_cs is taken directly from the meteo dataset (M09), so no extra clear-sky model is
required.
327
328 % Current-time series aligned with targets y(t+H)
329 GHI_t_all = y_all(idx); % GHI(t)
330 GHIcs_t_all = GHI_cs(idx); % GHI_cs(t)
331 GHIcs_tH_all = GHI_cs(idx+H); % GHI_cs(t+H)
332
333 % Apply the SAME target-time daylight mask as ANN/persistence (isDay refers to target time)
334 GHI_t = GHI_t_all(isDay);
335 GHIcs_t = GHIcs_t_all(isDay);
336 GHIcs_tH = GHIcs_tH_all(isDay);
337
338 eps_cs = 10; % W/m^2 (numerical guard)
339 scale = zeros(size(GHIcs_t));
340 ok_cs = isfinite(GHIcs_t) & isfinite(GHIcs_tH) & (GHIcs_t > eps_cs);
341 scale(ok_cs) = GHIcs_tH(ok_cs) ./ GHIcs_t(ok_cs);
342
343 y_sp = clamp(GHI_t .* scale, 0, GHI_max_phys);
344
345 % Split scaled persistence predictions
346 yhat_sp_tr = y_sp(iTr);
347 yhat_sp_va = y_sp(iVa);
348 yhat_sp_te = y_sp(iTe);
349
350 M_SP_tr = metric_block(ytr, yhat_sp_tr);
351 M_SP_va = metric_block(yva, yhat_sp_va);
352 M_SP_te = metric_block(yte, yhat_sp_te);
353
354 disp('=== Scaled persistence metrics (GHI, daytime targets) ===');
355 disp(table( ...
356 ["Train";"Val";"Test"], ...
357 [M_SP_tr.MAE; M_SP_va.MAE; M_SP_te.MAE], ...
358 [M_SP_tr.RMSE;M_SP_va.RMSE;M_SP_te.RMSE], ...
359 [M_SP_tr.MBE; M_SP_va.MBE; M_SP_te.MBE], ...
360 [M_SP_tr.nRMSE_pct;M_SP_va.nRMSE_pct;M_SP_te.nRMSE_pct], ...
361 [M_SP_tr.nMBE_pct; M_SP_va.nMBE_pct; M_SP_te.nMBE_pct], ...
362 'VariableNames', {'Split','MAE','RMSE','MBE','nRMSE_pct','nMBE_pct'}));
363
364
365 %% =====
366 % 6) Figures - GHI (TEST)
367 %% =====
368 K = min(800, numel(yte));
369
370 % Fig: timeseries preview
371 figure('Units','centimeters','Position',[5 5 16 9]);
372 plot(tte(1:K), yte(1:K), 'LineWidth', 1); hold on;
373 plot(tte(1:K), yhat_te(1:K), 'LineWidth', 1);
374 plot(tte(1:K), yhat_pers_te(1:K), 'LineWidth', 1);
375 plot(tte(1:K), yhat_sp_te(1:K), 'LineWidth', 1);
376 xlabel('Time'); ylabel('GHI [W/m^2]');
377 legend('Measured','ANN','Persistence','Scaled persistence','Location','best');
378 title(sprintf('M1--A1: GHI forecast (Test, H=%dh)', H));
379 grid on; box on;
380 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_GHI_TestPreview_H%dh.png',H)));
381
382 % Fig: scatter
383 figure('Units','centimeters','Position',[5 5 14 12]);
384 scatter(yte, yhat_te, 6, 'filled'); grid on; box on;
385 xlabel('Measured GHI [W/m^2]'); ylabel('Predicted GHI [W/m^2]');
386 title(sprintf('M1--A1: Scatter GHI_{pred} vs GHI_{meas} (Test, H=%dh)', H));
387 hold on;
388 xmax = max(yte);
389 plot([0 xmax],[0 xmax], 'k--', 'LineWidth', 1);
390 hold off;
391 axis equal; xlim([0 xmax]); ylim([0 xmax]);
392 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_GHI_Scatter_H%dh.png',H)));
393
394 % Fig: scatter (persistence)
395 figure('Units','centimeters','Position',[5 5 14 12]);
396 scatter(yte, yhat_pers_te, 6, 'filled'); grid on; box on;
397 xlabel('Measured GHI [W/m^2]'); ylabel('Persistence GHI [W/m^2]');
398 title(sprintf('M1--A1: Persistence scatter (Test, H=%dh)', H));

```

```

399 hold on;
400 xmax = max(yte);
401 plot([0 xmax],[0 xmax], 'k--', 'LineWidth',1);
402 hold off;
403 axis equal; xlim([0 xmax]); ylim([0 xmax]);
404 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_GHI_Scatter_Persistence_H%dh.png',H)));
405
406 % Fig: scatter (scaled persistence)
407 figure('Units','centimeters','Position',[5 5 14 12]);
408 scatter(yte, yhat_sp_te, 6, 'filled'); grid on; box on;
409 xlabel('Measured GHI [W/m^2]'); ylabel('Scaled persistence GHI [W/m^2]');
410 title(sprintf('M1--A1: Scaled persistence scatter (Test, H=%dh)', H));
411 hold on;
412 xmax = max(yte);
413 plot([0 xmax],[0 xmax], 'k--', 'LineWidth',1);
414 hold off;
415 axis equal; xlim([0 xmax]); ylim([0 xmax]);
416 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_GHI_Scatter_ScaledPersistence_H%dh.png',H)));
417
418
419 %% =====
420 % 7) Load measured PV (2018-2022) and align with METEO
421 %% =====
422 TMeas = timetable();
423 if exist(CFG.measuredFile,'file')==2
424 TMeas = loadMeasuredPVFile(CFG.measuredFile);
425 elseif exist(CFG.measuredFolder,'dir')
426 TMeas = loadMeasuredPVFolder(CFG.measuredFolder);
427 else
428 fprintf(' [WARN] Measured file/folder not found: %s (or %s)\n', CFG.measuredFile,
429 CFG.measuredFolder);
430 end
431
432 if ~isempty(TMeas)
433 fprintf(' [OK] Measured PV loaded: %d samples (%s -> %s)\n', height(TMeas), ...
434 datestr(TMeas.Properties.RowTimes(1)), datestr(TMeas.Properties.RowTimes(end)));
435
436 %% =====
437 % 7b) Load PVsyst export (optional) and keep as timetable
438 %% =====
439 TTPvs = timetable();
440 if exist(CFG.pvsystFile,'file')==2
441 TTPvs = loadPVsystHourly(CFG.pvsystFile);
442 fprintf(' [OK] PVsyst loaded: %d samples (%s -> %s)\n', height(TTPvs), ...
443 datestr(TTPvs.Properties.RowTimes(1)), datestr(TTPvs.Properties.RowTimes(end)));
444 else
445 fprintf(' [INFO] PVsyst file not found -> skipping PVsyst benchmark (%s).\n', CFG.pvsystFile);
446 end
447
448 % Restrict to eval window and align meteo (measured GHI) with measured PV
449 t0 = datetime(CFG.evalYears(1),1,1,0,0,0,'TimeZone','');
450 t1 = datetime(CFG.evalYears(2),12,31,23,0,0,'TimeZone','');
451
452 TTmet_eval = TTmet((TTmet.Properties.RowTimes>=t0) & (TTmet.Properties.RowTimes<=t1), :);
453
454 TT_eval = timetable();
455 if ~isempty(TTmeas)
456 TT_eval = synchronize(TTmet_eval, TTmeas, 'intersection');
457 fprintf(' [OK] Intersection TT_eval (meteo + measured): %d samples\n', height(TT_eval));
458 end
459
460 %% =====
461 % 8) PR calibration from measured PV (optional)
462 %% =====
463 PR_used = CFG.PR_default;
464
465 if CFG.calibratePR_fromMeasured && ~isempty(TT_eval)
466 % Need measured hourly energy. If only power is present, approximate energy by P*1h.
467 E_meas_Wh = nan(height(TT_eval),1);
468 if ismember('E_meas_Wh', string(TT_eval.Properties.VariableNames))
469 E_meas_Wh = TT_eval.E_meas_Wh;
470 elseif ismember('P_meas_kW', string(TT_eval.Properties.VariableNames))
471 E_meas_Wh = TT_eval.P_meas_kW * 1000 * CFG.dt_h;
472 end
473
474 GHI_ref = getVar(TT_eval,'M15'); % measured GHI
475 denom = CFG.Pnom_W .* (max(GHI_ref,0)/1000) .* CFG.eta_sys .* CFG.dt_h;
476
477 PR_eff = E_meas_Wh ./ max(denom, 1e-9);
478 PR_eff(~isfinite(PR_eff)) = NaN;
479
480 % Apply daylight filter for PR estimation
481 maskPR = (GHI_ref > CFG.GHI_day_th) & isfinite(PR_eff) & isfinite(E_meas_Wh);
482 if ismember('M17', string(TT_eval.Properties.VariableNames)) && CFG.useZenMask
483 maskPR = maskPR & (TT_eval.M17 < CFG.Zen_max);
484 end
485

```

```

486 PR_eff = PR_eff(maskPR);
487 PR_eff = clamp(PR_eff, CFG.PR_clip(1), CFG.PR_clip(2));
488
489 if numel(PR_eff) > 200
490 PR_used = median(PR_eff, 'omitnan');
491 fprintf('[OK] PR calibrated from measured data: PR=%.3f (median over %d hours)\n', PR_used,
numel(PR_eff));
492 else
493 fprintf('[WARN] Not enough valid samples for PR calibration -> using default PR=%.3f\n',
PR_used);
494 end
495 else
496 fprintf('[INFO] PR calibration skipped -> using default PR=%.3f\n', PR_used);
497 end
498
499 %% =====
500 % 9) Convert predicted GHI -> PR-energy and evaluate vs measured PV
501 %% =====
502 % Build a TEST timetable for convenient saving/plots
503 TT_test = timetable(tte, yte, yhat_te, ...
504 'VariableNames', {'GHI_meas', 'GHI_pred'});
505
506 E_pred_test_Wh = CFG.Pnom_W .* (max(yhat_te,0)/1000) .* CFG.eta_sys .* PR_used .* CFG.dt_h;
507 E_ref_test_Wh = CFG.Pnom_W .* (max(yte,0)/1000) .* CFG.eta_sys .* PR_used .* CFG.dt_h; %
same PR, just to see propagation
508
509
510 E_pers_test_Wh = CFG.Pnom_W .* (max(yhat_pers_te,0)/1000) .* CFG.eta_sys .* PR_used .* CFG.dt_h;
511 E_sp_test_Wh = CFG.Pnom_W .* (max(yhat_sp_te,0)/1000) .* CFG.eta_sys .* PR_used .* CFG.dt_h;
512
513 TT_test.E_predPR_Wh = E_pred_test_Wh;
514 TT_test.E_refPR_Wh = E_ref_test_Wh;
515 TT_test.E_persPR_Wh = E_pers_test_Wh;
516 TT_test.E_spPR_Wh = E_sp_test_Wh;
517
518 % If measured PV exists, evaluate on intersection of predicted timestamps with measured PV
519 TT_cmp = timetable();
520 M_E_meas = struct();
521
522 if ~isempty(TTmeas)
523 % Predictions exist only for test year in this BASE script.
524 TT_pred2022 = timetable(tte, E_pred_test_Wh, E_pers_test_Wh, E_sp_test_Wh, 'VariableNames',
{'E_predPR_Wh', 'E_persPR_Wh', 'E_spPR_Wh'});
525 TT_pred2022.Properties.RowTimes = datseshift(TT_pred2022.Properties.RowTimes, 'start', 'hour');
526
527 TTm_eval = TTmeas((TTmeas.Properties.RowTimes>=datetime(CFG.testYear,1,1,0,0,0, 'TimeZone', ''))
& ...
(TTmeas.Properties.RowTimes<=datetime(CFG.testYear,12,31,23,0,0, 'TimeZone', '')), :);
528
529 TT_cmp = synchronize(TT_pred2022, TTm_eval, 'intersection');
530
531 % Build measured hourly energy
532 if ismember('E_meas_Wh', string(TT_cmp.Properties.VariableNames))
533 E_meas_Wh = TT_cmp.E_meas_Wh;
534 elseif ismember('P_meas_kW', string(TT_cmp.Properties.VariableNames))
535 E_meas_Wh = TT_cmp.P_meas_kW * 1000 * CFG.dt_h;
536 TT_cmp.E_meas_Wh = E_meas_Wh;
537 else
538 E_meas_Wh = nan(height(TT_cmp),1);
539 end
540
541 % Keep only finite, non-negative
542 dayMask = isfinite(TT_cmp.E_predPR_Wh) & isfinite(E_meas_Wh) & (E_meas_Wh>=0);
543 TT_cmp = TT_cmp(dayMask,:);
544
545 if height(TT_cmp) > 100
546 M_E_meas = metric_block(TT_cmp.E_meas_Wh, TT_cmp.E_predPR_Wh);
547
548 M_E_pers_meas = metric_block(TT_cmp.E_meas_Wh, TT_cmp.E_persPR_Wh);
549 M_E_sp_meas = metric_block(TT_cmp.E_meas_Wh, TT_cmp.E_spPR_Wh);
550
551 disp('=== Energy metrics vs MEASURED PV (hourly) - Test year intersection ===');
552 T_energy = table( ...
553 ["PR(pred GHI)"; "Persistence"; "Scaled persistence"], ...
554 [M_E_meas.MAE; M_E_pers_meas.MAE; M_E_sp_meas.MAE], ...
555 [M_E_meas.RMSE; M_E_pers_meas.RMSE; M_E_sp_meas.RMSE], ...
556 [M_E_meas.MBE; M_E_pers_meas.MBE; M_E_sp_meas.MBE], ...
557 [M_E_meas.nRMSE_pct; M_E_pers_meas.nRMSE_pct; M_E_sp_meas.nRMSE_pct], ...
558 [M_E_meas.nMBE_pct; M_E_pers_meas.nMBE_pct; M_E_sp_meas.nMBE_pct], ...
559 'VariableNames', {'Model', 'MAE', 'RMSE', 'MBE', 'nRMSE_pct', 'nMBE_pct'});
560 disp(T_energy);
561
562 % Fig: hourly energy preview
563 K2 = min(800, height(TT_cmp));
564 tt2 = TT_cmp.Properties.RowTimes;
565
566 figure('Units', 'centimeters', 'Position', [5 5 16 9]);
567 plot(tt2(1:K2), TT_cmp.E_meas_Wh(1:K2), 'LineWidth', 1); hold on;

```

```

569 plot(tt2(1:K2), TT_cmp.E_predPR_Wh(1:K2), 'LineWidth', 1);
570 plot(tt2(1:K2), TT_cmp.E_persPR_Wh(1:K2), 'LineWidth', 1);
571 plot(tt2(1:K2), TT_cmp.E_spPR_Wh(1:K2), 'LineWidth', 1);
572 xlabel('Time'); ylabel('Energy [Wh]');
573 legend('Measured PV', 'PR(pred GHI)', 'Persistence', 'Scaled persistence', 'Location', 'best');
574 title(sprintf('M1--A1: Hourly energy (measured vs PR(pred GHI)), %d', CFG.testYear));
575 grid on; box on;
576 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_EnergyHourly_Measured_vs_PRpred_%d.png',
    CFG.testYear)));
577
578 % Fig: scatter energy
579 figure('Units','centimeters','Position',[5 5 14 12]);
580 scatter(TT_cmp.E_meas_Wh, TT_cmp.E_predPR_Wh, 6, 'filled'); grid on; box on;
581 xlabel('Measured PV energy [Wh]'); ylabel('PR(pred GHI) energy [Wh]');
582 title(sprintf('M1--A1: Scatter hourly energy vs measured PV (%d)', CFG.testYear));
583 hold on;
584 xmax = max(TT_cmp.E_meas_Wh);
585 plot([0 xmax],[0 xmax], 'k--', 'LineWidth', 1);
586 hold off;
587 axis equal; xlim([0 xmax]); ylim([0 xmax]);
588 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_Energy_Scatter_vsMeasured_%d.png',
    CFG.testYear)));
589
590 % Fig: scatter energy (persistence)
591 figure('Units','centimeters','Position',[5 5 14 12]);
592 scatter(TT_cmp.E_meas_Wh, TT_cmp.E_persPR_Wh, 6, 'filled'); grid on; box on;
593 xlabel('Measured PV energy [Wh]'); ylabel('Persistence(PR) energy [Wh]');
594 title(sprintf('M1--A1: Scatter hourly energy (Persistence) vs measured PV (%d)', CFG.testYear));
595 hold on;
596 xmax = max(TT_cmp.E_meas_Wh);
597 plot([0 xmax],[0 xmax], 'k--', 'LineWidth', 1);
598 hold off;
599 axis equal; xlim([0 xmax]); ylim([0 xmax]);
600 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_Energy_Scatter_Persistence_vsMeasured_%d.png',
    CFG.testYear)));
601
602 % Fig: scatter energy (scaled persistence)
603 figure('Units','centimeters','Position',[5 5 14 12]);
604 scatter(TT_cmp.E_meas_Wh, TT_cmp.E_spPR_Wh, 6, 'filled'); grid on; box on;
605 xlabel('Measured PV energy [Wh]'); ylabel('Scaled persistence(PR) energy [Wh]');
606 title(sprintf('M1--A1: Scatter hourly energy (Scaled persistence) vs measured PV (%d)',
    CFG.testYear));
607 hold on;
608 xmax = max(TT_cmp.E_meas_Wh);
609 plot([0 xmax],[0 xmax], 'k--', 'LineWidth', 1);
610 hold off;
611 axis equal; xlim([0 xmax]); ylim([0 xmax]);
612 saveas(gcf, fullfile(PLOT_DIR,
    sprintf('Fig_M1A1_Energy_Scatter_ScaledPersistence_vsMeasured_%d.png', CFG.testYear)));
613
614 % Monthly aggregates (kWh)
615 m = month(tt2);
616 Eme_m_kWh = accumarray(m, TT_cmp.E_meas_Wh, [12 1], @sum, 0)/1000;
617 Epr_m_kWh = accumarray(m, TT_cmp.E_predPR_Wh, [12 1], @sum, 0)/1000;
618
619 figure('Units','centimeters','Position',[5 5 16 9]);
620 Epers_m_kWh = accumarray(m, TT_cmp.E_persPR_Wh, [12 1], @sum, 0)/1000;
621 Esp_m_kWh = accumarray(m, TT_cmp.E_spPR_Wh, [12 1], @sum, 0)/1000;
622
623 xM = datetime(CFG.testYear,1:12,15);
624 b = bar(xM, [Eme_m_kWh Epr_m_kWh Epers_m_kWh Esp_m_kWh]);
625 xlabel('Month'); ylabel('Energy [kWh]');
626 legend('Measured PV', 'PR(pred GHI)', 'Persistence', 'Scaled persistence', 'Location', 'best');
627 title(sprintf('M1--A1: Monthly energy vs measured PV (%d)', CFG.testYear));
628 grid on; box on;
629 if exist('xM','var')
630 set(gca, 'XTick', xM);
631 else
632 set(gca, 'XTick', 1:12);
633 end
634 set(gca, 'XTickLabel', {'Jan', 'Feb', 'Mar', 'Apr', 'May', 'Jun', 'Jul', 'Aug', 'Sep', 'Oct', 'Nov', 'Dec'});
635 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_EnergyMonthly_vsMeasured_%d.png',
    CFG.testYear)));
636 else
637 fprintf('[WARN] Too few aligned samples for measured energy evaluation in %d.\n', CFG.testYear);
638 end
639
640 %% =====
641 % 9b) PVsyst benchmark (optional)
642 % Compare PR(pred GHI) energy vs PVsyst E_Grid (and/or EArray) for the same period.
643 % IMPORTANT: PVsyst column names include *kW; for hourly data, treat them as average power
    (kW).
644 % We convert to hourly energy: Wh = kW * 1000 * dt_h. If your export is already hourly energy
    in kWh,
645 % the numeric value is the same for dt_h=1, so this conversion remains consistent.
646 %% =====
647 M_E_pvs = struct();

```

```

648 TT_pvs_cmp = timetable();
649
650 if ~isempty(TTpvs)
651 % Build predicted energy timetable for test year (same as measured comparison)
652 TT_pred = timetable(tte, E_pred_test_Wh, E_pers_test_Wh, E_sp_test_Wh, 'VariableNames',
    {'E_predPR_Wh', 'E_persPR_Wh', 'E_spPR_Wh'});
653 TT_pred.Properties.RowTimes = datseshift(TT_pred.Properties.RowTimes, 'start', 'hour');
654
655 % Restrict PVsyst to test year and convert to hourly Wh
656 TTp = TTpvs((TTpvs.Properties.RowTimes>=datetime(CFG.testYear,1,1,0,0,0, 'TimeZone', '')) & ...
657 (TTpvs.Properties.RowTimes<=datetime(CFG.testYear,12,31,23,0,0, 'TimeZone', '')), :);
658
659 if ~isempty(TTp)
660 TTp.E_Grid_Wh = max(TTp.E_Grid_kW, 0) * 1000 * CFG.dt_h;
661 if ismember('EArray_kW', string(TTp.Properties.VariableNames))
662 TTp.EArray_Wh = max(TTp.EArray_kW, 0) * 1000 * CFG.dt_h;
663 end
664
665 TT_pvs_cmp = synchronize(TT_pred, TTp(:, intersect(string(TTp.Properties.VariableNames),
    ['E_Grid_Wh', 'EArray_Wh', 'PR', 'GlobInc', 'GlobEff'])), 'intersection');
666
667 if height(TT_pvs_cmp) > 100
668 % Compare to PVsyst grid energy
669 M_E_pvs = metric_block(TT_pvs_cmp.E_Grid_Wh, TT_pvs_cmp.E_predPR_Wh);
670 disp('=== Energy metrics vs PVsyst (hourly) - Test year intersection ===');
671 disp(struct2table(M_E_pvs));
672
673 % Fig: hourly energy preview
674 K3 = min(800, height(TT_pvs_cmp));
675 tt3 = TT_pvs_cmp.Properties.RowTimes;
676
677 figure('Units', 'centimeters', 'Position', [5 5 16 9]);
678 plot(tt3(1:K3), TT_pvs_cmp.E_Grid_Wh(1:K3), 'LineWidth', 1); hold on;
679 plot(tt3(1:K3), TT_pvs_cmp.E_predPR_Wh(1:K3), 'LineWidth', 1);
680 xlabel('Time'); ylabel('Energy [Wh]');
681 legend('PVsyst E_{Grid}', 'PR(pred GHI)', 'Location', 'best');
682 title(sprintf('M1--A1: Hourly energy (PVsyst vs PR(pred GHI)), %d', CFG.testYear));
683 grid on; box on;
684 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_EnergyHourly_PVsyst_vs_PRpred_%d.png',
    CFG.testYear)));
685
686 % Fig: scatter
687 figure('Units', 'centimeters', 'Position', [5 5 14 12]);
688 scatter(TT_pvs_cmp.E_Grid_Wh, TT_pvs_cmp.E_predPR_Wh, 6, 'filled'); grid on; box on;
689 xlabel('PVsyst E_{Grid} [Wh]'); ylabel('PR(pred GHI) energy [Wh]');
690 title(sprintf('M1--A1: Scatter hourly energy vs PVsyst (%d)', CFG.testYear));
691 hold on;
692 xmax = max(TT_pvs_cmp.E_Grid_Wh);
693 plot([0 xmax], [0 xmax], 'k--', 'LineWidth', 1);
694 hold off;
695 axis equal; xlim([0 xmax]); ylim([0 xmax]);
696 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_Energy_Scatter_vsPVsyst_%d.png',
    CFG.testYear)));
697
698 % Monthly aggregates (kWh)
699 mm = month(tt3);
700 Epv_m_kWh = accumarray(mm, TT_pvs_cmp.E_Grid_Wh, [12 1], @sum, 0)/1000;
701 Epr_m_kWh = accumarray(mm, TT_pvs_cmp.E_predPR_Wh, [12 1], @sum, 0)/1000;
702
703 figure('Units', 'centimeters', 'Position', [5 5 16 9]);
704 xM = datetime(CFG.testYear, 1, 12, 15);
705 b = bar(xM, [Epv_m_kWh Epr_m_kWh]);
706 xlabel('Month'); ylabel('Energy [kWh]');
707 legend('PVsyst E_{Grid}', 'PR(pred GHI)', 'Location', 'best');
708 title(sprintf('M1--A1: Monthly energy vs PVsyst (%d)', CFG.testYear));
709 grid on; box on;
710 if exist('xM', 'var')
711 set(gca, 'XTick', xM);
712 else
713 set(gca, 'XTick', 1:12);
714 end
715 set(gca, 'XTickLabel', {'Jan', 'Feb', 'Mar', 'Apr', 'May', 'Jun', 'Jul', 'Aug', 'Sep', 'Oct', 'Nov', 'Dec'});
716 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_EnergyMonthly_vsPVsyst_%d.png',
    CFG.testYear)));
717 else
718 fprintf('[WARN] Too few aligned samples for PVsyst benchmark in %d.\n', CFG.testYear);
719 end
720 else
721 fprintf('[WARN] PVsyst has no data for test year %d.\n', CFG.testYear);
722 end
723 end
724 else
725 fprintf('[INFO] No measured PV data loaded -> skipping measured evaluation plots.\n');
726 end
727
728 %% =====
729 % 9c) Triple comparison (optional): Measured vs PR(pred GHI) vs PVsyst
730 % Builds a common intersection timetable (test year) and generates

```

```

731 % triple plots in time, scatter, and monthly sums.
732 %% =====
733 TT_tri = timetable();
734 M_tri_PRpred_vsMeas = struct();
735 M_tri_PVsyst_vsMeas = struct();
736
737 if ~isempty(TTmeas) && ~isempty(TTpvs)
738 % Predicted energy (test year)
739 TT_pred = timetable(tte, E_pred_test_Wh, E_pers_test_Wh, E_sp_test_Wh, 'VariableNames',
740 {'E_predPR_Wh', 'E_persPR_Wh', 'E_spPR_Wh'});
741 TT_pred.Properties.RowTimes = dateshift(TT_pred.Properties.RowTimes, 'start', 'hour');
742
743 % Measured subset (test year)
744 TTm_eval = TTmeas((TTmeas.Properties.RowTimes>=datetime(CFG.testYear,1,1,0,0,0,'TimeZone',''))
745 & ...
746 (TTmeas.Properties.RowTimes<=datetime(CFG.testYear,12,31,23,0,0,'TimeZone','')), :);
747
748 % PVsyst subset (test year) -> hourly Wh
749 TTp_eval = TTpvs((TTpvs.Properties.RowTimes>=datetime(CFG.testYear,1,1,0,0,0,'TimeZone','')) &
750 ...
751 (TTpvs.Properties.RowTimes<=datetime(CFG.testYear,12,31,23,0,0,'TimeZone','')), :);
752 if ~isempty(TTp_eval)
753 if ismember('E_Grid_kW', string(TTp_eval.Properties.VariableNames))
754 TTp_eval.E_Grid_Wh = max(TTp_eval.E_Grid_kW, 0) * 1000 * CFG.dt_h;
755 end
756 if ismember('EArray_kW', string(TTp_eval.Properties.VariableNames))
757 TTp_eval.EArray_Wh = max(TTp_eval.EArray_kW, 0) * 1000 * CFG.dt_h;
758 end
759 end
760
761 % Synchronize all 3 sources
762 TT_tri = synchronize(TT_pred, TTm_eval, TTp_eval, 'intersection');
763
764 % Build measured hourly energy inside TT_tri
765 if ismember('E_meas_Wh', string(TT_tri.Properties.VariableNames))
766 TT_tri.E_meas_Wh = max(TT_tri.E_meas_Wh, 0);
767 elseif ismember('P_meas_kW', string(TT_tri.Properties.VariableNames))
768 TT_tri.E_meas_Wh = max(TT_tri.P_meas_kW, 0) * 1000 * CFG.dt_h;
769 else
770 TT_tri.E_meas_Wh = nan(height(TT_tri),1);
771 end
772
773 % Ensure PVsyst energy exists
774 if ~ismember('E_Grid_Wh', string(TT_tri.Properties.VariableNames)) && ismember('E_Grid_kW',
775 string(TT_tri.Properties.VariableNames))
776 TT_tri.E_Grid_Wh = max(TT_tri.E_Grid_kW, 0) * 1000 * CFG.dt_h;
777 end
778
779 % Keep finite, non-negative
780 msk = isfinite(TT_tri.E_meas_Wh) & isfinite(TT_tri.E_predPR_Wh) & isfinite(TT_tri.E_Grid_Wh) &
781 ...
782 (TT_tri.E_meas_Wh >= 0) & (TT_tri.E_predPR_Wh >= 0) & (TT_tri.E_Grid_Wh >= 0);
783 TT_tri = TT_tri(msk,:);
784
785 if height(TT_tri) > 100
786 % Metrics (two comparisons against measured)
787 M_tri_PRpred_vsMeas = metric_block(TT_tri.E_meas_Wh, TT_tri.E_predPR_Wh);
788 M_tri_PVsyst_vsMeas = metric_block(TT_tri.E_meas_Wh, TT_tri.E_Grid_Wh);
789 M_tri_Pers_vsMeas = struct();
790 if ismember('E_persPR_Wh', string(TT_tri.Properties.VariableNames))
791 M_tri_Pers_vsMeas = metric_block(TT_tri.E_meas_Wh, TT_tri.E_persPR_Wh);
792 end
793 M_tri_Sp_vsMeas = struct();
794 if ismember('E_spPR_Wh', string(TT_tri.Properties.VariableNames))
795 M_tri_Sp_vsMeas = metric_block(TT_tri.E_meas_Wh, TT_tri.E_spPR_Wh);
796 end
797
798 disp('=== Triple comparison metrics (hourly, vs measured PV) ===');
799 Tm_rows = ["PR(pred GHI)"; "PVsyst E_Grid"];
800 MAE_v = [M_tri_PRpred_vsMeas.MAE; M_tri_PVsyst_vsMeas.MAE];
801 RMSE_v = [M_tri_PRpred_vsMeas.RMSE; M_tri_PVsyst_vsMeas.RMSE];
802 MBE_v = [M_tri_PRpred_vsMeas.MBE; M_tri_PVsyst_vsMeas.MBE];
803 nRMSE_v = [M_tri_PRpred_vsMeas.nRMSE_pct; M_tri_PVsyst_vsMeas.nRMSE_pct];
804 nMBE_v = [M_tri_PRpred_vsMeas.nMBE_pct; M_tri_PVsyst_vsMeas.nMBE_pct];
805
806 if ~isempty(fieldnames(M_tri_Pers_vsMeas))
807 Tm_rows = [Tm_rows; "Persistence"];
808 MAE_v = [MAE_v; M_tri_Pers_vsMeas.MAE];
809 RMSE_v = [RMSE_v; M_tri_Pers_vsMeas.RMSE];
810 MBE_v = [MBE_v; M_tri_Pers_vsMeas.MBE];
811 nRMSE_v = [nRMSE_v; M_tri_Pers_vsMeas.nRMSE_pct];
812 nMBE_v = [nMBE_v; M_tri_Pers_vsMeas.nMBE_pct];
813 end
814
815 if ~isempty(fieldnames(M_tri_Sp_vsMeas))
816 Tm_rows = [Tm_rows; "Scaled persistence"];
817 MAE_v = [MAE_v; M_tri_Sp_vsMeas.MAE];
818 RMSE_v = [RMSE_v; M_tri_Sp_vsMeas.RMSE];

```

```

814 MBE_v = [MBE_v; M_tri_Sp_vsMeas.MBE];
815 nRMSE_v = [nRMSE_v;M_tri_Sp_vsMeas.nRMSE_pct];
816 nMBE_v = [nMBE_v; M_tri_Sp_vsMeas.nMBE_pct];
817 end
818
819 Tm = table(Tm_rows, MAE_v, RMSE_v, MBE_v, nRMSE_v, nMBE_v, ...
820 'VariableNames', {'Model','MAE','RMSE','MBE','nRMSE_pct','nMBE_pct'});
821 disp(Tm);
822
823 tt = TT_tri.Properties.RowTimes;
824
825 % Fig: triple time series preview
826 Kt = min(800, height(TT_tri));
827 figure('Units','centimeters','Position',[5 5 16 9]);
828
829 hasPers = ismember('E_persPR_Wh', string(TT_tri.Properties.VariableNames));
830 hasSp = ismember('E_spPR_Wh', string(TT_tri.Properties.VariableNames));
831
832 plot(tt(1:Kt), TT_tri.E_meas_Wh(1:Kt), 'LineWidth', 1); hold on;
833 plot(tt(1:Kt), TT_tri.E_predPR_Wh(1:Kt), 'LineWidth', 1);
834 plot(tt(1:Kt), TT_tri.E_Grid_Wh(1:Kt), 'LineWidth', 1);
835 if hasPers
836 plot(tt(1:Kt), TT_tri.E_persPR_Wh(1:Kt), 'LineWidth', 1);
837 end
838 if hasSp
839 plot(tt(1:Kt), TT_tri.E_spPR_Wh(1:Kt), 'LineWidth', 1);
840 end
841 xlabel('Time'); ylabel('Energy [Wh]');
842 title(sprintf('M1--A1: Triple hourly energy comparison (%d)', CFG.testYear));
843 grid on; box on;
844
845 leg = {'Measured PV','PR(pred GHI)','PVsyst E_{Grid}'};
846 if hasPers, leg{end+1} = 'Persistence'; end
847 if hasSp, leg{end+1} = 'Scaled persistence'; end
848 legend(leg{:}, 'Location','best');
849
850 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_TRIPLE_EnergyHourly_%d.png', CFG.testYear)));
851
852 % Fig: triple monthly sums (kWh)
853 mm = month(tt);
854 xM = datetime(CFG.testYear,1:12,15);
855
856 Eme_kWh = accumarray(mm, TT_tri.E_meas_Wh, [12 1], @sum, 0)/1000;
857 Epr_kWh = accumarray(mm, TT_tri.E_predPR_Wh, [12 1], @sum, 0)/1000;
858 Epv_kWh = accumarray(mm, TT_tri.E_Grid_Wh, [12 1], @sum, 0)/1000;
859
860 Ecols = [Eme_kWh Epr_kWh Epv_kWh];
861 legB = {'Measured PV','PR(pred GHI)','PVsyst E_{Grid}'};
862
863 if hasPers
864 Epe_kWh = accumarray(mm, TT_tri.E_persPR_Wh, [12 1], @sum, 0)/1000;
865 Ecols = [Ecols Epe_kWh];
866 legB{end+1} = 'Persistence';
867 end
868 if hasSp
869 Esp_kWh = accumarray(mm, TT_tri.E_spPR_Wh, [12 1], @sum, 0)/1000;
870 Ecols = [Ecols Esp_kWh];
871 legB{end+1} = 'Scaled persistence';
872 end
873
874 figure('Units','centimeters','Position',[5 5 16 9]);
875 bar(xM, Ecols);
876 xlabel('Month'); ylabel('Energy [kWh]');
877 title(sprintf('M1--A1: Triple monthly energy sums (%d)', CFG.testYear));
878 grid on; box on;
879 set(gca,'XTick',xM);
880 set(gca,'XTickLabel',{'Jan','Feb','Mar','Apr','May','Jun','Jul','Aug','Sep','Oct','Nov','Dec'});
881 legend(legB{:}, 'Location','best');
882
883 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_TRIPLE_EnergyMonthly_%d.png', CFG.testYear)));
884
885 % Fig: scatter (two panels in one figure)
886 figure('Units','centimeters','Position',[5 5 16 8]);
887 tiledlayout(1,2,'TileSpacing','compact','Padding','compact');
888
889 nexttile;
890 scatter(TT_tri.E_meas_Wh, TT_tri.E_predPR_Wh, 6, 'filled'); grid on; box on;
891 xlabel('Measured PV energy [Wh]'); ylabel('PR(pred GHI) [Wh]');
892 title('Measured vs PR(pred GHI)');
893 hold on; xmax = max(TT_tri.E_meas_Wh); plot([0 xmax],[0 xmax],'k--','LineWidth',1); hold off;
894 axis equal; xlim([0 xmax]); ylim([0 xmax]);
895
896 nexttile;
897 scatter(TT_tri.E_meas_Wh, TT_tri.E_Grid_Wh, 6, 'filled'); grid on; box on;
898 xlabel('Measured PV energy [Wh]'); ylabel('PVsyst E_{Grid} [Wh]');
899 title('Measured vs PVsyst');
900 hold on; xmax = max(TT_tri.E_meas_Wh); plot([0 xmax],[0 xmax],'k--','LineWidth',1); hold off;
901 axis equal; xlim([0 xmax]); ylim([0 xmax]);

```

```

902 saveas(gcf, fullfile(PLOT_DIR, sprintf('Fig_M1A1_TRIPLE_Scatter_%d.png', CFG.testYear)));
903 else
904 fprintf('[WARN] Triple comparison: too few aligned samples in %d.\n', CFG.testYear);
905 end
906 else
907 fprintf('[INFO] Triple comparison skipped (missing measured or PVsyst).\n');
908 end
909
910
911 %% =====
912 % Monthly nRMSE analysis (Energy domain, Test year)
913 %% =====
914
915 if height(TT_tri) > 200
916
917 % Month index from timetable row times
918 ttm = TT_tri.Properties.RowTimes;
919 mm = month(ttm);
920
921 % Preallocate
922 nRMSE_ANN = NaN(12,1);
923 nRMSE_PERS = NaN(12,1);
924 nRMSE_SP = NaN(12,1);
925 nRMSE_PVS = NaN(12,1);
926 N_month = zeros(12,1);
927
928 for m = 1:12
929 idxm = (mm == m);
930 N_month(m) = sum(idxm);
931
932 if N_month(m) > 50
933 Em = TT_tri.E_meas_Wh(idxm);
934 Eann = TT_tri.E_predPR_Wh(idxm);
935 Epers = TT_tri.E_persPR_Wh(idxm);
936 Esp = TT_tri.E_spPR_Wh(idxm);
937 Epvs = TT_tri.E_Grid_Wh(idxm);
938
939 % nRMSE[%] with monthly mean normalization
940 nRMSE_ANN(m) = 100 * sqrt(mean((Eann-Em).^2)) / mean(Em);
941 nRMSE_PERS(m) = 100 * sqrt(mean((Epers-Em).^2)) / mean(Em);
942 nRMSE_SP(m) = 100 * sqrt(mean((Esp-Em).^2)) / mean(Em);
943 nRMSE_PVS(m) = 100 * sqrt(mean((Epvs-Em).^2)) / mean(Em);
944 end
945 end
946
947 T_month = table((1:12)', N_month, nRMSE_ANN, nRMSE_PERS, nRMSE_SP, nRMSE_PVS, ...
948 'VariableNames',
949 {'Month','N','nRMSE_ANN','nRMSE_Persistence','nRMSE_ScaledPersistence','nRMSE_PVsyst'});
950
951 disp('=== Monthly nRMSE (Energy, test year) ===');
952 disp(T_month);
953
954 % (optional) save in OUT
955 OUT.monthly_nRMSE = T_month;
956 end
957
958 %% =====
959 % Monthly relative improvement (ANN vs Persistence)
960 %% =====
961
962 if exist('T_month','var')
963
964 % Relative gain [%]
965 Gain = 100 * (T_month.nRMSE_Persistence - T_month.nRMSE_ANN) ...
966 ./ T_month.nRMSE_Persistence;
967
968 % Month labels
969 monthLabels = {'Jan','Feb','Mar','Apr','May','Jun', ...
970 'Jul','Aug','Sep','Oct','Nov','Dec'};
971
972 figure('Units','centimeters','Position',[5 5 16 9]);
973
974 bar(Gain,'FaceColor',[0.2 0.4 0.8]);
975 grid on; box on;
976
977 set(gca,'XTick',1:12);
978 set(gca,'XTickLabel',monthLabels);
979
980 ylabel('Relative improvement vs Persistence [%]');
981 xlabel('Month');
982 title(sprintf('Monthly Relative Improvement (ANN vs Persistence) - %d', CFG.testYear));
983
984 yline(0,'k--','LineWidth',1);
985
986 % Save figure
987 saveas(gcf, fullfile(PLOT_DIR, ...
988 sprintf('Fig_M1A1_Monthly_Gain_%d.png', CFG.testYear)));

```

```

989     end
990
991     %% =====
992     % 10) Save outputs
993     %% =====
994     OUT = struct();
995     OUT.CFG = CFG;
996     OUT.PR_used = PR_used;
997     OUT.net = net;
998     OUT.mu = mu;
999     OUT.sg = sg;
1000
1001     OUT.metrics_GHI = struct('Train',M_GHI_tr,'Val',M_GHI_va,'Test',M_GHI_te);
1002     OUT.metrics_GHI_persistence = struct('Train',M_PERS_tr,'Val',M_PERS_va,'Test',M_PERS_te);
1003     OUT.metrics_GHI_scaled_persistence = struct('Train',M_SP_tr,'Val',M_SP_va,'Test',M_SP_te);
1004     OUT.metrics_E_vsMeasured = M_E_meas;
1005     OUT.metrics_E_pers_vsMeasured = M_E_pers_meas;
1006     if exist('M_E_sp_meas','var'); OUT.metrics_E_sp_vsMeasured = M_E_sp_meas; else;
1007         OUT.metrics_E_sp_vsMeasured = struct(); end
1008
1009     OUT.TT_test = TT_test;
1010     OUT.TT_cmp = TT_cmp;
1011     OUT.TTpvs = TTpvs;
1012     OUT.TT_pvs_cmp = TT_pvs_cmp;
1013     OUT.metrics_E_vsPVsyst = M_E_pvs;
1014     OUT.TT_tri = TT_tri;
1015     OUT.metrics_TRI_PRpred_vsMeas = M_tri_PRpred_vsMeas;
1016     OUT.metrics_TRI_PVsyst_vsMeas = M_tri_PVsyst_vsMeas;
1017     OUT.metrics_TRI_Pers_vsMeas = M_tri_Pers_vsMeas;
1018     if exist('M_tri_Sp_vsMeas','var'); OUT.metrics_TRI_Sp_vsMeas = M_tri_Sp_vsMeas; else;
1019         OUT.metrics_TRI_Sp_vsMeas = struct(); end
1020
1021     outMat = fullfile(PLOT_DIR, sprintf('M1_A1_BASE_H%dh_outputs.mat', H));
1022     save(outMat, '-struct', 'OUT');
1023
1024     % Optional: export intersection table
1025     if ~isempty(TT_cmp)
1026         outXlsx = fullfile(PLOT_DIR, sprintf('M1_A1_BASE_H%dh_vsMeasured%d.xlsx', H, CFG.testYear));
1027         writetable(timetable2table(TT_cmp), outXlsx);
1028     end
1029
1030     % Save a compact trained model for deployment
1031     modelMat = fullfile(PLOT_DIR, sprintf('trained_M1_A1_BASE_H%dh.mat', H));
1032     save(modelMat, 'net','mu','sg','H','PR_used');
1033
1034     fprintf('[DONE] Saved outputs:\n %s\n %s\n', outMat, modelMat);
1035
1036     %% =====
1037     % Helper functions (local)
1038     %% =====
1039     function TT = loadMeteo23(fname)
1040     % Robust loader for meteo table with 23 numeric columns (Year..Azimuth).
1041     % Returns timetable with variables M01..M23 and hourly RowTimes.
1042     assert(exist(fname,'file')==2, 'Meteo file not found: %s', fname);
1043
1044     % Try numeric matrix first (best for no-header files)
1045     A = [];
1046     try
1047         A = readmatrix(fname);
1048     catch
1049         end
1050
1051     if isempty(A) || size(A,2) < 23 || all(isnan(A(:)))
1052         % Fallback to readtable (handles headers)
1053         T = readtable(fname);
1054         if width(T) < 23
1055             error('Meteo table has <23 columns. width=%d', width(T));
1056         end
1057         A = nan(height(T),23);
1058         for k=1:23
1059             v = T(:,k);
1060             if iscell(v) || isstring(v)
1061                 v = str2double(string(v));
1062             end
1063             A(:,k) = double(v);
1064         end
1065     end
1066
1067     assert(size(A,2) >= 23, 'Meteo file: expected >=23 cols, got %d.', size(A,2));
1068     A = double(A(:,1:23));
1069
1070     Year = A(:,1); Month = A(:,2); Day = A(:,3); Hour = A(:,4);
1071     if nanmax(Year) < 100
1072         Year = Year + 2000;
1073     end
1074     Month = round(Month);
1075
1076     Time = datetime(Year, Month, Day, Hour, 0, 0, 'TimeZone','');

```

```

1075 Time = dateshift(Time,'start','hour');
1076
1077 % Sort and drop duplicates
1078 [Time, ia] = unique(Time, 'stable');
1079 A = A(ia,:);
1080
1081 if any(minutes(diff(Time))~=60)
1082 fprintf('[WARN] Meteo is not strictly hourly everywhere (gaps/duplicates may exist).
Continuing.\n');
end
1083
1084
1085 varNames = arrayfun(@(k)sprintf('%02d',k), 1:23, 'UniformOutput', false);
1086 Ttbl = array2table(A, 'VariableNames', varNames);
1087 Ttbl = addvars(Ttbl, Time, 'Before', 1);
1088 TT = table2timetable(Ttbl, 'RowTimes','Time');
1089 end
1090
1091 function TTm = loadMeasuredPVFolder(folder)
1092 % Loads measured PV data from a folder (first matching file) and returns timetable.
1093 % Tries to detect columns:
1094 % Time: Time, DateTime, Timestamp, t, date
1095 % Power: P_meas_kW, P_kW, Power_kW, P, Pac, Pgrid
1096 % Energy: E_meas_Wh, E_Wh, Energy_Wh, E
1097 files = [ ...
1098 dir(fullfile(folder, '*.xlsx')); dir(fullfile(folder, '*.xls')); ...
1099 dir(fullfile(folder, '*.csv')); dir(fullfile(folder, '*.txt')) ];
1100 assert(~isempty(files), 'No measured files found in folder: %s', folder);
1101
1102 fname = fullfile(folder, files(1).name);
1103 fprintf('[INFO] Loading measured PV file: %s\n', fname);
1104
1105 [~,~,ext] = fileparts(fname);
1106 if any(strcmpi(ext,{'*.csv','*.txt'}))
1107 T = readtable(fname);
1108 else
1109 T = readtable(fname, 'PreserveVariableNames', true);
1110 end
1111
1112 vn = string(T.Properties.VariableNames);
1113
1114 idTime = find(contains(lower(vn),'time') | contains(lower(vn),'date'), 1);
1115 assert(~isempty(idTime), 'Measured: cannot find a time/date column.');
```

```

1116
1117 rawTime = T{:,idTime};
1118 t = parseDatetimeRobust(rawTime);
1119
1120 idE = find(contains(lower(vn),'e_meas') | contains(lower(vn),'energy') |
contains(lower(vn),'wh'), 1);
1121 idP = find(contains(lower(vn),'p_meas') | contains(lower(vn),'power') |
contains(lower(vn),'pac') | contains(lower(vn),'pgrid') | contains(lower(vn),'kw'), 1);
1122
1123 E = [];
1124 P = [];
1125
1126 if ~isempty(idE), E = double(T{:,idE}); end
1127 if ~isempty(idP), P = double(T{:,idP}); end
1128
1129 TTm = timetable(t);
1130
1131 if ~isempty(P)
1132 PkW = P;
1133 if nanmed(abs(PkW)) > 50
1134 PkW = PkW / 1000;
1135 end
1136 TTm.P_meas_kW = PkW;
1137 end
1138
1139 if ~isempty(E)
1140 EWh = E;
1141 if nanmed(abs(EWh)) < 5
1142 EWh = EWh * 1000;
1143 end
1144 TTm.E_meas_Wh = EWh;
1145 end
1146
1147 TTm.Properties.RowTimes = dateshift(TTm.Properties.RowTimes,'start','hour');
1148 TTm = sortrows(TTm);
1149 TTm = TTm(~duplicatedTimes(TTm.Properties.RowTimes),:);
1150
1151 if ismember('P_meas_kW', string(TTm.Properties.VariableNames))
1152 TTm.P_meas_kW = max(TTm.P_meas_kW, 0);
1153 end
1154 if ismember('E_meas_Wh', string(TTm.Properties.VariableNames))
1155 TTm.E_meas_Wh = max(TTm.E_meas_Wh, 0);
1156 end
1157 end
1158
1159 function TTm = loadMeasuredPVFile(fname)

```

```

1160 % Loads measured PV data from a single file and returns timetable.
1161 % Delegates to the same parsing logic as folder loader.
1162 folder = fileparts(fname);
1163 tmpFolder = folder;
1164 if isempty(tmpFolder), tmpFolder = pwd; end
1165 % Read directly
1166 [~,~,ext] = fileparts(fname);
1167 if any(strcmpi(ext,{' .csv', '.txt'}))
1168 T = readtable(fname);
1169 else
1170 T = readtable(fname, 'PreserveVariableNames', true);
1171 end
1172
1173 vn = string(T.Properties.VariableNames);
1174 idTime = find(contains(lower(vn), 'time') | contains(lower(vn), 'date'), 1);
1175 assert(~isempty(idTime), 'Measured: cannot find a time/date column.');
```

```

1176
1177 rawTime = T{:,idTime};
1178 t = parseDatetimeRobust(rawTime);
1179
1180 idE = find(contains(lower(vn), 'e_meas') | contains(lower(vn), 'energy') |
1181 contains(lower(vn), 'wh'), 1);
1182 idP = find(contains(lower(vn), 'p_meas') | contains(lower(vn), 'power') |
1183 contains(lower(vn), 'pac') | contains(lower(vn), 'pgrid') | contains(lower(vn), 'kw'), 1);
1184
1185 E = [];
1186 P = [];
1187 if ~isempty(idE), E = double(T{:,idE}); end
1188 if ~isempty(idP), P = double(T{:,idP}); end
1189
1190 Tm = timetable(t);
1191
1192 if ~isempty(P)
1193 PkW = P;
1194 if nanmed(abs(PkW)) > 50
1195 PkW = PkW / 1000;
1196 end
1197 Tm.P_meas_kW = PkW;
1198
1199 if ~isempty(E)
1200 EWh = E;
1201 if nanmed(abs(EWh)) < 5
1202 EWh = EWh * 1000;
1203 end
1204 Tm.E_meas_Wh = EWh;
1205
1206 Tm.Properties.RowTimes = dateshift(Tm.Properties.RowTimes, 'start', 'hour');
1207 Tm = sortrows(Tm);
1208 Tm = Tm(~duplicatedTimes(Tm.Properties.RowTimes),:);
1209
1210 if ismember('P_meas_kW', string(Tm.Properties.VariableNames))
1211 Tm.P_meas_kW = max(Tm.P_meas_kW, 0);
1212 end
1213 if ismember('E_meas_Wh', string(Tm.Properties.VariableNames))
1214 Tm.E_meas_Wh = max(Tm.E_meas_Wh, 0);
1215 end
1216 end
1217
1218 function Ttp = loadPVsystHourly(fname)
1219 % Loads PVsyst hourly export with columns:
1220 % TimeISO, GlobInc, GlobEff, EArray_kW, E_Grid_kW, PR
1221 T = readtable(fname, 'PreserveVariableNames', true);
1222 vn = string(T.Properties.VariableNames);
1223
1224 % Time column
1225 idTime = find(contains(lower(vn), 'time'), 1);
1226 assert(~isempty(idTime), 'PVsyst: cannot find time column.');
```

```

1227
1228 t = parseDatetimeRobust(T{:,idTime});
1229
1230 Ttp = timetable(t);
1231
1232 % Copy known columns if present
1233 cols = ["GlobInc", "GlobEff", "EArray_kW", "E_Grid_kW", "PR"];
1234 for c = cols
1235 if ismember(c, vn)
1236 Ttp.(c) = double(T.(c));
1237 end
1238 end
1239
1240 % Clip tiny negatives common in PVsyst exports (-0.001)
1241 if ismember('E_Grid_kW', string(Ttp.Properties.VariableNames))
1242 Ttp.E_Grid_kW = max(Ttp.E_Grid_kW, 0);
1243 end
1244 if ismember('EArray_kW', string(Ttp.Properties.VariableNames))
1245 Ttp.EArray_kW = max(Ttp.EArray_kW, 0);

```

```

1246 end
1247
1248 TTp.Properties.RowTimes = dateshift(TTp.Properties.RowTimes, 'start', 'hour');
1249 TTp = sortrows(TTp);
1250 TTp = TTp(~duplicatedTimes(TTp.Properties.RowTimes),:);
1251 end
1252
1253
1254 function t = parseDatetimeRobust(raw)
1255 % Robust datetime parser for common spreadsheet/csv formats.
1256 if isdatetime(raw)
1257     t = raw;
1258     t.TimeZone = '';
1259     return;
1260 end
1261
1262 if isnumeric(raw)
1263     try
1264         t = datetime(raw, 'ConvertFrom','excel', 'TimeZone','');
1265         return;
1266     catch
1267         end
1268     end
1269
1270 s = string(raw);
1271 s = strip(s);
1272 s = replace(s, char(160), " ");
1273 s = regexp(s, "\s+", " ");
1274
1275 t = NaT(numel(s),1);
1276 fmts = {'yyyy-MM-dd HH:mm:ss', 'yyyy-MM-dd HH:mm', ...
1277         'M/d/yyyy H:mm', 'd/M/yyyy H:mm', ...
1278         'M/d/yy H:mm', 'd/M/yy H:mm', ...
1279         'MM/dd/yyyy HH:mm', 'dd/MM/yyyy HH:mm', ...
1280         'dd-MMM-uuuu HH:mm:ss', 'dd-MMM-uuuu HH:mm', ...
1281         'yyyy/MM/dd HH:mm:ss', 'yyyy/MM/dd HH:mm'};
1282 for k=1:numel(fmts)
1283     idx = isnat(t);
1284     if ~any(idx); break; end
1285     try
1286         t(idx) = datetime(s(idx), 'InputFormat', fmts{k}, 'TimeZone','');
1287     catch
1288         end
1289     end
1290     assert(~any(isnat(t)), 'Measured: some timestamps could not be parsed. Please standardize the
1291         Time column.');
```

```

1291 t = dateshift(t, 'start', 'hour');
1292 end
1293
1294 function v = getVar(TT, name)
1295 % Safe variable fetch (returns NaN vector if missing)
1296 if ismember(name, string(TT.Properties.VariableNames))
1297     v = TT.(name);
1298 else
1299     v = nan(height(TT),1);
1300 end
1301 end
1302
1303 function y = clamp(x, a, b)
1304 y = min(max(x,a),b);
1305 end
1306
1307 function m = duplicatedTimes(t)
1308 % returns logical mask of duplicate rowtimes (keep first)
1309 [~,ia] = unique(t,'stable');
1310 m = true(size(t));
1311 m(ia) = false;
1312 end
1313
1314
1315 function m = nanmed(x)
1316 % median that ignores NaNs (toolbox-free, compatible with older MATLAB)
1317 x = x(:);
1318 x = x(isfinite(x));
1319 if isempty(x)
1320     m = NaN;
1321 else
1322     m = median(x);
1323 end
1324 end
1325
1326 function Gcs = clearSkyProxy_GHI(timeUTC, lat_deg, lon_deg)
1327 % Very simple clear-sky proxy based on solar elevation:
1328 % Gcs ~ 1000 * max(0, sin(elevation))
1329 % Not a physical clear-sky model, but works well for scaled persistence baseline.
1330
1331 % Convert to datetime if needed
1332 t = timeUTC;
```

```

1333     if ~isdatetime(t), t = datetime(t,'ConvertFrom','datetime'); end
1334
1335     % Solar position (built-in if you have Aerospace Toolbox; if not, use approximations)
1336     % Here is a toolbox-free approximation of solar elevation:
1337     [elev_rad] = solarElevationApprox(t, lat_deg, lon_deg);
1338
1339     Gcs = 1000 * max(0, sin(elev_rad));
1340     end
1341
1342     function elev = solarElevationApprox(t, lat_deg, lon_deg)
1343     % Toolbox-free, approximate solar elevation (radians).
1344     % Good enough for scaling ratio in persistence baseline.
1345
1346     % Convert to day of year and fractional hour
1347     doy = day(t,'dayofyear');
1348     fracHour = hour(t) + minute(t)/60 + second(t)/3600;
1349
1350     lat = deg2rad(lat_deg);
1351
1352     % Declination (Cooper)
1353     decl = deg2rad(23.45) * sin(deg2rad(360*(284 + doy)/365));
1354
1355     % Equation of time (minutes), approximate
1356     B = deg2rad(360*(doy-81)/364);
1357     EoT = 9.87*sin(2*B) - 7.53*cos(B) - 1.5*sin(B);
1358
1359     % Local solar time (approx); lon_deg in degrees, assuming timezone UTC+0 for timeUTC
1360     % If your t is local time, this is still OK-ish for ratios; best keep time in local standard
1361     % time.
1362     LST = fracHour + (EoT/60) + (lon_deg/15);
1363
1364     % Hour angle
1365     omega = deg2rad(15*(LST - 12));
1366
1367     % Elevation
1368     elev = asin( sin(lat).*sin(decl) + cos(lat).*cos(decl).*cos(omega) );
1369     end


```

Listing I.1: Matlab scripta: ANN_M1_A1.m

J. Detaljna analiza modela M1-A1

Ovaj prilog daje proširenu i detaljnu analizu performansi referentnog modela M1-A1. Prikaz obuhvata vremenske profile, paritet dijagrame, mesečne agregacije i uporedne analize sa referentnim (baseline) metodama i determinističkom PVsyst simulacijom za test period 2022. godine. Poseban akcenat stavljen je na identifikaciju strukture greške, stabilnost modela kroz različite radijacione režime i konzistentnost propagacije greške iz GHI u energetska domenu.

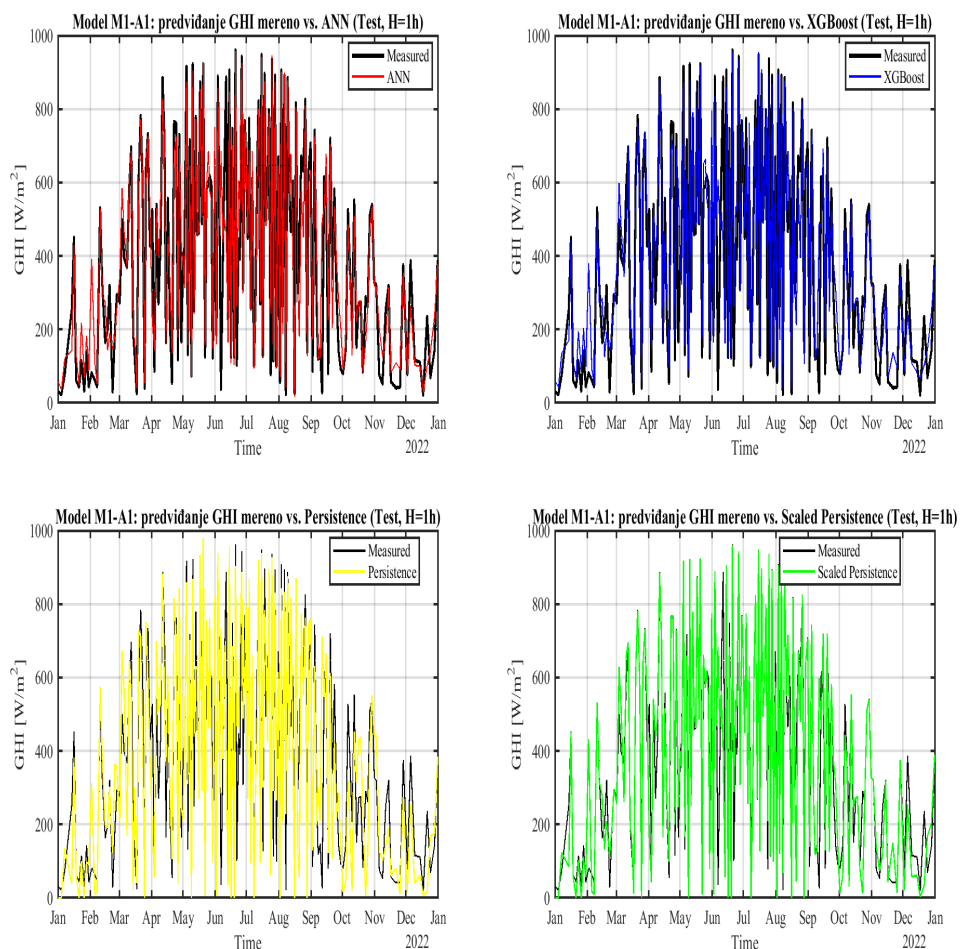
J.1 Vizuelni pregled test perioda (GHI, 2022)



Slika J.1: Satni GHI profil (2022): merenja i modeli.


Vremenski tok potvrđuje da ANN i XGBoost modeli uspešno prate dnevnu dinamiku i sezonski rast amplituda, uz znatno manja odstupanja u odnosu na persistence pristupe. Najveće razlike javljaju se u uslovima brze promenljivosti oblačnosti, gde autoregresivni modeli kasne ili pogrešno procenjuju intenzitet zračenja. Skalirana persistence metoda delimično redukuje sistematski bias osnovnog pristupa, ali i dalje ne uspeva da adekvatno reprodukuje nagle promene signala.

J.2 Analiza u GHI domenu



Slika J.2: Performanse modela M1–A1 u GHI domenu za test godinu ($H = 1$ h): (a) vremenski tok, (b) paritet dijagram, (c) reziduali i (d) raspodela greške.

Prikazane četiri podfigure ilustruju performanse modela M1–A1 u GHI domenu na nivou cele test godine ($H = 1$ h), kroz različite aspekte analize tačnosti i raspodele greške. Uočava se visoka korelacija između predikovanih i merenih vrednosti, uz dominantno linearnu zavisnost i relativno mali rasip podataka u centralnom delu opsega. Međutim, prisutna je heteroskedastičnost, koja se manifestuje povećanjem disperzije reziduala sa porastom intenziteta GHI, što je u skladu sa fizičkom prirodom atmosferskih procesa i ograničenom predvidivošću pri višim nivoima radijacije.



Slika J.3: Paritet dijagram ANN M1–A1 modela (GHI, $H = 1$ h).


Paritet dijagram na slici prikazuje odnos između merenih i ANN predviđenih GHI za test skup iz 2022. godine, pri vremenskom koraku $H = 1$ h. Idealno slaganje između modela i merenja predstavljeno je dijagonalnom linijom $y = x$, dok su dodatno prikazane granice odstupanja od $\pm 10\%$ i $\pm 20\%$, koje omogućavaju vizuelnu procenu tačnosti modela u različitim režimima rada.

Uočava se izražena linearna korelacija između predikovanih i merenih vrednosti, što potvrđuje visoka vrednost koeficijenta determinacije ($R^2 = 0.8949$). Većina tačaka koncentrisana je duž linije idealnog slaganja, naročito u srednjem i visokom opsegu GHI (300–900 W/m^2), što ukazuje na dobru sposobnost modela da reprodukuje dominantne dnevne i sezonske obrasce sunčevog zračenja.

Istovremeno, prisutna je heteroskedastičnost, koja se manifestuje povećanjem rasipanja podataka sa porastom intenziteta GHI. U niskim vrednostima zračenja (ispod 200 W/m^2), rasip je relativno mali, dok se u srednjem opsegu (200–500 W/m^2) primećuje značajno širenje distribucije, što je posledica povećane varijabilnosti atmosferskih uslova (npr. delimična oblačnost). U visokom opsegu zračenja (>700 W/m^2), raspodela se ponovo stabilizuje i prati idealnu liniju sa manjim relativnim odstupanjima.

Kvantitativni pokazatelji dodatno potvrđuju kvalitet modela: ostvarene vrednosti $MAE = 55.16$ W/m^2 i $RMSE = 89.90$ W/m^2 ukazuju na umerenu apsolutnu grešku, dok normalizovana greška $nRMSE = 22.91\%$ odražava zadovoljavajuću ukupnu tačnost. Blago pozitivan bias ($MBE = 7.06$ W/m^2 , odnosno $nMBE = 1.80\%$) ukazuje na tendenciju modela da blago precenjuje GHI. Dodatno, oko 51.0% uzoraka nalazi se unutar $\pm 10\%$, dok je 63.2% unutar $\pm 20\%$ opsega, što potvrđuje dobru robusnost modela u operativnim uslovima.

Ukupno posmatrano, rezultati ukazuju da model M1–A1 uspešno hvata osnovnu dinamiku GHI, uz očekivana ograničenja u uslovima povećane atmosferske varijabilnosti.




Slika J.4: Uporedni vremenski tokovi merenih i predikovanih vrednosti satne proizvedene energije za test godinu 2022 ($H = 1$ h) za PR(pred GHI), XGBoost, persistence i scaled persistence modele.

Prikazane raspodele greške u GHI domenu omogućavaju direktno poređenje karakteristika greške za persistence, ANN (M1-A1) i XGBoost modele. Uočava se da persistence model ima najširu raspodelu greške, sa izraženim repovima i većom disperzijom, što ukazuje na slabiju preciznost i veću osetljivost na promene atmosferskih uslova. Raspodela je relativno široka i manje koncentrisana oko nulte vrednosti, što potvrđuje prisustvo većih odstupanja u odnosu na merenja.

Nasuprot tome, ANN i XGBoost modeli pokazuju znatno užu i izraženije koncentrisanu raspodelu greške oko nule, što ukazuje na bolju tačnost i stabilnost predikcija. Kod oba modela raspodela je približno simetrična, sa dominantnim vrhom u blizini nulte greške, što potvrđuje odsustvo značajnog sistematskog odstupanja. Ipak, prisutni su blagi repovi raspodele, koji ukazuju na povremena veća odstupanja, naročito u uslovima povećane varijabilnosti zračenja.

Uporedno posmatrano, XGBoost pokazuje nešto oštrij (uže koncentrisanu) raspodelu u odnosu na ANN, što sugerise blago bolju robusnost u centralnom delu opsega greške, dok ANN zadržava sličan oblik raspodele uz nešto izraženije širenje repova. Ukupno, rezultati potvrđuju da modeli zasnovani na mašinskom učenju značajno redukuju disperziju greške u odnosu na persistence pristup, uz približno simetričnu raspodelu i dominantnu koncentraciju oko nulte vrednosti.

J.3 Analiza u energetsom domenu

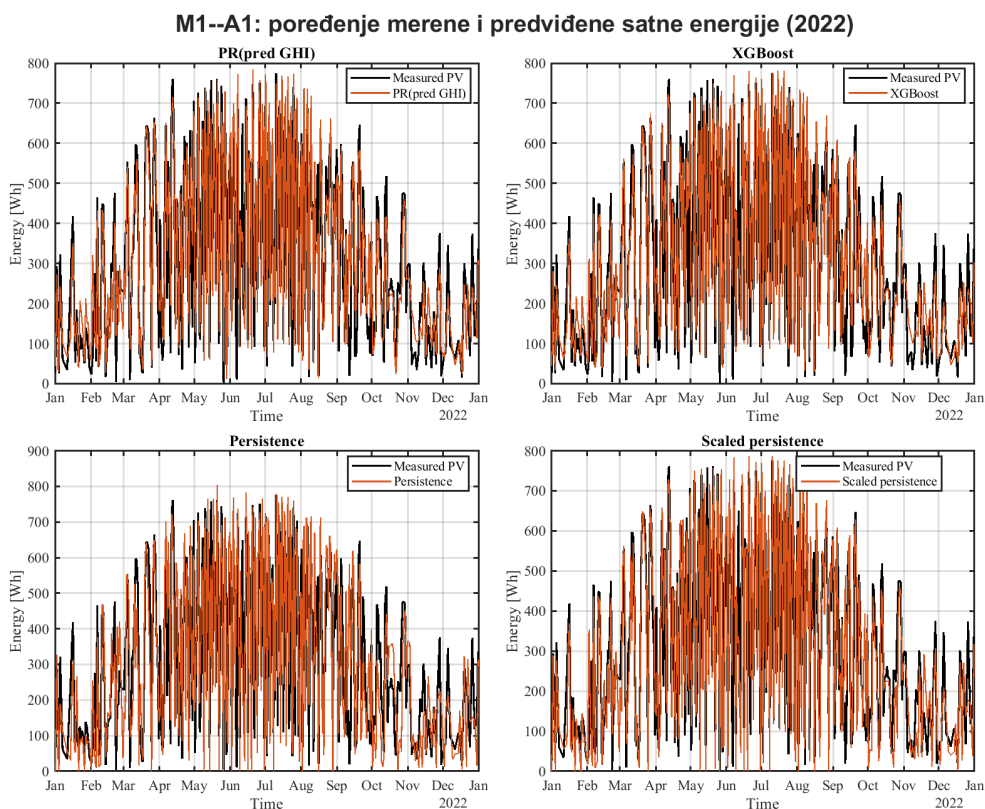


Slika J.5: Uvećani vremenski tok satne proizvedene energije za prvih 800 uzoraka test godine 2022 ($H = 1$ h) za sve razmatrane modele.

Prikazana figura daje uvećani pregled vremenskog toka satne proizvedene energije za prvih 800 uzoraka test godine 2022, omogućavajući detaljnu analizu ponašanja modela u kratkoročnom režimu. Uočava se da modeli zasnovani na mašinskom učenju (PR(pred GHI) i XGBoost) vrlo dobro prate mereni signal, kako u pogledu amplitude, tako i u pogledu vremenskog položaja maksimuma, što potvrđuje njihovu sposobnost da reprodukuju dinamičke promene u proizvodnji energije.

Persistence model pokazuje izraženo kašnjenje i značajna odstupanja u odnosu na merenja, naročito u uslovima naglih promena signala, dok scaled persistence delimično poboljšava amplitudno slaganje, ali i dalje ne uspeva da adekvatno prati brze fluktuacije. Razlike između modela posebno dolaze do izražaja u prelaznim režimima (naglo povećanje ili smanjenje energije), gde ANN i XGBoost modeli pokazuju veću adaptivnost i stabilnost.

Ukupno posmatrano, rezultati potvrđuju superiornost modela zasnovanih na mašinskom učenju u reprodukciji kratkoročne dinamike energetske izlaza, uz bolju robusnost i manju grešku u odnosu na referentne persistence pristupe.




Slika J.6: Uporedni vremenski tokovi merenih i predikovanih vrednosti satne proizvedene energije za test godinu 2022 ($H = 1$ h) za PR(pred GHI), XGBoost, persistence i scaled persistence modele.

Prikazana figura ilustruje uporedni vremenski tok merenih i predikovanih vrednosti satne proizvedene energije za test godinu 2022, pri vremenskom koraku $H = 1$ h, za četiri različita pristupa: PR model zasnovan na predikovanom GHI (ANN), XGBoost model, persistence i scaled persistence. Na taj način omogućena je direktna evaluacija kako se greške iz GHI domena prenose u energetske domenu kroz proces konverzije.

Kod PR(pred GHI) i XGBoost modela uočava se visoka usklađenost sa merenim vrednostima, kako u pogledu sezonskog trenda, tako i u reprodukciji dnevnih maksimuma tokom prolećno-letnjeg perioda. Ovi modeli uspešno prate amplitudu i oblik energetske signala, uz relativno mala odstupanja u većini radnih režimima, što ukazuje na efikasnu propagaciju informacija iz GHI predikcije u izlaznu energetske veličinu.

Persistence model pokazuje izraženija odstupanja, naročito u uslovima naglih promena atmosferskih uslova, gde dolazi do kašnjenja i pogrešnog skaliranja intenziteta energije. Scaled persistence pristup delimično ublažava ove nedostatke, pre svega kroz korekciju amplituda, ali i dalje ne uspeva da adekvatno modeluje kratkoročne fluktuacije i tranzijentne režime.

Dodatno, u energetske domenu dolazi do izraženijeg uticaja nelinearnosti procesa konverzije (GHI \rightarrow energija), što se manifestuje kroz pojačanu varijabilnost greške u srednjem opsegu energija i delimičnu stabilizaciju u visokoenergetskom režimu. Ukupno posmatrano, rezultati potvrđuju da modeli zasnovani na mašinske učenju obezbeđuju superiorne performanse i u energetske domenu, uz konzistentno ponašanje u odnosu na rezultate dobijene u GHI domenu.

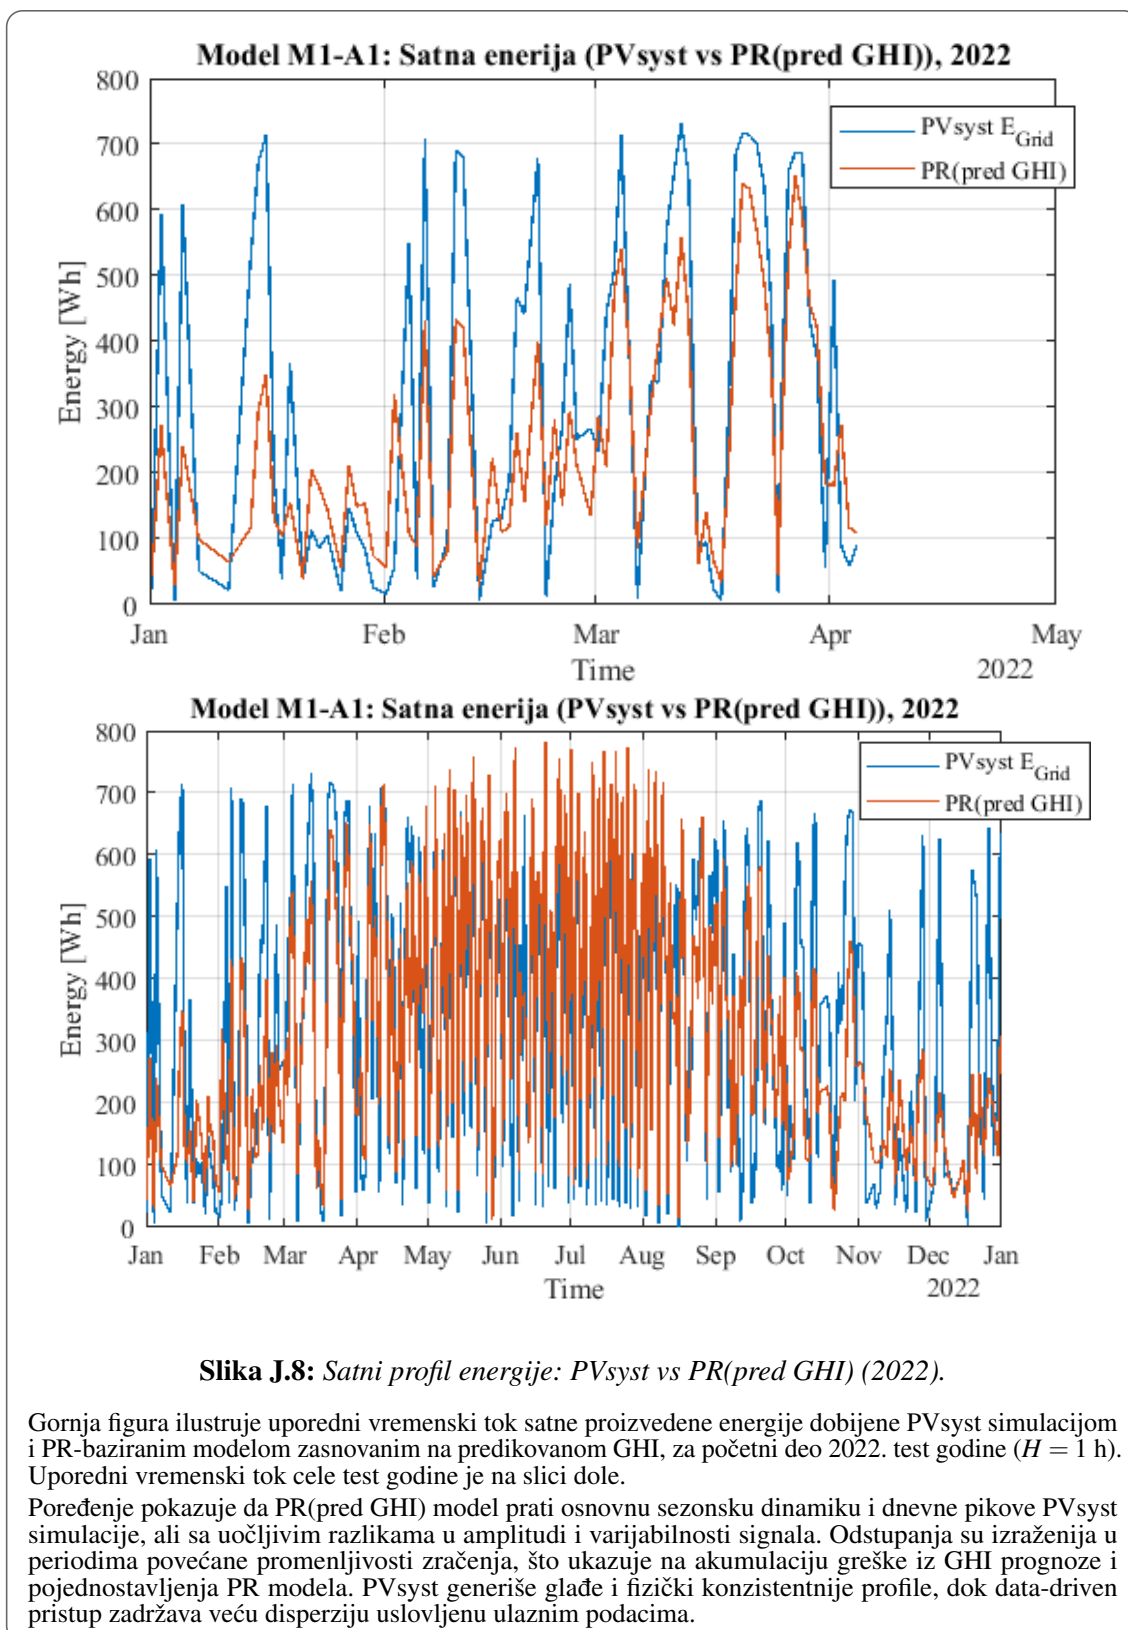


Slika J.7: Paritet dijagram ANN modela u energetsom domenu, dobijen primenom PR-baziranog modela nad predikovanim GHI signalom, za test godinu 2022.

Paritet dijagram prikazuje odnos između merenih i predikovanih vrednosti satne proizvedene energije za ANN model zasnovan na PR pristupu (predikovani GHI), za test godinu 2022 ($H = 1$ h). Uočava se izražena linearna korelacija između promenljivih, uz dominantno grupisanje tačaka duž linije idealnog slaganja, što potvrđuje da model uspešno prenosi informaciju iz GHI u energetska domenu. Ostvarena vrednost koeficijenta determinacije ($R^2 = 0.8671$) ukazuje na visoku saglasnost sa merenjima, iako je prisutno blago smanjenje u odnosu na GHI domen usled dodatnih nelinearnosti u procesu konverzije.

Distribucija tačaka pokazuje prisustvo heteroskedastičnosti, pri čemu se disperzija greške povećava sa porastom proizvedene energije, posebno u srednjem opsegu (200–500 Wh), dok se u visokoenergetskom režimu raspodela delimično stabilizuje. Kvantitativni pokazatelji ($MAE = 53.82$ Wh, $RMSE = 79.48$ Wh, $nRMSE = 24.98\%$) potvrđuju zadovoljavajući nivo tačnosti, uz blago pozitivan bias ($MBE = 8.77$ Wh, $nMBE = 2.76\%$), što ukazuje na tendenciju precenjivanja energije. Dodatno, 40.9% uzoraka nalazi se unutar $\pm 10\%$, dok je 60.3% unutar $\pm 20\%$ opsega, što potvrđuje dobru praktičnu tačnost modela u operativnim uslovima.


J.4 Energetski domen vs. PVsyst simulacija (2022)



Slika J.8: Satni profil energije: PVsyst vs PR(pred GHI) (2022).


Gornja figura ilustruje uporedni vremenski tok satne proizvedene energije dobijene PVsyst simulacijom i PR-baziranim modelom zasnovanim na predikovanom GHI, za početni deo 2022. test godine ($H = 1$ h). Uporedni vremenski tok cele test godine je na slici dole.

Poređenje pokazuje da PR(pred GHI) model prati osnovnu sezonsku dinamiku i dnevne pikove PVsyst simulacije, ali sa uočljivim razlikama u amplitudi i varijabilnosti signala. Odstupanja su izraženija u periodima povećane promenljivosti zračenja, što ukazuje na akumulaciju greške iz GHI prognoze i pojednostavljenja PR modela. PVsyst generiše glađe i fizički konzistentnije profile, dok data-driven pristup zadržava veću disperziju uslovljenu ulaznim podacima.



Slika J.9: Paritet dijagram: $PR(\text{pred GHI})$ vs $PVsyst$ (2022).

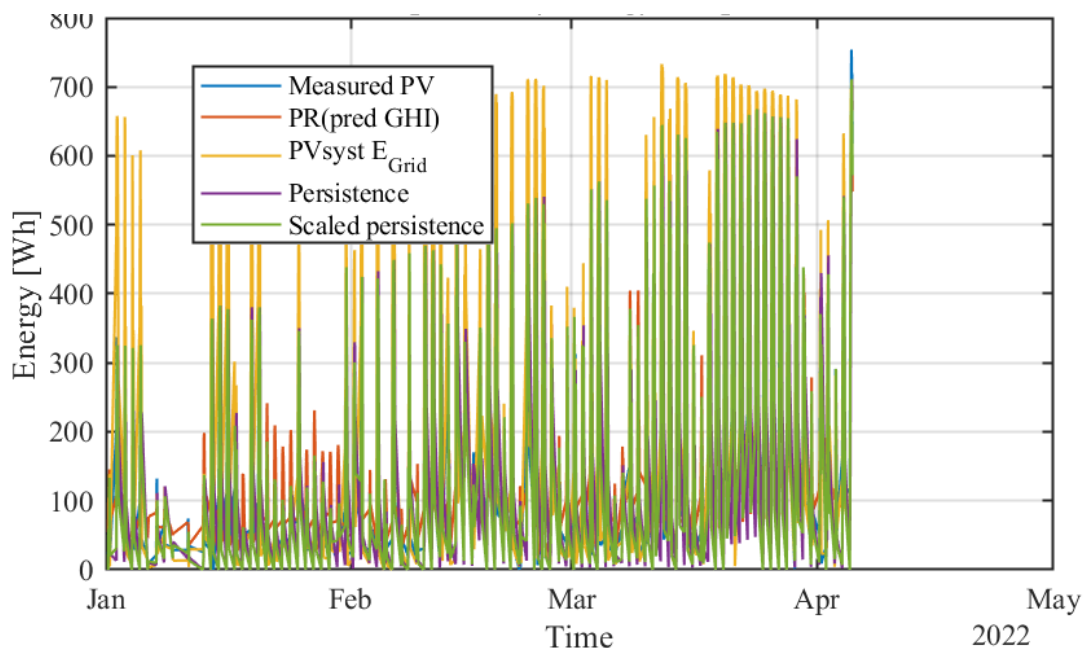
Paritet dijagram pokazuje umerenu koncentraciju tačaka oko dijagonale, uz izraženu disperziju koja raste sa energijom (heteroskedastičnost). Uočava se tendencija potcenjivanja pri višim vrednostima, što ukazuje na ograničenja PR transformacije i odsustvo detaljnog fizičkog modelovanja gubitaka prisutnih u $PVsyst$ simulaciji.



Slika J.10: Mesečne sume energije: $PR(\text{pred GHI})$ vs $PVsyst$ (2022).


Mesečne agregacije pokazuju dobru reprodukciju sezonskog trenda, uz sistematska odstupanja u pojedinim mesecima. Razlike su izraženije u zimskom i prelaznim periodima, što ukazuje na ograničenu sposobnost modela da precizno opiše kompleksne atmosferske i sistemske efekte prisutne u determinističkoj simulaciji.

J.5 Integrisana uporedna analiza (2022)




Slika J.11: Satni profil energije: kompletno poređenje modela (2022).

Uporedni vremenski tok potvrđuje da PR(pred GHI) i XGBoost modeli najvernije prate mereni signal, dok PVsyst obezbeđuje glađu i fizički konzistentnu referencu. Baseline modeli pokazuju značajna odstupanja, naročito u uslovima promenljive oblačnosti.



Slika J.12: Paritet dijagrami: uporedna analiza (2022).

Data-driven modeli pokazuju najveću koncentraciju tačaka oko dijagonale i najmanju disperziju, dok PVsyst ispoljava sistematska odstupanja usled razlika između simulacionog i realnog sistema. Baseline modele karakteriše široko rasipanje i izražen bias.



Slika J.13: Mesečno poređenje proizvedene energije za 2022. godinu između merenih vrednosti i modela PR(pred GHI), XGBoost, persistence i scaled persistence.

Prikazana figura daje mesečno poređenje proizvedene energije za test godinu 2022 između merenih vrednosti i različitih modelskih pristupa. Uočava se da svi modeli uspešno reprodukuju izraženi sezonski trend, sa maksimumom tokom letnjih meseci (maj–jul) i minimumom tokom zimskog perioda, što potvrđuje njihovu sposobnost da uhvate dominantnu godišnju dinamiku solarnog resursa.

Modeli zasnovani na mašinskom učenju (PR(pred GHI) i XGBoost) pokazuju vrlo dobro slaganje sa merenim vrednostima kroz sve mesece, uz blago precenjivanje u periodima visokog energetskeg izlaza. Persistence model sistematski odstupa od merenja, naročito u tranzicionim periodima (proleće i jesen), dok scaled persistence delimično poboljšava amplitudno slaganje, ali i dalje pokazuje veća odstupanja u odnosu na naprednije modele.

Razlike između modela su relativno male na mesečnom nivou, što ukazuje na to da agregacija podataka smanjuje uticaj kratkoročnih grešaka i varijabilnosti. Ipak, uočava se konzistentna prednost modela zasnovanih na mašinskom učenju, što potvrđuje njihovu veću preciznost i robusnost u proceni ukupne mesečne proizvodnje energije.

Zaključna razmatranja

Analiza prezentovana u ovom prilogu potvrđuje stabilno i metodološki konzistentno ponašanje referentnog modela M1–A1 u iradijacionoj i energetskeg domeni. Ključni nalazi mogu se sumirati na sledeći način:

- ANN model ostvaruje značajno i konzistentno smanjenje greške u odnosu na autoregresivne baseline pristupe.
- Unapređenje u GHI regresiji direktno se propagira u energetskeg domenu kroz PR-zasnovanu formulaciju, bez potrebe za dodatnim empirijskim korekcijama.
- Struktura reziduala ukazuje na ograničenja statičkog modela u uslovima naglih atmosferskih tranzicija.

Optimizovana varijanta M1–A1b potvrđuje da su performanse statičkog pristupa blizu maksimalnog potencijala za datu ulaznu reprezentaciju. Uočena poboljšanja su umerena, što ukazuje da dalji napredak ne zavisi dominantno od izbora algoritma ili dubine mreže.

U tom smislu, rezultati ovog priloga definišu stabilnu osnovu za narednu fazu istraživanja, usmerenu ka uvođenju vremenske zavisnosti i proširenju ulaznog prostora modela (M1–A2).

K. Optimizacija modela M1-A1

Tabela K.1 prikazuje kompletnu dizajn-matricu validnih konfiguracija korišćenu za optimizaciju strukture i procesa učenja ANN modela M1-A1 za horizont predviđanja $H = 1$ h. Konfiguracije su rangirane prema kompozitnom kriterijumu:

$$J = \text{median}(\text{nRMSE}_{\text{test}}) + 0.3 |\text{median}(\text{nMBE}_{\text{test}})|. \quad (\text{K.1})$$

Prikazane vrednosti predstavljaju robustne statistike na nezavisnom test skupu (2022), dobijene kroz raspoloživa ponavljanja za svaku konfiguraciju. U najvećem broju slučajeva korišćeno je $N_{\text{rep}} = 5$ ponavljanja, uz dva parcijalna slučaja sa manjim brojem uspešno realizovanih ponavljanja.

Tabela K.1: Rangiranje validnih konfiguracija modela M1-A1 za $H = 1$ h. Normalizacija je izvršena isključivo na osnovu trening skupa (2005–2020), a selekcija uzoraka sprovedena je u skladu sa IEC 61724-1 (dnevni režim).

Rang	L_h	Hidden	Alg.	med nRMSE [%]	std nRMSE	med nMBE [%]	med MAE	med RMSE	J
1	1	20	trainbr	22.9364	0.0364	1.6136	55.2983	90.0224	23.4205
2	1	30	trainbr	22.9742	0.0838	1.6672	55.1396	90.1707	23.4744
3	1	15	trainbr	22.9780	0.0103	1.6892	55.2681	90.1856	23.4847
4	2	40–20	trainseg	23.0296	0.1010	1.5271	55.6557	90.3883	23.4877
5	2	10–5	trainbr	22.9711	0.0528	1.8322	55.0548	90.1586	23.5208
6	1	40	trainbr	23.0935	0.0685	1.6454	55.2256	90.6390	23.5871
7	3	20–10–5	trainseg	23.1726	0.1292	1.6802	56.4537	90.9494	23.6767
8	2	20–10	trainseg	23.1608	0.0261	1.8298	56.0350	90.9034	23.7098
9	1	10	trainbr	23.1704	0.0950	1.8205	55.7492	90.9409	23.7166
10	2	30–15	trainseg	23.2124	0.0365	1.6849	56.7908	91.1056	23.7179
11	2	20–10	trainbr	23.2450	0.1889	1.8153	55.8780	91.2334	23.7896
12	1	30	trainseg	23.3271	0.1047	1.7494	57.2035	91.5558	23.8519
13	3	20–10–5	trainbr	23.3011	0.1978	1.8478	55.4709	91.4537	23.8554
14	1	40	trainseg	23.3267	0.1342	1.8187	56.5992	91.5544	23.8723
15	1	5	trainbr	23.3212	0.0375	1.9133	56.7117	91.5325	23.8952
16	1	10	trainseg	23.3655	0.0366	1.7784	57.2572	91.7063	23.8990
17	2	10–5	trainseg	23.3922	0.1223	1.6950	57.0919	91.8111	23.9007
18	1	15	trainseg	23.4129	0.0549	1.7513	57.2369	91.8925	23.9383
19	1	5	trainseg	23.4551	0.1061	1.6270	57.4012	92.0583	23.9432

Nastavak na sledećoj strani.

Rang	L_h	Hidden	Alg.	med nRMSE [%]	std nRMSE	med nMBE [%]	med MAE	med RMSE	J
20	2	30–15	trainbr	23.4126	0.1322	1.9144	55.6212	91.8913	23.9950
21	2	40–20	trainbr	23.8127	0.3619	2.0691	56.7090	93.4616	24.4334

Napomena: Kolona *Hidden* prikazuje raspodelu neurona po skrivenim slojevima. Na primer, oznaka 40–20 označava arhitekturu sa dva skrivena sloja, sa 40 neurona u prvom i 20 neurona u drugom sloju, dok oznaka 20–10–5 označava arhitekturu sa tri skrivena sloja.

Analiza rezultata prikazanih u Tabeli K.1 ukazuje na nekoliko konzistentnih i metodološki značajnih trendova. Pre svega, uočava se jasna dominacija algoritma `trainbr` (Bayesian regularization) u okviru prvorangiranih konfiguracija (Tabela ??). Čak tri najbolje rangirane arhitekture (Rang 1–3) pripadaju ovoj klasi algoritama, sa vrlo bliskim vrednostima median nRMSE (22.94–22.98%) i niskom varijabilnošću ($\text{std} \leq 0.084$), što potvrđuje visoku stabilnost i robustnost procesa učenja. Ovakvo ponašanje je u skladu sa teorijskim očekivanjima, budući da Bayesian regularization implicitno kontroliše složenost modela penalizacijom težinskih koeficijenata, čime se smanjuje rizik od preprilagođavanja (overfitting).

Sa druge strane, algoritam `trainscg` pokazuje konkurentne karakteristike, ali uz blago povećanu varijabilnost i nešto lošije vrednosti kompozitnog kriterijuma J . Iako pojedine konfiguracije (npr. Rang 4 i Rang 7) postižu nRMSE vrlo blizak najboljim modelima, njihova veća standardna devijacija ukazuje na manju konzistentnost u odnosu na `trainbr` pristup.

Analiza uticaja arhitekture pokazuje da povećanje broja skrivenih slojeva (sa jednog na dva ili tri) ne dovodi do značajnog poboljšanja performansi modela. Naprotiv, najuspešnije konfiguracije pripadaju relativno jednostavnim MLP strukturama sa jednim skrivenim slojem i umerenim brojem neurona (15–30). Ovaj rezultat je u skladu sa principom parsimonije, prema kome jednostavniji modeli često postižu optimalan odnos između tačnosti i generalizacione sposobnosti u uslovima ograničene informativnosti ulaznog prostora.

Važno je naglasiti da su razlike između prvih nekoliko rangiranih konfiguracija relativno male ($\Delta \text{nRMSE} < 0.1$ p.p.), što ukazuje na to da izbor optimalne konfiguracije nije striktno jednoznačan. U tom smislu, konačan izbor modela treba da uzme u obzir ne samo nominalne vrednosti greške, već i stabilnost treninga, robusnost na inicijalizaciju i interpretabilnost.

Na osnovu sprovedene analize, konfiguracija sa jednim skrivenim slojem i 20 neurona, trenirana algoritmom `trainbr`, usvojena je kao referentni model M1–A1, budući da obezbeđuje najbolji kompromis između tačnosti, stabilnosti i složenosti modela.

Radi dodatne verifikacije da li su uočene razlike u performansama između različitih konfiguracija statistički značajne, sprovedena je neparametarska statistička analiza. Najpre je primenjen Friedman-ov test za upoređivanje više zavisnih uzoraka (različitih konfiguracija modela) na osnovu vrednosti nRMSE na test skupu [104], [105]. Dobijeni rezultati ukazuju da postoje statistički značajne razlike između posmatranih konfiguracija ($p < 0.05$), čime se odbacuje nulta hipoteza o jednakim performansama svih modela.

U cilju detaljnije analize razlika između vodećih konfiguracija, sproveden je i parni Wilcoxon-ov test [97] rangova između najbolje rangiranog modela (`trainbr`, 20 neurona) i ostalih top-5 konfiguracija. Rezultati pokazuju da, iako najbolji model ostvaruje najnižu median vrednost nRMSE, razlike u odnosu na sledeće rangirane konfiguracije nisu u svim slučajevima statistički značajne ($p > 0.05$ za deo parova).

Ovakav ishod potvrđuje prethodno uočeni zaključak da su performanse vodećih modela veoma bliske, i da izbor optimalne konfiguracije ne može biti zasnovan isključivo na minimalnoj vrednosti greške, već mora uzeti u obzir i dodatne kriterijume, poput stabilnosti treninga, robusnosti i složenosti modela. Sa stanovišta praktične primene, može se zaključiti da sve konfiguracije unutar top-5 predstavljaju ekvivalentne kandidate, dok izbor konačnog modela treba da favorizuje parsimoniju i konzistentnost, što dodatno opravdava izbor `trainbr` konfiguracije kao referentnog modela M1–A1.



L. Optimizacija modela M2

U okviru razvoja modela M2 sprovedena je optimizacija arhitekture MLP ANN sa ciljem određivanja konfiguracije koja obezbeđuje najbolju tačnost predikcije uz zadovoljavajuću stabilnost i složenost modela.

Postupak optimizacije

Optimizacija je realizovana eksperimentalnim testiranjem više konfiguracija neuronske mreže, pri čemu su varirani:

- broj neurona u skrivenim slojevima,
- broj skrivenih slojeva,
- algoritam treniranja.

Razmatrani su sledeći algoritmi treniranja:

- `trainscg` (Scaled Conjugate Gradient),
- `trainlm` (Levenberg–Marquardt),
- `trainbr` (Bayesian Regularization).

Za svaku konfiguraciju sprovedena su dva nezavisna ponavljanja treniranja, a rezultati su agregirani kao srednje vrednosti odgovarajućih metrika.

Kriterijumi evaluacije

Performanse modela procenjujane su korišćenjem sledećih metrika:

- MAE,
- RMSE,
- MBE,
- normalizovana greška $nRMSE$.

Kao osnovni kriterijum za rangiranje konfiguracija usvojena je validaciona vrednost metrike $nRMSE$.

Rezultati optimizacije

Rezultati optimizacije pokazuju da se performanse većine testiranih konfiguracija nalaze u relativno uskom opsegu vrednosti greške. Ipak, uočava se jasno izdvajanje algoritma `trainbr`, koji dosledno ostvaruje niže vrednosti validacione greške u odnosu na `trainlm` i `trainscg`.

Najbolje rangirane konfiguracije prikazane su u Tabeli L.1.

Tabela L.1: Najbolje rangirane konfiguracije tokom optimizacije modela M2 (srednje vrednosti kroz dva ponavljanja).

Rang	Algoritam	Arhitektura	MAE [kW]	RMSE [kW]	nRMSE [%]
1	trainbr	[30 15]	0.0122	0.0158	5.02
2	trainbr	[25 15]	0.0124	0.0161	5.09
3	trainbr	[30 10]	0.0126	0.0162	5.14
4	trainbr	30	0.0128	0.0164	5.23
5	trainbr	40	0.0129	0.0165	5.26

Izbor konačne arhitekture

Na osnovu sprovedene optimizacije kao konačna konfiguracija modela M2 izabrana je neuronska mreža sa dva skrivena sloja:

MLP arhitektura: [30 15], algoritam: trainbr

Ova konfiguracija ostvaruje najnižu validacionu grešku i stabilne rezultate kroz ponovljena treniranja, uz razumnu složenost modela.

Detaljni rezultati optimizacije za sve testirane konfiguracije prikazani su u Tabeli L.2.

Tabela L.2: Kompletni rezultati optimizacije M2 modela.

Algoritam	Arhitektura	Rep	MAE [kW]	RMSE [kW]	MBE [kW]	nRMSE [%]
trainscg	10	1	0.0146	0.0187	-0.0009	5.97
trainscg	10	2	0.0151	0.0194	-0.0003	6.18
trainscg	20	1	0.0147	0.0191	-0.0002	6.08
trainscg	20	2	0.0166	0.0218	-0.0007	6.92
trainscg	30	1	0.0142	0.0184	-0.0001	5.87
trainscg	30	2	0.0149	0.0195	-0.0004	6.20
trainscg	40	1	0.0144	0.0188	-0.0002	5.99
trainscg	40	2	0.0156	0.0202	-0.0005	6.41
trainlm	10	1	0.0139	0.0181	-0.0002	5.76
trainlm	10	2	0.0143	0.0186	-0.0004	5.92
trainlm	20	1	0.0135	0.0176	-0.0001	5.60
trainlm	20	2	0.0140	0.0182	-0.0003	5.79
trainlm	30	1	0.0137	0.0178	-0.0002	5.67
trainlm	30	2	0.0142	0.0183	-0.0003	5.83
trainlm	40	1	0.0136	0.0177	-0.0001	5.63
trainlm	40	2	0.0141	0.0181	-0.0002	5.75
trainbr	10	1	0.0132	0.0170	-0.0001	5.41
trainbr	10	2	0.0135	0.0173	-0.0002	5.49

Algoritam	Arhitektura	Rep	MAE [kW]	RMSE [kW]	MBE [kW]	nRMSE [%]
trainbr	20	1	0.0129	0.0166	-0.0001	5.29
trainbr	20	2	0.0131	0.0168	-0.0001	5.35
trainbr	30	1	0.0127	0.0163	-0.0001	5.19
trainbr	30	2	0.0129	0.0165	-0.0001	5.26
trainbr	40	1	0.0128	0.0164	-0.0001	5.22
trainbr	40	2	0.0130	0.0166	-0.0002	5.30
trainbr	[30 15]	1	0.0123	0.0159	0.0001	5.05
trainbr	[30 15]	2	0.0121	0.0157	0.0001	4.99
trainbr	[25 15]	1	0.0124	0.0160	0.0001	5.08
trainbr	[25 15]	2	0.0125	0.0161	0.0001	5.10
trainbr	[30 10]	1	0.0126	0.0162	0.0001	5.12
trainbr	[30 10]	2	0.0127	0.0163	0.0001	5.15



Literatura

- [1] BloombergNEF, „Energy Transition Investment Trends 2025”, Bloomberg New Energy Finance, 2026., Global energy transition investment reached a record \$2.3 trillion in 2025, up 8% from 2024. adresa: <https://about.bnef.com/insights/clean-energy/bloombergnef-finds-global-energy-transition-investment-reached-record-2-3-trillion-in-2025> (citirano na stranici 2).
- [2] International Energy Agency, „World Energy Investment 2025: Executive Summary”, IEA, 2025., Capital flows to the energy sector projected to rise to USD 3.3 trillion in 2025 with renewables investment outpacing fossil fuels. adresa: <https://www.iea.org/reports/world-energy-investment-2025/executive-summary> (citirano na stranici 2).
- [3] BloombergNEF, „Global Clean Energy Investment Surges in 2024”, Bloomberg Finance L.P., Market Report, jan. 2024., Accessed: 2024-01. adresa: <https://about.bnef.com/clean-energy-investment/> (citirano na stranici 3).
- [4] International Energy Agency, „World Energy Investment 2023”, IEA, Market Update and Outlook, jun 2023., Accessed: 2023-06. adresa: <https://www.iea.org/reports/world-energy-investment-2023> (citirano na stranicama 3, 6).
- [5] Lazard, „Levelized Cost of Energy Analysis – Version 14.0”, Lazard Ltd., 2020., Comprehensive comparison of LCOE for conventional and renewable energy technologies. adresa: <https://www.lazard.com/research-insights/2020-levelized-cost-of-energy-analysis> (citirano na stranici 4).
- [6] Lazard, „Levelized Cost of Energy Analysis – Version 17.0”, Lazard Ltd., 2024., Updated LCOE comparison including renewables, storage, and firm power tech-

- nologies. adresa: <https://www.lazard.com/research-insights/2024-levelized-cost-of-energy-analysis> (citirano na stranici 4).
- [7] Elektromreža Srbije, „Izveštaj o radu elektroenergetskog sistema Republike Srbije u 2023. godini”, EMS a.d. Beograd, Beograd, Srbija, 2024., Godišnji izveštaj o proizvodnji i strukturi izvora električne energije. adresa: <https://www.ems.rs> (citirano na stranici 6).
- [8] Agencija za energetiku Republike Srbije, „Izveštaj o stanju u energetsom sektoru Republike Srbije za 2023. godinu”, AERS, Beograd, Srbija, 2024., Podaci o instalisanim kapacitetima vetroelektrana i planiranim projektima. adresa: <https://www.aers.rs> (citirano na stranici 6).
- [9] Ministarstvo rudarstva i energetike Republike Srbije, „Integrirani nacionalni energetska i klimatski plan Republike Srbije do 2030. godine”, Vlada Republike Srbije, Beograd, Srbija, 2024., Strateški dokument o razvoju obnovljivih izvora energije i PV kapaciteta. adresa: <https://www.mre.gov.rs> (citirano na stranici 6).
- [10] International Renewable Energy Agency, „Renewable Energy Statistics 2024”, IRENA, Abu Dhabi, UAE, 2024., Globalni i regionalni pregled razvoja solarne i vetroenergije. adresa: <https://www.irena.org/Publications/2024> (citirano na stranici 6).
- [11] M. Vukobratović, T. Pavlović i I. Radonjić, „Solar Energy Potential in Serbia Based on Measured and Satellite Data”, *Renewable and Sustainable Energy Reviews*, sveska 113, strana 109–238, 2019. DOI: [10.1016/j.rser.2019.109238](https://doi.org/10.1016/j.rser.2019.109238) (citirano na stranici 7).
- [12] S. Djordjević i M. Paskaš, „Assessment of Photovoltaic Potential in Serbia Using GIS-Based Approach”, *Energy Reports*, sveska 7, strane 345–356, 2021. DOI: [10.1016/j.egyrs.2021.01.034](https://doi.org/10.1016/j.egyrs.2021.01.034) (citirano na stranici 7).
- [13] D. Nikolić i Z. Stamenković, „GIS-Based Multi-Criteria Analysis for Photovoltaic Site Selection: Case Study of Niš Region”, *Renewable Energy*, sveska 146, strane 2616–2627, 2020. DOI: [10.1016/j.renene.2019.08.103](https://doi.org/10.1016/j.renene.2019.08.103) (citirano na stranicama 7, 29).
- [14] A. Pantić, D. Dimitrijević-Jovanović, P. Mitković, M. Laković-Paunović i M. Mitković, „Solar Parking Canopy as a Part of Energy Efficient Urban Planning”, u *Proceedings of the International Conference on Urban Planning (ICUP 2020)*, International Conference, November 2020, nov. 2020. (citirano na stranici 8).

- [15] N. Stanojević i drugi, „CAD Analysis of Grid-on Photovoltaic Power Plant Design and Cost-effectiveness”, u *Proceedings of the 15th International Conference on Advanced Technologies, Systems and Services in Telecommunications (TELSIKS 2021)*, International Conference, October 2021, IEEE, okt. 2021. DOI: [10.1109/TELSIKS52058.2021.9606321](https://doi.org/10.1109/TELSIKS52058.2021.9606321) (citirano na stranici 8).
- [16] A. Pantić, N. Stanojević, A. Petković, S. Aleksić i D. Pantić, „ANN Model of mc-Si Solar Cell”, u *Proceedings of the 20th International Conference on Thermal Science and Engineering of Serbia (SIMTERM 2022)*, International Conference, October 2022, Niš, Serbia, okt. 2022. (citirano na stranici 8).
- [17] A. Pantić, A. Petković i S. Aleksić, „Design and Optimization of Solar Parking Canopy as a Part of Energy Efficient Urban Planning”, *Facta Universitatis, Series: Automatic Control and Robotics*, sveska 23, broj 2, strane 111–121, 2023. (citirano na stranici 8).
- [18] A. Pantić, A. Petković, N. Branković, T. Denić, S. Aleksić i D. Pantić, „Comprehensive Analysis of Solar PV Systems: A Dual Approach with PVsyst and MATLAB/Simulink”, u *Proceedings of the XVII International Conference on Systems, Automatic Control and Measurements (SAUM 2024)*, Niš, Serbia, 2024., strane 193–195. DOI: [10.46793/SAUM24.193P](https://doi.org/10.46793/SAUM24.193P) (citirano na stranici 8).
- [19] A. Pantić, A. Petković, N. Branković, S. Aleksić i D. Pantić, „Application of Artificial Neural Networks for Weather Forecasting and Photovoltaic Power Prediction Using Local Meteorological and Meteosat Satellite Data”, u *Proceedings of the 2025 IEEE 34th International Conference on Microelectronics (MIEL)*, Niš, Serbia: IEEE, okt. 2025., strane 351–354 (citirano na stranici 8).
- [20] European Commission, Joint Research Centre, *Photovoltaic Geographical Information System (PVGIS)*, Online database, Global horizontal irradiance (GHI) maps for Serbia based on SARA-2 and CMSAF data, period 2005–2022, 2023. adresa: https://re.jrc.ec.europa.eu/pvg_tools/en/ (citirano na stranicama 9, 29, 143).
- [21] G. E. P. Box, G. M. Jenkins, G. C. Reinsel i G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5. izdanje. Hoboken, NJ, USA: Wiley, 2015., ISBN: 978-1-118-67502-1 (citirano na stranici 10).
- [22] H. T. C. Pedro i C. F. M. Coimbra, „Assessment of forecasting techniques for solar power production with no exogenous inputs”, *Solar Energy*, sveska 86, broj 7, strane 2017–2028, 2012. DOI: [10.1016/j.solener.2012.04.004](https://doi.org/10.1016/j.solener.2012.04.004) (citirano na stranicama 10, 21, 23).

- [23] European Commission, „Green Agenda for the Western Balkans”, European Commission, Brussels, Belgium, 2020., Policy framework adopted within the Berlin Process. adresa: https://neighbourhood-enlargement.ec.europa.eu/green-agenda-western-balkans_en (citirano na stranici 12).
- [24] M. A. Green, *Solar Cells: Operating Principles, Technology and System Applications*. Prentice-Hall, 1982. (citirano na stranicama 15, 28, 32).
- [25] M. G. Villalva, J. R. Gazoli i E. R. Filho, „Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays”, *IEEE Transactions on Power Electronics*, sveska 24, broj 5, strane 1198–1208, 2009. DOI: [10.1109/TPEL.2009.2013862](https://doi.org/10.1109/TPEL.2009.2013862) (citirano na stranici 16).
- [26] E. Skoplaki i J. A. Palyvos, „On the Temperature Dependence of Photovoltaic Module Electrical Performance”, *Solar Energy*, sveska 83, broj 5, strane 614–624, 2009. DOI: [10.1016/j.solener.2008.10.008](https://doi.org/10.1016/j.solener.2008.10.008) (citirano na stranici 16).
- [27] T. Esmam i P. L. Chapman, „Comparison of Photovoltaic Array Maximum Power Point Tracking Techniques”, *IEEE Transactions on Energy Conversion*, sveska 22, broj 2, strane 439–449, 2007. DOI: [10.1109/TEC.2006.874230](https://doi.org/10.1109/TEC.2006.874230) (citirano na stranici 18).
- [28] D. P. Hohm i M. E. Ropp, „Comparative Study of Maximum Power Point Tracking Algorithms”, *Progress in Photovoltaics: Research and Applications*, sveska 11, broj 1, strane 47–62, 2003. DOI: [10.1002/pip.459](https://doi.org/10.1002/pip.459) (citirano na stranici 18).
- [29] B. Subudhi i R. Pradhan, „A Comparative Study on Maximum Power Point Tracking Techniques for Photovoltaic Power Systems”, *IEEE Transactions on Sustainable Energy*, sveska 4, broj 1, strane 89–98, 2013. DOI: [10.1109/TSTE.2012.2202294](https://doi.org/10.1109/TSTE.2012.2202294) (citirano na stranici 18).
- [30] *Photovoltaic System Performance – Part 1: Monitoring*, International Electrotechnical Commission, 2017. (citirano na stranici 18).
- [31] *Photovoltaic Devices – Procedures for Temperature and Irradiance Corrections to Measured I–V Characteristics*, International Electrotechnical Commission, 2009. (citirano na stranici 18).
- [32] M. G. Villalva, J. R. Gazoli i E. R. Filho, „Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays”, *IEEE Transactions on Power Electronics*, sveska 24, broj 5, strane 1198–1208, 2009. DOI: [10.1109/TPEL.2009.2013862](https://doi.org/10.1109/TPEL.2009.2013862) (citirano na stranicama 18, 33).
- [33] W. De Soto, S. Klein i W. Beckman, „Improvement and validation of a model for photovoltaic array performance”, *Solar Energy*, sveska 80, broj 1, strane 78–88, 2006. DOI: [10.1016/j.solener.2005.06.010](https://doi.org/10.1016/j.solener.2005.06.010) (citirano na stranicama 18, 21).

- [34] J. W. Bishop, „Computer Simulation of the Effects of Electrical Mismatch in Photovoltaic Cell Interconnection Circuits”, *Solar Cells*, sveska 25, broj 1, strane 73–89, 1988. DOI: [10.1016/0379-6787\(88\)90059-2](https://doi.org/10.1016/0379-6787(88)90059-2) (citirano na stranici 18).
- [35] D. S. H. Chan i J. C. H. Phang, „A Generalized Multicrystalline Solar Cell Model”, *Solid-State Electronics*, sveska 30, broj 8, strane 805–812, 1987. DOI: [10.1016/0038-1101\(87\)90061-3](https://doi.org/10.1016/0038-1101(87)90061-3) (citirano na stranici 18).
- [36] K. Ishaque, Z. Salam i H. Taheri, „Accurate Mathematical Model of a PV Module Using Two-Diode Model”, *Solar Energy*, sveska 85, broj 9, strane 2111–2121, 2011. DOI: [10.1016/j.solener.2011.06.004](https://doi.org/10.1016/j.solener.2011.06.004) (citirano na stranici 18).
- [37] D. L. King, W. E. Boyson i J. A. Kratochvil, „Sandia Photovoltaic Array Performance Model”, *Sandia National Laboratories Report*, broj SAND2004-3535, 2004. (citirano na stranicama 19, 21).
- [38] D. Faiman, „Assessing the Outdoor Operating Temperature of Photovoltaic Modules”, *Progress in Photovoltaics: Research and Applications*, sveska 16, broj 4, strane 307–315, 2008. DOI: [10.1002/pip.813](https://doi.org/10.1002/pip.813) (citirano na stranicama 19, 21, 33).
- [39] E. Skoplaki i J. A. Palyvos, „On the temperature dependence of photovoltaic module electrical performance: A review of efficiency/power correlations”, *Solar Energy*, sveska 83, broj 5, strane 614–624, 2009. DOI: [10.1016/j.solener.2008.10.008](https://doi.org/10.1016/j.solener.2008.10.008) (citirano na stranicama 19, 21).
- [40] H. J. Wenger, T. E. Hoff, J. W. Pepper i R. J. Dargatz, „Performance of PVUSA Utility-Scale Photovoltaic Systems”, u *Proceedings of the 1st World Conference on Photovoltaic Energy Conversion*, 1994., strane 1069–1074 (citirano na stranicama 19, 21).
- [41] B. Marion i drugi, „Comparison of Measured and Modeled Photovoltaic System Performance”, *Solar Energy*, sveska 79, broj 6, strane 639–652, 2005. DOI: [10.1016/j.solener.2005.06.001](https://doi.org/10.1016/j.solener.2005.06.001) (citirano na stranici 19).
- [42] G. Makrides, B. Zinsser, M. Norton i G. E. Georghiou, „Performance of Photovoltaic Systems Under Actual Operating Conditions”, *Renewable Energy*, sveska 35, broj 1, strane 193–200, 2010. DOI: [10.1016/j.renene.2009.04.011](https://doi.org/10.1016/j.renene.2009.04.011) (citirano na stranicama 19, 21).
- [43] P. Gilman i drugi, „SAM Photovoltaic Model Technical Reference”, National Renewable Energy Laboratory (NREL), tehnički izveštaj NREL/TP-6A20-64102, 2016. (citirano na stranici 20).
- [44] A. Mermoud i T. Lejeune, „Performance Assessment of a Grid-Connected PV Plant”, *PVsyst Technical Report*, 2010. (citirano na stranici 20).

- [45] N. Blair, P. Gilman, S. Janzou, J. Freeman, N. DiOrio i M. Wagner, *System Advisor Model (SAM) Version 2020.11.29: Technical Reference Manual*, National Renewable Energy Laboratory (NREL), Golden, CO, USA, 2020. DOI: [10.2172/1766936](https://doi.org/10.2172/1766936) adresa: <https://sam.nrel.gov/> (citirano na stranicama 21, 42).
- [46] National Renewable Energy Laboratory, *System Advisor Model (SAM) Documentation and Tutorials*, Accessed: 2025-01-12, 2022. adresa: <https://sam.nrel.gov/documentation> (citirano na stranicama 21, 42).
- [47] A. Mellit i S. A. Kalogirou, „Artificial intelligence techniques for modelling and forecasting of solar radiation data: A review”, *Renewable Energy*, sveska 33, broj 8, strane 1729–1742, 2008. DOI: [10.1016/j.renene.2007.08.001](https://doi.org/10.1016/j.renene.2007.08.001) (citirano na stranicama 21–23).
- [48] C. Voyant i drugi, „Machine learning methods for solar radiation forecasting: A review”, *Renewable Energy*, sveska 105, strane 569–582, 2017. DOI: [10.1016/j.renene.2016.12.095](https://doi.org/10.1016/j.renene.2016.12.095) (citirano na stranicama 21–23).
- [49] L. Benali, G. Notton, A. Fouilloy, C. Voyant i C. Paoli, „A hybrid model for solar radiation forecasting using support vector regression and wavelet decomposition”, *Renewable Energy*, sveska 130, strane 333–344, 2019. DOI: [10.1016/j.renene.2018.06.079](https://doi.org/10.1016/j.renene.2018.06.079) (citirano na stranicama 21, 23).
- [50] S. A. Kalogirou, „Artificial neural networks in renewable energy systems applications: A review”, *Renewable and Sustainable Energy Reviews*, sveska 5, broj 4, strane 373–401, 2001. DOI: [10.1016/S1364-0321\(01\)00006-5](https://doi.org/10.1016/S1364-0321(01)00006-5) (citirano na stranici 21).
- [51] F. Z. Benkouider, S. Chettih i A. Mellit, „Deep Learning-Based Forecasting of Photovoltaic Power Using LSTM Networks”, *Energy*, sveska 198, strana 117 248, 2020. DOI: [10.1016/j.energy.2020.117248](https://doi.org/10.1016/j.energy.2020.117248) (citirano na stranici 21).
- [52] G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang i L. Yang, „Physics-Informed Machine Learning”, *Nature Reviews Physics*, sveska 3, strane 422–440, 2021. DOI: [10.1038/s42254-021-00314-5](https://doi.org/10.1038/s42254-021-00314-5) (citirano na stranici 22).
- [53] G. E. P. Box, G. M. Jenkins, G. C. Reinsel i G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5. izdanje. Hoboken, NJ, USA: Wiley, 2015., ISBN: 978-1-118-67502-1 (citirano na stranici 22).
- [54] Y. Liu, Y. Zhou i D. Chen, „Forecasting of solar radiation using time series models”, *Applied Energy*, sveska 92, strane 313–321, 2012. DOI: [10.1016/j.apenergy.2011.11.054](https://doi.org/10.1016/j.apenergy.2011.11.054) (citirano na stranici 22).
- [55] R. J. Hyndman i G. Athanasopoulos, *Forecasting: Principles and Practice*. OTexts, 2018. adresa: <https://otexts.com/fpp2/> (citirano na stranici 22).

- [56] L. Breiman, „Random Forests”, *Machine Learning*, sveska 45, broj 1, strane 5–32, 2001. DOI: [10.1023/A:1010933404324](https://doi.org/10.1023/A:1010933404324) (citirano na stranici 23).
- [57] K. Hornik, M. Stinchcombe i H. White, „Multilayer Feedforward Networks are Universal Approximators”, *Neural Networks*, sveska 2, broj 5, strane 359–366, 1989. DOI: [10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8) (citirano na stranicama 23, 110).
- [58] S. Hochreiter i J. Schmidhuber, „Long Short-Term Memory”, *Neural Computation*, sveska 9, broj 8, strane 1735–1780, 1997. DOI: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735) (citirano na stranici 23).
- [59] K. Cho i drugi, „Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation”, *arXiv preprint arXiv:1406.1078*, 2014. (citirano na stranici 23).
- [60] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong i W.-C. Woo, „Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting”, u *Advances in Neural Information Processing Systems (NeurIPS)*, sveska 28, 2015. (citirano na stranici 23).
- [61] F. Wang, Z. Mi, S. Su i H. Zhao, „Deep learning based forecasting of photovoltaic power generation using convolutional neural networks and long short-term memory”, *Applied Energy*, sveska 275, strana 115 369, 2020. DOI: [10.1016/j.apenergy.2020.115369](https://doi.org/10.1016/j.apenergy.2020.115369) (citirano na stranici 23).
- [62] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison i F. Antonanzas-Torres, „Review of photovoltaic power forecasting”, *Solar Energy*, sveska 136, strane 78–111, 2016. DOI: [10.1016/j.solener.2016.06.069](https://doi.org/10.1016/j.solener.2016.06.069) (citirano na stranici 23).
- [63] J. A. Duffie i W. A. Beckman, *Solar Engineering of Thermal Processes*, 4th. Hoboken, NJ, USA: Wiley, 2013. (citirano na stranicama 28, 29, 31, 35).
- [64] G. M. Masters, *Renewable and Efficient Electric Power Systems*, 2nd. Wiley, 2013. (citirano na stranicama 28, 34).
- [65] *IEC 61724-1:2021 — Photovoltaic System Performance — Part 1: Monitoring*, Geneva, Switzerland: International Electrotechnical Commission, 2021. (citirano na stranicama 28, 46, 79).
- [66] *IEC 60891:2021 — Photovoltaic Devices — Procedures for Temperature and Irradiance Corrections to Measured I–V Characteristics*, Geneva, Switzerland: International Electrotechnical Commission, 2021. (citirano na stranici 28).
- [67] J. Malczewski, *GIS and Multicriteria Decision Analysis*. John Wiley & Sons, 1999. (citirano na stranici 29).

- [68] R. Luthander, J. Widén, D. Nilsson i J. Palm, „Photovoltaic Self-Consumption in Buildings: A Review”, *Applied Energy*, sveska 142, strane 80–94, 2015. DOI: [10.1016/j.apenergy.2014.12.028](https://doi.org/10.1016/j.apenergy.2014.12.028) (citirano na stranicama 31, 38).
- [69] *PVsyst User's Manual*, Photovoltaic system simulation software, PVsyst SA, 2023. (citirano na stranici 32).
- [70] HOMER Energy by UL Solutions, *HOMER Pro 3.15 User Manual: Microgrid and Hybrid System Optimization Software*, Accessed: 2025-01-12, UL Solutions, 2023. adresa: <https://www.homerenergy.com/products/pro/index.html> (citirano na stranicama 32, 42).
- [71] C. Moler, *Numerical Computing with MATLAB*. SIAM, 2004. (citirano na stranici 32).
- [72] *IEC 61215-1:2021 — Terrestrial Photovoltaic (PV) Modules — Design Qualification and Type Approval*, Geneva, Switzerland: International Electrotechnical Commission, 2021. (citirano na stranici 32).
- [73] *IEC 61730-1:2023 — Photovoltaic (PV) Module Safety Qualification*, Geneva, Switzerland: International Electrotechnical Commission, 2023. (citirano na stranici 32).
- [74] *IEC 62109-1:2022 — Safety of Power Converters for Use in Photovoltaic Power Systems*, Geneva, Switzerland: International Electrotechnical Commission, 2022. (citirano na stranici 32).
- [75] N. M. e. a. Haegel, „Terawatt-Scale Photovoltaics: Trajectories and Challenges”, *Science*, sveska 364, broj 6443, strane 836–838, 2019. DOI: [10.1126/science.aaw1845](https://doi.org/10.1126/science.aaw1845) (citirano na stranici 32).
- [76] *IEC 62548:2016 — Photovoltaic (PV) Arrays — Design Requirements*, Geneva, Switzerland: International Electrotechnical Commission, 2016. (citirano na stranici 34).
- [77] R. Teodorescu, M. Liserre i P. Rodriguez, *Grid Converters for Photovoltaic and Wind Power Systems*. Wiley, 2011. (citirano na stranici 34).
- [78] *EN 1991-1-4:2005+A1:2010 — Eurocode 1: Actions on Structures — Part 1-4: General Actions — Wind Actions*, Brussels, Belgium: European Committee for Standardization (CEN), 2010. (citirano na stranici 35).
- [79] *EN 1991-1-3:2003+A1:2015 — Eurocode 1: Actions on Structures — Part 1-3: General Actions — Snow Loads*, Brussels, Belgium: European Committee for Standardization (CEN), 2015. (citirano na stranici 35).

- [80] *IEC 61643-31:2018 — Low-Voltage Surge Protective Devices — Part 31: Requirements and Test Methods for SPDs for Photovoltaic Installations*, Geneva, Switzerland: International Electrotechnical Commission, 2018. (citirano na stranici 35).
- [81] *IEC 60364-7-712:2017 — Low-voltage Electrical Installations — Requirements for PV Power Supply Systems*, Geneva, Switzerland: International Electrotechnical Commission, 2017. (citirano na stranici 36).
- [82] W. Short, D. J. Packey i T. Holt, „A Manual for the Economic Evaluation of Energy Efficiency and Renewable Energy Technologies”, National Renewable Energy Laboratory (NREL), Golden, CO, USA, 2022. (citirano na stranicama 36, 37, 143, 144).
- [83] International Renewable Energy Agency, „Renewable Power Generation Costs in 2022”, IRENA, Abu Dhabi, UAE, 2023. (citirano na stranici 36).
- [84] K. Branker, M. J. M. Pathak i J. M. Pearce, „A Review of Solar Photovoltaic Levelized Cost of Electricity”, *Renewable and Sustainable Energy Reviews*, sveska 15, broj 9, strane 4470–4482, 2011. DOI: [10.1016/j.rser.2011.07.104](https://doi.org/10.1016/j.rser.2011.07.104) (citirano na stranicama 36, 37, 143, 144).
- [85] D. C. Jordan i S. R. Kurtz, „Photovoltaic Degradation Rates — An Analytical Review”, *Progress in Photovoltaics*, sveska 21, broj 1, strane 12–29, 2013. DOI: [10.1002/pip.1182](https://doi.org/10.1002/pip.1182) (citirano na stranicama 37, 143).
- [86] A. Mermoud i T. Lejeune, *PVsyst 7.4 User Manual: Photovoltaic System Design Software*, Accessed: 2025-01-12, PVsyst SA, 2023. adresa: <https://www.pvsyst.com/> (citirano na stranici 42).
- [87] A. Mermoud i B. Wittmer, „Validation of PVsyst Simulation Results with Measured Data from PV Installations”, *Solar Energy*, sveska 236, strane 135–148, 2022. DOI: [10.1016/j.solener.2022.02.037](https://doi.org/10.1016/j.solener.2022.02.037) (citirano na stranici 42).
- [88] T. Huld, R. Müller, R. Marquez i M. Suri, „Advanced MATLAB-Based Modeling of Photovoltaic Systems Using Combined Meteorological and PVGIS Data”, *Renewable Energy*, sveska 195, strane 1203–1217, 2022. DOI: [10.1016/j.renene.2022.06.023](https://doi.org/10.1016/j.renene.2022.06.023) (citirano na stranici 42).
- [89] H. Rezk, A. M. Eltamaly, M. A. Abdelkareem i M. Al-Dhaifallah, „Dynamic Simulation and Optimization of Grid-Connected PV Systems Using MATLAB/Simulink”, *Energy Conversion and Management*, sveska 243, strana 114 340, 2021. DOI: [10.1016/j.enconman.2021.114340](https://doi.org/10.1016/j.enconman.2021.114340) (citirano na stranici 42).

- [90] A. Lamont, E. O'Neill-Carrillo i Y. Ueda, „Simulation of Hybrid Renewable Energy Systems Using HOMER Pro for Economic Optimization”, u *Proceedings of the IEEE PES Innovative Smart Grid Technologies Conference (ISGT)*, 2021., strane 1–6. DOI: [10.1109/ISGT49243.2021.9372218](https://doi.org/10.1109/ISGT49243.2021.9372218) (citirano na stranici 42).
- [91] M. Sengupta, Y. Xie, A. Lopez, A. Habte, G. Maclaurin i J. Shelby, „The National Solar Radiation Data Base (NSRDB)”, *Renewable and Sustainable Energy Reviews*, sveska 89, strane 51–60, 2018. DOI: [10.1016/j.rser.2018.03.003](https://doi.org/10.1016/j.rser.2018.03.003) (citirano na stranici 54).
- [92] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd. O'Reilly Media, 2019. (citirano na stranici 59).
- [93] T. S. Breusch i A. R. Pagan, „A Simple Test for Heteroscedasticity and Random Coefficient Variation”, *Econometrica*, sveska 47, broj 5, strane 1287–1294, 1979. DOI: [10.2307/1911963](https://doi.org/10.2307/1911963) (citirano na stranici 89).
- [94] W. H. Greene, *Econometric Analysis*, 8. izdanje. Pearson, 2018. (citirano na stranici 89).
- [95] C. M. Bishop, *Pattern Recognition and Machine Learning* (Information Science and Statistics). New York: Springer, 2006., ISBN: 978-0-387-31073-2. DOI: [10.1007/978-0-387-45528-0](https://doi.org/10.1007/978-0-387-45528-0) adresa: <https://doi.org/10.1007/978-0-387-45528-0> (citirano na stranicama 93, 148).
- [96] A. Blumer, A. Ehrenfeucht, D. Haussler i M. K. Warmuth, „Occam's razor”, *Information Processing Letters*, sveska 24, broj 6, strane 377–380, 1987. DOI: [10.1016/0020-0190\(87\)90114-1](https://doi.org/10.1016/0020-0190(87)90114-1) (citirano na stranici 93).
- [97] F. Wilcoxon, „Individual comparisons by ranking methods”, *Biometrics Bulletin*, sveska 1, broj 6, strane 80–83, 1945. DOI: [10.2307/3001968](https://doi.org/10.2307/3001968) (citirano na stranicama 95, 195).
- [98] T. Hastie, R. Tibshirani i J. Friedman, *The Elements of Statistical Learning*. Springer, 2009. (citirano na stranici 111).
- [99] S. J. Pan i Q. Yang, „A Survey on Transfer Learning”, *IEEE Transactions on Knowledge and Data Engineering*, sveska 22, broj 10, strane 1345–1359, 2010. (citirano na stranicama 111, 112).
- [100] International Renewable Energy Agency, „Renewable Power Generation Costs in 2023”, IRENA, Abu Dhabi, UAE, 2024. (citirano na stranici 143).
- [101] M. F. Møller, „A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning”, *Neural Networks*, sveska 6, broj 4, strane 525–533, 1993. DOI: [10.1016/S0893-6080\(05\)80056-5](https://doi.org/10.1016/S0893-6080(05)80056-5) adresa: [https://doi.org/10.1016/S0893-6080\(05\)80056-5](https://doi.org/10.1016/S0893-6080(05)80056-5) (citirano na stranici 147).

- [102] D. J. C. MacKay, „Bayesian Interpolation”, *Neural Computation*, sveska 4, broj 3, strane 415–447, 1992. DOI: [10.1162/neco.1992.4.3.415](https://doi.org/10.1162/neco.1992.4.3.415) adresa: <https://doi.org/10.1162/neco.1992.4.3.415> (citirano na stranicama 148, 149).
- [103] F. D. Foresee i M. T. Hagan, „Gauss-Newton Approximation to Bayesian Regularization”, u *Proceedings of the 1997 International Joint Conference on Neural Networks (IJCNN)*, sveska 3, IEEE, 1997., strane 1930–1935. DOI: [10.1109/IJCNN.1997.614194](https://doi.org/10.1109/IJCNN.1997.614194) adresa: <https://doi.org/10.1109/IJCNN.1997.614194> (citirano na stranici 148).
- [104] M. Friedman, „A comparison of alternative tests of significance for the problem of m rankings”, *Annals of Mathematical Statistics*, sveska 11, broj 1, strane 86–92, 1940. DOI: [10.1214/aoms/1177731944](https://doi.org/10.1214/aoms/1177731944) (citirano na stranici 195).
- [105] J. Demsar, „Statistical comparisons of classifiers over multiple data sets”, *Journal of Machine Learning Research*, sveska 7, strane 1–30, 2006. (citirano na stranici 195).

Biografija autora/Author's biography

Dipl. inž. Aleksandar Pantić, istraživač saradnik, rođen je 1988. godine u Nišu. Diplomirao je na Elektronskom fakultetu Univerziteta u Nišu 2015. godine.

Nakon diplomiranja, bio je angažovan u Inovacionom centru naprednih tehnologija d.o.o. (ICNT) Niš, gde je učestvovao u realizaciji više inovacionih i naučno-istraživačkih projekata. Od 2019. godine zaposlen je na Elektronskom fakultetu Univerziteta u Nišu, gde je angažovan u Centru za naučno-istraživački rad u zvanju istraživača saradnika.

Autor je i koautor većeg broja naučnih radova publikovanih u međunarodnim časopisima sa SCI liste, kao i radova prezentovanih na nacionalnim i međunarodnim naučnim konferencijama. Takođe je koautor univerzitetske zbirke zadataka „Solarne komponente – zbirka rešenih zadataka i problema“.

Učestvovao je u realizaciji više naučno-istraživačkih i razvojnih projekata, kao i u pripremi i pisanju projektnih prijava. Posebno se izdvaja učešće u pripremi projekta „Visionary Engineering & Collaborative Technology Operations (RCF-VECTOR)“, koji je odobren za finansiranje u okviru RCF fonda.

U okviru nastavnih aktivnosti, aktivno je učestvovao u radu sa studentima osnovnih i master akademskih studija, pružajući stručnu pomoć pri izradi završnih i master radova.

Oblast njegovog naučno-istraživačkog rada obuhvata modelovanje i optimizaciju fotonaponskih sistema, primenu veštačkih neuronskih mreža u energetici, kao i analizu i predviđanje performansi PV sistema korišćenjem meteoroloških i satelitskih podataka.

Trenutno je doktorand na Elektronskom fakultetu Univerziteta u Nišu, gde radi doktorску disertaciju pod nazivom „Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih (PV) sistema“.

Dipl. Eng. Aleksandar Pantić, Research Associate, was born in 1988 in Niš, Serbia. He received his B.Sc. degree from the Faculty of Electronic Engineering, University of Niš, in 2015.

After graduation, he was engaged at the Innovation Center of Advanced Technologies Ltd. (ICNT) Niš, where he participated in the implementation of several innovation and scientific research projects. Since 2019, he has been affiliated with the Faculty of Electronic Engineering, University of Niš, where he has been engaged as a Research Associate within the Center for Scientific Research.

He is the author and co-author of numerous scientific papers published in international journals indexed in the Web of Science, as well as papers presented at national and international scientific conferences. He is also a co-author of the university-level problem book entitled “Solar Components – Collection of Solved Problems and Exercises”.

He has participated in the implementation of multiple scientific research and development projects, as well as in the preparation and writing of project proposals. Notably, he contributed to the preparation of the project “Visionary Engineering & Collaborative Technology Operations (RCF-VECTOR)”, which has been approved for funding within the RCF program.

Within teaching-related activities, he has been actively involved in mentoring and assisting undergraduate and master's students in the preparation of their final and master theses.

His research interests include modeling and optimization of photovoltaic systems, application of artificial neural networks in energy systems, and analysis and forecasting of PV system performance using meteorological and satellite data.

He is currently a PhD candidate at the Faculty of Electronic Engineering, University of Niš, working on his doctoral dissertation entitled “Advanced Techniques for Design and Performance Prediction of Photovoltaic (PV) Systems”.

Spisak radova autora

Međunarodni časopisi indeksirani u Web of Science (SCI lista)

[1] Sanja Aleksić, **Aleksandar Pantić**, and Dragan Pantić, “High electric field stress model of n-channel VDMOSFET based on artificial neural network,” *Journal of Computational Electronics*, vol. 17, no. 3, pp. 1088–1097, 2018.

<https://doi.org/10.1007/s10825-018-1167-z>

[2] S. Aleksić, V. Mitić, B. Ranđelović, **A. Pantić**, B. Marković, A. Karoui, and B. Vlahović, “Fractal correction in advanced solar energy material’s current-voltage equation,” *International Journal of Modern Physics B*, vol. 36, no. 2, Art. no. 2250016, 2022.

[doi:10.1142/S0217979222500163](https://doi.org/10.1142/S0217979222500163)

[3] S. Đorđević, L. Pantić, M. Krstić, I. Radonjić, M. Mančić, and **A. Pantić**, “Enhancing monocrystalline solar module efficiency through front-surface cooling with 96% alcohol,” *Applied Sciences*, vol. 13, no. 9, Art. no. 5331, 2023.

[doi:10.3390/app13095331](https://doi.org/10.3390/app13095331)

[4] **A. Pantić**, A. Petković, N. Branković, S. Aleksić, and D. Pantić, “Neural network-based photovoltaic power forecasting using integrated ground and satellite meteorological data,” *Facta Universitatis, Series: Electronics and Energetics*, vol. XX, no. XX, Mar. 2026.

[doi:10.xxxx/xxxxx](https://doi.org/10.xxxx/xxxxx)

Domaći časopis

[5] **A. Pantić**, A. Petković, and S. Aleksić, “Design and optimization of solar parking canopy as a part of energy efficient urban planning,” *Facta Universitatis, Series: Automatic Control and Robotics*, vol. 23, no. 2, pp. 111–121, 2024.

[doi:10.22190/FUACR241028008P](https://doi.org/10.22190/FUACR241028008P)

Međunarodne konferencije

[6] **A. Pantić**, I. Stevanović, and D. Pantić, “Ultracapacitor Energy Storage System,” in *Proc. 19th International Conference on Thermal Science and Engineering of Serbia (SIMTERM)*, Sokobanja, Serbia, Oct. 2019.

[7] **A. Pantić**, D. Dimitrijević-Jovanović, P. Mitković, M. Laković-Paunović, and M. Mitković, “Solar Parking Canopy as a Part of Energy Efficient Urban Planning,” in *Proc. International Conference on Urban Planning (ICUP 2020)*, Nov. 2020.

[8] N. Stanojević, **A. Pantić**, F. Filipović, B. Branković, S. Aleksić, M. Petronijević,

and D. Pantić, “CAD Analysis of Grid-on Photovoltaic Power Plant Design and Cost-effectiveness,” in *Proc. 15th International Conference on Advanced Technologies, Systems and Services in Telecommunications (TELSIKS)*, Niš, Serbia, Oct. 2021.

[doi:10.1109/TELSIKS52058.2021.9606321](https://doi.org/10.1109/TELSIKS52058.2021.9606321).

[9] N. Stanojević and A. Pantić, “Simulacija samostalnog fotonaponskog sistema,” in *Proc. 14th IEEE Student Projects Conference (STEC)*, Niš, Serbia, 2021, pp. 185–188.

[10] **A. Pantić**, N. Stanojević, A. Petković, S. Aleksić, and D. Pantić, “ANN Model of mc-Si Solar Cell,” in *Proc. 20th International Conference on Thermal Science and Engineering of Serbia (SIMTERM)*, Niš, Serbia, Oct. 2022, pp. 642–647.

[11] S. Aleksić, B. Randelović, **A. Pantić**, N. Stanojević, and D. Milošević, “Primeri primene fraktalne analize za karakterizaciju novih materijala,” in *Proc. LXVI Conference on Electronics, Telecommunications, Computers, Automation and Nuclear Engineering (ETRAN)*, Novi Pazar, Serbia, Jun. 2022.

[12] U. Jovanović, D. Krstić, J. Malenović-Nikolić, D. Zigar, and **A. Pantić**, “Impact of Ambient Temperature on a Temperature Distribution within a Human Head When Exposed to Electromagnetic Radiation,” in *Proc. 20th International Conference on Thermal Science and Engineering of Serbia (SIMTERM)*, Niš, Serbia, Oct. 2022.

[13] D. Markushev, N. Branković, S. Aleksić, D. Pantić, A. Pantić, and D. Markushev, “How to use sound as a powerful tool for new materials characterization,” in *Proc. 11th International Conference on Electrical, Electronic and Computing Engineering (IcETRAN)*, Niš, Serbia, Jun. 2024.

[doi:10.1109/IcETRAN62308.2024.10645122](https://doi.org/10.1109/IcETRAN62308.2024.10645122).

[14] **A. Pantić**, A. Petković, and S. Aleksić, “Design and optimization of solar parking canopy as a part of energy efficient urban planning,” *Facta Universitatis, Series: Automatic Control and Robotics*, vol. 23, no. 2, pp. 111–121, 2023.

[15] D. Markushev, N. Branković, S. Aleksić, D. Pantić, **A. Pantić**, and D. Markushev, “How to use sound as a powerful tool for new materials characterization,” in *Proc. 11th International Conference on Electrical, Electronic and Computing Engineering (IcETRAN)*, Niš, Serbia, 2024, pp. 1–6. [doi:10.1109/IcETRAN62308.2024.10645122](https://doi.org/10.1109/IcETRAN62308.2024.10645122).

[16] **A. Pantić**, A. Petković, N. Branković, T. Denić, S. Aleksić, D. Pantić, “Comprehensive Analysis of Solar PV Systems: A Dual Approach with PVSyst and Matlab/Simulink,” in *Proc. XVII International Conference on Systems, Automatic Control and Measurements (SAUM)*, Niš, Serbia, 2024, pp. 193–195.

[doi:10.46793/SAUM24.193P](https://doi.org/10.46793/SAUM24.193P).

[17] S. Aleksić, D. Pantić, N. Branković, **A. Pantić**, and A. Petković, “Reliability Characterization of n-channel VDMOSFET on Elevated Temperatures,” in *Proc. First RESIST Workshop: Cross-Layer Reliability Assessment of Electronic Systems (RESIST)*, Faculty of Electronic Engineering, University of Niš, Niš, Serbia, May 2025, p. 18.

[18] N. Branković, D. K. Markushev, D. Pantić, S. Aleksić, D. Markushev, and **A. Pantić**, “Reliability Assessment of a Novel Photoacoustic Method for Material Characterization,” in *Proc. First RESIST Workshop: Cross-Layer Reliability Assessment of Electronic Systems (RESIST)*, Faculty of Electronic Engineering, University of Niš, Niš, Serbia, May 2025, p. 21.

[19] **A. Pantić**, A. Petković, N. Branković, S. Aleksić, D. Pantić, “Application of Artificial Neural Networks for Weather Forecasting and Photovoltaic Power Prediction Using Local Meteorological and Meteosat Satellite Data,” in *Proc. 2025 IEEE 34th International Conference on Microelectronics (MIEL)*, Niš, Serbia, Oct. 2025. pp. 351–354.

[doi:10.1109/MIEL66332.2025.11261189](https://doi.org/10.1109/MIEL66332.2025.11261189).

Izdavačka delatnost - udžbenici

Sanja Aleksić, **Aleksandar Pantić**, Neda Stanojević, Adriana Petković i Dragan Pantić, *SOLARNE KOMPONENTE - zbirka rešenih zadataka i problema*, izd. Atlantis - Niš, Elektronski fakultet u Nišu, 2023. ISBN 978-86-6125-263-1

6.1 Pregled publikovanih radova

U tabeli 6.3 dat je pregled publikovanih radova kandidata sa odgovarajućim kategorijama prema važećem pravilniku i ukupnim brojem ostvarenih bodova.

Tabela 6.3: *Pregled publikovanih radova kandidata sa odgovarajućim kategorijama i bodovima.*

R.br.	Publikacija	Kategorija	Bodovi
1	Applied Sciences (2023)	M22	5
2	Int. J. Mod. Phys. B (2022)	M23	3
3	Facta Univ. ACR (2024)	M24	2
4	Facta Univ. E&E (2026)	M24	2
<i>Međunarodne konferencije</i>			
5	MIEL 2025 (IEEE)	M33	1
6	TELSIKS 2021 (IEEE)	M33	1
7	IcETLAN 2024 (IEEE)	M33	1
8	SIMTERM 2022 (rad 1)	M33	1
9	SIMTERM 2022 (rad 2)	M33	1
10	SIMTERM 2019	M33	1
11	ICUP 2020	M33	1
12	ETLAN 2022	M33	1
<i>Ostali skupovi / radionice</i>			
13	STEC 2021	M34	0.5
14	RESIST 2025 (rad 1)	M34	0.5
15	RESIST 2025 (rad 2)	M34	0.5
Ukupno:			21.5



Sažetak / Summary

Doktorska disertacija pod naslovom „*Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema*“ bavi se razvojem savremenih metoda za modelovanje i predikciju proizvodnje solarnih fotonaponskih (PV) sistema primenom metoda mašinskog učenja i analitičkih energetske modele. Osnovni cilj istraživanja je unapređenje tačnosti i pouzdanosti procene proizvodnje PV sistema kroz integraciju meteoroloških podataka, simulacionih modela i metoda veštačke inteligencije.

U radu je razvijen metodološki okvir za predikciju proizvodnje PV sistema zasnovan na kombinaciji fizičkih modela i metoda mašinskog učenja, sa posebnim fokusom na primenu veštačkih neuronskih mreža (ANN) za modelovanje nelinearne zavisnosti između meteoroloških parametara i izlazne snage ili proizvedene energije fotonaponskog sistema.

Analizirana su dva konceptualno različita pristupa predikciji proizvodnje PV sistema. Prvi pristup (M1) zasniva se na indirektnom modelovanju, pri čemu se najpre predviđa globalno horizontalno zračenje (GHI), a zatim se dobijene vrednosti transformišu u energetske proizvodnje primenom fizičkog modela PV sistema. Drugi pristup (M2) zasniva se na direktnoj predikciji izlazne snage ili energije korišćenjem jedinstvene ANN arhitekture.

Razvijeni modeli evaluirani su na osnovu višegodišnjih meteoroloških i energetske podataka za region Niša korišćenjem standardnih statističkih metrika greške (MAE, RMSE i nRMSE). Dobijeni rezultati pokazuju visok nivo tačnosti i stabilno ponašanje modela u različitim meteorološkim uslovima.

Komparativna analiza indirektnog i direktnog pristupa pokazuje da oba modela imaju specifične prednosti u zavisnosti od ciljane aplikacije. Indirektni pristup omogućava veću interpretabilnost i bolju analizu fizičkih procesa, dok direktni pristup obezbeđuje jednostavniju strukturu modela pogodnu za operativne sisteme prognoze proizvodnje električne energije.

The doctoral dissertation entitled “*Advanced Techniques for the Design and Prediction of Photovoltaic System Characteristics*” focuses on the development of advanced methods for modeling and forecasting the performance of solar photovoltaic (PV) systems using machine learning techniques and analytical energy models. The primary objective of the research is to improve the accuracy and reliability of PV power forecasting through the integration of meteorological data, simulation models, and artificial intelligence methods.

A methodological framework for PV power forecasting is developed based on the combination of physical models and data-driven approaches. Particular emphasis is placed on the application of artificial neural networks (ANN) for modeling nonlinear relationships between meteorological variables and the output power or energy production of photovoltaic systems.

Two conceptually different forecasting approaches are investigated. The first approach (M1) represents an indirect modeling strategy in which global horizontal irradiance (GHI) is first predicted and then converted into PV energy production using a physical PV system model. The second approach (M2) represents a direct forecasting strategy where a unified ANN architecture directly predicts PV output power or energy.

The developed models are evaluated using multi-year meteorological and energy datasets for the Niš region, applying standard statistical error metrics such as MAE, RMSE, and nRMSE. The obtained results demonstrate high forecasting accuracy and stable model performance under different meteorological conditions.

The comparative analysis of the two approaches shows that each method provides specific advantages depending on the intended application. The indirect approach offers better interpretability and insight into physical processes, while the direct approach provides a simpler model structure suitable for operational PV power forecasting systems.

Ključne reči / Keywords:

fotonaponski sistemi, predikcija proizvodnje PV sistema, veštačke neuronske mreže, mašinsko učenje, meteorološki podaci / photovoltaic systems, PV power forecasting, artificial neural networks, machine learning

IZJAVA O AUTORSTVU

Izjavljujem da doktorska disertacija, pod naslovom:

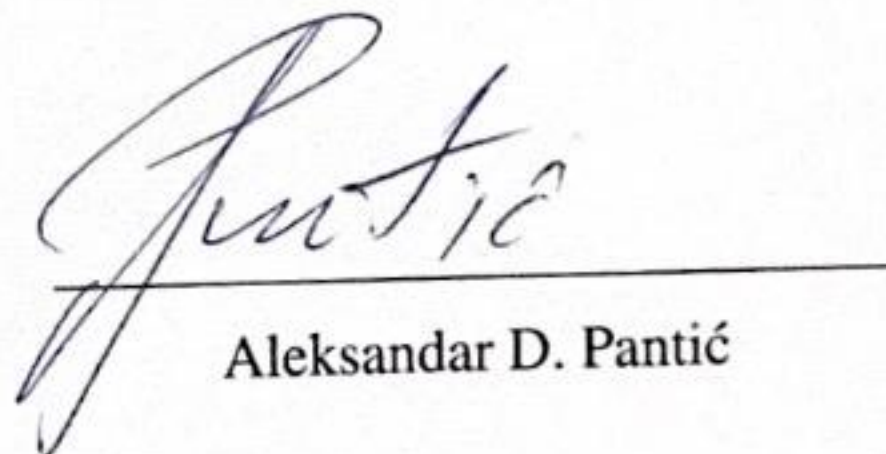
Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema

- rezultat sopstvenog istraživačkog rada,
- da predložena disertacija u celini ni u delovima nije bila predložena za dobijanje bilo koje diplome prema studijskim programima drugih visokoškolskih ustanova,
- da su rezultati korektno navedeni i
- da nisam kršio autorska prava i koristio intelektualnu svojinu drugih lica.

Dozvoljavam da se objavi moj lični podaci, koji su vezani za uspešno odbranenu doktorsku disertaciju, kao što su ime i prezime, godina i mesto rođenja i datum odbrane disertacije.

U Nišu, 27.03.2026

Potpis autora disertacije


Aleksandar D. Pantić

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

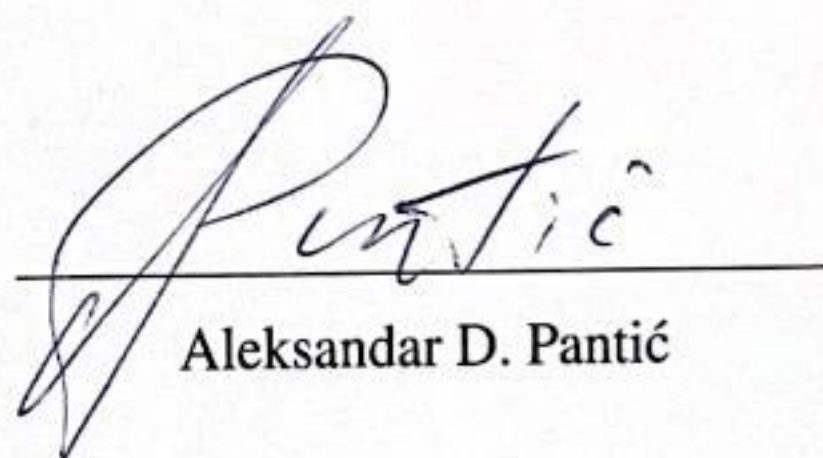
Naslov disertacije:

Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema

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

U Nišu, 27.03.2026

Potpis autora disertacije


Aleksandar D. Pantić

IZJAVA O KORIŠĆENJU

Ovlašćujem Univerzitetsku biblioteku "Nikola Tesla" u Digitalni repozitorijum Univerziteta u Nišu unese moju doktorsku disertaciju pod naslovom:

Napredne tehnike projektovanja i predviđanja karakteristika fotonaponskih sistema

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

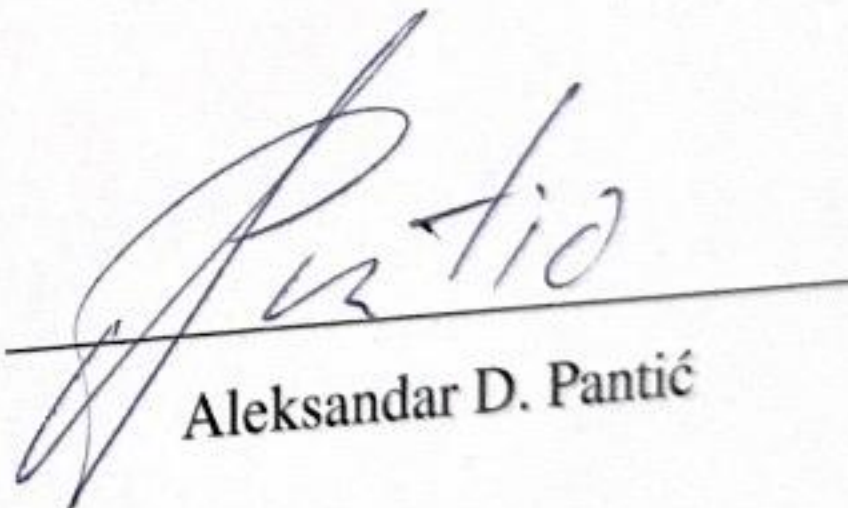
Moju doktorsku disertaciju pohranjenu u Digitalni repozitorijum Univerziteta u Nišu mogu da koriste svi koji poštuju odredbe sadržane u odabranom tipu licence Creative Commons za koju sam se odlučio.

Odabrana Creative Commons licenca:

1. Autorstvo (CC BY)
2. Autorstvo - nekomercijalno (CC BY-NC)
3. Autorstvo - bez prerade (CC BY-ND)
4. Autorstvo - nekomercijalno - bez prerade (CC BY-NC-ND)
5. Autorstvo - deliti pod istim uslovima (CC BY-SA)

U Nišu, 27.03.2026

Potpis autora disertacije


Aleksandar D. Pantić