

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Ervin Čeperić

**Modeli predviđanja u energetske
sustavima temeljeni na metodi potpornih
vektora**

DOKTORSKI RAD

Rijeka, 2026.

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Ervin Čeperić

**Modeli predviđanja u energetske
sustavima temeljeni na metodi potpornih
vektora**

DOKTORSKI RAD

Mentor: Prof. dr. sc. Kristijan Lenac

Komentor: Prof. dr. sc. Saša Vlahinić

Rijeka, 2026.

UNIVERSITY OF RIJEKA
FACULTY OF ENGINEERING

Ervin Čeperić

**Support Vector Machine-based
Predictive Models for Energy Systems**

DOCTORAL THESIS

Supervisor: Professor Kristijan Lenac, PhD
Co-supervisor: Professor Saša Vlahinić, PhD

Rijeka, 2026

Mentor rada: Prof. dr. sc. Kristijan Lenac

Komentor rada: Prof. dr. sc. Saša Vlahinić

Doktorski rad obranjen je dana _____ na Tehničkom fakultetu
Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. Prof. dr. sc. Goran Mauša, Tehnički fakultet, Sveučilište u Rijeci

2. Prof. dr. sc. Vedran Kirinčić, Tehnički fakultet, Sveučilište u Rijeci

3. Prof. dr. sc. Juraj Havelka, Fakultet elektrotehnike i računarstva, Sveučilište u
Zagrebu

Doktorski rad ima: 193 stranica

ZAHVALE

Zahvaljujem svojim mentorima, prof. dr. sc. Kristijanu Lencu i prof. dr. sc. Saši Vlahiniću, na stručnom vodstvu, strpljenju i potpori tijekom izrade ovog doktorskog rada. Njihove smjernice i savjeti bili su od neprocjenjive važnosti za oblikovanje i uspješan završetak istraživanja.

Zahvaljujem Tehničkom fakultetu Sveučilišta u Rijeci na pruženoj institucionalnoj potpori i mogućnosti za provođenje istraživanja.

Zahvaljujem kolegama u HEP-u na razumijevanju i podršci koju su mi pružili tijekom studija uz rad.

Posebnu zahvalnost dugujem svojoj obitelji na bezuvjetnoj potpori, razumijevanju i strpljenju koje su mi iskazivali tijekom cijelog trajanja doktorskog studija.

SAŽETAK

Kratkoročno predviđanje električnog opterećenja (engl. *Short-Term Load Forecasting*, STLF) i kratkoročno predviđanje cijene prirodnog plina (engl. *Short-Term Natural Gas Price Forecasting*, ST-NGPF) imaju važnu ulogu u planiranju i vođenju elektroenergetskih sustava te u upravljanju rizikom i donošenju odluka na energetske tržištima. Visoka razina točnosti prognoza nužna je za osiguranje pouzdanosti sustava i ekonomske učinkovitosti, osobito u uvjetima izražene nelinearnosti, sezonalnosti i volatilnosti podataka te snažnog utjecaja meteoroloških i tržišnih čimbenika.

U radu se razvija unificirani metodološki okvir za kratkoročno predviđanje u energetici temeljen na metodi potpornih vektora za regresiju (engl. *Support Vector Regression*, SVR). Predloženi okvir integrira sustavan inženjering značajki, podatkovno utemeljene postupke odabira značajki te prilagođene strategije optimizacije hiperparametara. U području STLF-a razvijen je sezonski prilagođeni model (SSA-SVR, engl. *Strategic Seasonality-Adjusted SVR*) te hibridni model DNN-SVR, kojim se kombiniraju reprezentacijske sposobnosti dubokih neuronskih mreža i generalizacijska svojstva SVR-a. Radi povećanja preciznosti predviđanja uspostavljena je struktura zasebnih satno-specijaliziranih podmodela. U području ST-NGPF-a primijenjen je sezonski prilagođeni SVR okvir, prilagođen specifičnoj dinamici i volatilnosti tržišnih podataka.

Empirijska validacija provedena je na više stvarnih skupova podataka. U domeni STLF-a korišteni su podaci sustava ISO New England, jedne sjevernoameričke elektroprivrede te hrvatskog elektroenergetskog sustava, dok je za ST-NGPF analizirano referentno tržište prirodnog plina Henry Hub. Modeli su trenirani na višegodišnjim vremenskim nizovima uz razmatranje različitih konfiguracija ulaznih varijabli i vremenskih horizonata predikcije (do 24 sata unaprijed za opterećenje te do 7 dana unaprijed za cijenu prirodnog plina). U STLF-u su korištene energetske, meteorološke i kalendarske značajke, uključujući i globalne numeričke vremenske prognoze, dok su u ST-NGPF-u analizirane tržišne i makroekonomske varijable poput cijena

povezanih energenata, razine zaliha i sezonskih pokazatelja.

Rezultati istraživanja pokazuju da predloženi modeli sustavno nadmašuju referentne statističke i samostalne modele strojnog učenja. U području STLF-a hibridni DNN–SVR model postiže višu razinu točnosti u odnosu na pojedinačne modele dubokog učenja, dok struktura satno-specijaliziranih podmodela dodatno poboljšava performanse u odnosu na jedinstveni model. U području ST-NGPF-a optimirani SVR modeli ostvaruju bolje rezultate od tradicionalnih ekonometrijskih pristupa, osobito na duljim horizontima predviđanja.

Znanstveni doprinos rada ogleda se u razvoju sezonski prilagođenog SVR modela, hibridnog DNN–SVR pristupa te uspostavi generičkog i eksperimentalno verificiranog SVR-okvira za kratkoročno predviđanje u energetske sustavima. Dodatno je provedena sustavna analiza utjecaja konstrukcije i odabira značajki, sezonalnosti i veličine skupa podataka na generalizacijsku sposobnost modela. Dobiveni rezultati empirijski potvrđuju hipoteze o učinkovitosti hibridne integracije SVR-a, satne dekompozicije modela i uključivanja globalnih meteoroloških prognoza te ukazuju na praktičnu primjenjivost razvijenih modela u realnim energetske sustavima i tržišnim okruženjima. Time je potvrđena opća valjanost i primjenjivost razvijenog metodološkog okvira u tehnički i tržišno različitim energetske sustavima.

Ključne riječi: kratkoročno predviđanje opterećenja, predviđanje cijena prirodnog plina, metoda potpornih vektora, duboke neuronske mreže, odabir značajki, energetske sustavi, strojno učenje.

ABSTRACT

Short-Term Load Forecasting (STLF) and Short-Term Natural Gas Price Forecasting (ST-NGPF) play a crucial role in the planning and operation of power systems, as well as in risk management and decision-making processes in energy markets. A high level of forecasting accuracy is essential to ensure system reliability and economic efficiency, particularly under conditions of pronounced nonlinearity, seasonality, data volatility, and strong influence of meteorological and market-related factors.

This dissertation develops a unified methodological framework for short-term forecasting in energy systems based on Support Vector Regression (SVR). The proposed framework integrates systematic feature engineering, data-driven feature selection procedures, and tailored hyperparameter optimization strategies. In the STLF domain, a seasonality-adjusted model (SSA-SVR, Strategic Seasonality-Adjusted SVR) and a hybrid DNN–SVR model are developed, combining the representational capabilities of deep neural networks with the generalization properties of SVR. To enhance forecasting precision, a structure of separate hour-specific submodels is established. In the ST-NGPF domain, a seasonality-adjusted SVR framework is applied and adapted to the specific dynamics and volatility of market data.

Empirical validation is conducted on multiple real-world datasets. In the STLF domain, data from the ISO New England system, a North American utility, and the Croatian power system are used, while for ST-NGPF the reference Henry Hub natural gas market is analyzed. The models are trained on multi-year time series considering different configurations of input variables and forecasting horizons (up to 24 hours ahead for load and up to 7 days ahead for natural gas prices). In STLF, energy, meteorological, and calendar features are utilized, including global numerical weather prediction data, whereas in ST-NGPF market and macroeconomic variables such as related energy prices, storage levels, and seasonal indicators are analyzed.

The research results demonstrate that the proposed models systematically outperform

benchmark statistical and standalone machine learning models. In the STL domain, the hybrid DNN–SVR model achieves higher forecasting accuracy compared to individual deep learning models, while the hour-specific modeling structure further improves performance relative to a unified global model. In the ST-NGPF domain, optimized SVR models outperform traditional econometric approaches, particularly at longer forecasting horizons.

The scientific contribution of this dissertation lies in the development of a seasonality-adjusted SVR model, a hybrid DNN–SVR approach, and the establishment of a generic and experimentally validated SVR-based framework for short-term forecasting in energy systems. A systematic analysis of the impact of feature construction and selection, seasonality, and dataset size on the generalization capability of the models is also conducted. The obtained results empirically confirm the hypotheses regarding the effectiveness of hybrid SVR integration, hour-specific model decomposition, and the inclusion of global meteorological forecasts, and demonstrate the practical applicability of the developed models. Consequently, the applicability of the proposed methodological framework is validated across technically and market-wise diverse energy systems

Keywords: short-term load forecasting, natural gas price forecasting, support vector machine, deep neural networks, feature selection, energy systems, machine learning.

SADRŽAJ

Zahvale	I
Sažetak	III
Abstract	V
Popis slika	XIV
Popis tablica	XVII
Lista pojmova	XXI
1. Uvod	1
1.1. Problem i predmet istraživanja	1
1.2. Hipoteze istraživanja	2
1.3. Pregled dosadašnjih istraživanja	3
1.4. Znanstveni doprinos	4
1.5. Svrha, ciljevi i struktura rada	6
2. Pregled područja istraživanja	9
2.1. Kratkoročno predviđanje električnog opterećenja – značaj i izazovi	9
2.2. Pregled metoda kratkoročnog predviđanja opterećenja	10
2.2.1. Klasične statističke i modeli vremenskih serija	10
2.2.2. Metode strojnog učenja	11

2.2.3.	Napredni modeli dubokog učenja	12
2.2.4.	Hibridni i ansamblski pristupi predviđanju	13
2.3.	Kratkoročno predviđanje cijene prirodnog plina - značaj i specifičnosti	14
2.4.	Pregled metoda predviđanja cijene prirodnog plina	14
2.4.1.	Klasični statistički i ekonometrijski modeli	14
2.4.2.	Metode strojnog učenja	15
2.4.3.	Modeli dubokog učenja za predviđanje cijena prirodnog plina	16
2.4.4.	Regionalne specifičnosti glavnih tržišta prirodnog plina	17
2.5.	Ključna ograničenja i istraživački kontekst	18
2.5.1.	Nelinearnost i kompleksni obrasci	18
2.5.2.	Dimenzionalnost i odabir značajki	19
2.5.3.	Ograničenja postojećih modela	19
2.5.4.	Motivacija i smjer istraživanja	20
3.	Teorijske osnove metode potpornih vektora i algoritama za odabir značajki	21
3.1.	Temeljni principi SVM-a	21
3.1.1.	Klasifikacija maksimizacijom margine i linearni SVM-ovi	21
3.1.1.1.	Margina	21
3.1.1.2.	Linearni SVM klasifikator	22
3.1.2.	Jezgreni trik i Mercerov uvjet	23
3.1.3.	Nelinearni SVM klasifikatori	25
3.1.4.	VC-teorija i minimizacija strukturalnog rizika	29
3.2.	Metoda potpornih vektora za procjenu funkcije	30
3.2.1.	Metoda potpornih vektora za procjenu linearne funkcije	30
3.2.2.	SVM za procjenu nelinearne funkcije	31
3.2.3.	VC-granica za pogrešku generalizacije	33
3.3.	Optimizacija hiperparametara	35
3.3.1.	Klasične metode pretraživanja hiperparametara	35

3.3.2.	Optimizacija rojem čestica	36
3.3.3.	Hibridni algoritam PSwarm	36
3.4.	Odabir značajki	37
3.4.1.	Genetski algoritmi s informacijskim kriterijem (GA–IT)	38
3.4.2.	Minimalna redundancija i maksimalna relevantnost (mRMR)	38
3.4.3.	Relief metoda odabira značajki	38
3.4.4.	StepwiseFS metoda odabira značajki	38
3.4.5.	Odabir značajki temeljen na algoritmu <i>Gradient Boosting</i>	39
3.5.	Osnove dubokih neuronskih mreža	39
4.	Unificirani metodološki okvir temeljen na SVR-u i hibridnim proširenjima	43
4.1.	Opći metodološki okvir i temeljni SVR pristup	44
4.2.	Protokol pripreme i predobrade podataka	46
4.2.1.	Opći protokol kontrole kvalitete i očuvanja vremenskog integriteta	46
4.2.2.	Postupanje s nedostajućim vrijednostima i konzervativna obrada	46
4.2.3.	Predobrada i skaliranje uz očuvanje vremenske izolacije	47
4.2.4.	Kronološka podjela podataka i izolacija postupka podešavanja	47
4.2.5.	Očuvanje fizički smislenih varijacija i strukturnih promjena	47
4.3.	Formulacija višekoračnog prediktivnog zadatka i konstrukcija ulaznog prostora	48
4.3.1.	Taksonomija ulaznih varijabli u STLf i ST-NGPF	48
4.3.2.	Konstrukcija značajki i odabir značajki	49
4.3.3.	Satno-specijalizirani i jedinstveni pristup	50
4.3.4.	Konstrukcija ulaznog prostora za satno-specijalizirane modele	51
4.3.4.1.	Opća struktura ulaznog vektora za satno uvjetovane modele	52
4.3.5.	Implikacije formulacije zadatka na odabir značajki	52
4.4.	Kalibracija modela: odabir značajki, optimizacija hiperparametara i završno treniranje	53
4.4.1.	Odabir značajki u SSA–SVR konfiguracijama	53

4.4.2.	Optimizacija hiperparametara SVR modela primjenom PSwarm algoritma	53
4.4.3.	Optimizacija završnog SVR sloja u DNN-SVR arhitekturi primjenom grid search postupka	54
4.4.4.	Treniranje konačnog modela s fiksiranim hiperparametrima	54
4.5.	Protokol evaluacije: vremenska podjela i metrike	54
4.5.1.	Strategija vremenske podjele podataka i validacije	54
4.5.2.	Evaluacija modela (metrike)	55
4.6.	Integracija dubokog učenja u SVR okvir	56
4.6.1.	Teorijska motivacija i pozicioniranje DNN–SVR modela	56
4.6.2.	Arhitektura i operativni slijed modeliranja	56
4.6.3.	Odabir značajki u DNN-SVR postavu	58
4.6.4.	Metodološke prednosti integracije	58
4.7.	Sažetak metodološkog okvira i plan eksperimenata	58
5.	Eksperimentalna validacija i komparativna analiza modela za kratkoročno predvi- đanje potrošnje električne energije	61
5.1.	Skupovi podataka i postavke eksperimenta	61
5.1.1.	ISO New England: Opis i priprema podataka	61
5.1.1.1.	Meteorološki podaci, kalendarske značajke i predobrada	62
5.1.2.	North-American Utility: Opis i priprema podataka	62
5.1.3.	Hrvatska: Opis i priprema podataka	63
5.1.3.1.	Sezonalnost, praznici i kalendarske značajke	64
5.1.3.2.	Vremenska pokrivenost i eksperimentalna podjela skupa po- dataka	65
5.1.3.3.	Integracija globalnih vremenskih prognoza	68
5.1.4.	Specifična predobrada i kontrola kvalitete STLTF skupa podataka	69
5.1.4.1.	Nedostajuće vrijednosti i provjera konzistentnosti podataka	69
5.1.4.2.	Strukturne promjene u potrošnji i vremenski integritet podataka	70
5.1.4.3.	Skaliranje i standardizacija ulaznih značajki	70

5.1.5.	Konstrukcija ulaznog prostora i satno uvjetovani odabir značajki za STLFEksperimente	71
5.1.5.1.	Ulazne značajke za satno uvjetovane regresijske modele . . .	71
5.1.5.2.	Dimenzionalnost kandidatskog ulaznog prostora prije primjene odabira značajki	72
5.1.5.3.	Satno specijalizirani odabir značajki	73
5.1.6.	Jedinstveni satno uvjetovani DNN-SVR model kao alternativna eksperimentalna konfiguracija	74
5.1.6.1.	Konstrukcija ulaznog vektora i satno uvjetovanje	74
5.1.6.2.	Odabir značajki i postupak skaliranja	76
5.1.6.3.	Treniranje modela i postupak izvođenja prognoze	76
5.2.	Eksperimentalna evaluacija i analiza performansi SSA-SVR modela	76
5.2.1.	ISO New England: Usporedba SSA-SVR, ANN i SIWNN	76
5.2.2.	North-American Utility: Usporedba SSA-SVR s neuronskim i hibridnim valićnim modelima	81
5.2.3.	Usporedba algoritama za odabir značajki na SSA-SVR	88
5.2.4.	Učinak vremenskih i kalendarskih varijabli na SSA-SVR	88
5.3.	Eksperimentalna evaluacija i analiza performansi DNN-SVR modela	91
5.3.1.	Analiza značajki dobivenih metodom XGBoost	93
5.3.2.	Samostalni DNN model kao nelinearni ekstraktor značajki: arhitektura i odabir konfiguracije	95
5.3.3.	Ablacijska analiza utjecaja SVR regresijske faze u hibridnom DNN-SVR modelu	97
5.3.4.	Statistička validacija robusnosti modela putem višestrukih inicijalizacija	99
5.3.5.	Usporedba satno-specijaliziranih i jedinstvenih prediktivnih modela . .	101
5.3.6.	Utjecaj integracije globalnih meteoroloških prognoza	102
5.3.7.	Referentni sekvencijski i Transformer modeli za usporedbu s DNN-SVR pristupom	105
5.3.8.	Hiperparametarske postavke referentnih modela	106

5.4. Sinteza rezultata i implikacije	106
5.4.1. Validacija metodologije na javnim skupovima ISO New England i North-American Utility	106
5.4.2. Integrirana analiza rezultata na hrvatskom elektroenergetskom sustavu .	108
5.4.2.1. Opća evaluacija hibridnog DNN-SVR okvira	108
5.4.2.2. Sinergija dubokih neuronskih mreža i SVR regresije	108
5.4.2.3. Utjecaj strategije modeliranja i satne dekompozicije	109
5.4.2.4. Generalizacijska svojstva i skalabilnost metodološkog okvira	110
5.4.2.5. Operativne implikacije i računalna složenost	111
5.4.2.6. Generalizacija i skalabilnost pristupa	111
6. Eksperimentalna validacija i komparativna analiza modela za kratkoročno predviđanje cijena prirodnog plina	113
6.1. Skup podataka i postavke eksperimenta	113
6.1.1. Skup ulaznih varijabli i domenska motivacija	113
6.1.2. Konstrukcija značajki: vremenske odgode i transformacije	115
6.1.3. Definicija eksperimentalnih skupova ulaza	115
6.1.4. Odabir značajki i procedure treniranja	116
6.1.5. Podjela podataka, metrike i protokol evaluacije	117
6.2. Jednodnevno predviđanje cijene prirodnog plina: rezultati i komparativna analiza	117
6.2.1. Učinak algoritama za odabir značajki na SVR model	120
6.2.2. Komparativna analiza modela na testnom skupu	120
6.3. Jednotjedno predviđanje cijene prirodnog plina: rezultati i komparativna analiza	121
6.3.1. Učinak algoritama za odabir značajki na SVR model	121
6.3.2. Komparativna analiza modela na testnom skupu	124
6.4. Analiza robusnosti eksperimentalne postavke	124
6.5. Diskusija i sažetak ključnih nalaza	125
7. Zaključak i smjernice za daljnja istraživanja	127

7.1. Sažetak ciljeva	127
7.2. Sažetak rezultata istraživanja	128
7.3. Znanstveni doprinosi rada	129
7.4. Potvrda postavljenih hipoteza	130
7.5. Integrirana analiza STLF i ST-NGPF rezultata	131
7.6. Metodološke i operativne implikacije	132
7.7. Ograničenja istraživanja	133
7.8. Smjernice za daljnja istraživanja	134
7.9. Završna sinteza	135
A Matematičke osnove metode potpornih vektora	137
A1. Izvod dualne formulacije linearnog SVM-a	137
1.1.1. Linearno odvojiv slučaj	137
1.1.2. Linearno neodvojiv slučaj	139
A2. VC-teorija i minimizacija strukturalnog rizika	141
1.2.1. Empirijski rizik naspram pogreške generalizacije	141
1.2.2. Minimizacija strukturalnog rizika	143
A3. Detaljna izvedba linearne procjene funkcije pomoću SVM-a	145
A4. Specifikacije algoritama za odabir značajki	148
1.4.1. Genetski algoritmi s informacijskim kriterijem (GA-IT)	148
1.4.2. Minimalna redundancija i maksimalna relevantnost (mRMR)	149
1.4.3. Relief metoda odabira značajki	149
1.4.4. StepwiseFS metoda odabira značajki	150
1.4.5. Odabir značajki temeljen na algoritmu <i>Gradient Boosting</i>	151
1.4.5.1. Osnove algoritma <i>Gradient Boosting</i>	152
1.4.5.2. Rangiranje značajki u modelima gradijentnog pojačanja	152
1.4.5.3. Prednosti pristupa temeljenog na gradijentnom pojačanju	153
B Detaljni eksperimentalni rezultati	155

B1.	Detaljni opis i priprema referentnih skupova podataka	155
2.1.1.	ISO New England: meteorološki podaci i njihova obrada	155
2.1.1.1.	Meteorološki podaci i njihova obrada	155
2.1.1.2.	Sezonalnost i kalendarske značajke (praznici)	156
2.1.2.	North-American Utility: meteorološki podaci i ograničenja	157
2.1.2.1.	Sličnosti i razlike u odnosu na ISO New England skup podataka	158
B2.	Proširena usporedba algoritama za odabir značajki	158
B3.	Arhitekture referentnih sekvencijskih i Transformer-baziranih modela	160
2.3.1.	Referentni sekvencijski LSTM model	160
2.3.1.1.	Arhitektura i inženjering značajki	161
2.3.1.2.	Seqvencijski LSTM model s dekomerom i mehanizmom pažnje	161
2.3.1.3.	Eksperimentalna postavka i analiza rezultata	162
2.3.2.	Referentni Transformer modeli	162
2.3.2.1.	Enkodorski Transformer (Model 1.)	163
2.3.2.2.	Hibridni Transformer enkoder + SVR (Model 2.)	164
2.3.2.3.	Temporal Fusion Transformer (TFT, Model 3.)	165
2.3.2.4.	PatchTST-temeljeni Transformer (Model 4)	166
2.3.2.5.	Ulazne značajke i dizajn ulaznih tokova kroz modele	167
2.3.2.6.	Usporedba performansi Transformer-baziranih modela	168
2.3.2.7.	Utjecaj količine podataka na višehorizontne modele	169
B4.	Hiperparametarske postavke referentnih modela	170
Literatura		175
Životopis		191
Biography		193

POPIS SLIKA

3.1	Linearna klasifikacija: prikaz jedinstvene razdvajajuće hiperravnine u dvodimenzionalnom ulaznom prostoru. Margina je udaljenost između isprekidanih linija.	23
3.2	(Gore) Preslikavanje ulaznog prostora u visokodimenzionalni prostor značajki gdje je ostvareno linearno razdvajanje, što odgovara nelinearnom razdvajanju u izvornom ulaznom prostoru; (Dolje) Ilustracija jezgrenog trika u kojem je odabrana funkcija $K(x, z)$ i prikaz u obliku skalarnog produkta moguć je pod uvjetom da je $K(\cdot, \cdot)$ simetrična pozitivno definitna jezgrena funkcija.	25
3.3	Primalno i dualno tumačenje metode potpornih vektora pomoću neuronskih mreža.	26
3.4	Kod nelinearnih klasifikatora metode potpornih vektora potporni vektori (označeni crnim točkama) nalaze se blizu granice odluke, što je ilustrirano ovdje na jednostavnom primjeru binarnog problema koji nije linearno separabilan.	27
4.1	Blok dijagram temeljne SVR metodologije s uključenom sezonskom konstrukcijom značajki (SSA-SVR), prikazujući glavne faze modeliranja od pripreme podataka do implementacije, uz povratnu vezu iz faze validacije prema fazi generiranja značajki.	45
4.2	Shematski prikaz predloženog hibridnog DNN-SVR modela. Proces započinje s ulaznim podacima, prolazi kroz DNN slojeve (trenirane za svaki podskup podataka), te završava SVR regresijskim slojem koji daje konačnu prognozu.	57
5.1	Frekvencijska analiza podataka o opterećenju za Hrvatsku (2006-2022)	66

5.2	Vremensko pokrivanje skupova za treniranje (pune trake, razdoblje 2006.–2021.) i testiranje (isprekidane trake, 2022.). Evaluirano je pet prozora za treniranje: sveobuhvatni skup (2006.–2021.), tri srednjoročna razdoblja (2012.–2021., 2014.–2021., 2016.–2021.) te kratkoročni skup (2018.–2021.). Svi modeli koriste 80/20 podjelu za treniranje i validaciju unutar razvojnog razdoblja, dok se testiranje provodi isključivo na podacima iz 2022.	67
5.3	Mjesečne MAPE vrijednosti na skupu podataka ISO New England za 2006. godinu za modele ANN, SIWNN i SSA-SVR u režimu korištenja stvarnih (a.w.) i prognoziranih (f.w.) vremenskih podataka	80
5.4	Grafička usporedba MAPE vrijednosti modela na <i>North-American Utility</i> skupu podataka.	85
5.5	Usporedba satnih MAPE vrijednosti između predloženog SSA-SVR modela i ESN modela [33] na 24-satnom predviđanju opterećenja (<i>North-American Utility</i> skup podataka). Prikazane su vrijednosti MAPE za svaki sat dan-a pri korištenju simuliranih (predviđenih) meteoroloških podataka. SSA-SVR model u pravilu ostvaruje niži MAPE po satu te ujednačeniju točnost kroz dane sate u usporedbi s ESN modelom.	87
5.6	Satna usporedba MAPE pogreške između samostalnog DNN modela i hibridnog DNN-SVR modela za testnu godinu 2022.	99
5.7	Utjecaj uključivanja NWP-temeljenih meteoroloških prognoza na točnost hibridnog DNN-SVR modela.	103
5.8	Satna usporedba MAPE pogreške za satno specijalizirani hibridni DNN-SVR model s uključenim i isključenim prognostičkim meteorološkim varijablama.	104
A1	Ako očekivani rizik $R(\theta)$ i empirijski rizik $R_{emp}(\theta)$ oba konvergiraju na vrijednost $\inf_{\theta} R(\theta)$ kada broj podataka N teži beskonačnosti, tada je proces učenja konzistentan.	142

A2	<i>Primjer s $N = 4$ točke u $n = 2$ dimenzijskom ulaznom prostoru. Te se točke mogu označiti na $2^4 = 16$ mogućih načina. Najviše 3 točke mogu se razdvojiti pravcima, jer je poznato da posljednja dva slučaja predstavljaju XOR probleme koje nije moguće razdvojiti pravcem. To rezultira VC dimenzijom jednakom 3. Za nelinearne klasifikatore ova VC dimenzija može biti i veća.</i>	143
A3	<i>Princip strukturne minimizacije rizika i ilustracija granice pogreške generalizacije ovisno o VC dimenziji.</i>	144
A4	<i>(Gore) Vapnikova ε-neosjetljiva funkcija gubitka za procjenu funkcije; (Dolje) ε-cijev točnosti i točke koje ne mogu postići tu točnost, što motivira uvođenje varijabli odstupanja.</i>	145
B1	<i>Primjeri vremenskih pomaka (lags) odabranih StepwiseFS algoritmom za sate 7 i 18 na North-American Utility skupu podataka</i>	160

POPIS TABLICA

5.1	Sažetak kategorija ulaznih značajki prije satno-specijaliziranog odabira značajki temeljenog na algoritmu XGBoost	73
5.2	Usporedba mjesečnih MAPE vrijednosti za modele ANN, SIWNN i SSA-SVR na ISO New England skupu podataka za 2006. godinu, korištene stvarne temperature u predikciji	78
5.3	Usporedba mjesečnih MAPE vrijednosti za modele ANN, SIWNN i SSA-SVR na ISO New England skupu podataka za 2006. godinu, korištene prognozirane temperature	79
5.4	Usporedba MAPE točnosti za modele na North-American Utility skupu podataka za 1h i 24h predikciju, s korištenjem stvarnih i prognoziranih temperatura.	85
5.5	Utjecaj izostavljanja značajki $H_{1,...,4}$ i T_{CR}, T_{HR}, T_{XHR} te treniranja s izmjerenim temperaturama na točnost modela SSA-SVR (MAPE vrijednosti za ISO New England, 2006. godina, korištene prognozirane vremenske varijable)	89
5.6	Utjecaj izostavljanja ulaznih varijabli i korištenja samo izmjerenih temperatura na MAPE — North-American Utility skup podataka	90
5.7	Strukture DNN mreža i prosječna minimalna validacijska MAE pogreška (satno specijalizirana postavka).	97
5.8	Ablacijska analiza: usporedba samostalnog DNN modela i hibridnog DNN-SVR modela s RBF jezgrom za arhitekturu 256×256 (satno specijalizirani višemodelni pristup, testna godina 2022.).	98
5.9	Statistička validacija putem višestrukih inicijalizacija (10 nezavisnih pokretanja, inicijalizacije 0–9) za samostalni DNN i hibridni DNN-SVR model.	100

5.10	Usporedba satno specijaliziranih podmodela i jedinstvenog prediktivnog modela za DNN i hibridni DNN-SVR pristup.	101
5.11	Utjecaj prognostičkih meteoroloških prediktora temeljenih na NWP-u na performanse hibridnog DNN-SVR modela.	103
5.12	Sažetak performansi referentnih sekvencijskih i Transformer-baziranih modela na testnoj godini 2022.	105
6.1	Rezultati SVR modela s odabirom značajki (5 varijabli) - jednodnevna prognoza	118
6.2	Rezultati SVR modela s odabirom značajki (10 varijabli) - jednodnevna prognoza	119
6.3	Usporedba odabranih modela za jednodnevnu prognozu (rezultati na testnom skupu)	120
6.4	Rezultati SVR modela s odabirom značajki (5 varijabli) - tjedno	122
6.5	Rezultati SVR modela s odabirom značajki (10 varijabli) - tjedno predviđanje .	123
6.6	Usporedba odabranih modela za tjednu prognozu (rezultati na testnom skupu) .	124
B1	Usporedba performansi različitih algoritama odabira značajki na skupovima podataka ISO New England i North-American Utility (izraženo u MAPE) . . .	159
B2	Utjecaj veličine skupa za treniranje na performanse sekvencijskog LSTM modela	162
B3	Usporedba konfiguracija i strategija treniranja Transformer modela.	169
B4	Utjecaj veličine skupa za treniranje na performanse TFT modela.	170
B5	Hiperparametarske postavke referentnih prognostičkih modela.	172

LISTA POJMOVA

U nastavku je dan popis kratica korištenih u ovom radu.

Kratica	Engleski naziv	Hrvatski naziv
ANN	Artificial Neural Network	Umjetna neuronska mreža
AR	Autoregressive	Autoregresijski model
ARIMA	Autoregressive Integrated Moving Average	Autoregresijski integrirani model pomičnih prosjeka
CatBoost	Categorical Boosting	—
CNN	Convolutional Neural Network	Konvolucijska neuronska mreža
DNN	Deep Neural Network	Duboka neuronska mreža
DNN–SVR	Deep Neural Network – Support Vector Regression	Duboka neuronska mreža – regresija potpornim vektorima
ECMWF	European Centre for Medium-Range Weather Forecasts	Europski centar za srednjoročne vremenske prognoze
ESN	Echo State Network	Mreža s odjekom stanja
FNN	Feedforward Neural Network	neuronska mreža naprijednog širenja
FS	Feature Selection	Odabir značajki
GA	Genetic Algorithm	Genetski algoritam
GBM	Gradient Boosting Machine	Stroj gradijentnog pojačavanja
GPR	Gaussian Process Regression	Regresija Gausovim procesima

1. UVOD

1.1. Problem i predmet istraživanja

Tijekom posljednja dva desetljeća elektroenergetski sustavi diljem svijeta prolaze kroz značajne transformacije potaknute digitalizacijom, liberalizacijom tržišta, sve većom integracijom obnovljivih izvora energije i zahtjevima za povećanjem energetske učinkovitosti. U takvim uvjetima, donošenje pravovremenih i preciznih operativnih odluka postaje ključno, osobito u područjima predviđanja potrošnje električne energije i kretanja cijena energenata. Tradicionalne metode predviđanja pokazale su ograničenu učinkovitost u okruženju obilježenom izraženom nelinearnošću, sezonalnošću i tržišnom volatilnošću.

Ovaj doktorski rad usmjeren je na dva metodološki povezana problema u okviru energetskog planiranja i analitike:

- **Kratkoročno predviđanje električnog opterećenja** (eng. *Short-Term Load Forecasting*, STLF) – ključno za operativno vođenje elektroenergetskog sustava, optimizaciju proizvodnih i prijenosnih resursa te učinkovitu integraciju obnovljivih izvora energije.
- **Kratkoročno predviđanje cijene prirodnog plina** (eng. *Short-Term Natural Gas Price Forecasting*, ST-NGPF) – presudno za donošenje strateških odluka u nabavi energenata, formiranju cijena i upravljanju tržišnim rizicima u uvjetima povećane volatilnosti energetskih tržišta.

Predmet istraživanja obuhvaća razvoj i evaluaciju prediktivnih modela temeljenih na metodi potpornih vektora (eng. *Support Vector Machines*, SVM), s naglaskom na njezinu regresijsku inačicu (*Support Vector Regression*, SVR), uz integraciju algoritama za odabir značajki (*Feature Selection*, FS) i modela dubokog učenja (*Deep Neural Networks*, DNN). Cilj je ispitati mogućnosti ovih modela i njihovih hibridnih varijanti u poboljšanju točnosti kratkoročnih predviđanja

električne potrošnje i cijene prirodnog plina.

1.2. Hipoteze istraživanja

Na temelju teorijskog pregleda, dosadašnjih spoznaja i preliminarne eksperimentalnih rezultata, postavljene su sljedeće znanstvene hipoteze koje čine osnovu za daljnja istraživanja i empirijsku validaciju:

1. Integracija metode potpornih vektora u završni sloj duboke neuronske mreže može povećati točnost predviđanja u energetske sustavima.

Hipoteza polazi od pretpostavke da integracija metode potpornih vektora u završni sloj duboke neuronske mreže omogućuje učinkovitije iskorištavanje dubokih nelinearnih reprezentacija naučenih iz podataka. Takva hibridna arhitektura kombinira visoku izražajnost dubokih neuronskih mreža s robusnom regresijskom aproksimacijom temeljenom na principu maksimalne margine, što može rezultirati povećanom točnošću kratkoročnog predviđanja potrošnje električne energije u odnosu na samostalne DNN modele.

2. Korištenje modela potrošnje električne energije prilagođenih jednosatnim vremenskim intervalima dana može poboljšati točnost predviđanja

Ova hipoteza polazi od pretpostavke da intradnevni obrasci potrošnje električne energije pokazuju izraženu heterogenost, zbog čega jedinstveni prognostički model mora istodobno aproksimirati različite režime ponašanja sustava. Razdvajanje prognostičkog zadatka po jednosatnim vremenskim intervalima omogućuje prilagodbu modela specifičnim satnim karakteristikama potrošnje, što može dovesti do smanjenja pogreške predviđanja.

3. Korištenje globalnog prognostičkog modela za vremensku prognozu može poboljšati točnost predviđanja potrošnje električne energije.

Hipoteza se temelji na pretpostavci da globalni prognostički meteorološki modeli, unatoč ograničenoj prostornoj rezoluciji, sadrže relevantnu informaciju o budućim vremenskim uvjetima koja se može učinkovito iskoristiti kao egzogeni ulaz u modele za kratkoročno predviđanje potrošnje električne energije, čime se može poboljšati točnost predviđanja u odnosu na modele bez prognostičkih meteoroloških podataka.

Postavljene hipoteze primarno se odnose na STLTF domenu, dok se ST-NGPF koristi kao dodatna validacija opće primjenjivosti razvijenog metodološkog okvira.

1.3. Pregled dosadašnjih istraživanja

Problem kratkoročnog predviđanja u energetske sustavima predmet je intenzivnog istraživanja već više od tri desetljeća, pri čemu su se metodološki pristupi postupno razvijali od klasičnih statističkih modela prema sve složenijim tehnikama strojnog i dubokog učenja. U nastavku je sažet pregled ključnih razvojnih pravaca u obje domene razmatrane u ovom radu; detaljna analiza literature dana je u Poglavlju 2..

Razvoj metoda kratkoročnog predviđanja opterećenja. Rane metode STLF-a temeljile su se na klasičnim statističkim pristupima, uključujući regresijsku analizu, ARIMA modele i metode eksponencijalnog izgladivanja (Odjeljak 2.2.1.). Iako su ti pristupi postavili temelje zahvaljujući teorijskoj utemeljenosti i transparentnosti, pokazali su ograničenu učinkovitost u uvjetima izražene nelinearnosti i složenih intradnevni obrazaca potrošnje. Uvođenje metoda strojnog učenja, ponajprije umjetnih neuronskih mreža i metode potpornih vektora za regresiju (SVR), donijelo je značajan napredak u modeliranju nelinearnih odnosa između ulaznih varijabli i opterećenja (Odjeljak 2.2.2.). SVR se pritom istaknuo svojom robusnom generalizacijom, otpornošću na šum i teorijskom utemeljenošću temeljenom na principu maksimalne margine. Posljednje desetljeće obilježeno je usponom modela dubokog učenja — LSTM mreža, konvolucijskih neuronskih mreža i Transformer arhitektura — koji automatski uče složene reprezentacije iz velikih skupova podataka (Odjeljak 2.2.3.). Paralelno s tim, razvijeni su hibridni i ansamblski pristupi koji kombiniraju prednosti više modela, primjerice statistički model za linearnu komponentu i neuronsku mrežu za nelinearnu komponentu (Odjeljak 2.2.4.).

Razvoj metoda kratkoročnog predviđanja cijene prirodnog plina. U domeni ST-NGPF-a, ekonometrijski modeli poput ARIMA-e, GARCH-a i vektorskih autoregresijskih (VAR) modela tradicionalno su služili kao temeljni alati za analizu i prognozu cijena (Odjeljak 2.4.1.). Međutim, njihova linearna struktura i pretpostavka stacionarnosti ograničavaju im primjenjivost u uvjetima visoke tržišne volatilnosti i strukturnih promjena. Primjena metoda strojnog učenja — umjetnih neuronskih mreža, SVR-a i ansamblskih tehnika temeljenih na stablima odluke — omogućila je modeliranje nelinearnih tržišnih odnosa i obuhvaćanje većeg broja utjecajnih čimbenika (Odjeljak 2.4.2.). U novije se vrijeme istražuju i modeli dubokog učenja, uključujući LSTM, CNN–LSTM hibride i Transformer arhitekture, koji pokazuju potencijal za preciznije hvatanje

složenih vremenskih obrazaca na energetske tržištima (Odjeljak 2.4.3.).

Ključna ograničenja postojećih pristupa. Unatoč značajnom napretku, u literaturi su identificirana ograničenja koja motiviraju ovo istraživanje (Odjeljak 2.5.):

- Klasični linearni modeli ne mogu adekvatno obuhvatiti nelinearne i dinamičke obrasce karakteristične za potrošnju električne energije i kretanje cijena energenata.
- Složeni modeli dubokog učenja, unatoč visokoj izražajnosti, skloni su prenaučenosti i zahtijevaju velike količine podataka za pouzdanu generalizaciju, što ograničava njihovu primjenu na manjim ili kraćim skupovima podataka.
- Većina predloženih modela razvijena je i validirana za jednu specifičnu domenu ili jedan skup podataka, bez sustavne provjere primjenjivosti na različitim sustavima i skalama.
- Postupci odabira značajki često su provedeni heuristički, bez sustavne kvantifikacije njihova doprinosa točnosti i stabilnosti modela.
- Rijetki su radovi koji nude unificirani metodološki okvir primjenjiv na tehnički determinirane sustave opterećenja i tržišno uvjetovane sustave cijena energenata.

Upravo ova ograničenja usmjeravaju ovo istraživanje prema razvoju SVR-temeljenog metodološkog okvira koji integrira kontroliranu konstrukciju ulaznog prostora, automatizirani odabir značajki i hibridnu integraciju s dubokim učenjem, s ciljem postizanja visoke točnosti uz robusnost i generalizabilnost na različite energetske domene.

1.4. Znanstveni doprinos

Na temelju identificiranih ograničenja u dosadašnjim pristupima, ovaj rad ostvaruje sljedeće znanstvene doprinose:

1. **Unificirani SSA–SVR metodološki okvir.** Razvijen je formalizirani i reproducibilni okvir za kratkoročno predviđanje koji integrira sezonsku prilagodbu, konstrukciju proširenog ulaznog prostora, automatizirani odabir značajki i optimizaciju hiperparametara u jedinstven postupak modeliranja. Za razliku od većine postojećih pristupa koji su razvijeni za pojedinačnu domenu ili sustav, predloženi je okvir generički — uspješno primijenjen na tri različita elektroenergetska sustava i jedno tržište energenata — čime je demonstrirana njegova strukturna generalizabilnost.

2. **Hibridni DNN–SVR model.** Predložen je i eksperimentalno validiran hibridni model koji koristi duboku neuronsku mrežu za ekstrakciju nelinearnih reprezentacija te SVR kao završnu regresijsku komponentu. Za razliku od samostalnih DNN modela koji su skloni prenaučivosti, hibridna arhitektura iskorištava SVR-ovu regularizaciju temeljenu na principu maksimalne margine, čime se postiže konzistentno i statistički značajno poboljšanje točnosti uz očuvanje robusnosti.
3. **Metodologija satno specijaliziranog modeliranja.** Uvedena je struktura zasebnih podmodela za svaki sat u danu (24 specijalizirana podmodela), čime je omogućeno preciznije prilagođavanje intradnevnom obrascima potrošnje. Dok većina pristupa u literaturi koristi jedinstveni konsolidirani model, satna dekompozicija smanjuje heterogenost problema učenja i omogućuje diferencirano upravljanje pogreškom po vremenskim intervalima.
4. **Integracija globalnih numeričkih vremenskih prognoza.** Empirijski je potvrđena vrijednost uključivanja NWP-temeljenih prognostičkih meteoroloških podataka kao egzogenih varijabli u STL modela. Dok se većina studija oslanja na izmjerene meteorološke podatke, korištenje prognoza simulira operativno realne uvjete i pruža stabilno poboljšanje točnosti predviđanja.
5. **Sustavna kvantifikacija doprinosa odabira značajki.** Provedena je sustavna analiza utjecaja različitih algoritama za odabir značajki (Relief, mRMR, sekvencijalne metode, genetski algoritmi uz informacijsku teoriju te pristupi temeljeni na gradijentnom boostingu) na točnost i stabilnost modela u obje domene. Za razliku od postojećih studija koje odabir značajki tretiraju kao sporednu komponentu, ovaj rad kvantitativno pokazuje da kontrolirana selekcija ulaznih varijabli predstavlja ključan čimbenik generalizacije modela.
6. **Komparativna analiza s referentnim metodama.** Provedena je sustavna usporedba razvijenih modela s relevantnim referentnim pristupima različite razine složenosti — klasičnim ANN i ARIMA modelima te suvremenim LSTM i Transformer arhitekturama — pod ujednačenim eksperimentalnim uvjetima. Time je omogućena objektivna procjena relativne učinkovitosti predloženih metoda i potvrđena njihova konkurentnost u odnosu na suvremene pristupe.

Navedeni doprinosi detaljno su razrađeni i empirijski potkrijepljeni u eksperimentalnim poglavljima rada (Poglavljja 5 i 6) te sintetizirani u zaključku (Poglavlje 7).

1.5. Svrha, ciljevi i struktura rada

Svrha ovog rada jest razviti i eksperimentalno verificirati unificirani metodološki okvir za kratkoročno predviđanje u energetske sustavima, temeljen na metodi potpornih vektora za regresiju (SVR), koji je primjenjiv na probleme kratkoročnog predviđanja električnog opterećenja (STLF) i kratkoročnog predviđanja cijene prirodnog plina (ST-NGPF). Poseban naglasak stavljen je na modeliranje u uvjetima nelinearnosti, sezonalnosti, visoke dimenzionalnosti i volatilnosti podataka, uz integraciju postupaka odabira značajki i optimizacije hiperparametara te, u području STLF-a, povezivanje s metodama dubokog učenja.

Glavni ciljevi istraživanja su:

- Razviti generičku strategiju modeliranja temeljenu na SVR-u za kratkoročno predviđanje opterećenja i cijene prirodnog plina, uz definiranje arhitekture modela prilagođene različitim vremenskim horizontima.
- Konstruirati sezonski prilagođeni SVR model (SSA-SVR) te ispitati prednosti strukturiranja zasebnih podmodela po jednosatnim intervalima u problemu 24-satnog predviđanja opterećenja.
- Razviti i evaluirati hibridni DNN–SVR model u području STLF-a, s ciljem iskorištavanja reprezentacijskih sposobnosti dubokih neuronskih mreža i robusnosti SVR-a.
- Ispitati učinkovitost različitih algoritama za odabir značajki (Relief, mRMR, sekvencijalne metode, genetski algoritmi uz informacijsku teoriju te pristupi temeljeni na gradijentnom boostingu) u kontekstu povećanja točnosti, robusnosti i interpretabilnosti modela.
- Empirijski validirati predložene okvire na stvarnim skupovima podataka (ISO New England, North American Utility, hrvatski elektroenergetski sustav i tržište Henry Hub) uz ujednačenu metodologiju obrade, treniranja i evaluacije modela.
- Analizirati utjecaj veličine skupa podataka, sezonalnosti, vremenskog horizonta i strukture ulaznih varijabli na generalizacijsku sposobnost modela u obje domene primjene.

U istraživanju su primijenjene sljedeće znanstvene metode: sustavna analiza literature, matematičko modeliranje metodom potpornih vektora za regresiju, primjena algoritama za odabir značajki i smanjenje dimenzionalnosti, razvoj i integracija arhitekture dubokog učenja, heuristička optimizacija hiperparametara te eksperimentalna validacija na stvarnim vremenskim nizovima.

Rad je strukturiran u sedam poglavlja.

Poglavlje 1 definira istraživački problem, predmet i hipoteze rada, daje sažet pregled dosadašnjih istraživanja, eksplicitno navodi znanstvene doprinose te opisuje svrhu, ciljeve i metodološki pristup.

Poglavlje 2 daje pregled literature iz područja STLf-a i ST-NGPF-a, s naglaskom na razvoj metodologija od klasičnih statističkih i ekonometrijskih modela do suvremenih metoda strojnog i dubokog učenja te identificira istraživačke izazove i otvorena pitanja.

Poglavlje 3 prikazuje teorijske osnove metode potpornih vektora, formulaciju SVR-a, odabir kernel-funkcija i postupke optimizacije, kao i temeljne principe algoritama za odabir značajki.

Poglavlje 4 opisuje predloženi metodološki okvir, uključujući obradu podataka, inženjering značajki, implementaciju SSA-SVR i DNN-SVR modela, optimizaciju hiperparametara te eksperimentalni dizajn evaluacije.

Poglavlje 5 prikazuje rezultate primjene razvijenih modela u području STLf-a kroz tri studije slučaja, uz detaljnu komparativnu analizu i raspravu o utjecaju pojedinih komponenti metodologije.

Poglavlje 6 obrađuje primjenu SVR okvira u području ST-NGPF-a na tržištu Henry Hub, uz usporedbu s referentnim ekonometrijskim modelima i analizu utjecaja različitih skupova značajki.

Poglavlje 7 iznosi zaključke, sintetizira znanstvene doprinose, potvrđuje postavljene hipoteze te predlaže smjernice za buduća istraživanja.

2. PREGLED PODRUČJA ISTRAŽIVANJA

2.1. Kratkoročno predviđanje električnog opterećenja – značaj i izazovi

Kratkoročno predviđanje električnog opterećenja (eng. *Short-Term Load Forecasting*, STLF) označava proces predviđanja električnog opterećenja, odnosno potrošnje električne energije, u kratkom vremenskom horizontu – od nekoliko sati unaprijed do najviše jednog tjedna. Ono predstavlja jedan od ključnih zadataka u planiranju i pogonu suvremenih elektroenergetskih sustava. Precizne prognoze opterećenja od presudne su važnosti za svakodnevno upravljanje elektroenergetskim sustavom: operatori prijenosnih i distribucijskih mreža, kao i elektroprivredna poduzeća, oslanjaju se na kratkoročne prognoze kako bi optimizirali raspodjelu proizvodnje, upravljali pričuvnim izvorima, planirali radove održavanja i osigurali pouzdanost rada mreže [20].

Točna kratkoročna predviđanja potrošnje omogućuju učinkovitiju integraciju obnovljivih izvora energije, stabilnije formiranje tržišnih cijena te preciznije trgovanje električnom energijom. Čak i relativno male pogreške mogu imati značajne ekonomske posljedice – podcjenjivanje potrošnje dovodi do povećanih troškova hitne nabave energije, dok precjenjivanje rezultira rasipanjem resursa [52]. Kratkoročne prognoze koriste se i kao ulazni podaci za sigurnosne analize sustava [20].

Tradicionalne statističke metode (ARIMA, eksponencijalno izgladivanje) bile su temelj ranih prognoza, no pokazale su ograničenu učinkovitost u uvjetima nelinearnosti, što je usmjerilo pozornost prema metodama strojnog učenja – neuronskim mrežama, neizrazitoj logici i hibridnim

pristupima. Suvremeni modeli, uključujući duboko učenje i metodu potpornih vektora za regresiju (SVR), postižu visoku razinu točnosti, no STLTF ostaje aktivno istraživačko područje jer i minimalna poboljšanja donose znatne ekonomske koristi.

2.2. Pregled metoda kratkoročnog predviđanja opterećenja

2.2.1. Klasične statističke i modeli vremenskih serija

Rani pristupi kratkoročnom predviđanju opterećenja prvenstveno su primjenjivali klasične statističke metode i metode vremenskih serija. Te su metode privlačne zbog svoje jednostavnosti, razumljivosti te dobro utemeljene teorijske osnove koja stoji iza njih. Jedan od temeljnih pristupa jest regresijska analiza (eng. *regression analysis*), u kojoj se opterećenje izražava kao funkcija različitih čimbenika (prediktora) poput vremenskih indeksa, meteoroloških varijabli (temperatura, vlažnost), tipa dana (radni dan, vikend, praznik) i moguće ekonomskih pokazatelja.

Linearni regresijski modeli za STLTF često uključuju članove poput stupnjeva dana grijanja i hlađenja (eng. *heating and cooling degree-days*) kako bi obuhvatili osjetljivost opterećenja na temperaturu, no imaju poteškoća sa složenim nelinearnim ovisnostima.

ARIMA modeli, utemeljeni na Box–Jenkins metodologiji, kombiniraju autoregresijske članove i pokretne prosjeke uz diferenciranje radi postizanja stacionarnosti, a sezonske inačice (SARIMA) dodatno uključuju periodičke obrasce. ARIMA modeli spadaju među najčešće korištene jednovarijantne metode za STLTF [52], no njihova je učinkovitost ograničena bez eksplicitnog uključivanja egzogenih varijabli, što vodi do proširene varijante ARIMAX. Metode ekspanencijskog izgladivanja, osobito Holt-Wintersova tehnika s višestrukim sezonskim ciklusima, također su se pokazale korisnima; Taylor je uveo dvostruko- i trostruko-sezonski model ekspanencijskog izgladivanja za obuhvaćanje dnevnih i tjednih obrazaca opterećenja [126].

Modeli prostora stanja (eng. *state-space modeling*), temeljeni na Kalmanovom filteru i njegovim nelinearnim inačicama, prikladni su za stvarnovremensko prognoziranje zahvaljujući rekurzivnoj prirodi. Gaur i Majumdar [46] primijenili su prošireni (EKF) i bezmirisni Kalmanov filter (UKF) na nelinearni model prostora stanja s egzogenim varijablama te postigli poboljšanu točnost u odnosu na linearne filtere i mreže s odjekom stanja.

Tradicionalne statističke metode postavile su temelje za STLTF i još se koriste kao referentni

modeli zahvaljujući transparentnosti i manjim zahtjevima za podacima. Ipak, ograničenost u modeliranju nelinearnih odnosa potaknula je istraživanje tehnika umjetne inteligencije.

2.2.2. Metode strojnog učenja

Tijekom 1990-ih istraživači su započeli s primjenom umjetnih neuronskih mreža (eng. *Artificial Neural Networks*, ANN) na STLTF, vođeni potrebom za modeliranjem nelinearnosti koje klasični linearni modeli nisu mogli obuhvatiti. Empirijske studije pokazale su da ANN modeli, poput višeslojnog perceptrona, često nadmašuju tradicionalne metode, osobito kada je odnos između opterećenja i vremenskih čimbenika izrazito nelinearan [59]. Khotanzad i sur. razvili su sustav ANNSTLTF koji je ostvario vrlo nisku pogrešku predviđanja satne potrošnje [70]. Međutim, ANN modeli su skloni prenaučivosti (eng. *overfitting*) te se suočavaju s prokletstvom dimenzionalnosti (eng. *curse of dimensionality*) pri velikom broju ulaznih značajki [20].

Paralelno su istraživani pristupi temeljeni na neizrazitoj logici (eng. *fuzzy set theory*), koji omogućuju obradu nepreciznih ulaznih veličina i uključivanje stručnog znanja putem pravila oblika ako-onda. Song i sur. (2005) pokazali su da neizrazita linearna regresija poboljšava prognoze za dane s neuobičajenim obrascima potrošnje [120]. Kombiniranje neizrazite logike s neuronskim mrežama, primjerice u obliku neuro-fuzzy sustava [52], pokazalo je potencijal za bolje modeliranje nelinearnosti. Nguyen i Liao (2011) primijenili su prilagodljivi neuro-neizraziti sustav zaključivanja (ANFIS) za satnu prognozu potrošnje te ostvarili vrlo nisku pogrešku predviđanja uz zadržavanje interpretabilnosti [94]. Hibridni pristupi – uključujući kombinacije ANN-a s neizrazitom logikom, evolucijskom optimizacijom i ansamblima – općenito ostvaruju veću točnost od pojedinačnih modela [59, 94], no zahtijevaju složeno podešavanje i nemaju jasan teorijski okvir, što je otvorilo put formalnijim metodama poput metode potpornih vektora (SVM).

U kontekstu STLTF-a naglasak se stavlja na regresijsku varijantu metode potpornih vektora – SVR (eng. *Support Vector Regression*), čije su teorijske osnove detaljno obrađene u Poglavlju 3. Pai i Hong [99] pokazali su da SVR nadmašuje ARIMA i neuronske mreže u regionalnoj prognozi opterećenja, osobito uz optimizaciju hiperparametara, dok su i drugi istraživači potvrdili stabilnost i bolju generalizaciju SVM-a na ograničenim i šumovitim podacima [127].

Čeperić i suradnici predložili su strateški okvir SSA-SVR (eng. *Strategic Seasonality-Adjusted SVR*) [20] koji uključuje eksplicitno računanje sezonalnosti, paralelnu arhitekturu

prognoziranja (zasebni SVR modeli za svaki sat), automatiziran odabir značajki te optimizaciju hiperparametara metodom PSO (eng. *Particle Swarm Optimization*). Taj pristup ostvario je veću točnost od dotadašnjih modela temeljenih na neuronskim mrežama [20].

Osim SVR-a, u STLTF su primijenjene i druge metode temeljene na jezgrama: LS-SVM [39] te regresija Gaussovih procesa (GPR) [144] koja omogućuje i probabilističko predviđanje s intervalima nesigurnosti [91]. Nie i sur. [96] predložili su hibridni model ARIMA+SVM koji ostvaruje veću točnost od svake metode pojedinačno. Primjena SVR-a donijela je u STLTF principijelniji pristup s boljom generalizacijom i manjim rizikom od prenaučnosti.

2.2.3. Napredni modeli dubokog učenja

Posljednje desetljeće obilježio je uspon dubokog učenja u predviđanju vremenskih serija. U STLTF-u se primjenjuju duboke unaprijed usmjerene mreže (FNN), duboke mreže vjerovanja (DBN), konvolucijske neuronske mreže (CNN), rekurentne neuronske mreže (RNN) s varijantama LSTM i GRU te Transformer arhitekture.

Duboki FNN modeli, uz dovoljno podataka i regularizaciju, konzistentno nadmašuju plitke mreže i tradicionalne statističke metode [53, 77]. He i sur. (2017) pokazali su poboljšanu točnost DBN modela u kombinaciji s teorijom kopula [55], no DBN arhitekture danas su uglavnom zamijenjene suvremenim *end-to-end* modelima. CNN modeli uspješno izdvajaju lokalne vremenske obrasce iz sekvenci opterećenja, samostalno ili u kombinaciji s RNN mrežama [68].

LSTM arhitektura prevladava problem nestajućih gradijenata klasičnih RNN-ova uvođenjem mehanizama vrata (eng. *input, output, forget gates*), čime omogućuje učenje dugoročnih obrazaca. Kong i sur. (2019) pokazali su da *sequence-to-sequence* LSTM značajno nadmašuje tradicionalne metode [75]. GRU kao pojednostavljena varijanta postiže usporedivu točnost uz brže treniranje [1].

Transformeri [134] primjenjuju mehanizam samopozornosti za paralelnu obradu i hvatanje dugoročnih ovisnosti. U STLTF-u su razvijeni specijalizirani modeli: *Temporal Fusion Transformer* (TFT) [82], *MDS-Transformer* [84], *Informer* [151] te *PatchTST* [80, 97, 105]. Iako se u ovom radu ne koriste izravno, predstavljaju važan smjer razvoja.

Modeli dubokog učenja zahtijevaju velike količine podataka i pažljivu regularizaciju. U

ovom radu primijenjeni su prvenstveno na hrvatskom skupu podataka (2006.–2023.), čija duljina omogućuje relevantnu usporedbu, dok na kraćim skupovima poput ISO New England prednost dubokih sekvencijskih arhitektura nije jednako izražena.

2.2.4. Hibridni i ansamblski pristupi predviđanju

Hibridni modeli u STLF-u tipično kombiniraju statističke i metode strojnog učenja (npr. ARIMA+ANN, ARIMA+SVM) kako bi statistički model opisao linearnu dinamiku, a model strojnog učenja modelirao nelinearne obrasce u rezidualima [96, 148]. Teorijska motivacija za takvo razdvajanje proizlazi iz činjenice da realne vremenske serije opterećenja sadrže i linearne (trend, sezonalnost) i nelinearne (meteorološki utjecaj, anomalije) komponente, koje je teško obuhvatiti jednim modelom. Zhang (2003) formalizirao je ovaj pristup pokazujući da dekompozicija serije na linearni i nelinearni dio, uz specijalizirane modele za svaku komponentu, može smanjiti ukupnu pogrešku predviđanja [148]. Među hibridnim arhitekturama dubokog učenja ističe se *CNN–LSTM*, u kojem CNN izdvaja lokalne vremenske obrasce, a LSTM obuhvaća dugoročnije ovisnosti, čime se postiže niža pogreška predviđanja od samostalnih pristupa [72, 106].

Ansamblske metode (eng. *ensemble methods*) kombiniraju prognoze više modela radi veće robusnosti, a njihova učinkovitost proizlazi iz dekompozicije ukupne pogreške na pristranost i varijancu. Ako pojedinačni modeli imaju različite izvore pogrešaka (tj. njihove pogreške nisu savršeno korelirane), agregiranje prognoza smanjuje varijancu predviđanja bez povećanja pristranosti. U natjecanjima poput GEFCom2017, uspješne strategije temeljile su se na uprosječivanju predikcija iz različitih modela i konfiguracija [78]. Muqtadir i sur. (2025) empirijski pokazuju da integracija više modela (LightGBM, XGBoost, CatBoost) unutar ansambla ublažava specifične slabosti pojedinačnih algoritama [92]. Ansambli dubokih modela dodatno poboljšavaju točnost smanjenjem varijance [141]. Ključne ansamblske tehnike uključuju bagiranje, koje smanjuje varijancu poduzorkovanjem trenirajućeg skupa [71], te *boosting*, koji iterativno korigira pogreške prethodnih modela [92]. Metode temeljene na stablima (Random Forest, Gradient Boosted Trees) osobito su učinkovite u modeliranju nelinearnosti i procjeni važnosti značajki, što ih čini pogodnima i kao komponente za odabir ulaznih varijabli u složenijim sustavima [11, 36]. Pregledne studije potvrđuju prednost metoda strojnog učenja nad klasičnim pristupima [53], ali i naglašavaju da dobra obrada značajki može biti presudnija od složenosti samog modela [11].

2.3. Kratkoročno predviđanje cijene prirodnog plina - značaj i specifičnosti

Prirodni plin je drugi najzastupljeniji primarni izvor energije, a kratkoročno predviđanje njegove cijene (eng. *Short-Term Natural Gas Price Forecasting*, ST-NGPF) od presudne je važnosti za proizvođače, potrošače, trgovce i regulatore na energetske tržištima. Cijena plina izravno utječe na cijenu električne energije, industrijsku proizvodnju i investicijske odluke, a točna predviđanja omogućuju bolje upravljanje rizicima, planiranje nabave i oblikovanje regulatornih mjera [125].

Kratkoročne prognoze odnose se na horizont od jednog dana do nekoliko mjeseci, uvjetovane zahtjevima trgovanja i operativnog poslovanja. Kratkoročne cijene plina pod utjecajem su neravnoteža ponude i potražnje, vremenskih uvjeta, razina zaliha i tržišnog sentimenta, a njihovo predviđanje otežava izražena nestacionarnost, sezonalnost i volatilnost. Jednostavni linearni modeli često nisu dostatni u takvim uvjetima, što potiče primjenu naprednih metoda strojnog učenja.

Unatoč praktičnoj važnosti, ST-NGPF ostaje relativno nedovoljno istražen u usporedbi s prognoziranjem potrošnje električne energije. Ključni izazovi uključuju visoku dimenzionalnost ulaznih podataka, identifikaciju najrelevantnijih značajki te prilagodbu volatilnosti tržišta, što zahtijeva primjenu sofisticiranih modela potpomognutih tehnikama odabira značajki i optimizacije hiperparametara.

2.4. Pregled metoda predviđanja cijene prirodnog plina

2.4.1. Klasični statistički i ekonometrijski modeli

Rani pokušaji predviđanja cijena prirodnog plina javljaju se krajem 20. stoljeća. Buchanan i sur. (2001) istraživali su informativnu vrijednost trgovinskih pozicija za prognozu smjera kretanja spot cijena [16]. Usporedno su se razvile formalne statističke metode, pri čemu su ARIMA modeli postali osnovni alat zahvaljujući metodološkoj jasnoći i skromnim zahtjevima za podacima [150]. Hosseinipoor i Hajirezaie (2016) pokazali su da ARIMA proširen GARCH komponentom daje kvalitetnu aproksimaciju spot cijena na Henry Hubu [62], Mishra (2012)

primijenila je ARIMA(1,2,1) u kombinaciji s ACE metodom [90], a Zhao i sur. (2018) potvrdili su uspješnost modela ARIMA(2,1,1) za predviđanje troškova goriva i spot cijena plina [150]. Sezonske inačice SARIMA i SARIMAX uspješno hvataju periodičke obrasce; Manigandan i sur. (2021) primijenili su ih na mjesečne podatke o proizvodnji i potrošnji plina u SAD-u [86].

ARIMA i SARIMA modeli pretpostavljaju linearnu dinamiku i stacionarnost, pa imaju poteškoća s nelinearnostima i strukturnim lomovima kakvi obilježavaju tržišta plina. Zhao i sur. (2018) primjećuju značajan pad točnosti tijekom epizoda povišene volatilnosti. ARIMA modeli stoga se često koriste kao referentni okvir: Villacorta Cardoso i Cruz (2016) pokazali su da hibridni ARIMA–ANN blago nadmašuje samostalne pristupe [138], dok Sahed i sur. (2020) potvrđuju veću točnost nelinearnih neuronskih modela [111].

Paralelno su se razvili ekonometrijski pristupi: strukturni VAR modeli koji povezuju cijene plina s fundamentalnim čimbenicima [15, 95], GARCH modeli za volatilnost [85] te kointegracijski modeli i VECM za odnos plina i nafte [100, 107]. Ti pristupi pružaju uvid u fundamentalne veze, no razlikuju se od modela strojnog učenja koji su u središtu ovog rada.

2.4.2. Metode strojnog učenja

Krajem 1990-ih započela je primjena neuronskih mreža i drugih *soft computing* tehnika na predviđanje cijena plina. Reiter i Economides (1999) [110] među prvima su eksperimentirali s ANN-om za kratkoročnu prognozu cijena plina u SAD-u. Salehnia i sur. (2013) pokazali su da MLP model za predviđanje dnevnih Henry Hub spot cijena ostvaruje oko 33% manju pogrešku od linearnih modela [112], a Siddiqui i sur. (2019) potvrdili su veću točnost ANN-a u odnosu na ARIMA u uvjetima tržišne volatilnosti [118].

Azadeh i sur. (2012) primijenili su hibridni neuro-neizraziti pristup za predviđanje cijena plina u industrijskom kontekstu s nepreciznim pokazateljima, kombinirajući ANN s neizrazitim pravilima kako bi integrirali stručna znanja o tržišnim uvjetima [7]. Panella i sur. (2012) predstavili su neuronsku mrežu temeljenu na mješavini Gaussovih funkcija s poboljšanom točnošću u odnosu na tradicionalne modele [101].

Hibridni pristupi koji spajaju klasične metode vremenskih serija s neuronskim mrežama (npr. ARIMA–ANN) iskorištavaju prednosti obaju pristupa. Jin i Kim (2015) primijenili su valične transformacije (eng. *wavelet transform*) za dekompoziciju cijena plina na komponente

različitih frekvencija, čime je omogućena specijalizacija modela po frekvencijskim pojasevima [66]. Nguyen i Nabney (2010) razvili su sličan pristup za britansko tržište, kombinirajući valičnu dekompoziciju s MLP-om i GARCH-om [93]. Rani ANN modeli koristili su pretežno plitke arhitekture (jedan skriveni sloj) koje su bile dovoljne za tada dostupne podatke i manje sklone prenaučnosti [18, 112].

Tijekom 2010-ih fokus se proširio na raznovrsne tehnike strojnog učenja. Su i sur. (2019) usporedili su ANN, SVR, GBM i GPR na mjesečnim Henry Hub spot cijenama, pri čemu je SVR prepoznat kao robusna metoda s osobito dobrim rezultatima na manjim skupovima podataka [122]. Ansamblske metode temeljene na stablima odluke (slučajne šume, gradijentno pojačanje) značajno poboljšavaju točnost agregiranjem pojedinačnih stabala [122]; Zhang i Hamori (2020) kombinirali su gradijentno pojačanje s dinamičkim kliznim prozorom za predviđanje kriznih epizoda [149].

Modeli strojnog učenja često se primjenjuju i s tehnikama dekompozicije vremenskih serija (EMD, Fourierova transformacija). Wang i sur. (2020) implementirali su vagani hibridni model u kojem se komponente dobivene dekompozicijom predviđaju različitim modelima (SVR, LSTM, IPSS) i agregiraju u jedinstvenu prognozu [140]. SVR donosi snažnu regularizaciju, ansambl stabala robusnost, a metode pojačanja visoku točnost kroz iterativno ispravljanje pogrešaka. Komparativna prednost strojnog učenja posebno je izražena pri promjenama režima, jer se modeli brže prilagođavaju novim obrascima. Do sredine 2010-ih prepoznato je da nijedna metoda ne pruža optimalne rezultate u svim uvjetima, čime je potaknut trend kombiniranja prognoza iz više modela.

2.4.3. Modeli dubokog učenja za predviđanje cijena prirodnog plina

Sredinom do kasnih 2010-ih istraživači su počeli primjenjivati duboko učenje na predviđanje cijena plina, pri čemu su glavnu pozornost privukle LSTM i GRU arhitekture (koje koriste mehanizme vrata za modeliranje dugoročnih ovisnosti) te u novije vrijeme Transformer modeli.

Wang i sur. (2021) predložili su hibridni model koji koristi GRU mrežu s PSO-ALS optimizacijom hiperparametara i CEEMDAN-SE dekompozicijom, ostvarivši najniže pogreške u usporedbi s klasičnim pristupima [139]. Uspješnost LSTM arhitektura potvrdili su Wang i sur. (2020) hibridnim LSTM-SVR-IPSS modelom za dnevne Henry Hub spot cijene [140], Zhan i Tang (2022) kombinacijom LSTM-a s dekompozicijom signala [147], naprednije varijante poput

ConcaveLSTM-a [35], te sustavna usporedba Liu i sur. (2025) koja potvrđuje dosljedno bolju točnost LSTM-a u odnosu na FNN, SVM i Random Forest [83].

Mehanizmi pozornosti i Transformer arhitekture omogućuju paralelno modeliranje vremenskih obrazaca. Guan i sur. (2022) razvili su višemodalni BiLSTM-BERT-Transformer model koji ostvaruje 79% točnosti u klasifikaciji cjenovnog trenda [49]. Aziz i Simensen (2023) primijenili su *Temporal Fusion Transformer* (TFT) za predviđanje spot cijena plina u Njemačkoj, pri čemu TFT nadmašuje referentne modele i nudi interpretabilnost zahvaljujući mehanizmu fokusirane pažnje [76]. Syukron (2025) primijenio je PatchTST arhitekturu koja segmentira vremenski niz u paralelno obrađivane podnizove te je nadmašila AutoFormer, Informer i tradicionalne metode [124].

Duboki modeli donose izazove interpretabilnosti i zahtjeva za velikim količinama podataka, dok se u istraživanjima cijena plina najčešće raspolaže uzorcima ograničene duljine. U ovom radu navedeni modeli nisu izravno implementirani ni uspoređivani s predloženim SVR pristupima, ali njihov prikaz doprinosi razumijevanju šireg istraživačkog okvira i pravaca budućeg razvoja.

2.4.4. Regionalne specifičnosti glavnih tržišta prirodnog plina

Ranije spomenute metode primijenjene su na glavnim trgovačkim čvorištima, čije se strukturne razlike izravno odražavaju na izbor ulaznih varijabli i modelske strategije. **Henry Hub** u Louisiani (SAD) služi kao referentna točka za NYMEX terminski ugovor i globalno je najlikvidnije čvorište za trgovanje prirodnim plinom. Zahvaljujući dugogodišnjoj deregulaciji i transparentnom objavljivanju tržišnih podataka, Henry Hub pruža obilje povijesnih podataka i korišten je u brojnim ključnim studijama [112, 122]. Cijena na Henry Hubu primarno je uvjetovana domaćom ravnotežom ponude i potražnje, razinama skladištenja te vremenskim prilikama na području SAD-a. Prognoziranje na ovom likvidnom tržištu zahtijeva obuhvaćanje širokog spektra čimbenika – od sezone potražnje i domaće proizvodnje do logistike skladištenja i utjecaja šireg energetske kompleksa – pri čemu napredne metode s podacima u stvarnom vremenu mogu ostvariti prednost nad jednostavnim referentnim modelima.

U Europi, **NBP** (*National Balancing Point*, Ujedinjeno Kraljevstvo) i **TTF** (*Title Transfer Facility*, Nizozemska) predstavljaju vodeća virtualna trgovačka čvorišta. TTF je posljednjih godina preuzeo ulogu europske referentne cijene, osobito nakon energetske krize 2022. godine, kada je europsko tržište doživjelo izrazitu volatilnost uslijed poremećaja u opskrbi. Europske

cijene snažno su uvjetovane uvoznom ovisnošću (cjevovodni plin i LNG), regulatornim okvirom te sezonskim obrascem skladištenja, što nameće drukčiji skup ulaznih varijabli u usporedbi s Henry Hubom [18, 95]. Na azijskom tržištu, **JKM** (*Japan/Korea Marker*) odražava spot cijene LNG-a u tihooceanskomu bazenu. JKM cijene karakterizira sezonska premija povezana s grijanjem u zimskim mjesecima te konkurencija s europskim LNG uvoznicima [145].

Unatoč strukturnim razlikama, temeljne metode predviđanja (ARIMA, SVR, LSTM) primjenjive su na svim tržištima uz prilagodbu ulaznih varijabli i prognoznog horizonta. Metode s vremenski promjenjivim parametrima [45] osobito su vrijedne za obuhvaćanje strukturnih promjena poput deregulacije, uvođenja novih LNG terminala ili geopolitičkih poremećaja.

2.5. Ključna ograničenja i istraživački kontekst

Pregled literature o STLF-u i NGPF-u pokazuje zajedničke izazove: nelinearni odnosi u podacima, visoka volatilnost tržišta i velika dimenzionalnost ulaznih podataka otežavaju izgradnju modela koji su istodobno točni, robusni i praktični.

2.5.1. Nelinearnost i kompleksni obrasci

Odnosi između ulaznih varijabli i izlaznih veličina u energetske sustavima često su izrazito nelinearni. U STLF-u, interakcija temperature i opterećenja pokazuje izrazito nelinearnu ovisnost: pri umjerenim temperaturama potražnja je relativno niska, dok ekstremne hladnoće i vrućine uzrokuju neproporcionalan porast potrošnje uslijed grijanja odnosno klimatizacije. Slični obrasci javljaju se u dinamici cijena plina, gdje nelinearni utjecaji ponude, zaliha i vremenskih uvjeta čine odnose među varijablama složenima za modeliranje.

Tradicionalni linearni modeli teško zahvaćaju takve obrasce, dok složeni modeli strojnog učenja donose rizik prenaučivosti – modeli s mnogo parametara mogu se previše prilagoditi treniranom skupu i izgubiti sposobnost generalizacije [20]. Problem je osobito izražen kod dubokih modela (LSTM, Transformer), koji mogu zapamtiti specifičnosti podataka umjesto općih uzoraka. Prenaučenost se ublažava regularizacijom, odabirom primjerene složenosti i ranim zaustavljanjem treniranja. U domeni cijena plina, dodatni izazov predstavljaju visoka volatilnost i promjene režima uzrokovane ekstremnim događajima (npr. hladni valovi, geopolitičke krize, poremećaji u infrastrukturi), što zahtijeva prilagodljive modele s vremenski promjenjivim

parametrizacijama [45]. Ovi se izazovi ne mogu riješiti pukim povećanjem složenosti modela, već zahtijevaju pažljiv odabir arhitekture, regularizacijskih strategija i protokola validacije.

2.5.2. Dimenzionalnost i odabir značajki

Modeli za STLTF i NGPF mogu uključivati desetke pa i stotine ulaznih varijabli – od povijesnih vrijednosti ciljne veličine s različitim vremenskim pomacima, preko meteoroloških i kalendarskih značajki, do tržišnih i fundamentalnih pokazatelja. Takva visoka dimenzionalnost ulaznog prostora dovodi do prokletstva dimenzionalnosti (eng. *curse of dimensionality*): s povećanjem broja značajki eksponencijalno raste potreban broj primjera za pouzdanu procjenu parametara, dok se istovremeno povećava rizik prenaučivosti jer model može iskoristiti šumne korelacije umjesto stvarnih uzročnih veza.

Selekcija značajki – eliminacijom redundantnih i nerelevantnih ulaza – ključna je za poboljšanje generalizacijske sposobnosti i interpretabilnosti modela. Za tu se svrhu koriste filtrirajuće metode (npr. Relief, mRMR) koje rangiraju značajke prema statističkim kriterijima neovisno o modelu, omotačke metode (eng. *wrapper methods*) koje evaluiraju podskupove značajki izravno na ciljnom modelu, te ugrađene metode poput odabira temeljenog na gradijentnom pojačanju. Empirijski rezultati u STLTF i NGPF domenama dosljedno pokazuju da se primjenom odabira značajki postiže značajno smanjenje pogreške predviđanja [20, 21].

2.5.3. Ograničenja postojećih modela

Statistički modeli (ARIMA, eksponencijalno izgladivanje) pretpostavljaju linearnu ili lokalno linearnu dinamiku i ne opisuju dovoljno dobro nelinearne obrasce karakteristične za energetske sustave, osobito u uvjetima strukturnih promjena i promjena režima. S druge strane, metode strojnog učenja mogu patiti od prenaučivosti i nedostatka interpretabilnosti: duboki modeli funkcioniraju kao “crne kutije” čije je odluke teško objasniti regulatorima i operatorima sustava.

U STLTF-u, specifičan izazov predstavlja činjenica da modeli moraju istovremeno dobro predviđati vršna i bazna opterećenja, radne dane i vikende, te različite sezonske uvjete – što otežava izgradnju jednog modela koji jednako dobro radi na svim razinama agregacije i u svim operativnim uvjetima. U NGPF-u, izazov je pouzdano predviđanje kako u mirnim razdobljima stabilnih cijena tako i u turbulentnim tržišnim epizodama obilježenim naglim cjenovnim skokovima.

Ograničenja s aspekta podataka – ograničena količina, nedostaci u kvaliteti, neravnomjerna pokrivenost pojedinih razdoblja – djelomično se rješavaju predobradom, augmentacijom ili transfernim učenjem [108], no pouzdanost modela uvelike ovisi o raspoloživim podacima i njihovoj reprezentativnosti za buduće operativne uvjete.

2.5.4. Motivacija i smjer istraživanja

Na temelju identificiranih ograničenja, ovaj rad predlaže pristup temeljen na regresiji potpornim vektorima (SVR) u kombinaciji s algoritmima za odabir značajki i hibridnim modeliranjem s dubokim neuronskim mrežama. SVR pruža povoljan balans između sposobnosti modeliranja nelinearnih odnosa (putem jezgrenih funkcija) i otpornosti na prenaučenosť (putem ugrađene regularizacije temeljene na principu strukturne minimizacije rizika). Za razliku od dubokih modela koji zahtijevaju velike količine podataka za stabilno treniranje, SVR postiže konkurentne rezultate i na ograničenim skupovima podataka, što ga čini osobito prikladnim za domene poput NGPF-a, gdje su povijesni nizovi često kraći.

Integracija s postupcima odabira značajki adresira problem dimenzionalnosti sustavnim identificiranjem najrelevantnijih ulaznih varijabli, dok hibridni DNN-SVR pristup kombinira reprezentacijsku moć dubokih mreža s robustnom SVR regresijom u završnom sloju. Detaljan opis predložene metodologije dan je u Poglavljima 3 i 4.

3. TEORIJSKE OSNOVE METODE POTPORNIH VEKTORA I ALGORITAMA ZA ODABIR ZNAČAJKI

U ovom poglavlju dajemo kratak pregled formulacija standardne metode potpornih vektora, koje je uveo Vapnik. Razmatramo linearne i nelinearne SVM klasifikatore za odvojive i neodvojive skupove podataka, kao i linearnu i nelinearnu procjenu funkcije pomoću SVM-a koja se temelji na Vapnikovoj ε -neosjetljivoj funkciji gubitka. Proširenje s linearnog na nelinearni slučaj postiže se takozvanim *kernel* trikom. U drugom dijelu ovog poglavlja raspravljamo o nizu modifikacija i proširenja povezanih s ovom SVM metodologijom.

3.1. Temeljni principi SVM-a

3.1.1. Klasifikacija maksimizacijom margine i linearni SVM-ovi

3.1.1.1. Margina

Dok je regularizacijski član (eng. *weight decay*) važan aspekt postizanja dobre generalizacije u kontekstu neuronskih mreža za regresiju, margina ima donekle sličnu ulogu u problemima klasifikacije. Koncept margine predstavlja prvi važan korak u razumijevanju formulacije metode potpornih vektora.

Na slici 3.1 prikazan je ilustrativan primjer separabilnog problema u dvodimenzionalnom ulaznom prostoru s jedinstvenom razdvajajućom hiperravninom. Vapnik je razmotrio skaliranje problema tako da točke najbliže hiperravnini zadovoljavaju $|w^T x_k + b| = 1$. Time se dobiva

kanonski oblik za par (w, b) hiperravnine koji zadovoljava $y_k(w^T x_k + b) \geq 1$.

U tom slučaju margina iznosi $\frac{2}{\|w\|_2}$. Stoga točke najbliže hiperravnini imaju udaljenost $\frac{1}{\|w\|_2}$, čime se maksimizira udaljenost do najbližih primjera iz obje klase.

Stoga je poželjno maksimizirati marginu, što odgovara minimizaciji $\|w\|_2$. Ta minimizacija $w^T w$ usko je povezana s korištenjem regularizacijskog člana pri treniranju neuronskih mreža.

3.1.1.2. Linearni SVM klasifikator


Počeci pristupa SVM-a za izgradnju optimalne razdvajajuće hiperravnine sežu u radove Vapnika i Lerneru iz 1963. te Vapnika i Červonenkisa iz 1964. [132, 133], dok je općenita nelinearna verzija novijeg datuma [130]. Formulacija SVM-a provodi se u kontekstu teorije konveksne optimizacije: problem se postavlja u primarnom prostoru težina, formulira se Lagrangeova funkcija, izvode uvjeti optimalnosti i rješava dualni problem u prostoru Lagrangeovih multiplikatora.

Za linearno separabilan slučaj s klasifikatorom $y(x) = \text{sign}[w^T x + b]$, maksimizacija margine uz uvjet ispravne klasifikacije svih primjera vodi na primarni problem minimizacije $\frac{1}{2}w^T w$ uz ograničenja $y_k[w^T x_k + b] \geq 1$. Primjenom Lagrangeovog postupka i postavljanjem uvjeta optimalnosti dobiva se dualni problem kvadratnog programiranja (QP):

$$\begin{aligned} \text{[D]: } \max_{\alpha} \quad J_D(\alpha) &= -\frac{1}{2} \sum_{k,l=1}^N y_k y_l x_k^T x_l \alpha_k \alpha_l + \sum_{k=1}^N \alpha_k \\ \text{uz uvjet da } \quad \sum_{k=1}^N \alpha_k y_k &= 0. \end{aligned}$$

Rezultirajući klasifikator ima oblik $y(x) = \text{sign} \left[\sum_{k=1}^N \alpha_k y_k x_k^T x + b \right]$, pri čemu su mnoge vrijednosti α_k jednake nuli – konačni klasifikator ovisi samo o primjerima s nenultim α_k , koji se nazivaju *potporni vektori*. Rješenje QP problema je globalno i, za pozitivno definitnu matricu, jednoznačno [17, 43].

Za linearno neodvojiv slučaj, Cortes i Vapnik [27] proširili su formulaciju uvođenjem slack varijabli $\xi_k \geq 0$ koje toleriraju pogrešne klasifikacije, čime primarni problem postaje minimizacija $\frac{1}{2}w^T w + c \sum_{k=1}^N \xi_k$. Rezultirajući dualni QP problem ima isti oblik kao (A9), uz



Slika 3.1: Linearna klasifikacija: prikaz jedinstvene razdvajajuće hiperravnine u dvodimenzionalnom ulaznom prostoru. Margina je udaljenost između isprekidanih linija.

dodatna ograničenja $0 \leq \alpha_k \leq c$:

$$\begin{aligned}
 \text{[D]: } \quad & \max_{\alpha} \quad J_D(\alpha) = -\frac{1}{2} \sum_{k,l=1}^N y_k y_l x_k^T x_l \alpha_k \alpha_l + \sum_{k=1}^N \alpha_k \\
 & \text{pod uvjetom da} \quad \sum_{k=1}^N \alpha_k y_k = 0, \\
 & \quad \quad \quad 0 \leq \alpha_k \leq c, \quad k = 1, \dots, N.
 \end{aligned}$$

Detaljna matematička izvedba primarnog problema, Lagrangeove funkcije, KKT uvjeta i dualnih formulacija za oba slučaja dana je u Priritku A, Odjeljak A1..

3.1.2. Jezgreni trik i Mercerov uvjet

Važan napredak u teoriji metode potpornih vektora (SVM) ostvaren je zahvaljujući tome što je Vapnik 1995. godine linearnu metodu proširio u nelinearnu tehniku [130, 131]. Kako bi se to postiglo, ulazni podaci preslikavaju se u visokodimenzionalni prostor značajki, koji može imati i beskonačno mnogo dimenzija. Konstrukcija linearne razdvajajuće hiperravnine zatim se provodi

u tom visokodimenzionalnom prostoru značajki*, nakon nelinearnog preslikavanja $\varphi(x)$ ulaznih podataka u prostor značajki (slika 3.2).

Iznenadujuće, nije potrebna eksplicitna konstrukcija nelinearnog preslikavanja $\varphi(x)$. Ovo se temelji na sljedećem rezultatu. Za svaku simetričnu i neprekidnu funkciju $K(x, z)$ koja zadovoljava Mercerov uvjet [89], postoji Hilbertov prostor $\mathcal{H}$, preslikavanje $\varphi : \mathbb{R}^n \rightarrow \mathcal{H}$ i pozitivni brojevi λ_i takvi da vrijedi [48]:

$$K(x, z) = \sum_{i=1}^{n_{\mathcal{H}}} \lambda_i \phi_i(x) \phi_i(z), \quad (3.1)$$

gdje su $x, z \in \mathbb{R}^n$ i $n_{\mathcal{H}}$ je dimenzija prostora $\mathcal{H}$ (koji može biti beskonačno dimenzionalan). Mercerov uvjet zahtijeva da

$$\int K(x, z) g(x) g(z) dx dz \geq 0, \quad (3.2)$$

za svaku kvadratično integrabilnu funkciju $g(x)$. Ovdje se integral izračunava nad kompaktnim podskupom $\mathbb{R}^n$. Možemo zapisati $K(x, z) = \sum_{i=1}^n \sqrt{\lambda_i} \phi_i(x) \sqrt{\lambda_i} \phi_i(z)$ te definirati $\varphi_i(x) = \sqrt{\lambda_i} \phi_i(x)$ i $\varphi_i(z) = \sqrt{\lambda_i} \phi_i(z)$ tako da se funkcija jezgre može izraziti kao skalarni produkt (često nazivan i točkasti produkt):

$$K(x, z) = \varphi(x)^T \varphi(z). \quad (3.3)$$

Stoga je posjedovanje pozitivno poludefinitne[†] jezgre uvjet koji jamči da se može zapisati jednadžba (3.3). To također implicira da je jezgra K rastavljiva. Takve rastavljive jezgre korištene su, primjerice, i za rješavanje integralnih jednadžbi [32].

Primjena jednadžbe (3.3) često se naziva *jezgreni trik*. Omogućuje rad u iznimno visokodimenzionalnom prostoru značajki bez potrebe za eksplicitnim računanjem u tom prostoru. Izračuni se, nakon primjene jezgrenog trika, provode u drugom prostoru. U slučaju metode potpornih vektora polazi se od formulacije u primarnom prostoru težina, pri čemu se ulazni podaci preslikavaju funkcijom $\varphi(\cdot)$ u visokodimenzionalni prostor značajki. Problem se, međutim, ne


*Sa stajališta neuronskih mreža, zapravo bi bilo bolje taj prostor nazvati visokodimenzionalnim *skrivenim* slojem, jer se u prepoznavanju uzoraka pojam *prostor značajki* često koristi u značenju *ulaznog prostora*. Ipak, u nastavku ćemo koristiti izraz *prostor značajki*, jer je u ovom području uobičajen.

[†]Ovdje koristimo terminologiju linearne algebre: pojmovi *pozitivno definitan* i *pozitivno poludefinitan*. Odgovarajuća terminologija u funkcionalnoj analizi često je *strogo pozitivno definitan* i *pozitivno definitan*, redom.

rješava u tom primarnom prostoru težina, već u dualnom prostoru Lagrangeovih multiplikatora, nakon primjene jezgrenog trika. Na taj način može se implicitno raditi u visokodimenzionalnom prostoru značajki (prostoru skrivenog sloja) bez izvođenja izračuna u tom prostoru (slika 3.3).

3.1.3. Nelinearni SVM klasifikatori

Proširenje s linearnih klasifikatora metode potpornih vektora na nelinearne klasifikatore metode potpornih vektora je jednostavno. Ustvari, dovoljno je formalno zamijeniti x izrazom $\varphi(x)$ i primijeniti jezgri trik gdje god je to moguće. Treba, međutim, imati na umu da $\varphi(x)$ može biti beskonačne dimenzije, te stoga i vektor w može biti beskonačno dimenzionalan. Dok se kod linearnih klasifikatora metode potpornih vektora primarni problem može jednako uspješno riješiti u prostoru w kao i dualni problem u vrijednostima potpore α , u nelinearnom slučaju to više nije tako, jer je u primarnom problemu nepoznati vektor w beskonačne dimenzije.




Slika 3.2: (Gore) Preslikavanje ulaznog prostora u visokodimenzionalni prostor značajki gdje je ostvareno linearno razdvajanje, što odgovara nelinearnom razdvajanju u izvornom ulaznom prostoru; (Dolje) Ilustracija jezgrenog trika u kojem je odabrana funkcija $K(x, z)$ i prikaz u obliku skalarnog produkta moguć je pod uvjetom da je $K(\cdot, \cdot)$ simetrična pozitivno definitna jezgrena funkcija.

Primarni problem $\boxed{P}$

Parametarski: procjena $w \in \mathbb{R}^{n_h}$

$$y(x) = \text{sign} [w^T \varphi(x) + b]$$




Kernel trik

$$K(x_k, x_l) = \varphi(x_k)^T \varphi(x_l)$$

Primarni problem $\boxed{P}$

Neparametarski: procjena $\alpha \in \mathbb{R}^N$

$$y(x) = \text{sign} \left[\sum_{k=1}^{\#sv} \alpha_k y_k K(x, x_k) + b \right]$$




Slika 3.3: Primalno i dualno tumačenje metode potpornih vektora pomoću neuronskih mreža.

Formalno, zamjenom x s $\varphi(x)$ u linearnoj formulaciji iz Odjeljka 3.1.1 i primjenom jezgrenog trika, nelinearni primarni problem poprima isti oblik kao jednadžba za linearni slučaj s mekim marginama, uz zamjenu x_k s $\varphi(x_k)$:

$$\begin{aligned} \text{[P]: } \min_{w, b, \xi} \quad & J_P(w, \xi) = \frac{1}{2} w^T w + c \sum_{k=1}^N \xi_k \\ \text{uz uvjet da} \quad & y_k [w^T \varphi(x_k) + b] \geq 1 - \xi_k, \\ & \xi_k \geq 0, \quad k = 1, \dots, N. \end{aligned} \tag{3.4}$$

Ključna razlika u odnosu na linearni slučaj jest da vektor w sada pripada (potencijalno



Slika 3.4: Kod nelinearnih klasifikatora metode potpornih vektora potporni vektori (označeni crnim točkama) nalaze se blizu granice odluke, što je ilustrirano ovdje na jednostavnom primjeru binarnog problema koji nije linearno separabilan.

beskonačno dimenzionalnom) prostoru značajki $\mathbb{R}^{n_H}$, te se primarni problem ne može izravno riješiti. Stoga se koristi dualni pristup — primjenom istog Lagrangeovog postupka kao u Odjeljku 3.1.1, uz jezgreni trik $K(x_k, x_l) = \varphi(x_k)^T \varphi(x_l)$, dobiva se dualni problem:

$$\begin{aligned}
 \text{[D]: } \quad \max_{\alpha} J_D(\alpha) &= -\frac{1}{2} \sum_{k,l=1}^N y_k y_l K(x_k, x_l) \alpha_k \alpha_l + \sum_{k=1}^N \alpha_k \\
 \text{uz uvjet da } \quad \sum_{k=1}^N \alpha_k y_k &= 0, \\
 0 \leq \alpha_k &\leq c, \quad k = 1, \dots, N.
 \end{aligned} \tag{3.5}$$

Nelinearni klasifikator metode potpornih vektora tada ima oblik

$$y(x) = \text{sign} \left[\sum_{k=1}^N \alpha_k y_k K(x, x_k) + b \right], \tag{3.6}$$

pri čemu su α_k pozitivne realne konstante dobivene rješavanjem QP problema. Pomak b određuje se iz KKT uvjeta — analogno linearnom slučaju, za svaku točku iz skupa za učenje za koju vrijedi $0 < \alpha_k < c$ vrijedi $y_k [\sum_l \alpha_l y_l K(x_k, x_l) + b] = 1$, iz čega se izračunava b (numerički

je često bolje uzeti prosječnu vrijednost preko tih točaka).

Neka svojstva nelinearnog klasifikatora metode potpornih vektora i njegovog rješenja su sljedeća:

– **Odabir jezgrene funkcije:**

Za jezgru $K(\cdot, \cdot)$ moguće je nekoliko izbora. Neki od uobičajenih su:

$$K(x, x_k) = x_k^T x \quad (\text{linearni SVM})$$

$$K(x, x_k) = (\tau + x_k^T x)^d \quad (\text{polinomni SVM stupnja } d)$$

$$K(x, x_k) = \exp\left(-\frac{\|x - x_k\|_2^2}{\sigma^2}\right) \quad (\text{RBF jezgra})$$

$$K(x, x_k) = \tanh(\kappa_1 x^T x_k + \kappa_2) \quad (\text{MLP jezgra})$$

Mercerov uvjet vrijedi za sve vrijednosti σ u slučaju RBF jezgre i za sve pozitivne vrijednosti τ u slučaju polinomne jezgre, ali ne i za sve moguće izbore κ_1, κ_2 u slučaju MLP jezgre. Daljnja rasprava o jezgrenim funkcijama bit će dana u nastavku ovog poglavlja.

– **Globalno i jedinstveno rješenje:**

Kao i u slučaju linearnog SVM-a, rješenje konveksnog QP problema i ovdje je globalno i jedinstveno pod uvjetom da se za $K(\cdot, \cdot)$ odabere pozitivno definitna jezgrene funkcija. Ovaj izbor jamči da je i matrica uključena u QP problem pozitivno definitna te da se može primijeniti jezgrena trik. Za pozitivno poludefinitnu jezgru rješenje QP problema jest globalno, ali nije nužno jedinstveno.

– **Rijetkost:**

Kao i u slučaju linearnog SVM klasifikatora, mnoge vrijednosti α_k u vektoru rješenja jednake su nuli. U dualnom prostoru nelinearni SVM klasifikator poprima oblik

$$y(x) = \text{sign} \left[\sum_{k=1}^{\#SV} \alpha_k y_k K(x, x_k) + b \right],$$

pri čemu se zbroj uzima samo po onim vrijednostima α_k koje nisu jednake nuli, a koje odgovaraju potpornim vektorima x_k iz skupa za učenje. Na slici 3.3 prikazano je neuronsko tumačenje ovoga. Broj skrivenih čvorova jednak je broju potpornih vektora (SV) dobivenih rješavanjem konveksnog QP problema. U slučaju RBF jezgre vrijedi:

$$y(x) = \text{sign} \left[\sum_{k=1}^N \alpha_k y_k \exp \left(-\frac{\|x - x_k\|_2^2}{\sigma^2} \right) + b \right] = \text{sign} \left[\sum_{k=1}^{\#SV} \alpha_k y_k \exp \left(-\frac{\|x - x_k\|_2^2}{\sigma^2} \right) + b \right],$$

gdje #SV označava broj potpornih vektora.

– **Geometrijsko značenje potpornih vektora:**

Potporni vektori dobiveni rješavanjem QP problema nalaze se u blizini nelinearne granice odluke, kao što je ilustrirano na slici 3.4.

– **Parametarski i neparametarski aspekti:**

I primarni i dualni problem imaju prikaz u obliku neuronske mreže (slika 3.3). Problem u prostoru težina (primalni problem) je parametarski, dok je dualni problem neparametarski. Vrijedi primijetiti da veličina QP problema u dualnom pristupu ne ovisi o dimenziji n ulaznog prostora.

U usporedbi s tradicionalnim višeslojnim perceptronskim neuronskim mrežama, konveksnost je važno svojstvo nelinearnih SVM klasifikatora. Kod metode potpornih vektora s RBF jezgrom, gotovo sve nepoznanice dobivaju se kao rješenje konveksnog problema, što nije slučaj kod MLP mreža. Nadalje, u klasičnim MLP mrežama broj skrivenih čvorova mora se unaprijed odrediti, dok se kod nelinearnih SVM-a taj broj automatski određuje iz QP problema kao broj potpornih vektora.

3.1.4. VC-teorija i minimizacija strukturalnog rizika

Važnost margine u SVM formulacijama može se sagledati u širem kontekstu Vapnik-Červonenkisove (VC) statističke teorije učenja [130, 131]. Glavni cilj VC teorije jest okarakterizirati pogrešku generalizacije, a ne samo pogrešku na specifičnim skupovima podataka. Ključan rezultat Vapnika pokazuje da se pogreška generalizacije $R(\theta)$ može s gornje strane ograničiti zbrojem empirijskog rizika i pouzdanog člana koji ovisi o VC dimenziji h – kombinatornoj mjeri složenosti skupa funkcija. VC dimenzija definira se kao najveći broj točaka koje skup funkcija može razbiti (razdvojiti) na sve moguće načine; za linearne hiperravnine u $\mathbb{R}^n$ iznosi $n + 1$.

Na temelju VC ograde, Vapnik uvodi koncept strukturne minimizacije rizika (SRM), u kojem se razmatraju ugnježdjeni skupovi funkcija rastuće složenosti te se traži optimalan kompromis između empirijskog rizika i složenosti modela. Za SVM klasifikatore, gornja ograda na VC

dimenziju dana je izrazom $h \leq \min(\lfloor r^2 a^2 \rfloor, n) + 1$, gdje je r radijus najmanje kugle u prostoru značajki, a a ograda na $\|w\|_2^2$. Parametri poput σ RBF jezgre i konstante kazne c , koji ne proizlaze iz QP problema, biraju se tako da VC ograda bude minimalna [10, 88, 113, 114]. Detaljna matematička izvedba VC teorije, ograde generalizacije, definicije VC dimenzije i principa strukturne minimizacije rizika dana je u Privitku A, Odjeljak A2..

3.2. Metoda potpornih vektora za procjenu funkcije

3.2.1. Metoda potpornih vektora za procjenu linearne funkcije

Osim za klasifikaciju, metoda potpornih vektora uvedena je i za probleme procjene funkcija [130]. Za linearnu procjenu funkcije $f(x) = w^T x + b$ koristi se Vapnikova ε -neosjetljiva funkcija gubitka:

$$|y - f(x)|_{\varepsilon} = \begin{cases} 0, & \text{ako } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon, & \text{inače} \end{cases}$$

Primarni problem s varijablama odstupanja ξ_k, ξ_k^* glasi:

[P]: $\min_{w, b, \xi, \xi^*} J_P(w, \xi, \xi^*) = \frac{1}{2} w^T w + c \sum_{k=1}^N (\xi_k + \xi_k^*)$

uz uvjet da $y_k - w^T x_k - b \leq \varepsilon + \xi_k,$

$w^T x_k + b - y_k \leq \varepsilon + \xi_k^*,$

$\xi_k, \xi_k^* \geq 0, \quad k = 1, \dots, N$

Primjenom Lagrangeovog postupka dobiva se dualni QP problem:

$$\begin{aligned}
 \text{[D]: } \max_{\alpha, \alpha^*} \quad J_D(\alpha, \alpha^*) = & -\frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N (\alpha_k - \alpha_k^*)(\alpha_l - \alpha_l^*) x_k^T x_l \\
 & - \varepsilon \sum_{k=1}^N (\alpha_k + \alpha_k^*) + \sum_{k=1}^N y_k (\alpha_k - \alpha_k^*) \\
 \text{uz uvjet da } \quad & \sum_{k=1}^N (\alpha_k - \alpha_k^*) = 0, \\
 & \alpha_k, \alpha_k^* \in [0, c]
 \end{aligned}$$

Model u dualnom prostoru ima oblik:

$$f(x) = \sum_{k=1}^N (\alpha_k - \alpha_k^*) x_k^T x + b$$

pri čemu pomak b slijedi iz komplementarnih KKT uvjeta. Rješenje je globalno, jedinstveno i rijetko – mnogi elementi vektora rješenja jednaki su nuli. Detaljna izvedba Lagrangeove funkcije i uvjeta optimalnosti dana je u Privitku A, Odjeljak A3..

3.2.2. SVM za procjenu nelinearne funkcije

Linearna regresija metodom potpornih vektora sada se može proširiti iz linearnog na nelinearni slučaj, i to primjenom tzv. jezgrenog trika.

U primarnom prostoru težina model ima oblik

$$f(x) = w^T \varphi(x) + b, \quad (3.7)$$

uz zadani skup podataka za učenje $\{x_k, y_k\}_{k=1}^N$ i preslikavanje $\varphi(\cdot) : \mathbb{R}^n \rightarrow \mathbb{R}^{n_h}$ u visokodimenzionalni prostor značajki, koje može biti beskonačno dimenzionalno te je definirano samo implicitno. Valja napomenuti da u ovom nelinearnom slučaju i vektor w može postati beskonačno dimenzionalan. Optimizacijski problem u primarnom prostoru težina glasi:

$$\begin{aligned}
 \text{[P]:} \quad & \min_{w, b, \xi, \xi^*} J_P(w, \xi, \xi^*) = \frac{1}{2} w^T w + c \sum_{k=1}^N (\xi_k + \xi_k^*) \\
 \text{uz uvjete da} \quad & y_k - w^T \varphi(x_k) - b \leq \varepsilon + \xi_k, \\
 & w^T \varphi(x_k) + b - y_k \leq \varepsilon + \xi_k^*, \\
 & \xi_k, \xi_k^* \geq 0, \quad k = 1, \dots, N
 \end{aligned} \tag{3.8}$$

Zapravo, možemo formalno zamijeniti x iz linearnog slučaja procjene funkcije s $\varphi(x)$.

Nakon formiranja Lagrangeove funkcije i postavljanja uvjeta optimalnosti dobiva se sljedeći dualni problem:

$$\begin{aligned}
 \text{[D]:} \quad & \max_{\alpha, \alpha^*} J_D(\alpha, \alpha^*) = -\frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N (\alpha_k - \alpha_k^*)(\alpha_l - \alpha_l^*) K(x_k, x_l) \\
 & \quad - \varepsilon \sum_{k=1}^N (\alpha_k + \alpha_k^*) + \sum_{k=1}^N y_k (\alpha_k - \alpha_k^*) \\
 \text{uz uvjete da} \quad & \sum_{k=1}^N (\alpha_k - \alpha_k^*) = 0, \\
 & \alpha_k, \alpha_k^* \in [0, c].
 \end{aligned} \tag{3.9}$$

Ovdje je primijenjen jezgri trik s $K(x_k, x_l) = \varphi(x_k)^T \varphi(x_l)$ za $k, l = 1, \dots, N$. Dualna reprezentacija modela glasi:

$$f(x) = \sum_{k=1}^N (\alpha_k - \alpha_k^*) K(x, x_k) + b, \tag{3.10}$$

gdje su α_k, α_k^* rješenje QP problema, a b slijedi iz komplementarnih KKT uvjeta.

Rješenje QP problema je globalno i jednoznačno pod uvjetom da je odabrana jezgrena funkcija pozitivno definitna. Kao i kod klasifikatora metodom potpornih vektora, rješenje je rijetko. Veličina QP problema ne ovisi o dimenziji ulaznog prostora. Dok se u linearnom slučaju primarni problem mogao jednako dobro riješiti, kod nelinearnog problema procjene funkcije to više nije moguće, jer vektor w može postati beskonačno dimenzionalan i funkcija $\varphi(\cdot)$ često nije eksplicitno poznata. U usporedbi sa slučajem nelinearnog klasifikatora metodom potpornih vektora, nelinearna formulacija regresije metodom potpornih vektora sadrži više parametara za podešavanje. U slučaju RBF jezgre, σ, c, ε smatraju se dodatnim parametrima za podešavanje

koji se ne dobivaju rješavanjem QP problema, nego se moraju odrediti na drugi način, npr. temeljem kros-validacije ili primjenom VC granica u slučaju regresije.

Kako bi se bolje kontrolirao broj potpornih vektora, predložene su i druge formulacije poput ν -cijevne *regresije metodom potpornih vektora* [115]. U ovoj metodi primarna ciljna funkcija modificirana je na sljedeći način:

$$\frac{1}{2}w^T w + c \left(\nu \varepsilon + \frac{1}{N} \sum_{k=1}^N (\xi_k + \xi_k^*) \right), \quad (3.11)$$

U ovom pristupu parametrom ν može se kontrolirati udio potpornih vektora kojima je dopušteno nalaziti se izvan cijevi, što je u asimptotskom smislu izravno proporcionalno broju potpornih vektora.

3.2.3. VC-granica za pogrešku generalizacije

Za nelinearni slučaj procjene funkcije također su izvedene VC-granice [24, 25, 114, 131]. Za empirijski rizik s kvadratnom funkcijom gubitka

$$R_{\text{emp}}(\theta) = \frac{1}{N} \sum_{k=1}^N (y_k - f(x_k; \theta))^2 \quad (3.12)$$

i predviđeni rizik

$$R(\theta) = \int (y_k - f(x_k; \theta))^2 p(x, y) dx dy \quad (3.13)$$

vrijedi sljedeća VC-granica:

$$R(\theta) \leq R_{\text{emp}}(\theta) \left(1 - c \sqrt{\frac{h(\ln(aN/h) + 1) - \ln \eta}{N}} \right)_+^{-1} \quad (3.14)$$

gdje h označava VC-dimenziju skupa aproksimirajućih funkcija. U [25] za konstante je odabrano $a = c = 1$. Ova ograda vrijedi s vjerojatnošću $1 - \eta$. Oznaka $(x)_+$ znači $(x)_+ = x$ ako je $x > 0$, a 0 inače.

Procijenjeni rizik može se izraziti kao

$$R_{\text{est}} = g(h, N) \cdot \frac{1}{N} \sum_{k=1}^N (y_k - f(x_k; \theta))^2 \quad (3.15)$$

gdje je $g(h, N)$ korekcijska funkcija.

Nakon što se formula dovede u ovaj oblik, jednostavno je uspostaviti vezu s dobro poznatim klasičnim kriterijima u statistici (vidi Vapnik [131]), kao što su:

- **Konačna pogreška predviđanja (FPE)** (Akaike) [2]

$$g(d, N) = \frac{1 + d/N}{1 - d/N} \quad (3.16)$$

- **Generalizirano unakrsno vrednovanje (GCV)** (Craven i Wahba) [28]

$$g(d, N) = \frac{1}{\left(1 - \frac{d}{N}\right)^2} \quad (3.17)$$

- **Shibatin kriterij za odabir modela (SMS)** [117]

$$g(d, N) = 1 + 2 \cdot \frac{d}{N} \quad (3.18)$$

- **Schwarzov kriterij** (MDL kriterij) [116]

$$g(d, N) = 1 + \frac{\frac{d}{N} \log N}{2(1 - \frac{d}{N})} \quad (3.19)$$

pri čemu je d broj slobodnih parametara modela koji je linearan u parametrima.

Nedavni rad na temu generalizacije i matematičkih temelja teorije učenja predstavili su Cucker i Smale u [31]. U ovom radu izvedene su ograde pogreške generalizacije uz pažljivu analizu pogreške aproksimacije i pogreške uzorka, pri čemu su rezultati navedeni, primjerice, za Soboljeve prostore i Hilbertove prostore s reprodukcijom jezgrom.

Napomena: Osim opisanih temeljnih formulacija, u literaturi postoje brojne inačice i proširenja metode potpornih vektora. Pozitivno definitne jezgrene funkcije mogu se kombinirati linearno ili multiplikativno, kao i normirati, čime se iz postojećih jezgri dobivaju nove uz očuvanje Mercerovih svojstava [29]. Također su razvijene specijalizirane jezgre za različite tipove podataka – primjerice za sekvencijske podatke (stringove) u obradi teksta [29, 54] ili bioinformatičke sekvence – što omogućuje primjenu SVM-a izvan domena standardnih realnih vektora. Nadalje, predložene su varijante SVM algoritma temeljene na alternativnim funkcijama gubitka: *Least Squares*

SVM metoda koristi kvadrirani gubitak umjesto ϵ -neosjetljivog intervala (što pojednostavljuje rješenje, ali gubi svojstvo rijetkosti) [123], dok uporaba logističke funkcije gubitka dovodi SVM u okvir logističke regresije. Razvijeni su i različiti algoritmi treniranja prilagođeni velikim skupovima podataka – primjerice dekompozicijski algoritmi poput SMO metode za sekvencijalnu optimizaciju [103] ili algoritmi unutarnje točke – koji omogućuju brže rješavanje optimizacijskog problema kod vrlo velikog broja uzoraka. Detaljna razmatranja tih proširenja izlaze iz okvira ovog rada te ovdje služe samo kao napomena o postojanju šireg konteksta razvoja SVM metodologije.

3.3. Optimizacija hiperparametara

Učinkovitost SVR modela izravno ovisi o pravilnom podešavanju njegovih hiperparametara, među kojima su najznačajniji regularizacijski faktor C , širina ε -cijevi (parametar osjetljivosti) te parametri jezgrene funkcije (npr. širina RBF kernela). Odabir ovih hiperparametara je od presudne važnosti za postizanje visoke točnosti predviđanja – ako je, primjerice, vrijednost faktora C prevelika, model može postati prenaučan [20].

3.3.1. Klasične metode pretraživanja hiperparametara

Tradicionalni pristupi za podešavanje hiperparametara oslanjaju se na ručno ispitivanje kombinacija ili pretraživanje rešetke (eng. *grid search*). U grid pretraživanju unaprijed se definira konačna rešetka mogućih vrijednosti za svaki hiperparametar, te se iscrpno isprobavaju sve kombinacije uz križnu validaciju ili odvojeni validacijski skup. Ova metoda je jednostavna i konceptualno jasna, a preporučena je u ranim SVM priručnicima [63]. Međutim, glavna mana iscrpnog grid pretraživanja jest izrazito visok računalni trošak, osobito kada broj hiperparametara raste ili je potrebna fina granularnost pretrage [63]. Broj kombinacija raste eksponencijalno s brojem parametara, pa grid search brzo postaje neizvediv u višedimenzionalnom prostoru. Čak i u slučajevima s relativno malim brojem hiperparametara, potpuno pretraživanje može biti vrlo vremenski zahtjevno.

Kao alternativa determinističkom pretraživanju rešetke, moguće je primijeniti i slučajno pretraživanje (eng. *random search*) hiperparametarskog prostora. Ova metoda nasumično isprobava kombinacije vrijednosti te je pokazano da često pronalazi jednake ili bolje modele uz znatno manji utrošak računskog vremena [12]. Ipak, i grid i random pretraživanje ne

iskorištavaju nikakve informacije o trendu poboljšanja tijekom pretrage. Stoga se u novije vrijeme sve češće poseže za inteligentnijim metodama – metaheurističkim algoritmima optimizacije – koji usmjeravaju pretragu prema boljim područjima prostora rješenja. Ovi algoritmi nastoje automatski kalibrirati model, smanjujući potrebu za ručnom intervencijom pri podešavanju hiperparametara.

3.3.2. Optimizacija rojem čestica

Optimizacija rojem čestica (eng. *Particle Swarm Optimization*, PSO) spada među najpopularnije metaheurističke algoritme za podešavanje hiperparametara modela strojnog učenja, pa tako i SVR-a [20]. PSO je inspiriran kolektivnim ponašanjem jata ptica ili grupe insekata pri traženju izvora hrane. U okviru PSO algoritma, skupina kandidata rješenja naziva se roj, a pojedinačna rješenja nazivaju se čestice. Svaka čestica predstavlja jedan mogući skup hiperparametara (tj. točku u prostoru hiperparametara). Čestice simultano “lebde” kroz prostor rješenja te prilagođavaju svoje pozicije iterativno, pri čemu uzimaju u obzir vlastito najbolje pronađeno rješenje kao i globalno najbolje rješenje cijelog roja. Na taj način, informacije o trenutno najuspješnijim parametrima šire se populacijom i usmjeravaju pretragu prema obećavajućim regijama.

Zbog ovakvog mehanizma, PSO može vrlo brzo locirati kombinacije hiperparametara visoke kvalitete (blizu globalno optimalnih vrijednosti) uz znatno manji broj evaluacija modela nego što je to potrebno kod konvencionalnog grid pretraživanja. Prethodna istraživanja potvrđuju da PSO tipično pronalazi skoro optimalne hiperparametre brže od grid searcha, što rezultira poboljšanom točnošću predikcije modela uz manju računalnu zahtjevnost [42, 65].

3.3.3. Hibridni algoritam PSwarm

Iako optimizacija rojem čestica učinkovito pretražuje globalni prostor rješenja, kao stohastička metoda ne jamči konvergenciju prema globalnom optimumu. S ciljem poboljšanja konvergencijskih svojstava razvijen je hibridni algoritam PSwarm, koji kombinira globalnu eksploracijsku sposobnost PSO-a s determinističkom lokalnom pretragom temeljenom na metodi uzorka (eng. *pattern search*).

PSwarm su predložili Vaz i Vicente [135, 136] kao hibridni optimizacijski okvir u kojem komponenta roja čestica identificira obećavajuća područja prostora pretraživanja, nakon čega se

u tim područjima provodi lokalna deterministička optimizacija metodom uzorka. Na taj se način ostvaruje ravnoteža između globalne eksploracije i lokalne eksploatacije.

Kombinacijom stohastičke i determinističke komponente PSwarm zadržava prednosti obje metode: učinkovito globalno pretraživanje karakteristično za PSO te poboljšana konvergencijska svojstva zahvaljujući lokalnoj pretrazi. Time se povećava vjerojatnost pronalaska globalnog optimuma te smanjuje rizik zadržavanja u lokalnim minimumima. Zaustavni kriteriji, poput maksimalnog broja evaluacija funkcije cilja ili izostanka poboljšanja kroz definirani broj iteracija, osiguravaju kontrolirano završavanje algoritma.

Eksperimentalna analiza pokazala je da PSwarm ostvaruje robusnu izvedbu i konkurentnu računalnu učinkovitost u odnosu na druge globalne optimizacijske metode [136]. Zbog navedenih svojstava, algoritam je prikladan za optimizaciju hiperparametara modela u složenim i nelinearnim problemima, uključujući podešavanje parametara SVR modela u energetske primjenama.

3.4. Odabir značajki

U okviru ovog rada korišteno je više metoda za odabir značajki (eng. *Feature Selection*, FS) s ciljem identifikacije najrelevantnijeg podskupa ulaznih varijabli za modele kratkoročnog predviđanja. Postupci odabira značajki omogućuju eliminaciju irelevantnih i redundantnih varijabli, čime se poboljšava točnost, robusnost i interpretabilnost modela te smanjuje računalna složenost procesa treniranja [51].

Primijenjene metode uključuju:

- **GA-IT** – postupak odabira značajki temeljen na genetskim algoritmima i kriterijima informacijske teorije (eng. *Genetic Algorithms* i *Information Theory*);
- **mRMR** – metoda minimalne redundancije i maksimalne relevantnosti (eng. *Minimum Redundancy Maximum Relevance*) temeljena na međusobnoj informaciji između varijabli;
- **Relief** – algoritam koji procjenjuje važnost značajki prema njihovoj sposobnosti razlikovanja sličnih instanci;
- **StepwiseFS** – sekvencijalni postupak odabira značajki temeljen na postupnom uključivanju ili isključivanju varijabli u regresijskom modelu (eng. *stepwise regression*);
- **GB-FS** – odabir značajki temeljen na modelima gradijentnog pojačanja (eng. *Gradient Boosting*), pri čemu se koristi mjera važnosti značajki iz algoritama poput XGBoost,

LightGBM i CatBoost.

3.4.1. Genetski algoritmi s informacijskim kriterijem (GA–IT)

GA–IT pristup kombinira heurističko pretraživanje genetskim algoritmima s kriterijima informacijske teorije za odabir značajki. Podskupovi značajki kodirani su binarnim kromosomima, a fitness funkcija kvantificira informativnost odabranog podskupa korištenjem entropije ili međusobne informacije. Postupak je učinkovit u visokodimenzionalnim i nelinearnim prostorima kombinacija značajki [119]. Detaljan opis algoritma dan je u Pravitku A, Odjeljak 1.4.1..

3.4.2. Minimalna redundancija i maksimalna relevantnost (mRMR)

Metoda mRMR temelji se na teoriji informacija te koristi koncept međusobne informacije za identifikaciju značajki koje su istodobno visoko relevantne za ciljnu varijablu i minimalno redundantne međusobno. Algoritam iterativno dodaje značajku koja maksimizira razliku između relevantnosti i redundancije, čime se osigurava da svaka nova značajka doprinosi dodatnoj informaciji o ciljnoj varijabli [102]. Detaljna formulacija kriterija mRMR dana je u Pravitku A, Odjeljak 1.4.2..

3.4.3. Relief metoda odabira značajki

Relief algoritam je filter metoda koja procjenjuje važnost značajki na temelju lokalne strukture podataka, analizirajući najbliže susjede istih i različitih klasa. Značajke koje pokazuju veću razliku između klasa, a stabilnost unutar iste klase, dobivaju veću težinu. Proširenja poput ReliefF i RRelief unaprijedila su robusnost i primjenjivost na regresijske probleme [74, 128]. Detaljan opis algoritma dan je u Pravitku A, Odjeljak 1.4.3..

3.4.4. StepwiseFS metoda odabira značajki

StepwiseFS je sekvencijalna *wrapper* metoda koja iterativno dodaje ili uklanja varijable iz regresijskog modela prema statističkim kriterijima (p-vrijednost, AIC, BIC). Postupak može slijediti strategije *forward selection*, *backward elimination* ili njihovu kombinaciju. Iako je računalno učinkovita i intuitivna, kao pohlepni postupak ne jamči pronalazak globalno optimalnog

podskupa značajki [51]. Detaljan opis dan je u Privitku A, Odjeljak 1.4.4..

3.4.5. Odabir značajki temeljen na algoritmu *Gradient Boosting*

Modeli gradijentnog pojačanja (GB), poput XGBoost, LightGBM i CatBoost [22, 69, 104], predstavljaju *embedded* pristup odabiru značajki pri čemu se procjena važnosti dobiva kao nusprodukt optimizacijskog postupka. Važnost se kvantificira metrikama poput dobitka (smanjenje funkcije gubitka), učestalosti korištenja i pokrivenosti uzoraka. Prednosti pristupa uključuju učinkovitost pri visokoj dimenzionalnosti, robusnost na nelinearnosti i interakcije te ugrađene mehanizme regularizacije [44]. Detaljan opis osnova algoritma, metrika rangiranja značajki te prednosti pristupa dan je u Privitku A, Odjeljak 1.4.5..

3.5. Osnove dubokih neuronskih mreža

Duboko učenje predstavlja granu strojnog učenja koja se oslanja na modele neuronskih mreža s više slojeva (duboke neuronske mreže). Feedforward neuronske mreže (FNN), koje uključuju višeslojne perceptrone (MLP), jedan su od temeljnih i najčešće korištenih oblika arhitektura neuronskih mreža, a ujedno čine i osnovu mnogih modela dubokog učenja. Kod FNN-a informacije teku samo u jednom smjeru – od ulaznog sloja, kroz jedan ili više skrivenih slojeva, do izlaznog sloja – bez povratnih veza ili ciklusa karakterističnih za rekurentne mreže. Ovakva arhitektura čini FNN konceptualno jednostavnima i stabilnima za treniranje, budući da nema unutarnje povratne sprege.

Ključna prednost FNN-a leži u njihovoj sposobnosti učenja nelinearnih odnosa između ulaza i izlaza. Zahvaljujući nelinearnim aktivacijskim funkcijama u neuronima, FNN s dovoljno skrivenih neurona može aproksimirati proizvoljnu kontinuiranu funkciju na zadanom zatvorenom skupu (tzv. teorem o univerzalnoj aproksimaciji [61]). Drugim riječima, uz dovoljan kapacitet modela, FNN teoretski mogu naučiti bilo kakvu kompleksnu funkcionalnu vezu između ulaznih podataka i ciljnih vrijednosti. Ova univerzalna sposobnost aproksimacije čini ih pogodnima za rješavanje složenih zadataka predikcije.

U području kratkoročnog predviđanja električnog opterećenja (STLF), gdje odnosi među varijablama uključuju vremensku dinamiku, sezonske obrasce i egzogene utjecaje, FNN arhitekture često se koriste kao osnovni modeli za predikciju. Primjeri njihove primjene u literaturi

uključuju radove [3, 6, 9], gdje se FNN koriste za razvoj prediktivnih modela, pri čemu su autori istraživali poboljšanja kroz optimizaciju arhitekture ili obradu podataka. Iako u tim radovima FNN nisu izravno uspoređene s tradicionalnim statističkim metodama, potvrđena je njihova praktična primjenjivost i konkurentna točnost u stvarnim scenarijima.

Iako već jedan skriveni sloj omogućuje univerzalnu aproksimaciju, veća dubina mreže (više slojeva) često poboljšava efikasnost učenja složenih obrazaca. Teorijski rezultati pokazuju da dublje mreže mogu reprezentirati određene funkcije znatno učinkovitije (s manje neurona) nego pliće mreže [34], što motivira upotrebu dubokih arhitektura u praksi.

U primjeni, feedforward neuronske mreže mogu se koristiti kao samostalni modeli za predikciju ili kao dio hibridnih arhitektura. U ovom istraživanju predlaže se upravo potonji pristup, u kojem FNN služi za automatsko učenje značajki iz ulaznih podataka, a drugi algoritam – u ovom slučaju SVR – preuzima ulogu završne regresije. Takav hibridni pristup ima za cilj objediniti snagu FNN-a u reprezentaciji složenih nelinearnih odnosa i robusnost SVR-a u preciznoj prognozi. FNN se koristi za ekstrakciju reprezentativnih značajki iz povijesnih opterećenja, meteoroloških podataka i vremenskih atributa, dok SVR na temelju tih naučenih značajki generira konačnu prognozu električne potrošnje.

Osnovna arhitektura tipičnog FNN modela obuhvaća ulazni sloj, jedan ili više skrivenih (potpuno povezanih) slojeva te izlazni sloj. Svaki skriveni sloj sastoji se od neuronskih jedinica koje izračunavaju linearne kombinacije izlaza prethodnog sloja te na njih primjenjuju nelinearne aktivacijske funkcije, dok izlazni sloj za regresijske zadatke koristi linearnu aktivaciju.

Aktivacijske funkcije

Aktivacijske funkcije uvode nelinearnost u model i omogućuju mreži aproksimaciju složenih funkcija. Najčešće korištena aktivacijska funkcija u modernim dubokim mrežama jest ReLU (eng. *Rectified Linear Unit*), definirana kao

$$f(z) = \max(0, z) . \quad (3.20)$$

ReLU je računalno učinkovita i ublažava problem nestajućih gradijenata (eng. *vanishing gradient problem*) koji se javlja kod sigmoidne funkcije $\sigma(z) = 1/(1 + e^{-z})$ i hiperboličnog tangensa $\tanh(z)$, budući da za pozitivne ulaze gradijent iznosi 1. Sigmoidna funkcija i $\tanh$ i dalje se

koriste u kontekstu LSTM mreža i izlaznih slojeva za klasifikaciju, no u skrivenim slojevima modernih FNN arhitektura ReLU dominira zbog bržeg treniranja i bolje generalizacije [48].

Optimizacija

Treniranje FNN-a provodi se postupkom propagacije pogreške unatrag (eng. *backpropagation*), kojim se izračunavaju parcijalne derivacije funkcije gubitka u odnosu na težine mreže. Dobiveni gradijenti koriste se za ažuriranje težina pomoću optimizacijskih algoritama. Osnovni pristup jest stohastički gradijentni spust (eng. *Stochastic Gradient Descent, SGD*), no u praksi se najčešće primjenjuje Adam optimizator [73], koji kombinira adaptivnu stopu učenja za svaki parametar s momentom prvog i drugog reda. Adam konvergira brže od klasičnog SGD-a i zahtijeva manje ručnog podešavanja stope učenja (eng. *learning rate*). Stopa učenja dodatno se može smanjivati tijekom treniranja primjenom rasporeda učenja (eng. *learning rate scheduling*), čime se u kasnijim fazama postiže finija optimizacija.

Regularizacija

Duboke neuronske mreže, zbog velikog broja parametara i visoke izražajne moći, sklone su prekomjernom prilagođavanju (eng. *overfitting*), osobito u uvjetima ograničene količine podataka ili visoke dimenzionalnosti ulaznog prostora. Za razliku od SVR modela, kod kojih je regularizacija inherentno ugrađena kroz princip maksimizacije margine, kod dubokih mreža potrebno je eksplicitno primijeniti odgovarajuće strategije kontrole složenosti modela.

U ovom radu primarno je korištena tehnika ranog zaustavljanja (eng. *early stopping*). Postupak se temelji na praćenju pogreške na validacijskom skupu tijekom treniranja, pri čemu se optimizacija prekida u trenutku kada validacijska pogreška prestane opadati. Na taj se način sprječava daljnje prilagođavanje modela šumu u treniranim podacima te se poboljšava generalizacijska sposobnost modela.

U slučaju potrebe za dodatnom regularizacijom moguće je uključiti i *dropout* mehanizam, koji nasumično isključuje određeni postotak neuronskih jedinica tijekom svakog koraka treniranja, čime se smanjuje međusobna ovisnost neurona i potiče robusnije učenje reprezentacija [121]. Također se može primijeniti *L2* regularizacija težina, kojom se penaliziraju velike vrijednosti parametara modela i time ograničava njegova efektivna složenost.

Primjenom navedenih postupaka omogućuje se stabilnije treniranje dubokih modela i bolja kontrola njihove generalizacijske sposobnosti, što je osobito važno u kontekstu kratkoročnog predviđanja opterećenja.

Hibridni DNN-SVR pristup

Ključna motivacija za kombiniranje DNN-a sa SVR-om leži u komplementarnim prednostima ovih dviju metoda. DNN posjeduje izvanrednu sposobnost automatskog učenja hijerarhijskih reprezentacija iz sirovih podataka — skriveni slojevi mogu prepoznati složene nelinearne obrasce, vremensku dinamiku i interakcije među značajkama. S druge strane, SVR pruža snažnu regularizaciju kroz maksimizaciju margine i ε -neosjetljivu funkciju gubitka, čime se osigurava robusna generalizacija čak i na manjim skupovima podataka. U predloženoj hibridnoj arhitekturi (detaljnije obrađenoj u Poglavlju 4, Odjeljak 4.6), DNN služi kao ekstraktor značajki koji iz ulaznih podataka uči apstrahiranu reprezentaciju, a SVR na temelju tih naučenih značajki vrši završnu regresiju. Time se kombinira snaga apstrakcije dubokog učenja s robusnošću generalizacije SVR-a, što rezultira modelom koji može nadmašiti oba pristupa primijenjena pojedinačno.

4. UNIFICIRANI METODOLOŠKI OKVIR TEMELJEN NA SVR-U I HIBRIDNIM PROŠIRENJIMA

U ovom poglavlju prikazuje se predloženi generički okvir modeliranja temeljen na metodi potpornih vektora za regresiju (*Support Vector Regression*, SVR), inicijalno razvijen za kratkoročno predviđanje potrošnje električne energije (STLF) [20] i primijenjen na kratkoročno predviđanje cijena prirodnog plina (ST-NGPF) [21]. Okvir uspostavlja replikabilan i modularan slijed koraka: pripremu podataka, generiranje i odabir značajki, transformacije mjerila, izbor jezgrene funkcije, optimizaciju hiperparametara te konzistentnu evaluaciju na razdvojenim skupovima podataka. Isti se metodološki okvir primjenjuje konzistentno na obje studije slučaja razmatrane u ovom radu (STLF i ST-NGPF), pri čemu se prilagodbe odnose isključivo na domenski specifične elemente poput strukture ulaznih varijabli, vremenske rezolucije i definicije prognoznih horizonata.

Predloženi SVR okvir implementira se kroz dvije komplementarne konfiguracije: (i) SSA-SVR, odnosno SVR model proširen sezonski prilagođenom konstrukcijom ulaznih značajki, automatiziranim odabirom značajki te metaheurističkom optimizacijom hiperparametara [20, 21], te (ii) hibridni DNN-SVR, u kojem duboka neuronska mreža uči nelinearnu latentnu reprezentaciju ulaznog prostora, dok SVR čini završni regresijski sloj nad izlazima prethodnog sloja mreže [153]. DNN-SVR se razmatra u satno-specijaliziranoj (osnovni postav) i jedinstvenoj (satno uvjetovanoj) varijanti. U obje konfiguracije zadržava se konzistentan metodološki slijed koraka, dok se razlike očituju u konstrukciji prediktora i strategiji podešavanja modela.

4.1. Opći metodološki okvir i temeljni SVR pristup


Temeljnu SVR konfiguraciju označavamo kao SSA–SVR (*Strategic Seasonality-Adjusted support vector regression*) [20, 21]. SVR nudi robusnu alternativu neuronskim mrežama zahvaljujući snažnim garancijama generalizacije, manjoj podložnosti lokalnim minimumima te učinkovitom radu s visokodimenzionalnim ulaznim prostorima [20].

SSA-SVR proširuje osnovnu SVR metodu strukturiranom strategijom koja eksplicitno uzima u obzir sezonske utjecaje konstrukcijom kalendarskih i sezonskih ulaznih značajki (binarni indikatori za sate, dane, mjesece, vikende, praznike itd.). Ključne komponente uključuju: optimizaciju hiperparametara globalnim optimizatorom, paralelno modeliranje više predikcijskih potproblema, generiranje bogatog skupa kandidatskih značajki te automatizirani odabir najrelevantnijih ulaznih varijabli. Struktura prediktora (satno-specijalizirani ili jedinstveni model) razmatra se zasebno u Odjeljku 4.3..

Metodološki slijed odvija se u više faza: prikupljanje povijesnih podataka o ciljnoj varijabli i egzogenih čimbenika, kronološka podjela na razvojni skup (*development set*) i završni testni skup (*hold-out test set*), te razdvajanje razvojnog skupa na trenirajući i validacijski podskup. Slijedi generiranje kandidatskih značajki s vremenskim pomacima i optimizacija hiperparametara na validacijskom skupu. Ako rezultati validacije nisu zadovoljavajući, postupak se iterativno ponavlja uz proširenje skupa značajki. U praksi se modeli periodički ponovno treniraju kako bi zadržali točnost u uvjetima konceptnog zanošenja.

Glavni koraci SSA-SVR metodologije, prikazani na slici 4.1, sažeti su u nastavku:

1. **Priprema podataka:** prikupljanje povijesnih podataka o ciljnoj varijabli i relevantnih egzogenih podataka.
2. **Podjela na skupove:** kronološka podjela na trenirajući i validacijski skup.
3. **Generiranje značajki:** stvaranje kandidatskih ulaznih varijabli, uključujući vremenski pomaknute vrijednosti (eng. *lags*), meteorološke značajke i kalendarske indikatore.
4. **Paralelno modeliranje i odabir značajki:** definiranje predikcijskih horizonata i zasebna primjena algoritama za odabir značajki (npr. ReliefF, mRMR, GA&IT, StepwiseFS) za svaki podmodel, čime se formiraju optimizirani ulazno-izlazni skupovi za SVR treniranje.
5. **Optimizacija hiperparametara:** optimiranje C , ϵ , γ globalnim algoritmom pretraživanja na validacijskom skupu te treniranje konačnih SVR modela.



Slika 4.1: Blok dijagram temeljne SVR metodologije s uključenom sezonskom konstrukcijom značajki (SSA-SVR), prikazujući glavne faze modeliranja od pripreme podataka do implementacije, uz povratnu vezu iz faze validacije prema fazi generiranja značajki.

6. **Validacija:** provjera točnosti; ako nije zadovoljavajuća, postupak se iterativno ponavlja od koraka 3 uz proširenje skupa značajki.

7. **Implementacija:** operativno predviđanje s periodičkim ponovnim treniranjem modela.

Razlike između STLFI i ST-NGPFI implementacija proizlaze iz karakteristika promatranih

vremenskih serija: u STLTF domeni modelira se satni niz s horizontom od 24 sata (24 satno-specijalizirana podmodela), dok se u ST-NGPF domeni koriste dnevni podaci s definiranim dnevnim horizontima. Ulazne varijable također su domenski uvjetovane – STLTF modeli uključuju povijesno opterećenje, meteorološke značajke i kalendarske indikatore, dok ST-NGPF modeli obuhvaćaju povijesne cijene plina, cijene povezanih energenata i pokazatelje opskrbe. Unatoč tim razlikama, temeljna SSA–SVR metodologija ostaje identična u obje domene, čime se potvrđuje generičnost predloženog pristupa [20, 21].

4.2. Protokol pripreme i predobrade podataka

Pouzdana primjena nadziranog učenja nad energetske vremenskim serijama zahtijeva konzervativan i replikabilan protokol pripreme podataka koji osigurava konzistentnost ulaza, očuvanje fizički smislenih varijacija te sprječava propuštanje informacija (eng. *information leakage*). Za razliku od i.i.d. postavki, energetske vremenske serije karakterizira izražena vremenska ovisnost, sezonalnost i mogućnost strukturnih promjena, zbog čega postupci čišćenja, skaliranja i podjele moraju strogo poštovati kronološki slijed opažanja.

4.2.1. Opći protokol kontrole kvalitete i očuvanja vremenskog integriteta

Polazišna pretpostavka protokola jest da svaki uzorak mora biti vremenski jednoznačno definiran i usklađen između svih izvora podataka koji čine ulazni vektor. Stoga se prije bilo kakvog modeliranja provodi provjera: (i) potpunosti zapisa, (ii) konzistentnosti vremenskih oznaka i rezolucije, te (iii) pravilnog poravnanja ulaznih varijabli i ciljne veličine u skladu s prognoznim horizontom. Pri tome se inzistira na očuvanju vremenskog integriteta: sve transformacije (resampliranje, agregacije, konstrukcija vremenskih pomaka, spajanje više izvora) moraju biti definirane tako da ne uvode informacije iz budućnosti u ulazni prostor trenutka koji se predviđa.

4.2.2. Postupanje s nedostajućim vrijednostima i konzervativna obrada

Nedostajuće vrijednosti tretiraju se na način koji minimizira rizik uvođenja pristranosti i umjetnog smanjivanja varijabilnosti serije. U općem slučaju razlikuju se dva scenarija: (i)

nedostaci u obveznim ulaznim varijablama, koji onemogućuju formiranje potpunog ulaznog vektora, te (ii) nedostaci u neobveznim varijablama, koji se mogu riješiti izostavljanjem varijable ili redefinicijom skupa značajki. Kako bi se zadržala konzistentnost ulaza i osigurala replikabilnost, preferira se konzervativan pristup: uzorci s nepotpunim obveznim ulaznim vektorima izuzimaju se iz treniranja i validacije.

4.2.3. Predobrada i skaliranje uz očuvanje vremenske izolacije

Prije izrade značajki provodi se preliminarna obrada: uklanjanje nepravilnih vrijednosti, spajanje podataka iz različitih izvora kroz vremensku sinkronizaciju te primjena transformacija mjerila (standardizacija ili min–max skaliranje). Za algoritme čija učinkovitost ovisi o mjerilu ulaznih varijabli (npr. SVR s RBF jezgrom, modeli dubokog učenja), parametri transformacije određuju se isključivo na trenirajućem dijelu razvojnog skupa i nepromijenjeni primjenjuju na validacijski i testni skup, čime se sprječava propuštanje informacija iz budućih razdoblja.

4.2.4. Kronološka podjela podataka i izolacija postupka podešavanja

Kako bi se izbjegla optimistička pristranost, sve odluke koje uključuju izbor modela i podešavanje (npr. odabir značajki, izbor arhitekture, odabir hiperparametara, kriteriji zaustavljanja) donose se isključivo na razvojnim podacima, uz korištenje validacijskog podskupa kao aproksimacije budućih uvjeta prognoziranja. Završni testni skup ostaje potpuno izoliran do trenutka konačne evaluacije, nakon fiksiranja svih postavki. Time se osigurava da izmjerene performanse odražavaju stvarnu generalizacijsku sposobnost modela na doista neviđenim podacima, a ne posljedicu implicitnog prilagođavanja budućem razdoblju.

4.2.5. Očuvanje fizički smislenih varijacija i strukturnih promjena

Strukturne promjene i dugoročni trendovi u energetske serijama ne uklanjaju se automatski, već se zadržavaju kao dio realnog procesa generiranja podataka, osim ako se utvrdi da su posljedica pogreške mjerenja. Time se izbjegava stvaranje umjetno “stacionarnih” skupova podataka. Opisani protokol pripreme podataka predstavlja zajednički temelj svih eksperimentalnih poglavlja, dok se konkretne implementacijske odluke definiraju na razini pojedinih studija slučaja.

4.3. Formulacija višekoračnog prediktivnog zadatka i konstrukcija ulaznog prostora

4.3.1. Taksonomija ulaznih varijabli u STLF i ST-NGPF

U nastavku se daje pregled tipova podataka koji se u literaturi i praksi najčešće razmatraju u problemima kratkoročnog predviđanja opterećenja (STLF) te u problemima kratkoročnog predviđanja cijena prirodnog plina (ST-NGPF).

U problemima kratkoročnog predviđanja opterećenja (STLF):

- **Povijesni podaci o opterećenju** – prošle vrijednosti potrošnje (obično satna razina) čine temeljni ulaz za STLF modele.
- **Vremenski (kalendarski) podaci** – vrijeme dana, dan u tjednu, mjesec u godini te blagdani kodiraju dnevne, tjedne i sezonske obrasce potrošnje.
- **Meteorološki podaci** – temperatura, vlažnost, brzina vjetra i sunčevo zračenje izravno su povezani s potražnjom za energijom. Osim lokalnih mjerenja, moguće je integrirati i globalne numeričke vremenske prognoze (NWP) radi prostorno i vremenski dosljedne pokrivenosti, što je u eksperimentalnom dijelu rada ilustrirano primjenom globalnog ansambla NWP prognoza.
- **Ekonomski i društveni pokazatelji** – razina poslovne aktivnosti, kretanje stanovništva te izvanredni događaji mogu utjecati na potrošnju.
- **Podaci o infrastrukturi** – dostupnost proizvodnih jedinica, ispadi elektrana i stanje mreže objašnjavaju određene fluktuacije u opterećenju.
- **Ostali pokazatelji** – cijene energije, distribuirani energetske resursi, tehnički parametri sustava te u naprednim pristupima vanjski čimbenici poput analize vijesti.

Za ST-NGPF u literaturi se razmatra širok raspon ulaznih varijabli koje opisuju čimbenike ponude i potražnje:

- **Povijesne cijene prirodnog plina:** spot cijena i njezine transformacije (diferencije, relativne promjene, logaritamske transformacije) [129].
- **Cijene srodnih energenata:** loživog ulja, sirove nafte (WTI) i ugljena, čije promjene signaliziraju promjene u strukturi potražnje za energijom.

- **Meteorološki pokazatelji:** indeksi potreba za grijanjem i hlađenjem (*degree day* pokazatelji) koji kvantificiraju utjecaj vremenskih prilika na potrošnju plina.
- **Fundamentalni pokazatelji ponude:** broj aktivnih bušotina, dnevna proizvodnja te uvoz plina kao aproksimacija promjena u ponudi.
- **Sezonski i kalendarski indikatori:** binarne varijable za dane u tjednu i mjesece u godini.
- **Zalihe i logistički čimbenici:** razine skladištenja, tokovi LNG-a te prekogranične isporuke.
- **Utjecaj elektroenergetskog sustava:** proizvodnja iz obnovljivih izvora koja neizravno utječe na potražnju za plinom.
- **Makroekonomski pokazatelji:** industrijska proizvodnja, tržišna volatilnost i očekivanja [129].

U praktičnim postavkama koristi se samo podskup navedenih kategorija, ovisno o dostupnosti podataka i ciljevima analize; konkretne kombinacije specificirane su u eksperimentalnom poglavlju. Za razliku od potrošnje električne energije, dinamika cijene plina snažno je uvjetovana tržišnim očekivanjima i međuzavisnostima s drugim energetske robama, što zahtijeva integraciju fundamentalnih, meteoroloških i tržišnih informacija.

4.3.2. Konstrukcija značajki i odabir značajki

Metodološki okvir započinje generiranjem bogatog skupa kandidatskih značajki kombinacijom kontinuiranih varijabli (dinamika promatranih veličina) i binarnih varijabli (sezonski i kalendarski efekti). U sklopu inženjeringa značajki uvode se izvedene meteorološke varijable pomoću *degree-day* pokazatelja:

- *Potrebu za hlađenjem* (Cooling Degree Days),

$$T_c = \max(T - 20^{\circ}\text{C}, 0),$$

- *Potrebu za grijanjem* (Heating Degree Days),

$$T_h = \max(16.5^{\circ}\text{C} - T, 0),$$

- *Dodatnu potrebu za grijanjem,*

$$T_{ah} = \max(5.0^{\circ}\text{C} - T, 0).$$

Navedeni pragovi standardno se koriste u energetske analizama [21, 60]. Izvedene meteorološke značajke mogu se kombinirati s vremenskim pomacima i prognostičkim vrijednostima radi hvatanja kratkoročne dinamike.

Sezonski i kalendarski efekti kodiraju se kroz indikatorske varijable (sat u danu, dan u tjednu, mjesec u godini, blagdani) [39, 41], čime se modelima omogućuje učenje periodičnih obrazaca bez potrebe za zasebnim modelima po sezonama ili fazom klasteriranja. Detalji skaliranja i kronološke podjele opisani su u Odjeljku 4.2..

4.3.3. Satno-specijalizirani i jedinstveni pristup

U okviru kratkoročnog predviđanja opterećenja (STLF), jedna od ključnih metodoloških odluka odnosi se na način formuliranja prediktivnog zadatka s obzirom na vremenski horizont. U literaturi se pritom pojavljuju dva dominantna pristupa: (i) *satno-specijalizirani* pristup, u kojem se svaki ciljni sat tretira kao zaseban regresijski problem, te (ii) *jedinstveni* pristup, u kojem jedan model predviđa više vremenskih horizonata ili je eksplicitno uvjetovan ciljnim satom.

Satno-specijalizirani pristup. U satno-specijaliziranom pristupu ciljni horizonti (npr. pojedini sati u danu) modeliraju se kao neovisni regresijski zadaci. Za svaki ciljni sat može se razviti poseban prediktivni model, pri čemu se postupak odabira značajki (FS) provodi zasebno. Time se omogućuje precizno prilagođavanje skupa ulaznih varijabli specifičnim obrascima potrošnje karakterističnima za pojedini sat dana.

U praksi se mogu razlikovati dvije varijante treniranja satno-specijaliziranih modela:

- **Korištenje cjelokupnog skupa podataka**, pri čemu se svi povijesni zapisi koriste za treniranje svakog modela, ali s različitim ciljnim varijablama definiranim za odgovarajuće horizonte;
- **Korištenje podataka filtriranih po satu**, gdje se svaki model trenira isključivo na podskupu podataka koji odgovara određenom satu u danu, čime se osigurava visoka relevantnost podataka, ali se smanjuje njihov obujam.

Glavna prednost satno-specijaliziranog pristupa leži u mogućnosti finog prilagođavanja modela i skupa značajki specifičnostima pojedinih sati, što često rezultira većom točnošću predviđanja. Nedostatak takvog pristupa očituje se u povećanoj računalnoj složenosti, budući da se postupci odabira značajki, optimizacije hiperparametara i treniranja moraju provoditi

višestruko.

Jedinstveni prediktivni model. Alternativu predstavlja jedinstveni prediktivni model koji obuhvaća više vremenskih horizonata. U tom slučaju postupak odabira značajki provodi se jednom, pri čemu se identificira skup ulaznih varijabli koje su općenito relevantne za dnevni ciklus potrošnje. Kako bi se očuvala informacija o ciljnom horizontu, model se može dodatno uvjetovati varijablom koja eksplicitno označava ciljni sat ili vremenski pomak.

Prednost jedinstvenog pristupa očituje se u manjoj računalnoj zahtjevnosti, jednostavnijem upravljanju modelom i većoj stabilnosti u operativnim uvjetima. Takav pristup posebno je prikladan u situacijama s ograničenim brojem uzoraka ili kada je robusnost sustava važnija od maksimalne točnosti po pojedinom satu. S druge strane, jedinstveni model nužno predstavlja kompromis, jer isti skup značajki mora generalizirati obrasce potrošnje za različite sate, što može dovesti do smanjene preciznosti u satima s izraženim nelinearnostima ili specifičnim ponašanjem potrošnje.

Metodološke implikacije i izbor pristupa. Izbor između satno-specijaliziranog i jedinstvenog pristupa ne predstavlja isključivo pitanje prediktivne točnosti, već uključuje razmatranje računalne složenosti, dostupnosti podataka, stabilnosti modela i operativne održivosti. U ovoj doktorskom radu ne koristi se rekurzivno višekoračno predviđanje; svi ciljni horizonti predviđaju se izravnom (eng. *direct*) strategijom višekoračnog predviđanja, čime se izbjegava propagacija pogrešaka između vremenskih koraka. Konkretna arhitektura odabrana je u skladu s eksperimentalnim protokolom i karakteristikama pojedinog skupa podataka.

4.3.4. Konstrukcija ulaznog prostora za satno-specijalizirane modele

Konstrukcija ulaznog prostora za satno-specijalizirane modele sastoji se od dviju faza: (i) konstrukcije kandidatskog vektora značajki u trenutku izdavanja prognoze (prema strategijama iz Pododjeljka 4.3.3.), te (ii) redukcije dimenzionalnosti algoritmima odabira značajki. U ovom radu, odabir značajki temeljen na gradijentnom pojačanju primijenjen je isključivo u DNN-SVR modelu, dok se u SSA-SVR eksperimentima koriste alternativni algoritmi.

4.3.4.1. Opća struktura ulaznog vektora za satno uvjetovane modele

Za svaki ciljni horizont formira se vremenski usklađen ulazni vektor konkatencijom više komplementarnih skupina značajki, pri čemu se koriste isključivo informacije poznate u trenutku izdavanja prognoze. U općem slučaju mogu se razlikovati sljedeće kategorije ulaznih podataka:

- **Kratkoročna povijest ciljne varijable i egzogenih signala**, koja obuhvaća fiksni vremenski prozor neposredno prethodnih opažanja radi hvatanja lokalne dinamike i kratkoročnih ovisnosti.
- **Sidreni uzorci vezani uz periodičnost**, konstruirani pomoću vremenski pomaknutih vrijednosti koje očuvaju dnevne, tjedne ili gotovo-tjedne obrasce relativno u odnosu na ciljni sat predviđanja. U eksperimentalnom dijelu rada, satno uvjetovana sidra koriste se kao dodatak standardnim vremenskim pomacima u okviru hibridnog DNN-SVR modela, dok se u SSA-SVR konfiguracijama ulazni prostor konstruira isključivo na temelju vremenskih zaostataka (lagova) ciljne varijable i egzogenih signala.
- **Egzogeni prognostički prediktori**, koji uključuju numeričke vremenske prognoze ili druge unaprijed dostupne vanjske signale relevantne za ciljni problem.
- **Kalendarske i sezonske značajke**, koje omogućuju modelu eksplicitno uvažavanje periodičnih i institucionalnih obrazaca u podacima.

Ovakva modularna struktura ulaznog prostora omogućuje prilagodbu različitim modelskim arhitekturama, pri čemu se detaljna specifikacija pojedinih blokova definira na razini konkretne primjene.

4.3.5. Implikacije formulacije zadatka na odabir značajki

Razina granularnosti modela (Pododjeljak 4.3.3.) izravno određuje provodi li se odabir značajki zasebno po horizontima ili nad objedinjenim skupom podataka. Satno-specijalizirani pristup omogućuje finiju prilagodbu značajki, dok jedinstveni model traži skup varijabli informativan kroz širi raspon horizonata. Konkretni izbor strategije usuglašen je s arhitekturom modela i detaljno se razmatra u eksperimentalnim poglavljima.

4.4. Kalibracija modela: odabir značajki, optimizacija hiperparametara i završno treniranje

Faza *podešavanja modela* obuhvaća: (i) odabir značajki (*feature selection*, FS), (ii) optimizaciju hiperparametara na validacijskom skupu te (iii) treniranje konačnog modela s fiksnim postavkama. Sve odluke donose se isključivo na razvojnim podacima. U nastavku se postupak prikazuje odvojeno za (a) SSA–SVR (metaheuristička optimizacija) i (b) DNN-SVR (deterministički grid search nad fiksnim latentnim prostorom).

4.4.1. Odabir značajki u SSA–SVR konfiguracijama

Na razvojnom skupu primjenjuje se automatizirani odabir značajki korištenjem komplementarnih FS strategija: ReliefF, mRMR, GA&IT te stepwise metoda. Svaka metoda rangira kandidatske značajke prema vlastitom kriteriju važnosti, nakon čega se odabire *top-k* značajki kao kompromis između točnosti i složenosti. Odabir se provodi isključivo na razvojnim podacima, bez uvida u testno razdoblje.

4.4.2. Optimizacija hiperparametara SVR modela primjenom PSwarm algoritma

Nakon fiksiranja podskupa odabranih značajki, hiperparametri SVR modela optimiziraju se primjenom PSwarm algoritma (Odjeljak 3.3.3.), s ciljem minimizacije pogreške predviđanja na validacijskom skupu. Postupak obuhvaća:

1. **Definicija funkcije cilja:** mjera pogreške na validacijskom skupu (najčešće MAE ili MAPE).
2. **Prostor pretraživanja:** dopušteni rasponi za C , ε i γ (RBF jezgra), te parametri algoritma (veličina roja, maksimalan broj evaluacija, kriteriji zaustavljanja).
3. **Izvođenje optimizacije:** PSO dinamika s determinističkom lokalnom pretragom karakterističnom za PSwarm varijantu; svaka čestica evaluira se na validacijskom skupu.
4. **Odabir rješenja:** postupak se zaustavlja nakon dostizanja maksimalnog broja iteracija ili konvergencije; najbolje rješenje koristi se za treniranje konačnog SVR modela.

PSwarm postiže usporedivu ili bolju točnost uz manji broj evaluacija u odnosu na iscrpne pretrage [12, 42]. Odabrane postavke potvrđene su kao stabilne kroz višestruka pokretanja.

4.4.3. Optimizacija završnog SVR sloja u DNN-SVR arhitekturi primjenom grid search postupka

U hibridnom DNN-SVR postavu hiperparametri završnog SVR sloja optimiziraju se determinističkim *grid search* postupkom (Odjeljak 3.3.1.). Budući da je latentni prostor u trenutku optimizacije SVR-a već fiksiran, deterministički pristup omogućuje potpuno reproduktivno podešavanje bez dodatne stohastičnosti. Razvojni uzorci projiciraju se kroz istrenirani DNN radi dobivanja latentnih značajki, nakon čega se evaluira mreža vrijednosti hiperparametara na validacijskom skupu; optimalna kombinacija koristi se za treniranje završnog SVR sloja.

4.4.4. Treniranje konačnog modela s fiksiranim hiperparametrima

Nakon odabira značajki i optimizacije hiperparametara, konačni model uči se nad cjelokupnim razvojnim skupom s fiksiranim postavkama, bez korištenja informacija iz testnog razdoblja. Završno istrenirani model evaluira se na izdvojenom testnom skupu. Postupak dosljedno slijedi strukturu $FS \rightarrow HPO \rightarrow final\ training$.

4.5. Protokol evaluacije: vremenska podjela i metrike

4.5.1. Strategija vremenske podjele podataka i validacije

Primjenjuje se vremenski konzistentna strategija podjele: podaci se kronološki dijele na razvojni skup i završni testni skup, pri čemu testni skup predstavlja najkasniji segment serije. Razvojni skup dodatno se dijeli na trenirajući i validacijski podskup; validacijski dio služi za odabir značajki, konfiguraciju arhitekture i optimizaciju hiperparametara (uključujući *early stopping*), dok testni podaci ostaju izolirani do završne evaluacije. Validacijski segment uvijek kronološki slijedi trenirajući segment.

Ova strategija provodi se konzistentno kroz sve implementacijske varijante (SSA-SVR i DNN-SVR), osiguravajući usporedivost rezultata i interpretaciju razlika u performansama kao

posljedicu metodoloških razlika, a ne propuštanja informacija.

Dodatno, uvedena je analiza s više alternativnih prozora razvojnog razdoblja (uz istu testnu dionicu) radi procjene osjetljivosti modela na količinu podataka – ispituje se koristi li modelu dulja povijest ili je recentniji, kraći skup dostatan za stabilno treniranje. Konkretni vremenski intervali definirani su u eksperimentalnim poglavljima.

4.5.2. Evaluacija modela (metrike)

Za kvantitativnu ocjenu prediktivnih modela koriste se tri standardne metrike pogreške. MAPE (srednja apsolutna postotna pogreška) ističe se kao glavna mjera jer omogućuje usporedbu rezultata između različitih skupova podataka:

$$\text{MAPE} = 100\% \cdot \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|. \quad (4.1)$$

gdje je n broj opažanja, y_i stvarna vrijednost, a $\hat{y}_i$ predviđena vrijednost. MAE (prosječna apsolutna pogreška) mjeri odstupanja u istim jedinicama kao ciljane varijable:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|. \quad (4.2)$$

RMSE (korijen srednje kvadratne pogreške) snažnije kažnjava veće pogreške:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}. \quad (4.3)$$

Izbor metrika prilagođen je domeni problema: za STLTF se koriste MAPE i MAE, dok se za ST-NGPF koriste MAPE i RMSE (jer volatilnost cijena naglašava važnost praćenja većih odstupanja). Validacija je provedena u skladu s vremenski konzistentnom *hold-out* podjelom (Odjeljak 4.5.1.), pri čemu su konkretni vremenski presjeci definirani u eksperimentalnim poglavljima.

4.6. Integracija dubokog učenja u SVR okvir

Uvodi se hibridni DNN–SVR model koji integrira reprezentacijsku moć dubokog učenja s robustnim regresijskim svojstvima SVR-a. Istraživačka hipoteza polazi od pretpostavke da integracija SVR-a u završni sloj DNN-a omogućuje učinkovitije iskorištavanje dubokih nelinearnih reprezentacija uz završnu regresijsku aproksimaciju prema principu maksimalne margine, čime se može povećati točnost kratkoročnog predviđanja u odnosu na samostalne DNN modele.

4.6.1. Teorijska motivacija i pozicioniranje DNN–SVR modela

Ključna novost jest uvođenje DNN-a između faze odabira značajki i SVR modela, čime se omogućuje učenje hijerarhijskih latentnih reprezentacija. Koncept kombiniranja neuronskih mreža i SVM-a razvijao se kroz tri konceptualna koraka: (i) *NEUROSVM* – plitke neuronske mreže kao ekstraktor značajki za SVM klasifikator [47], (ii) *NSVM* – proširenje na regresiju s centralnim prostorom značajki optimiziranim za SVR [143], te (iii) *DNMSVM* – duboka neuronska mreža kao eksplicitno preslikavanje jezgre za SVM [81].

Za razliku od NSVM-a (plitke arhitekture) i DNMSVM-a (zajednička optimizacija), predloženi DNN–SVR koristi duboku arhitekturu s dvostupanjskim postupkom treniranja. Treniranje SVR-a u fiksnom latentnom prostoru osigurava pouzdaniju optimizaciju margine, povećava robusnost te omogućuje jasnu izolaciju doprinosa završnog SVR sloja.


4.6.2. Arhitektura i operativni slijed modeliranja

DNN-SVR varijanta primarno je implementirana u satno-specijaliziranoj konfiguraciji, dok je jedinstveni model razmatran kao usporedna varijanta (Odjeljak 4.3.). Svi početni koraci iz SSA-SVR okvira (priprema podataka, generiranje značajki, odabir značajki, podjela na skupove) ostaju nepromijenjeni; u nastavku se opisuju isključivo noviteti DNN-SVR arhitekture.

U hibridnom pristupu SVR operira nad niskodimenzionalnim latentnim reprezentacijama iz pretposljednog skrivenog sloja DNN-a, koji predstavlja komprimiranu, zadatku prilagođenu nelinearnu transformaciju ulaznog prostora [146].

Na slici 4.2 prikazan je shematski tijek predloženog hibridnog metodološkog slijeda modeli-

ranja, od pripreme podataka do završne validacije modela.



Slika 4.2: Shematski prikaz predloženog hibridnog DNN-SVR modela. Proces započinje s ulaznim podacima, prolazi kroz DNN slojeve (trenirane za svaki podskup podataka), te završava SVR regresijskim slojem koji daje konačnu prognozu.

Za svaki podmodel (Slika 4.2) trenira se DNN propagacijom pogreške unatrag uz optimizator poput Adam, minimizirajući srednju kvadratnu pogrešku. Prenaučenost se sprječava primarno ranim zaustavljanjem (early stopping), uz mogućnost aktiviranja dropout i $L2$ regularizacije. Nakon treniranja, izvorni izlazni sloj DNN-a zamjenjuje se SVR regresorom koji operira nad latentnim reprezentacijama prethodnog sloja. Kao jezgra koristi se RBF (*Radial Basis Function*), a hiperparametri SVR sloja podešavaju se determinističkim *grid search* postupkom (Odjeljak 4.4.3.). Opći protokol podešavanja modela definiran je u Odjeljku 4.4..

4.6.3. Odabir značajki u DNN-SVR postavu

U DNN-SVR postavu primijenjena je metoda odabira značajki temeljena na gradijentnom pojačanju (GB), koja pouzdano procjenjuje važnost varijabli u prisutnosti nelinearnosti i interakcija. Značajke se rangiraju prema doprinosu smanjenju pogreške na validacijskom skupu, a one ispod definiranog praga uklanjaju se. Postupak se provodi zasebno po horizontima (satno-specijalizirani modeli) ili jednokratno (jedinostveni model). Daljnja kalibracija provodi se prema Odjeljku 4.4.3..

4.6.4. Metodološke prednosti integracije

Očekivani benefiti integracije DNN i SVR paradigmi:

- **Potencijalno smanjenje prediktivne pogreške:** razdvajanje učenja reprezentacije i završne regresijske optimizacije može rezultirati učinkovitijim modeliranjem složenih nelinearnih odnosa.
- **Povećana robusnost:** SVR uvodi eksplicitnu kontrolu kompromisa između složenosti i pogreške (parametri C i ϵ), smanjujući rizik prenaučivosti.
- **Modularna struktura:** razdvajanje ekstrakcije značajki (DNN) i regresije (SVR) omogućuje transparentnu analizu doprinosa pojedinih komponenti.

U ovom radu predloženi DNN-SVR pristup empirijski se verificira na problemskoj domeni kratkoročnog predviđanja opterećenja (STLF), gdje se očekuje dodatno povećanje robusnosti i točnosti predviđanja u odnosu na bazne modele.

4.7. Sažetak metodološkog okvira i plan eksperimenata

Kao zaključak metodološkog dijela, Poglavlje 4 uspostavilo je generički i modularni okvir za prediktivno modeliranje u energetske sustavima, temeljen na SVR metodologiji, inženjeringu i odabiru značajki, optimizaciji hiperparametara te hibridnoj DNN-SVR arhitekturi. Definiran je jedinstven protokol pripreme podataka i evaluacije (vremenska podjela, razvojni skup s validacijom te izolirani testni skup), kao i konzistentan skup metrika pogreške, čime se osigurava usporedivost rezultata između različitih modela i problemskih domena. U nastavku rada razvijeni okvir primjenjuje se na dvije studije slučaja: Poglavlje 5 na kratkoročno predviđanje opterećenja

(STLF), a Poglavlje 6 na kratkoročno predviđanje cijene prirodnog plina (ST-NGPF).

Radi provjere predloženog okvira i hipoteza istraživanja, planirana je provedba sljedećih ključnih eksperimenata:

- **Eksperiment 1: Učinak odabira značajki i usporedba s referentnim metodama (STLF, ST-NGPF).** Ovaj eksperiment, proveden u okviru SVR-temeljnog modela, objedinjuje dvije komplementarne analize: (i) kvantifikaciju utjecaja različitih algoritama odabira značajki (ReliefF, mRMR, GA&IT, StepwiseFS) na točnost SVR prognoza, usporedbom izvedbe modela treniranog na odabranom podskupu značajki s izvedbom modela treniranog na punom skupu značajki, te (ii) pozicioniranje predloženog SVR-okvira u odnosu na referentne modele prikladne za pojedinu domenu (npr. ARIMA i jednostavni ML/NN pristupi za ST-NGPF, te referentni modeli iz literature za STLF). Cilj je pokazati da predloženi protokol (FS → HPO → final training) sustavno poboljšava točnost i stabilnost SVR-a te omogućuje usporedivu evaluaciju u odnosu na standardne pristupe.
- **Eksperiment 2: Doprinos globalnih prognostičkih meteoroloških ulaza u STLF (verifikacija hipoteze H3).** U domeni STLF-a ispituje se koristi li uključivanje globalnih numeričkih vremenskih prognoza kao egzogenih ulaza (u odnosu na varijante bez prognostičkih meteoroloških podataka ali s ograničenim lokalnim mjerenjima). Time se verificira hipoteza H3 da globalni prognostički meteorološki modeli mogu poboljšati točnost kratkoročnog predviđanja opterećenja pružajući relevantnu informaciju o budućim vremenskim uvjetima.
- **Eksperiment 3: Performanse hibridnog DNN-SVR modela (verifikacija hipoteze H1).** U domeni STLF-a evaluira se predloženi hibridni DNN-SVR u odnosu na bazne varijante (npr. samostalni DNN u istom evaluacijskom protokolu). Cilj je izravno provjeriti hipotezu H1 da integracija SVR-a kao završnog regresijskog sloja nad latentnim reprezentacijama DNN-a može povećati točnost kratkoročnog predviđanja u odnosu na samostalni DNN model
- **Eksperiment 4: Satno-specijalizirani modeli naspram jedinstvenog modela (verifikacija hipoteze H2).** U domeni STLF-a uspoređuje se satno-specijalizirana konfiguracija (skup podmodela prilagođenih jednosatnim intervalima) s jedinstvenim modelom uvjetovanim ciljnim satom/horizontom. Time se verificira hipoteza H2 da prilagodba modela jednosatnim vremenskim intervalima može poboljšati točnost predviđanja, jer omogućuje

učenje satno-specifičnih režima ponašanja i smanjuje kompromis koji jedinstveni model mora ostvariti preko heterogenih intradnevni obrazaca.

U svim eksperimentima primjenjuje se identičan protokol vremenski konzistentne podjele podataka te jedinstven skup evaluacijskih metrika, čime se osigurava da se razlike u performansama pripisuju isključivo metodološkim razlikama.

5. EKSPERIMENTALNA VALIDACIJA I KOMPARATIVNA ANALIZA MODELA ZA KRATKOROČNO PREDVIĐANJE PO- TROŠNJE ELEKTRIČNE ENERGIJE

5.1. Skupovi podataka i postavke eksperimenta

5.1.1. ISO New England: Opis i priprema podataka

U nastavku se razmatraju dva referentna skupa podataka korištena za eksperimentalnu evaluaciju temeljne SSA-SVR metodologije, u skladu s ranije objavljenim radovima. Za potrebe prediktivnog modeliranja potrošnje električne energije na području ISO New England, korišten je detaljan skup podataka koji obuhvaća sustavno mjerenu satnu potrošnju te relevantne vremenske podatke dobivene iz globalnih prognostičkih modela. Ciljna varijabla u ovom slučaju je stvarna sustavna opterećenost izražena u megavatima (MW), koja se utvrđuje temeljem mjerenja na razini elektroenergetskog sustava. Podaci su preuzeti od operatora prijenosnog sustava ISO New England te predstavljaju službene satne zapise sustavne potrošnje korištene u operativnom i planskom upravljanju sustavom. Satni zapisi sustavne potrošnje podložni su mogućim kasnijim korekcijama od strane ISO-NE, zbog čega se revidirane datoteke objavljuju naknadno. Tijekom mjeseci uvođenja i ukidanja ljetnog računanja vremena (travanj i listopad), satne vrijednosti u prijelaznim razdobljima ljetnog računanja vremena harmonizirane su interpolacijom temeljenom na aritmetičkoj sredini susjednih sati, kako bi se osigurala vremenska konzistentnost niza.

U svrhu evaluacije korišteni su povijesni podaci 2003.–2006., gdje je 2006. odabrana kao

testna godina, dok skup podataka za treniranje obuhvaća razdoblje od ožujka 2003. do kraja 2005. godine. Validacijski skup uvijek pokriva 60 dana neposredno prije testnog razdoblja. Parametri SVR modela (C , ε , širina jezgre) kao i konačni odabir ulaznih značajki putem FS algoritama podešavaju se isključivo na validacijskom skupu, čime se izbjegava pretreniranost i osigurava poštena evaluacija predikcijske sposobnosti modela.

5.1.1.1. Meteorološki podaci, kalendarske značajke i predobrada

Meteorološki podaci za ISO-NE regiju preuzeti su iz ECMWF MACC projekta (rezolucija $1,25^\circ$) i interpolirani metodom najmanjih kvadrata na ponderirani prosjek osam meteoroloških stanica (Boston, Bridgeport, Burlington, Concord, Portland, Providence, Windsor Locks i Worcester). U treniranju su korištene prognozirane, a ne stvarne temperature, čime se simuliraju operativni uvjeti. Uz osnovne temperaturne podatke, konstruirani su indeksi zahtjeva za grijanjem i hlađenjem (T_c , T_h , T_{ah}), definirani u Odjeljku 4.3.2., koji ukupno generiraju 288 temperaturno baziranih značajki. Kalendarski praznici kodirani su binarnim indikatorskim varijablama u skladu s metodološkim okvirom iz Poglavlja 4. Detaljan opis interpolacijske procedure, ponderiranja meteoroloških stanica i kodiranja praznika dan je u Pravitku B.

5.1.2. North-American Utility: Opis i priprema podataka

U svrhu dodatne evaluacije predložene SSA-SVR strategije za kratkoročno predviđanje električne potrošnje, provedena je primjena i na stvarnom skupu podataka jedne sjevernoameričke elektroprivrede. Radi pravnih i komercijalnih razloga, identitet dotične elektroenergetske tvrtke nije objavljen, što je u skladu s pristupom iz ranijih istraživanja [4, 20, 33].

Podaci korišteni u ovom eksperimentalnom slučaju uključuju satne zapise električnog opterećenja i temperature za razdoblje od siječnja 1988. do 12. listopada 1992. godine. Sustav pripada jednoj od glavnih sjevernoameričkih AC interkonekcija, koje funkcioniraju unutar vlastitih tehničkih i regulatornih okvira [33].

Za potrebe testiranja modela, provedeno je predviđanje satnih opterećenja za dvogodišnje razdoblje koje prethodi 12. listopada 1992. godine. Model je treniran isključivo na podacima dostupnima prije trenutka predikcije, čime je osigurana realna i vjerodostojna procjena njegove generalizacijske sposobnosti. Validacijski skup obuhvaća razdoblje od 365 dana koje neposredno

prethodi testnom razdoblju. Na tom validacijskom skupu izvršena je optimizacija svih ključnih parametara modela, uključujući SVR hiperparametre (parametar regularizacije C , širinu ε -cijevi te parametre jezgre) te automatski odabir ulaznih značajki pomoću algoritama odabira značajki (FS).

Za razliku od ISO-NE, ovaj skup ne uključuje indeks vlažnosti zraka, već se oslanja na temperaturne podatke u obliku vremenski pomaknutih vrijednosti. U oba testna slučaja primijenjen je istovjetan skup prazničnih dana i sezonskih kalendarskih varijabli. Detaljni opis meteoroloških ograničenja i usporedba sa skupom ISO-NE dani su u Priritku B.

5.1.3. Hrvatska: Opis i priprema podataka

Skup podataka korišten u ovom istraživanju obuhvaća podatke o potrošnji električne energije u Hrvatskoj, u razdoblju od 2006. do 2023. godine. Dio podataka dostupan je (od 2012 na dalje) putem javne platforme ENTSO-E Transparency Platform [38]. Podaci obuhvaćaju satne podatke u potrošnji električne energije u Hrvatskoj kao i predviđenu potrošnju za dan unaprijed.

U ovom istraživanju prošli podaci o opterećenju uključeni su u modele za predviđanje, koristeći povijesne podatke do dva tjedna unatrag (336 sati). Ovaj pristup hvata i kratkoročne i dugoročne trendove u potrošnji električne energije, omogućujući modelima prepoznavanje obrazaca koji se mogu ponavljati tijekom dana ili tjedna. Korištenjem širokog raspona prošlih vrijednosti opterećenja, model može uzeti u obzir cikličke promjene u potražnji, poput dnevnih vrhunaca i tjednih obrazaca, koji su ključni za STLF.

Za potrebe analize korišteni su prognostički podaci iz globalnog meteorološkog modela, s vremenskim horizontima predviđanja u rasponu od 0 do 72 sata, u koracima od 6 sati (tj. 0, 6, 12, 18, 24, 30, 36, 42, 48, 54, 60, 66 i 72 sata), počevši od ponoći.

Stvarne temperature iz meteoroloških stanica u dva grada dopunjavale su prognozirane podatke. Ova mjerenja dobivena su s web stranice Weather Underground [142], koja pruža povijesne podatke između ostalog i za dva najveća grada u Hrvatskoj: Zagreb i Split. Ovi gradovi su posebno odabrani za naše istraživanje, pružajući osnovu za validaciju točnosti predviđanja modela.

S obzirom na povremenu dostupnost drugih meteoroloških podataka, studija se prvenstveno usredotočila na podatke o temperaturi kako bi se održao značajan skup testova. Ovaj pristup

osigurao je integritet analize bez ugrožavanja cjelovitosti skupa podataka zbog nedostajućih vrijednosti.

Zaključno, integracija širokog spektra vrsta podataka, u kombinaciji s temeljitom pripremom podataka i inženjeringom značajki, ključna je za razvoj modela dubokog učenja koji može točno i pouzdano predviđati opterećenje električne energije. Ovaj pristup osigurava da model ne samo da bilježi povijesne i trenutne trendove u potrošnji električne energije, već se također prilagođava novim obrascima, čime se poboljšava točnost i pouzdanost predviđanja opterećenja.

5.1.3.1. Sezonalnost, praznici i kalendarske značajke

Točno predviđanje opterećenja električne energije uvelike se oslanja na različite vrste vremenskih podataka koji odražavaju cikličke obrasce, dnevne rutine i sezonske varijacije. Uključivanjem ovih podataka u analizu, modeli mogu bolje uzeti u obzir čimbenike koji utječu na potražnju za energijom te poboljšati točnost predviđanja. Ovo poglavlje naglašava ključnu ulogu kalendarskih informacija i periodičnih obrazaca u oblikovanju potrošnje električne energije, osobito kroz prizmu praznika, radnih dana i sezonskih ciklusa.

U skupu podataka uključene su kalendarske informacije koje kategoriziraju dane prema njihovom značaju. Praznici su podijeljeni u tri zasebne kategorije: veliki praznici (poput Nove godine), dani koji prethode određenim praznicima (npr. Badnjak i Stara godina) i ostali neradni dani. Osim toga, radni dani su kodirani broječno od 1 do 7, dok su mjeseci predstavljeni brojevima od 1 do 12. Ova kodiranja su u skladu sa standardnim kalendarskim notacijama i pomažu u hvatanju ponavljajućih obrazaca u potrošnji električne energije.

Za određene modele, važno je uhvatiti sezonsku varijabilnost pomoću trigonometrijskih funkcija, poput sinusa i kosinusa, kako bi se matematički modelirala sezonalnost. Takva parametrizacija omogućuje kontinuiranu reprezentaciju cikličkih varijabli bez diskontinuiteta na granicama perioda (npr. između prosinca i siječnja), čime se poboljšava numerička stabilnost modela. Opći oblik sezonske komponente može se izraziti kao kombinacija sinusnih i kosinusnih funkcija:

$$\text{Sezonska komponenta} = A \cdot \sin\left(\frac{2\pi t}{T}\right) + B \cdot \cos\left(\frac{2\pi t}{T}\right) \quad (5.1)$$

U ovoj formuli, t predstavlja vremenski indeks (npr. sat, dan ili mjesec), dok T označava

razdoblje sezonalnosti (npr. 24 za dnevnu sezonalnost ili 365 za godišnju sezonalnost). Koeficijenti A i B predstavljaju amplitude sinusne i kosinusne komponente. Ovaj pristup omogućuje modeliranje oscilirajuće prirode sezonskih podataka.


U vremenskoj analizi podataka o opterećenju za Hrvatsku za razdoblje 2006.–2022., prikazanoj na Slici 5.1, možemo uočiti nekoliko ključnih periodičnih komponenti koje odražavaju cikličku prirodu potrošnje električne energije:

- Godišnje varijacije: Najizraženiji vrh odgovara godišnjim ciklusima, koji su vjerojatno potaknuti sezonskim fluktuacijama u potražnji za električnom energijom. To uključuje veću potrošnju tijekom ljetnih mjeseci za hlađenje i zimi za grijanje.
- Polugodišnji obrasci: Drugi značajan obrazac pokazuje polugodišnje cikluse, sugerirajući ponavljajuće promjene u potražnji otprilike svakih šest mjeseci, što je potencijalno povezano s promjenama klimatskih uvjeta ili industrijskim operacijama tijekom godine.
- Tjedni ciklusi: Analiza ističe jasan tjedni ciklus, gdje potražnja za električnom energijom predvidljivo varira između radnih dana i vikenda, s vrhuncima potrošnje tijekom radnog tjedna i smanjenom potražnjom tijekom vikenda.
- Dnevni ciklusi : Očigledni su dnevni ciklusi, koji odražavaju tipične dnevne fluktuacije u potrošnji električne energije. Potražnja raste tijekom dana, korelirajući s kućnim, komercijalnim i industrijskim aktivnostima, dok noću opada.
- Poludnevne varijacije (12 sati): Podaci također otkrivaju poludnevne varijacije, koje vjerojatno odgovaraju jutarnjim i večernjim vrhuncima u potrošnji električne energije, potaknuti kućnim rutinama poput pripreme obroka, grijanja i rasvjete.

Ove uočene periodičnosti naglašavaju snažan utjecaj vremenskih čimbenika na potražnju za električnom energijom, što ističe važnost uključivanja takvih ciklusa u modele predviđanja za poboljšanje točnosti predviđanja.

5.1.3.2. Vremenska pokrivenost i eksperimentalna podjela skupa podataka

Ovaj pododjeljak opisuje konkretnu instancu strategije vremenske podjele (Poglavlje 4.5.1.) primijenjenu u eksperimentima kratkoročnog predviđanja opterećenja (STLF). Korišteni skup podataka obuhvaća satne vrijednosti električnog opterećenja, pripadne meteorološke ulaze iz lokalnih mjerenja te prognoze iz globalnog prognostičkog modela, pri čemu je vremensko pokrivanje definirano razdobljem od 2006. do 2022. godine. Tako dugačka vremenska serija



Slika 5.1: Frekvencijska analiza podataka o opterećenju za Hrvatsku (2006-2022)

omogućuje (i) realističnu procjenu generalizacije na potpuno neviđenom razdoblju te (ii) dodatnu analizu utjecaja duljine povijesnog prozora treniranja na stabilnost i točnost modela.


Uočene su određene praznine u seriji opterećenja, osobito tijekom studenog i prosinca 2011. godine. Nadalje, stvarni meteorološki podaci s meteoroloških postaja sadrže povremene nedostatke, izraženije u ranijem dijelu razdoblja (osobito prije 2012.). Među raspoloživim meteorološkim varijablama, temperatura pokazuje najveću pouzdanost i najpotpuniju pokrivenost, dok ostale varijable (npr. naoblaka, brzina vjetra) često izostaju. Uključivanje takvih varijabli zahtijevalo bi agresivno filtriranje opažanja ili imputaciju na velikom udjelu uzoraka, što bi znatno reduciralo efektivnu veličinu skupa za treniranje i potencijalno uvelo dodatnu pristranost. Stoga se u ovoj studiji, radi očuvanja robusnosti eksperimentalnog dizajna i replikabilnosti, koriste samo temperaturni podaci iz lokalnih mjerenja, dok se istovremeno zadržava potpuni skup meteoroloških prediktora iz globalnog prognostičkog modela, koji je dostupan konzistentno kroz promatrano razdoblje.

U skladu s principom vremenski izdvojenog testiranja, razdoblje 2006.–2021. koristi se kao razvojni skup (treniranje i validacija), dok je cijela 2022. godina rezervirana isključivo za testiranje. Takva podjela omogućuje procjenu performansi na doista neviđenim podacima te realističnu evaluaciju sposobnosti modela da generalizira na buduće uvjete rada sustava. Unutar

razvojnog razdoblja primjenjuje se podjela 80/20 za treniranje i validaciju, pri čemu validacijski dio predstavlja najrecentniji segment razvojnog skupa.

Kako bi se dodatno ispitao utjecaj veličine i vremenskog pokrivanja skupa za treniranje na preciznost i robusnost modela, definirano je više alternativnih prozora razvojnog razdoblja. Pri tome se zadržava ista testna godina (2022.), dok se treniranje/validacija izvodi na različito dugim povijesnim intervalima:

- **Sveobuhvatno razdoblje (2006.–2021.):** koristi puni dostupni razvojni skup kako bi se procijenila učinkovitost modela uz maksimalnu količinu povijesne informacije.
- **Srednjoročna razdoblja:** razdoblja 2012.–2021., 2014.–2021. i 2016.–2021. omogućuju analizu performansi pri postupnom smanjenju duljine povijesnog konteksta, uz zadržavanje više sezonskih ciklusa.
- **Kratkoročno razdoblje (2018.–2021.):** fokusira se na najrecentnije podatke te ispituje koliko je ograničen povijesni kontekst dovoljan za stabilno treniranje i generalizaciju.



Slika 5.2: Vremensko pokrivanje skupova za treniranje (pune trake, razdoblje 2006.–2021.) i testiranje (isprekidane trake, 2022.). Evaluirano je pet prozora za treniranje: sveobuhvatni skup (2006.–2021.), tri srednjoročna razdoblja (2012.–2021., 2014.–2021., 2016.–2021.) te kratkoročni skup (2018.–2021.). Svi modeli koriste 80/20 podjelu za treniranje i validaciju unutar razvojnog razdoblja, dok se testiranje provodi isključivo na podacima iz 2022.

Definirana varijabilnost razvojnih prozora omogućuje analizu odnosa između količine dostupnih podataka i potrebne arhitekturne složenosti dubokih neuronskih mreža u STLF zadatku. Budući da duboke arhitekture s većim brojem slojeva i parametara zahtijevaju značajnu količinu podataka za stabilno učenje i izbjegavanje prenaučenosti, različite duljine povijesnog konteksta omogućuju procjenu minimalne količine podataka potrebne za učinkovito treniranje modela određene dubine.

Na taj se način eksperimentalno ispituje postoji li interakcija između veličine razvojnog skupa

i optimalne dubine mreže, odnosno može li plića arhitektura pružiti usporedive performanse u scenarijima s ograničenim povijesnim podacima, dok dublje arhitekture ostvaruju prednost tek pri većem vremenskom pokrivanju skupa za treniranje. Time se dobiva empirijski uvid u kompromis između kapaciteta modela i raspoložive količine podataka, uz zadržavanje strogo vremenski izdvojenog testiranja na potpuno neviđenoj godini.

5.1.3.3. Integracija globalnih vremenskih prognoza

U cilju modeliranja utjecaja budućih meteoroloških uvjeta na električno opterećenje, u eksperimentalni okvir integrirani su podaci globalnih numeričkih vremenskih prognoza dostupni putem TIGGE baze podataka (*The International Grand Global Ensemble*) [40]. TIGGE objedinjuje ansamblske prognoze više globalnih centara za numeričku prognozu vremena (*Numerical Weather Prediction, NWP*) te osigurava konzistentnu vremensku i prostornu pokrivenost od listopada 2006. godine nadalje. Takva standardizirana baza omogućuje korištenje prognostičkih meteoroloških ulaza u režimu koji je usklađen s realnim operativnim uvjetima kratkoročnog predviđanja.

U okviru ovog istraživanja korišteni su prognostički podaci za sljedeće meteorološke parametre:

- 2-metarska temperatura zraka ($2t$),
- 2-metarska temperatura rosišta ($2d$),
- srednji tlak na razini mora (msl),
- ukupna naoblaka (tcc),
- ukupne oborine (tp),
- 10-metarska komponenta U vjetra ($10u$),
- 10-metarska komponenta V vjetra ($10v$).

Odabir navedenih varijabli temelji se na njihovoj fizikalnoj povezanosti s potrošnjom električne energije (temperaturni i vlažnostni uvjeti, atmosferski tlak, oborine i vjetar) te na konzistentnoj dostupnosti podataka kroz promatrano razdoblje. Svi meteorološki ulazi vremenski su poravnati s ciljnim horizontom predviđanja te integrirani u model u skladu s definiranim eksperimentalnim protokolom vremenske podjele.

Geografski obuhvat i odabir koordinata podataka.

Analiza se fokusira na dva najveća urbana središta u Hrvatskoj – Zagreb i Split – koja

reprezentiraju dominantne klimatske i potrošačke režime kontinentalnog i priobalnog područja.

Meteorološki podaci iz globalnog prognostičkog modela preuzeti su u GRIB (*Gridded Binary*) formatu, pri čemu su za svaki grad odabrane najbliže raspoložive točke prostorne mreže modela kako bi se osigurala reprezentativnost lokalnih atmosferskih uvjeta. S obzirom na diskretnu prostornu rezoluciju modela, korištene su sljedeće geografske koordinate mrežnih točaka:

- **Zagreb:** približno (46°N, 16°E) i (45.5°N, 16°E)
- **Split:** približno (43.5°N, 16.5°E) i (44°N, 15.5°E)

Odabir više susjednih mrežnih točaka omogućuje ublažavanje diskretizacijskih efekata prostorne rezolucije modela te smanjuje osjetljivost prediktora na lokalne anomalije pojedine ćelije mreže.

5.1.4. Specifična predobrada i kontrola kvalitete STLF skupa podataka

U skladu s općim protokolom kontrole kvalitete i predobrade definiranim u Poglavlju 4 (Odjeljak 4.2.), u ovoj studiji slučaja primijenjeni su konkretni postupci čišćenja, provjere konzistentnosti i transformacije podataka prilagođeni STLF skupu podataka. S obzirom na duljinu analiziranog operativnog skupa podataka od 17 godina, postupci su provedeni uz dosljednu primjenu protokola očuvanja vremenskog integriteta i izolacije skupova definiranog u Poglavlju 4, uz očuvanje fizički smislenih varijacija u vremenskim nizovima.

5.1.4.1. Nedostajuće vrijednosti i provjera konzistentnosti podataka

Satni podaci o potrošnji električne energije preuzeti s platforme ENTSO-E te NWP prognostičke varijable temeljene na TIGGE arhivi provjereni su s aspekta potpunosti i vremenske usklađenosti te u promatranom razdoblju čine efektivno kontinuiran vremenski niz. Suprotno tome, u lokalnim mjerenjima temperature zraka (Zagreb i Split) povremeno su prisutni nedostajući zapisi. Takvi uzorci uklonjeni su iz razvojnog skupa bez primjene imputacijskih tehnika, čime se osigurava da modeli uče isključivo na empirijski verificiranim i potpunim opažanjima. U neovisnom testnom skupu za 2022. godinu nisu korištene sintetički imputirane vrijednosti, kako bi evaluacija odražavala realistične operativne uvjete primjene.

5.1.4.2. Strukturne promjene u potrošnji i vremenski integritet podataka

Dugoročne promjene u potrošnji električne energije, uzrokovane gospodarskim kretanjima, mjerama energetske učinkovitosti te izvanrednim okolnostima poput razdoblja pandemije bolesti COVID-19, zadržane su eksplicitno u podacima. Modeli su trenirani isključivo na kronološki uređenim povijesnim uzorcima, dok je evaluacija provedena na prethodno neviđenoj testnoj godini 2022., bez ikakvog povratnog uvida iz testnog u trenirajući skup. Svi postupci resampliranja, konstrukcije značajki i integracije TIGGE prognostičkih podataka strogo poštuju vremensku os kako bi se spriječilo propuštanje informacija.

5.1.4.3. Skaliranje i standardizacija ulaznih značajki

S obzirom na različite numeričke zahtjeve pojedinih modelskih arhitektura, primijenjene su dvije komplementarne strategije transformacije podataka.

Za duboke neuronske arhitekture (DNN, hibridni DNN-SVR, LSTM Seq2Seq + Attention te Transformer-temeljene modele) ulazne kontinuirane značajke standardizirane su primjenom linearne z-score transformacije

$$x' = \frac{x - \mu_{\text{train}}}{\sigma_{\text{train}}},$$

pri čemu su parametri μ_{train} i σ_{train} procijenjeni isključivo na trenirajućem dijelu razvojnog skupa podataka. Dobiveni parametri zatim su nepromijenjeni primijenjeni na validacijski i testni skup.

Ciljna varijabla u DNN-temeljenim modelima dodatno je skalirana min–max transformacijom u interval $[0,1]$, pri čemu su granice intervala određene isključivo na trenirajućem skupu.

U SSA-SVR konfiguracijama primijenjeno je min–max skaliranje ulaznih značajki u interval $[-1, 1]$, također uz procjenu parametara isključivo na trenirajućem dijelu razvojnog skupa.

U svim slučajevima transformacije su definirane i parametrizirane bez korištenja informacija iz validacijskog ili testnog razdoblja, čime je očuvana vremenska izolacija i spriječeno propuštanje informacija.

5.1.5. Konstrukcija ulaznog prostora i satno uvjetovani odabir značajki za STLF eksperimente

U ovom poglavlju specificira se konkretna instanca konstrukcije ulaznog prostora i odabira značajki primijenjena u eksperimentima kratkoročnog predviđanja potrošnje električne energije (STLF). Postupak je proveden u skladu s općim metodološkim okvirom definiranim u Poglavlju 4, dok se ovdje navode točne eksperimentalne postavke, struktura ulaznih vektora i parametri odabira značajki korišteni za STLF skup podataka.

Prognoza se izdaje u trenutku $t = 08:00$, pri čemu se predviđaju satne vrijednosti potrošnje električne energije za sljedeći dan u rasponu od 00:00 do 23:00. To odgovara skupini prognoznih horizonata

$$\mathcal{H} = \{16, 17, \dots, 39\},$$

izraženih u satima unaprijed u odnosu na vrijeme izdavanja prognoze. U satno-specijaliziranoj konfiguraciji, za svaki ciljni sat $h \in \mathcal{H}$ trenira se zaseban prognostički model, pri čemu se konstrukcija ulaznog vektora i odabir značajki provode neovisno za svaki sat.

5.1.5.1. Ulazne značajke za satno uvjetovane regresijske modele

Za svaki ciljni sat $h \in \mathcal{H}$ formira se vremenski usklađen ulazni vektor konkatencijom sljedećih skupina značajki, pri čemu su sve informacije dostupne u trenutku izdavanja prognoze t :

- **Kratkoročna povijest (fiksni vremenski prozor).** Uključuje se horizontno neovisan prozor nedavnih opažanja potrošnje električne energije i izmjerenih temperatura zraka:

$$K_{nt} = \{0, 1, \dots, 32\}.$$

U ulazni vektor uključuju se vrijednosti $\{y_{t-\ell} : \ell \in K_{nt}\}$ te $\{T_{t-\ell}^{ZG}, T_{t-\ell}^{SP} : \ell \in K_{nt}\}$, gdje T^{ZG} i T^{SP} označavaju opažene temperature za Zagreb i Split.

- **Satno uvjetovana tjedna i gotovo-tjedna sidra.** Kako bi se očuvala periodična struktura potrošnje relativno u odnosu na ciljni sat, koriste se sidra definirana izrazom

$$\text{anchor}(X, k, h) = X_{t-(k-h)}.$$

Za potrošnju električne energije koriste se pomaci

$$k \in \{72, 96, 120, 144, 168, 336\},$$

dok se za temperaturu zraka (Zagreb i Split) koriste pomaci

$$k \in \{72, 96, 120, 144, 168\}.$$

Za sve ciljne sate $h \in \mathcal{H}$ odgovarajući vremenski indeksi odnose se na trenutke manje ili jednake t , te su stoga poznati u trenutku izvođenja prognoze.

- **Globalne numeričke vremenske prognoze (TIGGE NWP blok).** Uključuju se prognostičke meteorološke varijable iz TIGGE arhive za Zagreb i Split, pri čemu se koriste dvije susjedne mrežne točke po gradu, sedam meteoroloških varijabli (2t, 2d, msl, tcc, tp, 10u, 10v) te 13 prognostičkih koraka u rasponu od 0 do 72 sata u koracima od 6 sati. Time se dobiva ukupno

$$2 \times 2 \times 7 \times 13 = 364$$

prognostičke značajke po vremenskom zapisu.

- **Kalendarske značajke.** Uključuju se tri cjelobrojno kodirane varijable: tip blagdana (*holiday_type*), dan u tjednu (*weekday*) i mjesec u godini (*month*).

Svi vremenski trenuci za koje nedostaje barem jedna obvezna temperaturna vrijednost (Zagreb ili Split) isključeni su iz postupaka treniranja i validacije, u skladu s postupcima kontrole kvalitete opisanim u Odjeljku 5.1.4.1..

5.1.5.2. Dimenzionalnost kandidatskog ulaznog prostora prije primjene odabira značajki

Ukupan broj vremenski pomaknutih značajki po satu iznosi

$$d_{\text{lags}} = \underbrace{33}_{\text{kratkoročna potrošnja}} + \underbrace{6}_{\text{sidra potrošnje}} + \underbrace{2 \times 33}_{\text{kratkoročne temperature}} + \underbrace{2 \times 5}_{\text{sidra temperature}} = 115.$$

Dodavanjem TIGGE prognostičkog bloka i kalendarskih varijabli dobiva se ukupna dimenzi-

onalnost kandidatskog ulaznog prostora

$$d_{\text{FS}} = \underbrace{364}_{\text{TIGGE}} + \underbrace{115}_{\text{zaostaci}} + \underbrace{3}_{\text{kalendar}} = 482,$$

koja je konstantna za svaki ciljni sat $h \in \mathcal{H}$. Sažeti pregled kategorija ulaznih značajki prije primjene odabira značajki dan je u Tablici 5.1.

Tablica 5.1: Sažetak kategorija ulaznih značajki prije satno-specijaliziranog odabira značajki temeljenog na algoritmu XGBoost

Kategorija značajki	Broj	Opis
TIGGE NWP prognostičke varijable	364	2 grada (Zagreb, Split) $\times$ 2 susjedne mrežne točke $\times$ 7 meteoroloških varijabli (2t, 2d, msl, tcc, tp, 10u, 10v) $\times$ 13 prognostičkih koraka (0–72 h)
Zaostaci potrošnje električne energije	39	33 kratkoročna vremenska zaostatka + 6 satno-uvjetovanih tjednih i gotovo-tjednih sidara
Zaostaci temperature zraka	76	2 grada $\times$ (33 kratkoročna temperaturna zaostatka + 5 satno-uvjetovanih temperaturnih sidara)
Kalendarske značajke	3	Tip blagdana, dan u tjednu, mjesec u godini
Ukupno	482	Ukupan broj kandidatskih ulaznih značajki prije primjene odabira značajki

5.1.5.3. Satno specijalizirani odabir značajki

Za svaki ciljni sat h trenira se XGBoost regresijski model na razvojnom skupu podataka, uz kronološku podjelu 80% za treniranje i 20% za validaciju. Značajke čija relativna važnost, mjerena *gain*-metrikom unutar XGBoost modela, padne ispod praga 0,002 uklanjaju se. iz daljnje analize. Ovaj satno specijalizirani postupak omogućuje smanjenje dimenzionalnosti i multikolinearnosti ulaznog prostora, uz očuvanje najinformativnijih satno ovisnih potrošnih, meteoroloških i kalendarskih signala.

Dobiveni skup značajki u pravilu obuhvaća 30–40 varijabli po ciljnome satu. DNN i hibridni DNN-SVR modeli koriste puni skup tako odabranih značajki, dok Transformer-temeljeni modeli i LSTM Seq2Seq varijante primjenjuju odabir značajki isključivo na prognostički meteorološki

blok, pri čemu se povijesna potrošnja, opažene temperature i periodičke kalendarske varijable uključuju bez filtriranja, u skladu s njihovom višestrukom strujnom strukturom ulaza.

5.1.6. Jedinstveni satno uvjetovani DNN-SVR model kao alternativna eksperimentalna konfiguracija

Uz referentnu strategiju s 24 odvojena satno specijalizirana modela, razmatra se i alternativna konfiguracija temeljena na *jedinstvenom satno uvjetovanom DNN-SVR modelu*. Uvođenje ove konfiguracije proizlazi iz metodoloških razmatranja danih u Odjeljku 4.3.3., gdje je analiziran kompromis između modelne složenosti, računalnog troška i prediktivne učinkovitosti u odnosu na satno specijalizirani pristup.

U ovoj varijanti koristi se jedna zajednička arhitektura koja predviđa jedan ciljni sat u danu, pri čemu se isti model ponovno koristi za sve vremenske horizonte. Prognoza se, kao i u svim ostalim eksperimentima, izdaje u trenutku $t = 08:00$, dok se ciljane vrijednosti odnose na sate sljedećeg dana od 00:00 do 23:00, odnosno na horizonte

$$\mathcal{H} = \{16, 17, \dots, 39\},$$

izražene u satima unaprijed u odnosu na vrijeme t .

Postupak konstrukcije ulaznih značajki i odabira značajki temeljen na algoritmu gradijentnog pojačanja identičan je onome opisanom u Odjeljku 5.1.5., pri čemu se u ovoj konfiguraciji primjenjuje nad objedinjenim skupom podataka svih ciljanih sati.

5.1.6.1. Konstrukcija ulaznog vektora i satno uvjetovanje

Za svaki zahtijevani vremenski horizont $h \in \mathcal{H}$ konstruira se vremenski usklađen ulazni vektor sastavljen od više tematski razdvojenih blokova značajki. Sve uključene informacije dostupne su u trenutku izdavanja prognoze t , čime se osigurava operativna konzistentnost modela.

Definicije varijabli i postupci predobrade identični su onima navedenima u Odjeljku 5.1.5.; u nastavku se navode samo specifičnosti jedinstvenog satno uvjetovanog postava. Ulazni vektor formira se konkatencijom sljedećih skupina značajki:

- **Kratkoročna povijest (konstantni vremenski prozor).**

Radi osiguravanja stabilnog konteksta nedavnih opažanja, bez interferencije sa satno uvjetovanim sidrima, koristi se fiksni vremenski prozor

$$K_{nt} = \{0, 1, \dots, 8\}.$$

U ovaj blok uključuju se povijesne vrijednosti potrošnje električne energije $\{y_{t-\ell} : \ell \in K_{nt}\}$ te opažene temperature zraka na visini od 2 m za Zagreb i Split, $\{T_{t-\ell}^{ZG}, T_{t-\ell}^{SP} : \ell \in K_{nt}\}$.

– **Satno uvjetovana tjedna i gotovo-tjedna sidra.**

Kako bi se očuvala periodična struktura potrošnje relativno u odnosu na ciljni sat, primjenjuje se sidrena transformacija definirana izrazom

$$\text{anchor}(X, k, h) = X_{t-(k-h)}.$$

Za potrošnju električne energije koriste se pomaci

$$k \in \{48, 72, 96, 120, 144, 168, 336\},$$

dok se za temperaturu zraka (Zagreb i Split) koriste pomaci

$$k \in \{48, 72, 96, 120, 144, 168\}.$$

Za sve ciljne sate $h \in \{16, \dots, 39\}$ odgovarajući vremenski indeksi odnose se na trenutke manje ili jednake t , te su stoga poznati u trenutku izvođenja prognoze.

– **Globalne numeričke vremenske prognoze (TIGGE NWP blok).**

U ulazni vektor uključuje se isti skup globalnih numeričkih meteoroloških prognoza definiran u Odjeljku 5.1.5.. Blok obuhvaća prognostičke varijable iz TIGGE arhive za Zagreb i Split, čime se dobiva ukupno 364 prognostičke značajke po vremenskom zapisu.

– **Kalendarske značajke i oznaka ciljnog sata.**

Uz tri standardne kalendarske varijable (tip blagdana, dan u tjednu i mjesec u godini) koristi se i skalarna varijabla $target_hour = h$, kojom se jedinstveni model eksplicitno uvjetuje na ciljni sat predviđanja.

5.1.6.2. Odabir značajki i postupak skaliranja

Za razliku od satno specijaliziranog odabira značajki u konfiguraciji s 24 odvojena modela, u ovoj se varijanti odabir značajki provodi *jednokratno* nad objedinjenim skupom ulaznih podataka za sve ciljne sate $h \in \mathcal{H}$. Time se dobiva jedinstveni skup ulaznih značajki koji se koristi za sve horizonte predviđanja.

Parametri skaliranja određuju se isključivo na trenirajućem dijelu razvojnog skupa te se bez izmjena primjenjuju na validacijske i neovisne testne podatke, u skladu s protokolom opisanom u Poglavlju 4.

5.1.6.3. Treniranje modela i postupak izvođenja prognoze

Jedinstveni satno uvjetovani model slijedi isti dvostupanjski postupak kao i referentni hibridni DNN-SVR pristupi. Duboka neuronska mreža služi kao enkoder koji transformira ulazne značajke filtrirane postupkom odabira u kompaktnu latentnu reprezentaciju, dok SVR regresijska faza generira završnu prognozu.

U fazi izvođenja, za predviđanje ciljnog sata h formira se odgovarajući satno uvjetovani ulazni vektor (uključujući varijablu *target_hour*), koji se prosljeđuje kroz zamrznuti DNN enkoder te SVR regresijsku fazu, čime se dobiva procjena $\hat{y}_{t+h}$.

Dobiveni rezultati ove konfiguracije analiziraju se i uspoređuju s referentnom strategijom od 24 satno specijalizirana modela u narednim odjeljcima.

5.2. Eksperimentalna evaluacija i analiza performansi SSA-SVR modela

5.2.1. ISO New England: Usporedba SSA-SVR, ANN i SIWNN

Kako bi se objektivno procijenila učinkovitost predloženog SSA-SVR modela u odnosu na etabrirane metode, provedena je usporedba s dvama pristupima iz literature [23].

Prvi je standardna metoda neuronskih mreža (NN), u kojoj se koristi jedna mreža s ulazima: indeks dana u tjednu, prognostički meteorološki podaci te najnovije dostupno opterećenje (tipično od prethodnog dana, D-2). Ovakav pristup tretira niskofrekventne i visokofrekventne značajke

opterećenja zajedno, bez razlikovanja, što otežava precizno hvatanje naglih promjena. Dodatno, zbog ograničene korelacije između dana D-2 i prognoziranog dana, ulazni podaci imaju slabiju prediktivnu moć, što rezultira smanjenom točnošću prognoze.

Drugi, napredniji pristup je SIWNN (*Similar Day-Based Wavelet Neural Network*). Njegova je osnovna ideja odabrati „sličan dan” temeljem vremenskih uvjeta i indeksa dana u tjednu, a potom primijeniti dekompoziciju pomoću valne funkcije Daubechies 4 (Db4) kojom se opterećenje razdvaja na niskofrekventnu i visokofrekventnu komponentu. Za svaku komponentu trenira se zasebna višeslojna perceptronska mreža, a prognoze se zatim kombiniraju u konačnu predikciju za sljedeći dan. Kao dodatni ulaz koristi se i tzv. dopunsko opterećenje (eng. *supplemental load*) predviđeno opterećenje u 24. satu dana D (dobiveno prognozom od prethodnog dana), čime se bolje hvata početno stanje dana D+1.

Za razliku od standardnog NN pristupa, SIWNN koristi znatno širi skup meteoroloških varijabli: osjećajnu temperaturu zimi (eng. *wind-chill temperature*), indeks sparine ljeti (eng. *humidex*), brzinu vjetra, naoblaku i oborine. U ovom modelu visokofrekventne značajke potrošnje nisu tretirane kao šum, nego se eksplicitno modeliraju zajedno s dodatnim meteorološkim ulazima i visokofrekventnom komponentom sličnog dana, što je na testovima s ISO New England podacima (2006) dovelo do značajnog povećanja točnosti u odnosu na standardni NN pristup.

Objektive metode korištene su kao referentni okvir za usporedbu s predloženim SSA-SVR modelom, razvijenim u sklopu izvornog istraživanja autora ovog rada, čiji su glavni rezultati prethodno objavljeni u časopisu [20]. Testiranja provedena na ISO New England skupu za 2006. godinu pokazala su da SIWNN značajno nadmašuje standardni NN pristup, dok je SSA-SVR ostvario dodatno poboljšanje u odnosu na oba referentna modela.

Tablica 5.2 prikazuje rezultate za sve tri metode na testnom skupu ISO New England za 2006. godinu, pri čemu su korišteni stvarno izmjereni meteorološki podaci. Nasuprot tome, Tablica 5.3 prikazuje rezultate u scenariju s prognoziranim vremenskim podacima, što predstavlja realističniji okvir za operativne primjene u elektroenergetskim sustavima.

Za procjenu točnosti korištena je srednja apsolutna postotna pogreška (MAPE), a usporedba je provedena na cjelovitom skupu od 8760 satnih opažanja tijekom jedne kalendarske godine.

Rezultati pokazuju da SSA-SVR model ostvaruje niže godišnje MAPE vrijednosti u odnosu na referentne metode u oba razmatrana scenarija. U uvjetima korištenja prognoziranih meteoroloških podataka relativno smanjenje pogreške iznosi približno 20%, dok je u slučaju stvarno izmjerenih

temperatura prednost izraženija i doseže 23,4%.

Tablica 5.2: Usporedba mjesečnih MAPE vrijednosti za modele ANN, SIWNN i SSA-SVR na ISO New England skupu podataka za 2006. godinu, korištene stvarne temperature u predikciji

Mjesec	ANN*	SIWNN*	SSA-SVR
Siječanj	2.01	1.60	1.31
Veljača	1.50	1.43	1.12
Ožujak	1.55	1.47	0.93
Travanj	1.51	1.26	1.34
Svibanj	1.69	1.61	1.10
Lipanj	2.30	1.79	1.55
Srpanj	3.72	2.70	1.86
Kolovoz	3.33	2.62	1.50
Rujan	1.60	1.48	1.15
Listopad	1.52	1.38	1.20
Studeni	1.73	1.39	1.09
Prosinac	1.91	1.75	1.61
Prosjeak	2.03	1.71	1.31

* Rezultati za ANN i SIWNN modele preuzeti su iz literature [23].

Analiza mjesečne razdiobe pogreške (Tablica 5.2) pokazuje da SSA-SVR model postiže niže MAPE vrijednosti u svim sezonskim režimima. Prosječna godišnja MAPE iznosi 1,31%, u usporedbi s 1,71% kod SIWNN i 2,03% kod ANN modela. Posebno izražena razlika uočava se tijekom ljetnih mjeseci (srpanj i kolovoz), kada je opterećenje sustava snažno uvjetovano nelinearnim utjecajem temperature i povećanom uporabom klimatizacijskih sustava. Takva sezonska stabilnost upućuje na veću sposobnost modela da aproksimira kompleksne i vremenski promjenjive obrasce potrošnje.

Važno je naglasiti da su u ovoj analizi korištene stvarno izmjerene temperature, dok su u operativnim uvjetima dostupne isključivo prognostičke vrijednosti. Stoga rezultati predstavljaju gornju granicu ostvarive točnosti u idealiziranom scenariju te služe primarno za metodološku usporedbu modela.

Analizom rezultata prikazanih u Tablici 5.3 vidljivo je da SSA-SVR zadržava najniže MAPE

Tablica 5.3: Usporedba mjesečnih MAPE vrijednosti za modele ANN, SIWNN i SSA-SVR na ISO New England skupu podataka za 2006. godinu, korištene prognozirane temperature

Mjesec	ANN*	SIWNN*	SSA-SVR
Siječanj	2.12	1.65	1.53
Veljača	1.66	1.48	1.32
Ožujak	1.66	1.52	1.13
Travanj	1.59	1.32	1.37
Svibanj	1.76	1.66	1.12
Lipanj	2.42	1.83	1.56
Srpanj	3.86	3.24	2.06
Kolovoz	3.48	2.67	1.86
Rujan	1.66	1.52	1.19
Listopad	1.58	1.43	1.32
Studen	1.83	1.44	1.14
Prosinac	2.03	1.81	1.68
Prosje	2.14	1.80	1.44


* Rezultati za ANN i SIWNN preuzeti su iz literature

vrijednosti i u scenariju korištenja prognoziranih meteoroloških varijabli. Ukupna godišnja MAPE iznosi 1,44%, u usporedbi s 1,80% za SIWNN i 2,14% za ANN model.

Sezonski obrazac pogreške ostaje konzistentan s prethodnom analizom: najveće relativne razlike prisutne su tijekom ljetnih mjeseci, dok su u zimskom razdoblju razlike umjerenije, ali i dalje sustavno u korist SSA-SVR modela. Takva stabilnost kroz različite meteorološke režime ukazuje na otpornost modela na degradaciju ulaznih podataka.

Važno je naglasiti da je za SSA-SVR model korišten je globalni numerički prognostički model ECMWF, pri čemu su meteorološke varijable preuzimane u homogenoj prostornoj rezoluciji i interpolirane na definirane koordinate. Nasuprot tome, SIWNN i ANN modeli iz literature oslanjaju se na lokalne operativne meteorološke prognoze, koje su prostorno preciznije, ali često nisu konzistentno dostupne u prošlosti. Time se dodatno ističe snaga SSA-SVR modela u kontekstu robusnosti i praktične primjenjivosti, jer omogućuje korištenje globalno dostupnih i vremenski konzistentnih podataka, što je ključno za dugoročno operativno predviđanje.

Dobiveni rezultati potvrđuju da kombinacija sezonski prilagođenog SVR pristupa, bogatog inženjeringa značajki i korištenja globalnih vremenskih prognoza daje superiorne rezultate čak i u uvjetima u kojima su ulazni podaci manje precizni, čime se značajno povećava robusnost modela u realnim uvjetima elektroenergetskog planiranja.



Slika 5.3: Mjesečne MAPE vrijednosti na skupu podataka ISO New England za 2006. godinu za modele ANN, SIWNN i SSA-SVR u režimu korištenja stvarnih (a.w.) i prognoziranih (f.w.) vremenskih podataka

Na slici 5.3 prikazana je mjesečna usporedba točnosti predviđanja modela ANN, SIWNN i SSA-SVR tijekom 2006. godine na skupu podataka ISO New England. Svi modeli testirani su u dva režima: s korištenjem stvarnih (a.w., eng. *actual weather*) i prognoziranih vremenskih podataka (f.w., eng. *forecasted weather*).

Iz prikaza je vidljivo da predloženi SSA-SVR model ostvaruje superiorne rezultate u svim mjesecima, pri čemu u najizazovnijim mjesecima za kratkoročno predviđanje, srpnju i kolovozu, MAPE vrijednost ne prelazi 2.1%. Ova otpornost modela posebno dolazi do izražaja u uvjetima visoke nelinearnosti potrošnje električne energije izazvane intenzivnom uporabom klimatizacijskih uređaja.

Rezultati pokazuju da sve tri metode bilježe određeno pogoršanje točnosti kada se umjesto izmjerenih koriste prognozirane meteorološke vrijednosti. Kod ANN modela MAPE se povećava s 2.03 na 2.14 (pogoršanje od oko 5.4%), kod SIWNN modela s 1.71 na 1.80 (pogoršanje od oko 5.3%), dok je kod SSA-SVR modela porast s 1.31 na 1.44 (oko 9.9%). Iako apsolutna vrijednost pogreške SSA-SVR modela ostaje najniža u oba scenarija, rezultati pokazuju da su svi modeli osjetljivi na degradaciju ulaznih podataka. Unatoč tome, SSA-SVR zadržava jasnu prednost u odnosu na alternativne pristupe, što potvrđuje njegovu veću praktičnu vrijednost za operativnu primjenu u elektroenergetskim sustavima.

Jedan od važnih faktora pri operativnoj primjeni predikcijskih modela jest vrijeme potrebno za njihovo treniranje i evaluaciju. Predloženi SSA-SVR model pokazao se vrlo učinkovit i s aspekta računalnih resursa. Najveće zabilježeno vrijeme treniranja za testne slučajeve prikazane u ovom radu iznosilo je najviše 40 minuta (treniranje na 1311 uzoraka za učenje i 60 uzoraka za validaciju, na kojima su optimizirani svi modelni parametri), a provedeno je na Linux radnoj stanici opremljenoj s dva procesora Intel Xeon X5675. Evaluacija već istreniranog modela za dvogodišnji testni period provedena je gotovo trenutno — trajala je manje od 3 sekunde.

5.2.2. North-American Utility: Usporedba SSA-SVR s neuronskim i hibridnim valićnim modelima

Skup podataka *North-American Utility* obuhvaća višegodišnja mjerenja opterećenja jednog sjevernoameričkog elektrodistributera te pripadajuće meteorološke podatke (temperaturu okoline). Dostupni su satni zapisi u razdoblju od siječnja 1988. do listopada 1992., a podaci su javno

dostupni preko arhiva Sveučilišta Washington* [98].

Za potrebe usporedbe izdvojen je testni period od dvije godine (13. 10. 1990. – 12. 10. 1992.), dok su raniji podaci korišteni za treniranje i validaciju modela. Modeli su trenirani na cjelokupnom povijesnom skupu do početka testnog razdoblja, pri čemu su hiperparametri i odabir ulaznih značajki podešavani na validacijskom podskupu od jedne godine neposredno prije testnog perioda.

U nastavku se prikazuju tri referentna modela iz literature – wavelet-ANN pristup [109], wavelet-NN-EA hibrid [4] te ESN model [33] – koji su testirani na istom skupu podataka. Njihovi rezultati uspoređuju se s predloženim SSA-SVR modelom, razvijenim u sklopu izvornog istraživanja autora ovog rada, čiji su glavni rezultati prethodno objavljeni u časopisu [20]. Pregled ostvarene točnosti dan je u Tablici 5.4.

Wavelet-ANN modeli (M1–M4) – U istraživanju Reis i da Silva [109] predložena su četiri modela za kratkoročnu prognozu opterećenja temeljena na višeslojnim perceptronskim mrežama (MLP), uz različite kombinacije predobrade podataka i multirezolucijske valične analize (MRA).

Model **M1** definiran je kao osnovni benchmark te koristi samo standardizirane i normalizirane varijable opterećenja i temperature. Model **M2** proširuje ovaj pristup dodavanjem diferenciranih varijabli opterećenja, čime se poboljšava hvatanje kratkoročnih varijacija. Model **M3** kombinira standardizaciju, diferenciranje i valičnu dekompoziciju (Daubechies 2, tri razine), ali dekomponira diferencirani signal opterećenja umjesto izvornog, jer taj pristup daje informativnije značajke. Konačno, **M4** predstavlja najsloženiji pristup u kojem se svaka komponenta dobivena valičnom dekompozicijom (aproksimacija i detalji) modelira zasebno, a prognoza se rekonstruira njihovim zbrajanjem. Pri tome, za najviši detaljni nivo (D_1), koji sadrži uglavnom šum, prognoza se temelji samo na srednjoj vrijednosti, bez primjene NN.

Rezultati pokazuju da modeli imaju različite prednosti ovisno o horizontu prognoze. Za jednosatnu prognozu najučinkovitiji je bio **M2**, s MAPE od približno 1.1% uz korištenje stvarnih temperatura, dok je uporaba simuliranih (prognoziranih) temperatura rezultirala tek neznatnim povećanjem pogreške; vrlo konkurentan bio je i **M3**. Za 24-satnu prognozu najbolji je bio **M4**, s MAPE od 2.64% u slučaju stvarnih temperatura, odnosno 2.82% kada su korištene simulirane temperature. Ovdje se jednodnevna prognoza ostvaruje rekurzivnim postupkom, pri čemu se

*Skup podataka je dostupan u arhivu Sveučilišta Washington i često se koristi kao standardni benchmark u literaturi za STLF modele [4, 33, 98, 109].

predviđena vrijednost za jedan sat koristi kao ulaz u prognozu sljedećeg sata.

Važno je naglasiti da u ovom radu praznici i anomalni dani nisu bili uključeni u rezultate prognoze, već se predlaže da se oni rješavaju posebnim metodama. Za potrebe usporedbe sa SSA-SVR pristupom, u daljnjoj analizi korišteni su upravo najbolji rezultati za svaki horizont predikcije (M2 za jednosatnu i M4 za 24-satnu prognozu). Za razliku od wavelet-ANN pristupa, SSA-SVR evaluacija obuhvaća sve dane u godini, uključujući i praznike, što dodatno naglašava njegovu robusnost i praktičnu primjenjivost.

Wavelet-NN-EA – U istraživanju Amjady i Keynia [4] predložen je hibridni model koji spaja valićnu transformaciju (WT), višeslojne perceptronske mreže (NN) i evolucijski algoritam (EA). Povijesni niz opterećenja prvo se razlaže pomoću diskretne valićne transformacije (Db4, tri razine dekompozicije), čime se dobivaju aproksimacijske i detaljne komponente različitih frekvencijskih pojaseva. Svaka od tih komponenti predviđa se zasebnom neuronskom mrežom, a konačna prognoza rekonstruira se primjenom inverzne WT.

Trening mreže odvija se u dvije faze: najprije Levenberg–Marquardt (LM) algoritmom, a zatim se dobivene težine dodatno optimiraju evolucijskim algoritmom koji provodi lokalnu pretragu oko rješenja LM-a. Na taj se način ublažava rizik zarobljavanja u lokalnim minimumima i poboljšava generalizacijska sposobnost mreže. Za odabir ulaznih varijabli korišten je dvostupanjski korelacijski postupak: prvo se zadržavaju samo varijable s dovoljno visokom korelacijom s ciljem (iznad praga $cor1$), a potom se eliminiraju one koje su međusobno prejakno povezane (iznad $cor2$), čime se osigurava i relevantnost i međusobna nezavisnost značajki. Optimalne vrijednosti parametara ($cor1$, $cor2$ i broj skrivenih neurona) određene su unakrsnom validacijom, pri čemu se kao validacijski skup koristi dan neposredno prije dana prognoze.

Model je testiran na više stvarnih elektroenergetskih sustava, uključujući *North-American Utility* podatkovni skup. Dobiveni rezultati pokazuju značajno poboljšanje u odnosu na ranije wavelet-ANN pristupe: postignut je prosječni MAPE od 0.99% za jednosatnu prognozu te 2.04% za dnevnu prognozu (24 sata unaprijed). U ovom slučaju jednodnevna prognoza ostvaruje se rekursivnim postupkom, pri čemu se predviđena vrijednost za jedan sat koristi kao ulaz u prognozu sljedećeg sata. Ovi rezultati predstavljali su novo mjerilo točnosti u vrijeme objave istraživanja, iako su ostvareni uz pretpostavku idealno poznatih meteoroloških podataka (korištene su izmjerene temperature, a ne prognozirane vrijednosti).

Autori naglašavaju da praznici i dani s atipičnim obrascima opterećenja zahtijevaju posebne

modele, pa nisu bili uključeni u glavne rezultate. Unatoč tome, Wavelet-NN-EA pristup pokazao je izvanrednu točnost i robusnost u kratkoročnom predviđanju opterećenja.

ESN model – Deihimi i Showkati [33] primijenili su Echo State Network (ESN) za kratkoročnu prognozu opterećenja (1h i 24h unaprijed). ESN pripada paradigmi rezervoarskih računala (eng. *reservoir computing*), pri čemu veliki nelinearni rezervoar stanja ostaje nepromijenjen tijekom učenja, dok se trenira samo linearni izlazni sloj. Ovakva struktura omogućuje brzo učenje uz visoku sposobnost modeliranja složenih dinamičkih odnosa.

U predloženom pristupu, za **1h prognozu** koristi se jedan ESN s dva ulaza: trenutno opterećenje i predviđena temperatura za idući sat. Za **24h prognozu** koristi se 24 odvojena ESN-a, po jedan za svaki sat u danu, pri čemu se svaki model trenira i testira isključivo na podacima toga sata kroz uzastopne dane. Svaki od tih modela ima tri ulaza: trenutno opterećenje za taj sat, predviđena temperatura 24h unaprijed, te indeks tipa dana koji razlikuje radne dane (0.75) od vikenda i praznika (0.25). Na taj način u istraživanje su eksplicitno uključeni i vikendi i praznici, što čini zadatak zahtjevnijim nego u ranijim radovima.

Parametri rezervoara (veličina i spektralni radijus) određeni su dvostupanjskim postupkom: inicijalnim pretraživanjem (pokušaja i pogreške) i naknadnom optimizacijom putem genetskog algoritma. Dodatno, autori su trenirali i zasebne ESN prediktore za temperaturu te analizirali utjecaj pogrešaka u prognostičkim temperaturama na točnost prognoze opterećenja.


Dobiveni rezultati na *North-American Utility* skupu pokazuju da ESN postiže visoku točnost uz minimalan broj ulaza. U idealnom slučaju poznatih budućih temperatura (izmjerene vrijednosti), postignut je MAPE od 1.14% za 1h prognozu i 2.37% za 24h prognozu. Kada se koriste predviđene (dodan šum) temperature, pogreška se povećava na 1.21% za 1h i 2.53% za 24h prognozu. Ovi rezultati potvrđuju da ESN, unatoč jednostavnoj strukturi i malom broju ulaznih varijabli, može učinkovito modelirati kompleksnu dinamiku potrošnje te pružiti robusne prognoze čak i u prisutnosti pogrešaka u ulaznim meteorološkim podacima.

Analiza rezultata, prikazanih u Tablici 5.4 i na Slici 5.4, jasno pokazuje da predloženi SSA-SVR model nadmašuje sve usporedne modele iz literature po točnosti predikcije na skupu *North-American Utility*. Tablica daje egzaktnu numeričku vrijednost MAPE za sve scenarije (1h i 24h, stvarna i prognostička temperatura), dok grafički prikaz omogućuje intuitivno sagledavanje razlika među modelima. Ostvarena poboljšanja razlikuju se ovisno o horizontu prognoze i o tome koriste li se stvarne ili prognostičke temperature.

Tablica 5.4: Usporedba MAPE točnosti za modele na North-American Utility skupu podataka za 1h i 24h predikciju, s korištenjem stvarnih i prognoziranih temperatura.

Model	1h (stvarna T)	24h (stvarna T)	1h (prog. T)	24h (prog. T)
Wavelet-ANN [109]	1,10%	2,64%	1,11%	2,82%
Wavelet-NN-EA [4]	0,99%	2,04%	n.a.	n.a.
ESN [33]	1,14%	2,37%	1,21%	2,53%
SSA-SVR	0,72%	1,99%	0,73%	2,03%
<i>Poboljšanje SSA-SVR</i>	27,20%	2,50%	34,20%	19,90%

* Prognozirana temperatura dobivena je dodavanjem Gaussovog šuma sa standardnom devijacijom 0,55°C.



Slika 5.4: Grafička usporedba MAPE vrijednosti modela na North-American Utility skupu podataka.


U najpovoljnijem scenariju – kratkoročna 1h prognoza sa stvarnim temperaturama – SSA-SVR postiže MAPE od 0.72%, što je za oko 27% manja pogreška u odnosu na najbolji prethodni model (0.99% kod wavelet-NN-EA [4]). Za 24h prognozu sa stvarnim temperaturama SSA-SVR ostvaruje MAPE od 1.99%, čime je za približno 2.5% bolji od wavelet-NN-EA modela (2.04%).

Prednost SSA-SVR modela još je izraženija u realističnijem scenariju kada se koriste prognostičke temperature. U tom slučaju, za 1h prognozu SSA-SVR postiže MAPE od 0.73% u usporedbi s 1.21% kod ESN modela [33], što predstavlja relativno smanjenje pogreške od oko 34%. Na jednodnevnom horizontu (24h), SSA-SVR ostvaruje MAPE od 2.03%, dok ESN u istim uvjetima bilježi 2.53%, što znači da predloženi model smanjuje pogrešku za približno 20%.

Rezultati ukazuju da SSA-SVR model ostvaruje najniže MAPE vrijednosti u svim razmatranim scenarijima, uz osobito izraženu prednost u uvjetima korištenja prognostičkih meteoroloških varijabli. Za razliku od wavelet-ANN pristupa [109], koji uvodi multirezolucijsku analizu, ali se oslanja na standardni MLP sklon pretreniravanju, te wavelet-NN-EA modela [4], koji postiže visoku točnost ali uz cijenu složenosti i računalne zahtjevnosti, ili ESN modela [33], koji nudi jednostavnost i brzinu ali se pokazuje osjetljivijim na pogreške ulaznih temperatura, SSA-SVR objedinjuje prednosti više pristupa. Korištenjem sezone dekompozicije i pažljive selekcije značajki smanjuje dimenzionalnost i šum u podacima, dok SVR osigurava robusno nelinearno učenje uz optimizirane hiperparametre. Time se objašnjavaju bolji rezultati i potvrđuje praktična primjenjivost SSA-SVR modela za kratkoročno predviđanje opterećenja.

Osim prosječnih pokazatelja točnosti, vrijedno je promotriti i raspodjelu pogreške po satima unutar 24-satnog horizonta predikcije. U tu svrhu provedena je detaljna usporedba satnih MAPE vrijednosti između predloženog SSA-SVR modela i ESN pristupa [33]. Oba su modela testirana pri korištenju simuliranih meteoroloških prognoza (umjesto izmjerenih temperatura), kako bi se što vjernije oponašali stvarni uvjeti operativne primjene. Rezultati su prikazani na slici 5.5, gdje je prikazana MAPE po satu za SSA-SVR (puna linija) i ESN (isprekidana linija).

Uočljivo je da SSA-SVR ostvaruje niže vrijednosti MAPE tijekom većine dana. Primjerice, već u ranim jutarnjim satima SSA-SVR bilježi vrlo malu pogrešku (0,64% u 1h), dok ESN u istom satu doseže oko 2,30%. Tijekom dana SSA-SVR zadržava prednost u 21 od 24 sata, a najveće razlike prisutne su u kritičnim periodima, poput jutarnjeg porasta opterećenja (oko 7h), kada MAPE ESN modela prelazi 3,5%, dok SSA-SVR ostaje ispod 2,9%. Izuzetak su podnevni sati (12.–15. h), kada su rezultati dvaju modela usporedivi, a ESN model povremeno ostvaruje



Slika 5.5: Usporedba satnih MAPE vrijednosti između predloženog SSA-SVR modela i ESN modela [33] na 24-satnom predviđanju opterećenja (*North-American Utility* skup podataka). Prikazane su vrijednosti MAPE za svaki sat dan-a pri korištenju simuliranih (predviđenih) meteoroloških podataka. SSA-SVR model u pravilu ostvaruje niži MAPE po satu te ujednačeniju točnost kroz dane sate u usporedbi s ESN modelom.

tek neznatno manju pogrešku (npr. oko 1,95% prema 2,1% u 13h). Ukupno gledano, prosječna dnevna MAPE vrijednost SSA-SVR modela iznosi oko 1,99%, dok ESN doseže približno 2,55%, što jasno potvrđuje veću točnost i stabilnost predloženog modela.

Dobivena analiza naglašava važnost procjene performansi po satima, a ne samo na temelju agregiranih pokazatelja. Iako prosječni MAPE daje opći uvid, satna razdioba otkriva u kojim vremenskim intervalima modeli imaju slabosti. Za operatore elektroenergetskih sustava to je osobito važno tijekom vršnih sati potrošnje, kada su posljedice većih pogrešaka najkritičnije: precjenjivanje potražnje dovodi do nepotrebnog angažiranja viška kapaciteta i povećanja troškova, dok podcjenjivanje može rezultirati nedostatkom rezervi i ugrozom pouzdanosti sustava. Predloženi SSA-SVR model pokazuje ne samo nižu prosječnu pogrešku, već i znatno ujednačeniju točnost kroz cijeli dan, čime olakšava donošenje operativnih odluka o rasporedu proizvodnje,

nabavi energije i upravljanju balansnom energijom. Zaključno, analiza satne raspodjele pogreške dodatno potvrđuje stabilnost i prediktivnu pouzdanost SSA-SVR pristupa u odnosu na usporedni ESN model.

Rezultati na *North-American Utility* skupu potvrđuju učinkovitost predloženog SSA-SVR modela. On postiže najniže pogreške predikcije u usporedbi sa svim referentnim metodama iz literature, pri čemu su poboljšanja najizraženija u zahtjevnijim scenarijima – na duljim horizontima i pri korištenju prognostičkih podataka. Time se dodatno naglašava robusnost i praktična vrijednost razvijene strategije. Budući da su svi modeli ocijenjeni na jedinstven način, a SSA-SVR već u fazi učenja integrira prognostičke meteorološke podatke, dobiveni rezultati posebno ukazuju na njegovu prikladnost za stvarne operative uvjete kratkoročnog planiranja elektroenergetskog sustava.

5.2.3. Usporedba algoritama za odabir značajki na SSA-SVR

U sklopu razvoja predikcijskih modela provedena je sustavna usporedba učinkovitosti pet različitih algoritama za odabir značajki: GA&IT, MRMR, ReliefF, StepwiseFS te ekspertnog ručnog izbora. Usporedba je provedena na oba skupa podataka (ISO New England i North-American Utility), za jednosatno i 24-satno predviđanje, pri čemu je svaki algoritam odabirao ukupno 40 značajki (20 iz opterećenja i 20 iz temperaturnih varijabli) iz skupa od 456 kandidatskih varijabli.

StepwiseFS algoritam ostvario je najniže MAPE vrijednosti u svim razmatranim eksperimentalnim konfiguracijama: za ISO-NE 24h prognozu testni MAPE iznosi 1,31%, za NA Utility 24h prognozu 1,99%, a za NA Utility 1h prognozu 0,72%. Zbog tih rezultata StepwiseFS je odabran kao konačni algoritam za odabir značajki u svim daljnjim eksperimentima. Detaljne usporedne tablice svih algoritama, mjesečna razdioba pogrešaka te prikaz odabranih vremenskih pomaka za karakteristične sate dani su u Pravitku B.

5.2.4. Učinak vremenskih i kalendarskih varijabli na SSA-SVR

U ovom poglavlju predstavljena je evaluacija utjecaja pojedinih skupina ulaznih varijabli — kalendarskih praznika, transformiranih temperaturnih indeksa i vremenskih prognoza — na performanse SSA-SVR modela. Analiza je provedena zasebno za skupove podataka ISO New

England i North-American Utility, pri čemu navedene varijable nisu bile uključene u algoritme za odabir značajki. U tu svrhu uspoređivane su varijante modela kod kojih su određene značajke bile izostavljene ili zamijenjene pojednostavljenim varijablama, u odnosu na referentni model koji uključuje sve ulazne informacije. Dobiveni rezultati pružaju dublji uvid u osjetljivost modela na ključne ulazne podatke te omogućuju formuliranje preporuka u pogledu operativne primjene i povećanja robusnosti prediktivnih sustava.

Tablica 5.5: Utjecaj izostavljanja značajki $H_{1,...,4}$ i T_{CR}, T_{HR}, T_{XHR} te treniranja s izmjerenim temperaturama na točnost modela SSA-SVR (MAPE vrijednosti za ISO New England, 2006. godina, korištene prognozirane vremenske varijable)

Mjesec	SSA-SVR (referentni)	SSA-SVR bez $H_{1,...,4}$	SSA-SVR bez T_{CR}, T_{HR}, T_{XHR}	SSA-SVR treniran na izmjerenim temp.
Siječanj	1.53	1.82	1.76	1.58
Veljača	1.32	1.41	1.65	1.44
Ožujak	1.13	1.13	1.27	1.32
Travanj	1.37	1.39	1.45	1.36
Svibanj	1.12	1.21	1.25	1.29
Lipanj	1.56	1.95	2.20	2.39
Srpanj	2.06	2.26	2.54	3.33
Kolovoz	1.86	1.84	2.27	2.13
Rujan	1.19	1.28	1.35	1.32
Listopad	1.32	1.26	1.54	1.32
Studen	1.14	1.29	1.25	1.27
Prosinac	1.68	2.09	2.16	1.87
Prosjeck	1.44	1.58	1.72	1.72

Tablica 5.5 prikazuje usporedbu točnosti SSA-SVR modela na skupu ISO New England (2006.), pri čemu prvi stupac predstavlja **referentni model** treniran s kompletnim skupom značajki i prognoziranim temperaturama. Preostali stupci prikazuju varijante s ograničenim ili izmijenjenim skupom ulaznih varijabli.

Uklanjanje četiriju binarnih kalendarskih varijabli povezanih s praznicima ($H_{1,...,4}$) povećava prosječni MAPE na 1,58%, što je za približno **9,7 %** lošiji rezultat u odnosu na referentni

model. To potvrđuje važnost eksplicitnog kodiranja kalendarskih utjecaja, posebno u razdobljima nestandardne potrošnje.

Izostavljanje transformiranih temperaturnih indeksa T_{CR} (zahtjev za hlađenjem), T_{HR} (zahtjev za grijanjem) i T_{XHR} (dodatni zahtjev za grijanjem) te njihova zamjena sirovom temperaturom dovodi do prosječnog MAPE od 1,72%, odnosno **19,4 %** lošijeg rezultata. Ovaj nalaz jasno pokazuje koliki doprinos ima domenski vođen inženjering značajki u modeliranju utjecaja temperature.

Konačno, kada je model treniran na stvarnim, izmjerenim temperaturama, dok su u testiranju korištene prognozirane vrijednosti, također je ostvaren prosječni MAPE od 1,72%. I ovdje dolazi do pogoršanja od oko **19,4 %** u odnosu na referentni scenarij. Rezultat upućuje na važnost konzistentnosti distribucije ulaznih varijabli između faze učenja i faze primjene, odnosno na potrebu da se model trenira u uvjetima koji vjerno odražavaju operativni režim uporabe.

Sveukupno, rezultati potvrđuju da pažljivo dizajnirane ulazne značajke i konzistentno korištenje prognoziranih podataka tijekom treniranja i testiranja značajno povećavaju robusnost i točnost STLF modela.

Tablica 5.6: Utjecaj izostavljanja ulaznih varijabli i korištenja samo izmjerenih temperatura na MAPE — North-American Utility skup podataka

	SSA-SVR (stvarne T)	SSA-SVR (prog. T, ref.)	bez $H_1, \dots, 4$	bez T_{CR}, T_{HR} i T_{XHR}	samo izmjerene T (bez prognoze)
1h unaprijed	0.72%	0.73%	0.72% ($\pm 0\%$ vs. stvarne T)	0.73% (+1.3% vs. stvarne T)	0.76% (+5.5% vs. prog. T)
24h unaprijed	1.99%	2.03%	2.05% (+3.0% vs. stvarne T)	2.12% (+6.5% vs. stvarne T)	2.06% (+1.5% vs. prog. T)

Napomena: Prva kolona prikazuje rezultate modela treniranog i testiranog na stvarnim temperaturama, dok je druga kolona referentni model treniran i testiran na prognoziranim temperaturama (dobivenima dodavanjem Gaussovog šuma, $\sigma = 1^\circ\text{F}$). Treća i četvrta kolona uspoređuju se s modelom na stvarnim temperaturama (1. kolona), dok se peta kolona uspoređuje s referentnim modelom na prognoziranim temperaturama (2. kolona). Negativna vrijednost označava poboljšanje, a pozitivna pogoršanje u odnosu na odgovarajući referentni model.

Tablica 5.6 prikazuje utjecaj izostavljanja određenih vremenskih i kalendarskih ulaznih značajki na točnost predikcije opterećenja (izraženo kroz MAPE) za North-American Utility skup podataka. Dodatno su prikazane tri inačice SSA-SVR modela:

- (I) model treniran bez četiri binarne kalendarske varijable $H_{1,\dots,4}$ (indikator praznika: je li dan praznik te prethodni ili sljedeći dan praznik),
- (II) model bez triju deriviranih temperaturnih značajki T_{CR} , T_{HR} i T_{XHR} (čije je izostavljanje

nadomješteno korištenjem sirove, neobrađene temperature umjesto tih značajki),

- (III) model treniran isključivo s prethodno izmjerenim temperaturama, dakle bez korištenja prognostičkih podataka o temperaturi za dan predikcije (budući da ti podaci nisu dostupni u trenutku treniranja modela).

Za horizont od 1 sata unaprijed rezultati pokazuju minimalne razlike. Model bez prazničkih indikatora ostvaruje istu točnost kao i osnovni model na stvarnim temperaturama (0.72%), dok uklanjanje deriviranih temperaturnih značajki blago pogoršava performanse na 0.73% (+1.3% u odnosu na stvarne T). Najveći pad točnosti zabilježen je kod varijante koja koristi samo izmjerene temperature u odnosu na referentni model s prognoziranima: MAPE raste s 0.73% na 0.76%, što je relativno povećanje od +5.5%. Ipak, sve vrijednosti ostaju ispod 0.8%, što pokazuje da je model izrazito robustan za kratki horizont predviđanja.

Za dan unaprijed (24 sata) razlike su izraženije. Uklanjanje prazničkih indikatora povisuje MAPE sa 1.99% (stvarne T) na 2.05%, što predstavlja +3.0% lošiji rezultat. Izostavljanje transformiranih temperaturnih značajki dovodi do MAPE od 2.12%, tj. +6.5% u odnosu na referentni model na stvarnim temperaturama. Konačno, korištenje samo izmjerenih temperatura umjesto prognoziranih dovodi do pogreške od 2.06%, što je +1.5% više u odnosu na referentni model s prognoziranima.

Ukupno gledano, rezultati pokazuju da uklanjanje pojedinih ulaznih značajki ili oslanjanje isključivo na povijesne temperature dovodi do umjerenog povećanja pogreške, no osnovni SSA-SVR model i dalje zadržava vrlo niske vrijednosti MAPE (0.7% za 1h i 2% za 24h predikciju). U odnosu na ISO New England skup, osjetljivost North-American Utility modela na kalendarske i temperaturne značajke je slabija, što upućuje na to da obrasci potrošnje u ovom sustavu u većoj mjeri proizlaze iz stabilnih povijesnih obrazaca i manje ovise o eksplicitnom modeliranju tih varijabli.

5.3. Eksperimentalna evaluacija i analiza performansi

DNN-SVR modela

Ovo poglavlje prikazuje i analizira rezultate kratkoročnog predviđanja opterećenja (STLF) dobivene primjenom modela opisanih u Odjeljku 4.6., s naglaskom na predloženi satno specijalizirani hibridni okvir DNN-SVR. Za razliku od poglavlja 4.6., u kojem je razrađen teorijski i

metodološki temelj integracije dubokog učenja u SVR okvir, ovdje se fokus stavlja na empirijsku evaluaciju i komparativnu interpretaciju rezultata na hrvatskom skupu podataka.

Evaluacijski dizajn usmjeren je na pet međusobno povezanih ciljeva: (i) kvantificirati doprinos hibridizacije u odnosu na samostalni DNN model, (ii) usporediti strategije modeliranja (jedinostveni prediktivni model nasuprot sustavu od 24 satno specijalizirana modela), (iii) analizirati utjecaj duljine razvojnog razdoblja na stabilnost i generalizacijska svojstva DNN-SVR modela, (iv) procijeniti doprinos integracije globalnih numeričkih meteoroloških prognoza (NWP) i strukturu odabranih značajki dobivenih postupkom temeljenim na gradijentnom pojačanju te (v) pozicionirati predloženi hibridni pristup u odnosu na suvremene sekvencijske i Transformer-temeljene modele dubokog učenja unutar jedinstvenog eksperimentalnog protokola.

Prva, druga i četvrta točka izravno operacionaliziraju istraživačke hipoteze definirane u Poglavlju 1, dok treća i peta točka predstavljaju dodatne analize robusnosti i komparativne evaluacije. Takvom strukturom evaluacijskog dizajna osigurava se cjelovita i metodološki konzistentna provjera predloženog hibridnog DNN-SVR okvira, kako u odnosu na vlastite strukturne komponente, tako i u odnosu na suvremene sekvencijske i Transformer-temeljene pristupe dubokog učenja unutar jedinstvenog i strogo kontroliranog eksperimentalnog protokola.

Svi modeli predviđaju 24 satne vrijednosti opterećenja za sljedeći dan, pri čemu se prognoza izdaje u 08:00, što odgovara horizontu od 16 do 39 sati unaprijed. Godina 2022. korištena je isključivo kao neovisni testni skup (eng. *held-out test year*), čime se osigurava nepristrana procjena generalizacijskih svojstava modela. Tijekom razvoja modela primijenjena je kronološka podjela razvojnog razdoblja na 80% uzoraka za treniranje i 20% za validaciju, uz dosljednu primjenu istog protokola skaliranja kako bi se izbjeglo propuštanje informacija između skupova podataka.

Eksperimenti su provedeni u programskom jeziku Python 3.9.13. Modeli dubokog učenja implementirani su korištenjem biblioteke Keras (API 2.9.0) s TensorFlow pozadinom (TensorFlow 2.9.1), dok su SVR modeli i pripadni postupci predobrade ostvareni unutar biblioteke scikit-learn (v1.2). Odabir značajki temeljen na gradijentnom pojačanju proveden je pomoću biblioteke XGBoost (v1.7.2), a obrada podataka korištenjem NumPy (v1.22.3) i Pandas (v1.4.4). Izvedba je ostvarena na radnoj stanici opremljenoj Intel(R) procesorom, pri čemu je računalni trošak (vrijeme treniranja i inferencije) dodatno analiziran kao relevantan operativni čimbenik.

U nastavku poglavlja najprije se razmatra struktura i stabilnost odabranih značajki dobivenih

algoritmom XGBoost, nakon čega slijedi analiza referentnog samostalnog DNN modela, ablacijska procjena doprinosa SVR regresijske faze, statistička validacija robusnosti putem višestrukih inicijalizacija te usporedba strategija modeliranja i utjecaja integracije NWP prognostičkih varijabli. Završno, predloženi hibridni pristup pozicionira se u odnosu na sekvencijske (LSTM) i Transformer-temeljene referentne modele pod jedinstvenim eksperimentalnim protokolom.

5.3.1. Analiza značajki dobivenih metodom XGBoost

U istraživanjima kratkoročnog predviđanja opterećenja (STLF) dosljedno se naglašava važnost sustavnog odabira značajki kao preduvjeta stabilnih i robustnih prediktivnih performansi [20]. U ovom radu zadržan je temeljni SVR prediktivni okvir, dok je postupak odabira značajki unaprijeđen primjenom algoritma XGBoost, čime se omogućuje podatkovno vođena identifikacija najinformativnijih ulaznih varijabli uz očuvanje metodološke konzistentnosti s prethodnim pristupima.

Analiza je provedena na hrvatskom skupu podataka koji obuhvaća dugotrajno razdoblje od 2006. godine nadalje, čime je osigurana reprezentativnost različitih sezonskih, meteoroloških i potrošačkih obrazaca. Algoritam XGBoost primijenjen je u fazi odabira značajki u okviru DNN-SVR modeliranja, s ciljem procjene relativne važnosti ulaznih varijabli na temelju nelinearnih odnosa prisutnih u podacima. Nakon treniranja XGBoost modela s velikim brojem stabala (5000), uveden je prag važnosti od 0,002, pri čemu su zadržane samo značajke s mjerljivim doprinosom točnosti predviđanja, dok su redundantne i slabo informativne varijable isključene iz daljnje analize.

Takav postupak omogućuje usporedbu strukture odabranih značajki između jedinstvenog satno uvjetovanog modela i sustava od 24 satno specijalizirana modela, uz uvid u relativnu važnost povijesnih opterećenja, meteoroloških prediktora i kalendarskih indikatora. Dobiveni skup značajki korišten je dosljedno u svim eksperimentima unutar ovog poglavlja, čime je osigurana usporedivost rezultata između razmatranih modelskih konfiguracija.

Primjena metode XGBoost u ovom kontekstu omogućuje podatkovno vođen i nelinearan postupak rangiranja i filtriranja značajki, uz dobru skalabilnost i otpornost na multikolinearnost, u skladu s prednostima pristupa temeljenog na gradijentnom boostingu raspravljenima u Odjeljku 1.4.5.3..

U slučaju jedinstvenog modela za svih 24 sata izdvojeno je ukupno 41 značajka s najvećim doprinosom točnosti predviđanja. Rangiranjem prema važnosti, prepoznata je kombinacija podataka o prošlom opterećenju, varijabli vremenskih prognoza za dvije lokacije (Zagreb i Split) te vremenskih indikatora poput blagdana i radnih dana. Najznačajnijim prediktorom pokazalo se opterećenje iz tjedan dana ranije (168 sati), što jasno potvrđuje presudnu ulogu povijesnih obrazaca potrošnje u oblikovanju buduće potražnje. Među ostalim ključnim značajkama posebno se izdvajaju prognoze temperature i temperature rosišta na različitim vremenskim horizontima i dijelovima dana, čime se dodatno naglašava snažan utjecaj meteoroloških čimbenika na potrošnju električne energije. Primjerice, za Zagreb su najznačajnije prognoze temperature bile one na horizontima od 30, 12 i 36 sati nakon ponoći, dok su se za Split najvažnijima pokazale prognoze na horizontima od 36, 12 i 54 sata. Kada je riječ o temperaturi rosišta, prognoza na horizontu od 18 sati nakon ponoći imala je najveći značaj u oba grada. Osim prognostičkih varijabli, važnost povijesnih meteoroloških podataka potvrđena je i time što se izmjerena temperatura iz tjedan dana ranije (168 sati unatrag) izdvojila kao jedan od najutjecajnijih prediktora u oba promatrana slučaja.

Kod pristupa s 24 zasebna modela (po jedan za svaki sat u danu) uočena je određena varijabilnost u strukturi odabranih značajki među satima, no pojedine su varijable dosljedno zadržale dominantnu ulogu. Najvažniji prediktor u svim modelima bilo je opterećenje iz tjedan dana ranije (168 sati unatrag), koje se pokazalo najznačajnijim u njih 13. Time se još jednom potvrđuje stalna važnost tjednih obrazaca opterećenja u predviđanju potrošnje. Osim toga, opterećenje iz dva tjedna ranije (336 sati) pojavilo se u 20 modela, dok je opterećenje iz dva dana ranije (48 sati) bilo važno u 12 modela, što dodatno naglašava utjecaj povijesnih podataka na različitim vremenskim skalama.

Varijable vremenske prognoze pokazale su raznoliku važnost među pojedinim satnim modelima. Za Zagreb se prognostička temperatura na horizontu od 36 sati unatrag pojavila u 18 modela, dok je prognoza na horizontu od 18 sati korištena u njih 14. U slučaju Splita, najznačajnije su bile prognoze temperature na horizontima od 26 sati (uključene u 23 modela) i 30 sati (21 model). Kada je riječ o temperaturi rosišta, za Zagreb su najvažnijima bile prognoze na horizontima od 30 i 36 sati (u 13, odnosno 5 modela), dok su se za Split istaknule prognoze na horizontima od 30 sati (3 modela) i 18 sati (2 modela). Povijesne izmjerene vrijednosti temperature, osobito one od tjedan dana ranije (168 sati), također su se pokazale vrlo utjecajnim

– u 15 modela za Zagreb i 13 za Split.

Uz meteorološke i povijesne značajke, važnu ulogu zadržale su i kalendarske varijable. Varijabla „praznik” bila je uključena u svih 24 modela, dok se varijabla „radni dan” pojavila u njih 23. Osim toga, mjesec u godini pokazao se značajnim prediktorom u 15 modela, ponajprije u jutarnjim i poslijepodnevnim satima, što potvrđuje izražene sezonske obrasce u potrošnji električne energije.

Dobiveni rezultati ukazuju na stabilnu i interpretabilnu strukturu odabranih značajki u okviru hibridnog DNN-SVR modeliranja. Dominacija tjednih zaostataka opterećenja, uz dosljednu prisutnost meteoroloških i kalendarskih varijabli, potvrđuje fizičku i sezonsku utemeljenost modela. Ujednačena selekcija ključnih prediktora kroz različite satne konfiguracije dodatno potvrđuje robusnost postupka odabira značajki te osigurava konzistentan ulazni prostor za sve daljnje eksperimentalne analize.

Takva struktura značajki predstavlja stabilnu osnovu za analizu doprinosa hibridne regresijske faze u nastavku poglavlja.

5.3.2. Samostalni DNN model kao nelinearni ekstraktor značajki: arhitektura i odabir konfiguracije

Kako je metodološki okvir hibridnog DNN-SVR modela detaljno opisan u Poglavlju 4.6., u ovom se dijelu rada razmatra isključivo implementacija i evaluacija samostalne duboke neuronske mreže. Cilj je analizirati prediktivne sposobnosti DNN-a formuliranog kao višeslojni perceptron (FNN/MLP) te ga koristiti kao referentni model (*baseline*) za usporedbu s hibridnim DNN-SVR pristupom.

Samostalni DNN model trenira se izravno nad konstruiranim ulaznim značajkama te u ovom kontekstu preuzima dvostruku ulogu: (i) služi kao nelinearni prediktor kratkoročne potrošnje električne energije i (ii) omogućuje kvantifikaciju doprinosa eksplicitne SVR regresijske faze u hibridnoj konfiguraciji. Time se osigurava jasna i interpretabilna usporedba između čistog dubokog modela i predloženog hibridnog rješenja.

Sve razmatrane DNN arhitekture temelje se na višeslojnim perceptronima implementiranim u okviru TensorFlow/Keras biblioteke [26]. Svaka mreža sastoji se od ulaznog standardizacijskog sloja, dva ili više gusto povezanih skrivenih slojeva s ReLU aktivacijskom funkcijom te završnog

linearnog izlaznog neurona. Standardizacijski sloj prilagođen je isključivo na trenirajućem dijelu podataka, čime se sprječava propuštanje informacija iz validacijskog skupa i osigurava korektna evaluacija modela.

Modeli su trenirani pomoću Adam optimizatora sa stopom učenja 10^{-3} , uz korištenje srednje apsolutne pogreške (MAE) kao funkcije gubitka. Treniranje je provedeno do maksimalno 1000 epoha uz primjenu ranog zaustavljanja, pri čemu je korišten kronološki razdjeljak skupa podataka u omjeru 80/20 za treniranje i validaciju. Tijekom treniranja primijenjeno je nasumično miješanje mini-serija, a za konačnu evaluaciju zadržavana je epoha s najnižom validacijskom pogreškom. Ovakav postupak osigurava stabilnost učenja, smanjuje rizik od prenaučivosti i omogućuje pravednu usporedbu različitih arhitektura unutar jedinstvenog eksperimentalnog okvira.

Radi odabira najprikladnije DNN arhitekture provedeno je ciljano pretraživanje arhitektura uz zadržavanje jedinstvenog eksperimentalnog protokola. U satno specijaliziranom pristupu treniran je zaseban DNN model za svaki ciljni sat, koristeći isključivo pripadne uzorke. Kandidatne arhitekture razlikovale su se po dubini i širini mreže, pri čemu su razmatrane konfiguracije s dva ili više skrivenih slojeva i brojem neurona u rasponu od 32 do 256 po sloju.

Za svaku arhitekturu zabilježena je minimalna validacijska MAE pogreška za svaki pojedini sat, a kao kriterij odabira korištena je prosječna vrijednost tih minimalnih pogrešaka preko svih 24 sata. Takav kriterij omogućuje vrednovanje ukupne sposobnosti generalizacije modela duž cjelodnevnog profila potrošnje, umjesto optimizacije za izolirane satne segmente.

Rezultati prikazani u Tablici 5.7 pokazuju da arhitektura s dva skrivena sloja od po 256 neurona (256×256) ostvaruje najnižu prosječnu validacijsku pogrešku. Time se potvrđuje da ova konfiguracija predstavlja povoljan kompromis između modelne složenosti, stabilnosti treniranja i točnosti predviđanja. Slične potpuno povezane neuronske mreže s dva skrivena sloja i približno 256 neurona po sloju često se navode u literaturi o predviđanju opterećenja i energetske prognostičkim zadacima kao dovoljno izražajne za modeliranje složenih nelinearnih odnosa među ulaznim značajkama [50, 152].

S teorijskog stajališta, potpuno povezana neuronska mreža s dva skrivena sloja i dostatnom širinom predstavlja univerzalni aproksimator funkcija, pružajući dovoljnu reprezentacijsku sposobnost bez uvođenja nepotrebne dubine i dodatne optimizacijske složenosti [56]. Na temelju navedenih empirijskih i teorijskih razmatranja, arhitektura 256×256 odabrana je kao osnovni samostalni DNN model te kao temelj za hibridne DNN-SVR konfiguracije analizirane u nastavku

rada.

Tablica 5.7: Strukture DNN mreža i prosječna minimalna validacijska MAE pogreška (satno specijalizirana postavka).

Struktura DNN mreže ^a	Prosječna minimalna MAE
256 × 256	37,215
128 × 128 × 128	37,601
64 × 64 × 32	37,776
128 × 128	37,783
64 × 64	38,539
32 × 32	39,368

^a Broj neurona u pojedinim skrivenim slojevima, naveden redom i razdvojen znakom “×”.

5.3.3. Ablacijska analiza utjecaja SVR regresijske faze u hibridnom DNN-SVR modelu

U ovoj ablacijskoj analizi razmatra se učinak zamjene linearnog izlaznog sloja samostalnog DNN modela regresijskom fazom temeljenom na metodi potpornih vektora (SVR). Cilj analize jest kvantificirati doprinos SVR regresijske glave u odnosu na čisti duboki model, uz zadržavanje identičnog ulaznog prostora, postupka treniranja i satno specijalizirane konfiguracije.

Uspoređuju se dvije skupine prediktora: samostalni DNN modeli i hibridni DNN-SVR modeli, koji se razlikuju isključivo u završnoj regresijskoj fazi. U hibridnoj konfiguraciji, linearni gusto povezani izlazni sloj DNN-a zamijenjen je SVR modelom treniranim nad reprezentacijama iz prethodnog sloja neuronske mreže.

Svi eksperimenti provedeni su korištenjem najbolje DNN arhitekture identificirane u prethodnom pododjeljku (256 × 256). Ostali elementi eksperimentalnog okvira ostaju nepromijenjeni, čime se osigurava da uočene razlike u performansama proizlaze isključivo iz utjecaja SVR regresijske faze. Za SVR komponentu korištena je RBF jezgra, odabrana zbog svoje fleksibilnosti i sposobnosti modeliranja nelinearnih odnosa između naučenih dubokih reprezentacija i ciljne varijable, što je osobito važno u kontekstu kratkoročnog predviđanja opterećenja.

Hiperparametri SVR modela, uključujući parametar regularizacije C i parametar jezgre γ za RBF funkciju, optimizirani su postupkom iscrpnog pretraživanja mreže parametara, pri čemu

je kao kriterij odabira korištena validacijska MAE pogreška. Time se osigurava da uočena poboljšanja u točnosti proizlaze iz optimalne kombinacije dubokih značajki i kernel-temeljene regresije, a ne iz promjene eksperimentalnih uvjeta.

Tablica 5.8 prikazuje agregirane rezultate na testnom skupu za 2022. godinu. Uvođenje SVR regresijske faze dovodi do sustavnog smanjenja pogreške u odnosu na samostalni DNN model. Za arhitekturu 256×256 , hibridni DNN-SVR model s RBF jezgrom smanjuje MAPE s 1,9867% na 1,8950%, što predstavlja apsolutno smanjenje od 0,0917 postotnih bodova, odnosno relativno poboljšanje od 4,62%. U kontekstu hrvatskog elektroenergetskog sustava, takva inkrementalna poboljšanja točnosti imaju operativnu važnost jer doprinose smanjenju volumena odstupanja i pripadajućih troškova uravnoteženja, osobito u sustavu s izraženom uvoznom ovisnošću i izloženošću volatilnim cijenama uravnotežne energije [30, 37]. Preciznije kratkoročne prognoze dodatno omogućuju točnije planiranje dan-unaprijed i učinkovitiju nabavu prekograničnih prijenosnih kapaciteta, čime se smanjuje potreba za skupim intradnevni korekcijama i obračunima odstupanja [13].

Tablica 5.8: Ablacijska analiza: usporedba samostalnog DNN modela i hibridnog DNN-SVR modela s RBF jezgrom za arhitekturu 256×256 (satno specijalizirani višemodelni pristup, testna godina 2022.).


Struktura DNN mreže ^a	DNN		DNN-SVR (RBF)	
	MAPE (%)	MAE	MAPE (%)	MAE
256×256	1,9867	42,14	1,8950	40,14

Napomena: Svi modeli koriste identičan skup ulaznih značajki dobiven algoritmom odabira temeljenim na gradient-boost stablima. ^a Broj neurona u svakom skrivenom sloju, odvojenih znakom “×”.

Formalni statistički testovi dodatno potvrđuju ostvarena poboljšanja. Dvosmjerni Diebold–Mariano test proveden nad MAE gubicima odbacuje nul-hipotezu o jednakoj prediktivnoj točnosti u korist DNN-SVR (RBF) varijante ($DM = 6,118$, $p = 9,48 \times 10^{-10}$). Sličan zaključak daje i upareni Wilcoxonov test nad apsolutnim pogreškama ($W = 15,488,209$, $p = 1,003 \times 10^{-16}$).

Slika 5.6 prikazuje satno-specifičnu usporedbu pogreške. Za gotovo svih 24 sata hibridni DNN-SVR model s RBF jezgrom postiže jednaku ili nižu MAPE vrijednost u odnosu na samostalni DNN, pri čemu su najveća relativna poboljšanja zabilježena tijekom vršnih i prijelaznih razdoblja opterećenja. Time se potvrđuje da hibridna konfiguracija ne poboljšava samo agregiranu pogrešku, već dosljedno smanjuje pogrešku kroz cijeli dnevni ciklus.

Iako uvođenje SVR regresijske faze povećava računalnu složenost tijekom treniranja, ostvarena



Slika 5.6: Satna usporedba MAPE pogreške između samostalnog DNN modela i hibridnog DNN-SVR modela za testnu godinu 2022.

poboljšanja u točnosti opravdavaju taj dodatni trošak, dok vrijeme izvođenja predviđanja ostaje dovoljno kratko za operativnu primjenu u stvarnom vremenu. Ukupno gledano, ova ablacija potvrđuje da SVR regresijska faza donosi mjerljivu i statistički značajnu dodatnu vrijednost povrh naučenih DNN reprezentacija. Dok DNN učinkovito uči bogate nelinearne značajke iz opterećenja, meteoroloških i kalendarskih ulaza, SVR nad tim reprezentacijama primjenjuje marginom vođenu regresiju, čime se postiže točniji i stabilniji model kratkoročnog predviđanja potrošnje električne energije.

5.3.4. Statistička validacija robusnosti modela putem višestrukih inicijalizacija

Dobiveni rezultati ablacijske analize jasno ukazuju da zamjena linearnog izlaznog sloja DNN modela SVR regresijskom fazom donosi sustavno smanjenje pogreške predviđanja. Međutim, budući da su duboki neuronski modeli osjetljivi na slučajnu inicijalizaciju težina i stohastičnost procesa treniranja, nužno je dodatno provjeriti robusnost uočenih poboljšanja. Stoga je provedena statistička validacija temeljena na višestrukim nezavisnim inicijalizacijama modela, s ciljem potvrde da ostvareni dobici nisu posljedica povoljnog slučaja, već inherentnog doprinosa SVR regresijske faze.

Za samostalni DNN model i hibridni DNN-SVR model provedeno je ukupno 10 nezavisnih

pokretanja treniranja (inicijalizacije 0–9), pri čemu je korištena arhitektura 256×256 i cjelokupno trenirajuće razdoblje 2006.–2021.

Aggregirani rezultati prikazani su u Tablici 5.9, gdje su za svaki model navedene srednje vrijednosti MAPE pogreške, standardna devijacija te 95% interval pouzdanosti.

Tablica 5.9: Statistička validacija putem višestrukih inicijalizacija (10 nezavisnih pokretanja, inicijalizacije 0–9) za samostalni DNN i hibridni DNN-SVR model.

Model	Srednja vrijednost MAPE (%)	Standardna devijacija	95% interval pouzdanosti
DNN	1,9560	0,0341	[1,9331, 1,9790]
DNN-SVR	1,8757	0,0210	[1,8616, 1,8899]

Rezultati statističkog testiranja potvrđuju značajnost uočenog poboljšanja. Upareni t -test daje vrijednost $t = 15,80$ uz $p < 2,1 \times 10^{-8}$, čime se s vrlo visokom razinom pouzdanosti odbacuje hipoteza o jednakosti srednjih pogrešaka. Dodatno, Cohenova mjera veličine učinka iznosi $d = 4,76$, što ukazuje na iznimno velik efekt. Visoka vrijednost veličine učinka proizlazi iz vrlo male varijabilnosti rezultata među različitim inicijalizacijama, čime se dodatno potvrđuje stabilnost uočenog poboljšanja.

Dobiveni rezultati pokazuju da hibridni DNN-SVR model dosljedno nadmašuje samostalni DNN model neovisno o slučajnoj inicijalizaciji težina, pri čemu se ostvareno poboljšanje može smatrati statistički vrlo značajnim i stabilnim.

U kombinaciji s rezultatima ablacijske analize, ova statistička validacija potvrđuje da uočeno smanjenje pogreške proizlazi iz strukturne integracije SVR regresijske faze u DNN arhitekturu, a ne iz artefakata slučajne inicijalizacije ili pojedinačne realizacije procesa treniranja.

Na temelju provedenih ablacijske analize i statističke validacije može se zaključiti da integracija metode potpornih vektora u završnu regresijsku fazu duboke neuronske mreže donosi sustavno i statistički značajno poboljšanje točnosti predviđanja. Time se potvrđuje Hipoteza 1, prema kojoj kombinacija dubokih neuronskih reprezentacija i kernel-temeljene SVR regresije omogućuje učinkovitije modeliranje nelinearnih odnosa u energetske sustavima u odnosu na samostalne duboke neuronske modele.

5.3.5. Usporedba satno-specijaliziranih i jedinstvenih prediktivnih modela

U području kratkoročnog predviđanja potrošnje električne energije (STLF) uobičajeno se razmatraju različite strategije formuliranja prognostičkog zadatka, ovisno o načinu modeliranja intradnevne dinamike opterećenja. U skladu s metodološkim okvirom definiranim u Odjeljku 4.3.3., u ovom se radu eksperimentalno uspoređuju dvije strategije: (i) treniranje 24 satno specijalizirana modela te (ii) treniranje jedinstvenog (konsolidiranog) prediktivnog modela uvjetovanog ciljnim satom.

Usporedba je provedena pod potpuno usklađenim eksperimentalnim uvjetima za obje razmatrane arhitekture - samostalni DNN i hibridni DNN-SVR model. U svim konfiguracijama korišten je identičan skup ulaznih značajki, isti postupak treniranja, isti validacijski protokol s kronološkom podjelom podataka te validacijskim udjelom od 20% na razvojnome razdoblju. Završna evaluacija provedena je na neovisnoj testnoj godini 2022., čime je osigurana objektivna i nepristrana usporedba razmatranih strategija.

Tablica 5.10 prikazuje ostvarene vrijednosti MAPE za obje strategije učenja. Dobiveni rezultati jasno pokazuju da satno specijalizirani podmodeli dosljedno nadmašuju jedinstveni prediktivni model, unatoč činjenici da se svaki satni model trenira na manjem broju uzoraka.

Tablica 5.10: Usporedba satno specijaliziranih podmodela i jedinstvenog prediktivnog modela za DNN i hibridni DNN-SVR pristup.

Strategija učenja	Broj trenirajućih uzoraka ^a	DNN MAPE (%)	DNN-SVR MAPE (%)
24 satno specijalizirana modela	5 476	1,9867	1,8950
Jedinstveni prediktivni model	130 721	2,4114	2,3159

^a Ukupan broj trenirajućih uzoraka po konfiguraciji; svi modeli koriste validacijski udio od 20% na razvojnome razdoblju i evaluirani su na testnoj godini 2022.

U prosjeku, satno specijalizirani pristup rezultira smanjenjem MAPE vrijednosti za približno 18% u odnosu na jedinstveni prediktivni model, neovisno o korištenoj arhitekturi. U hibridnoj DNN-SVR konfiguraciji, satno specijalizirani modeli postižu MAPE od 1,8950%, dok jedinstveni hibridni model ostvaruje 2,3159%, što odgovara relativnom smanjenju pogreške od 18,2%. Slično ponašanje uočeno je i kod samostalnog DNN modela, gdje satno specijalizirana postavka (MAPE = 1,9867%) nadmašuje jedinstveni DNN model (MAPE = 2,4114%), uz relativno smanjenje

pogreške od 17,6%.

Dobiveni rezultati empirijski su u skladu s postavljenom Hipotezom 2, prema kojoj prilagodba modela jednosatnim vremenskim intervalima dana može doprinijeti povećanju točnosti kratkoročnog predviđanja potrošnje električne energije. Ovi rezultati potvrđuju da dekompozicija prognostičkog zadatka po satima predstavlja učinkovitu strategiju za smanjenje heterogenosti problema učenja. Satno specijalizirani modeli mogu se prilagoditi specifičnim intradnevni režimima potrošnje, poput izraženih jutarnjih rampi, poslijepodnevni plato-faza ili noćne potrošnje s manjom osjetljivošću na meteorološke uvjete. Nasuprot tome, jedinstveni prediktivni model mora istodobno aproksimirati znatno različite distribucije te odnose između opterećenja, meteoroloških i kalendarskih značajki za sve sate dana.

Posljedično, unatoč većem ukupnom broju uzoraka, jedinstveni model pokazuje višu prosječnu pogrešku u odnosu na strategiju temeljenu na satno specijaliziranim podmodelima. Time se dodatno potvrđuje temeljna teza ovoga rada da kombinacija satne dekompozicije prognostičkog zadatka i hibridne DNN-SVR arhitekture omogućuje učinkovitije učenje nelinearnih odnosa i vodi prema stabilnijim i točnijim prognozama kratkoročnog opterećenja.

5.3.6. Utjecaj integracije globalnih meteoroloških prognoza

Jedan od ključnih ciljeva ovoga istraživanja bio je kvantificirati u kojoj mjeri uključivanje globalnih numeričkih meteoroloških prognoza (NWP) doprinosi točnosti kratkoročnog predviđanja opterećenja.

U tu svrhu uspoređeni su hibridni DNN-SVR modeli koji koriste isključivo povijesne vrijednosti opterećenja i lokalna meteorološka opažanja s modelima koji dodatno uključuju prognostičke meteorološke varijable iz TIGGE arhive za lokacije Zagreb i Split. Analiza je provedena za dvije strategije učenja: (i) jedinstveni hibridni model koji istodobno predviđa svih 24 sata te (ii) skup od 24 satno specijalizirana hibridna modela, pri čemu je za svaki ciljni sat treniran zaseban prediktor. U svim konfiguracijama korišten je identičan skup ulaznih značajki, isti postupak treniranja i isti validacijski protokol, dok je završna evaluacija provedena na neovisnoj testnoj godini 2022. — Kvantitativni rezultati prikazani u Tablici 5.11 pokazuju da uključivanje prognostičkih meteoroloških varijabli dovodi do značajnog smanjenja pogreške predviđanja u obje razmatrane strategije. Kod jedinstvenog hibridnog modela ostvareno je smanjenje MAPE pogreške od približno 26%, dok je u slučaju satno specijaliziranog hibridnog okvira to smanjenje


izraženije i iznosi oko 29%. Ovi rezultati jasno ukazuju da se dodatna informacija sadržana u globalnim meteorološkim prognozama učinkovitije iskorištava kada je modeliranje prilagođeno pojedinim satima u danu.

Tablica 5.11: Utjecaj prognostičkih meteoroloških prediktora temeljenih na NWP-u na performanse hibridnog DNN-SVR modela.

Konfiguracija modela	Bez prognoza (MAPE %)	S prognozama (MAPE %)	Relativno smanjenje (%)
Jedinstveni hibridni model (24 h)	3,1332	2,3159	26,09
24 satno specijalizirana hibridna modela	2,6760	1,8950	29,19

Napomena: Rezultati su dobiveni na neovisnoj testnoj godini 2022.; svi modeli koriste identičan skup ulaznih značajki i isti postupak treniranja.


Grafički prikaz navedenih poboljšanja dan je na Slici 5.7, iz koje je vidljivo da obje strategije učenja ostvaruju osjetno niže pogreške pri uključivanju NWP prognoza, pri čemu kombinacija satno specijaliziranih modela i prognostičkih meteoroloških ulaza rezultira najnižom ukupnom pogreškom.



Slika 5.7: Utjecaj uključivanja NWP-temeljenih meteoroloških prognoza na točnost hibridnog DNN-SVR modela.

Detaljnija satna analiza za satno specijalizirani hibridni pristup prikazana je na Slici 5.8. Poboljšanja su uočena tijekom svih sati dana, no njihov intenzitet nije uniforman. Najizraženija relativna smanjenja pogreške javljaju se u ranom poslijepodnevnom i kasnom popodnevnom razdoblju (osobito između 13 h i 16 h), kao i u ranovečernjim satima, kada je potrošnja električne

energije snažno povezana s temperaturom i vremenski uvjetovanim ponašanjem korisnika. Suprotno tome, tijekom noćnih i ranih jutarnjih sati, kada je potrošnja stabilnija i manje osjetljiva na meteorološke promjene, doprinos prognostičkih varijabli je manji, ali i dalje konzistentno pozitivan.



Slika 5.8: Satna usporedba MAPE pogreške za satno specijalizirani hibridni DNN-SVR model s uključenim i isključenim prognostičkim meteorološkim varijablama.

Agregirano na razini cjelodnevnog profila, satno specijalizirana hibridna konfiguracija s uključenim NWP prognozama postiže znatno nižu ukupnu pogrešku u odnosu na varijante bez prognostičkih meteoroloških ulaza. Time se empirijski potvrđuje da globalne meteorološke prognoze predstavljaju vrijedan izvor informacija za kratkoročno predviđanje opterećenja, osobito kada su pravilno usklađene s ulaznim strukturama modela i iskorištene unutar satno specijalizirane hibridne DNN-SVR arhitekture.

Dobiveni rezultati potvrđuju Hipotezu 3, prema kojoj korištenje globalnog prognostičkog modela za vremensku prognozu može poboljšati točnost predviđanja potrošnje električne energije.

5.3.7. Referentni sekvencijski i Transformer modeli za usporedbu s DNN-SVR pristupom

Kako bi se predloženi hibridni DNN-SVR pristup pozicionirao u odnosu na suvremene sekvencijske modele, implementirano je nekoliko referentnih modela unutar istog eksperimentalnog protokola: (i) LSTM Seq2Seq model s mehanizmom pažnje [8, 57], (ii) enkoderski Transformer za satno specijalizirano predviđanje [64, 87], (iii) hibridni Transformer enkoder + SVR, (iv) Temporal Fusion Transformer (TFT) [82] te (v) PatchTST-temeljeni Transformer [97]. Svi modeli koriste isti skup ulaznih značajki, kronološku podjelu 80/20 za validaciju te evaluaciju na testnoj godini 2022. Detaljni opisi arhitektura, postupaka treniranja i dizajna ulaznih tokova za sve referentne modele dani su u Priritku B.

U tom kontekstu, LSTM model uključen je kao reprezentativni sekvencijski pristup koji se često koristi u STLTF literaturi, pri čemu pojedine studije pokazuju da takvi modeli mogu ostvariti bolje rezultate od klasičnih regresijskih pristupa na dnevnim horizontima predikcije [19].

Tablica 5.12 sažima ključne rezultate referentnih modela na testnoj godini 2022.

Tablica 5.12: Sažetak performansi referentnih sekvencijskih i Transformer-baziranih modela na testnoj godini 2022.

Model / konfiguracija	MAPE (%)	MAE (MW)
Hibridni DNN-SVR (24 satna modela)	1,8950	40,14
24 enkoderska Transformera + SVR	2,1012	43,51
PatchTST-temeljeni Transformer	2,1904	46,00
Temporal Fusion Transformer (TFT)	2,2199	46,65
LSTM Seq2Seq + Attention (2012–2021)	2,21	46,26
24 enkoderska Transformera (gusto povezani izlaz)	2,4355	47,47

Rezultati pokazuju da hibridni DNN-SVR model s 24 satno specijalizirana modela ostvaruje najnižu ukupnu pogrešku (MAPE = 1,8950%), nadmašujući sve referentne pristupe. Među Transformer-baziranim modelima, hibridna konfiguracija s SVR izlazom postiže MAPE od 2,1012%, čime se potvrđuje da integracija SVR regresijske faze može značajno unaprijediti performanse Transformer enkodera. PatchTST-temeljeni model ostvaruje MAPE od 2,1904%, što je poboljšanje u odnosu na standardne enkoderske konfiguracije, ali i dalje zaostaje za predloženim hibridnim DNN-SVR pristupom za približno 13,5%.

Analiza utjecaja veličine trenirajućeg skupa na LSTM i TFT modele pokazala je da srednjoročna razdoblja (2012–2021) osiguravaju optimalnu ravnotežu između količine podataka i sezonske reprezentativnosti, dok najkraća razdoblja (2018–2021) dovode do značajnog pada točnosti. Detaljni rezultati ove analize nalaze se u Priritku B.

Ukupno gledano, rezultati potvrđuju opravdanost hibridnog DNN-SVR pristupa kao robusnog i visoko učinkovitog rješenja za STLTF zadatke, koji nadmašuje i napredne višehorizontne Transformer arhitekture.

5.3.8. Hiperparametarske postavke referentnih modela

Podešavanje hiperparametara svih referentnih modela provedeno je na jedinstvenom validacijskom skupu (2021. godina), uz dosljednu primjenu istih kronoloških podjela podataka i istog postupka skaliranja za sve arhitekture. Time je osigurano da uočene razlike u točnosti predviđanja proizlaze iz strukturnih svojstava modela, a ne iz razlika u eksperimentalnom protokolu. Detaljne hiperparametarske konfiguracije za sve referentne modele, uključujući LSTM Seq2Seq, enkoderske Transformer modele, TFT, PatchTST te hibridni DNN-SVR, dane su u Tablici B5 u Priritku B.

5.4. Sinteza rezultata i implikacije

5.4.1. Validacija metodologije na javnim skupovima ISO New England i North-American Utility

Rezultati primjene predložene strategije kratkoročnog predviđanja potrošnje električne energije na dva odabrana javna skupa podataka – ISO New England i North-American Utility – potvrđuju njezinu učinkovitost i opću primjenjivost. U oba testna slučaja model je ostvario visoku točnost predviđanja te nadmašio alternativne pristupe, uključujući i neke od najboljih modela iz literature [4, 23, 33, 109]. Time je ispunjen osnovni cilj strategije: poboljšati točnost STLTF modela uz istovremeno smanjenje potrebe za ručnim intervencijama u procesu izgradnje modela. Dodatno, budući da su korišteni podaci javno dostupni, cjelokupna metodologija validirana je na transparentan način, što drugim istraživačima omogućuje jednostavnu reprodukciju rezultata i usporedbu svojih modela s ovdje dobivenima. Ova sekcija detaljno razmatra kako je svaka faza

predložene strategije pridonijela ostvarenim rezultatima na skupovima ISO-NE i NA Utility, uz osvrt na ranije prikazane tablice rezultata.

Ukupni učinci svih navedenih faza predložene strategije ogledaju se u superiornim performansama modela te praktičnijoj primjeni sustava za predviđanje opterećenja. Točnost predviđanja povećana je u usporedbi s postojećim pristupima, što je kvantitativno demonstrirano na oba javna skupa podataka (ISO-NE i NA Utility) kroz niže ostvarene MAPE u odnosu na prethodne modele. Pri tome je osobito značajno da su poboljšanja postignuta istovremeno uz smanjeno oslanjanje na ekspertno znanje i ručne prilagodbe. Ulazne značajke i parametri odabrani su automatizirano, čime su subjektivni faktori uklonjeni iz procesa izgradnje modela. Istovremeno, uključivanje relevantnih značajki (praznika, sezonskih indikatora, prognostičke temperature) osiguralo je da model samostalno adresira uobičajene izvore pogrešaka u predviđanju. Posljedično, operateri elektroenergetskog sustava mogu imati veće povjerenje u model i manje potrebe za korekcijama “ručnim načinom”, što doprinosi učinkovitijem operativnom planiranju. Nadalje, ponovljivost i transparentnost metodologije potvrđene su kroz korištenje otvorenih podataka: cjelokupna strategija validirana je na javno dostupnim i dobro poznatim skupovima podataka za predviđanje opterećenja. To znači da istraživačka zajednica može izravno usporediti nove ili alternativne modele s ovdje prikazanim rezultatima, što postavlja novi referentni okvir za buduća istraživanja u području kratkoročnog predviđanja potrošnje. Kroz ovakvu rigoroznu validaciju, rad je dao doprinos ne samo u vidu poboljšanog modela, već i kroz demonstraciju pristupa koji je lakše usporediv, provjerljiv i primjenjiv na različite sustave. Ukupno gledajući, strategija predstavljena u ovom radu uspješno je ispunila zadane ciljeve: povećala je točnost predviđanja u odnosu na postojeće metode, smanjila potrebu za ručnim intervencijama pri izgradnji i održavanju modela, te osigurala ponovljiv i objektivan postupak koji je potvrđen na relevantnim stvarnim podatkovnim setovima. Takav sustavni pristup kratkoročnom predviđanju potrošnje električne energije predstavlja važan iskorak ka pouzdanijim i automatiziranim operativnim predviđanjima, a istovremeno stvara čvrstu osnovu za daljnja unaprjeđenja i istraživanja na ovom području.

5.4.2. Integrirana analiza rezultata na hrvatskom elektroenergetskom sustavu

5.4.2.1. Opća evaluacija hibridnog DNN-SVR okvira

U ovom radu analizirana je učinkovitost satno specijaliziranog hibridnog DNN-SVR okvira za kratkoročno predviđanje potrošnje električne energije na nacionalnoj razini. Analiza se temelji na opsežnom skupu podataka za Republiku Hrvatsku koji obuhvaća razdoblje od 17 godina, uz jasno izdvojenu neovisnu testnu godinu, čime je osigurana robusna i nepristrana evaluacija predloženog prognostičkog okvira.

Za razliku od pristupa u kojima se metoda potpornih vektora uvodi isključivo kao alternativni izlazni sloj neuronske mreže, u ovom su istraživanju objedinjeni elementi koji se rijetko razmatraju u jedinstvenom eksperimentalnom okviru. To uključuje satno specijaliziranu dekompoziciju prognostičkog zadatka kroz skup od 24 odvojena hibridna modela, sustavan postupak odabira značajki temeljen na algoritmima gradijentnog pojačanja, integraciju globalnih numeričkih meteoroloških prognoza iz TIGGE arhive te jedinstvenu usporedbu s modernim dubokim arhitekturama provedenim pod potpuno usklađenim eksperimentalnim uvjetima.

Dobiveni rezultati konzistentno ukazuju da takva strukturirana hibridizacija donosi mjerljiva poboljšanja u točnosti predviđanja. Komponente dubokih neuronskih mreža djeluju kao nelinearni ekstraktori značajki prilagođeni pojedinim satima u danu, dok SVR regresijske faze, osobito s RBF jezgrom, učinkovito iskorištavaju kompaktne naučene reprezentacije za postizanje nižih pogrešaka u odnosu na samostalne DNN i SVR modele. U usporedbi s baznim LSTM i Transformer-temeljenim modelima, implementiranim prema istom skupu podataka i evaluacijskom protokolu, predloženi hibridni okvir postiže usporedivu ili bolju točnost, osobito na izdvojenoj testnoj godini 2022., čime se dodatno potvrđuje njegova praktična vrijednost u realnim STLF primjenama.

5.4.2.2. Sinergija dubokih neuronskih mreža i SVR regresije

Ključni doprinos predloženog hibridnog modela proizlazi iz sinergijske kombinacije dviju komplementarnih komponenti. Duboka neuronska mreža služi kao snažan nelinearni ekstraktor značajki, pri čemu uči apstraktne reprezentacije iz povijesnih podataka o potrošnji električne energije, meteoroloških varijabli i vremenskih obilježja. Na tim naučenim reprezentacijama

regresijska faza temeljena na metodi potpornih vektora (SVR), osobito uz primjenu RBF jezgre, ostvaruje robusnu i preciznu aproksimaciju ciljne varijable.

Takav dvostupanjski postupak omogućuje iskorištavanje prednosti oba pristupa: duboko učenje učinkovito modelira složene nelinearne obrasce koji bi samostalnom SVR modelu često ostali nedostupni, dok SVR osigurava stabilnu regresijsku granicu koja se u praksi pokazuje učinkovitijom od jednostavnog gusto povezanog izlaznog sloja neuronske mreže. Za najbolje razmatrane konfiguracije, hibridni DNN-SVR model ostvario je MAPE od 1,8950%, što predstavlja relativno smanjenje pogreške od 4,62% u odnosu na samostalni DNN model (MAPE = 1,9867%).

Zanimljivo je uočiti da hibridni DNN-SVR model nadmašuje i pristup temeljen na kombinaciji Transformer arhitekture i SVR regresije, iako oba koriste identičnu SVR regresijsku fazu. Razlog takvog ponašanja može se pripisati prirodi naučenih reprezentacija i dizajnu ulaznog prostora. Transformer modeli, temeljeni na mehanizmu samopažnje, generiraju kontekstualno ponderirane reprezentacije koje su često rjeđe i distribuiranije, dok potpuno povezani slojevi DNN-a proizvode gušće i homogenije značajke koje su prikladnije za kernel-temeljenu regresiju s RBF jezgrom. Dodatno, satno uvjetovani DNN modeli koriste pažljivo odabrane skupove značajki (tipično 30–40 po satu), dobivene postupkom odabira temeljenim na algoritmima gradijentnog pojačanja, čime se postiže kompaktniji i informativniji ulazni prostor prilagođen specifičnom prognostičkom zadatku.

Primijenjena dvostupanjska strategija treniranja, pri kojoj se parametri DNN enkodera i SVR regresijske faze optimiraju odvojeno, omogućuje jasnu atribuciju doprinosa svake komponente. Provedena ablacijska analiza potvrdila je da smanjenje pogreške proizlazi iz strukturne integracije kernel-temeljene regresije nad dubokim reprezentacijama, a ne iz slučajnih inicijalizacija ili pojedinačnih realizacija procesa treniranja.

5.4.2.3. Utjecaj strategije modeliranja i satne dekompozicije

Dobiveni rezultati jasno ukazuju na presudnu ulogu strategije modeliranja u zadatku kratkoročnog predviđanja potrošnje električne energije. Satno specijalizirani pristup, u kojem se trenira 24 odvojena prognostička modela (po jedan za svaki sat u danu), pokazao se znatno učinkovitijim od jedinstvenog prediktivnog modela koji istodobno aproksimira sve intradnevne režime potrošnje.

Takva dekompozicija prognostičkog zadatka omogućuje svakom pojedinom modelu da se prilagodi specifičnim obrascima potrošnje karakterističnima za pojedine sate u danu, poput izraženih jutarnjih rampi, poslijepodnevnih vršnih opterećenja ili stabilnijih noćnih režima. Posebno u slučaju feed-forward DNN arhitektura, satna specijalizacija pokazala se učinkovitijom strategijom od pokušaja generalizacije preko cjelodnevnog profila opterećenja.

Empirijski rezultati potvrđuju da jedinstveni modeli, iako raspolažu većim ukupnim brojem uzoraka, moraju istodobno aproksimirati heterogene intradnevne odnose, što dovodi do povećane prosječne pogreške. Nasuprot tome, satno specijalizirani modeli uspijevaju smanjiti složenost problema učenja fokusiranjem na užu i homogeniji distribucijski prostor, čime se postiže dosljedno niža pogreška predviđanja. Ovi nalazi u potpunosti su u skladu s zaključcima iz literature i dodatno potvrđuju da je strategija modeliranja ključan čimbenik uspješne primjene dubokih neuronskih mreža u STLF zadacima.

5.4.2.4. Generalizacijska svojstva i skalabilnost metodološkog okvira

Provedena analiza pokazala je jasnu povezanost između duljine razvojnog razdoblja korištenog za učenje modela i točnosti kratkoročnog predviđanja potrošnje električne energije. Dulja razvojna razdoblja omogućuju modelima učenje stabilnijih sezonskih, intragodišnjih i dugoročnih obrazaca potrošnje, što se dosljedno očituje u nižim vrijednostima pogreške. Istodobno, takav pristup podrazumijeva povećani računalni trošak, osobito u fazi optimizacije hiperparametara SVR regresijske faze unutar hibridnog modela.

Dodatno, uključivanje prognostičkih varijabli iz TIGGE arhive dovelo je do konzistentnog smanjenja pogreške u svim razmatranim konfiguracijama, pri čemu su najveća poboljšanja zabilježena u satno specijaliziranom hibridnom okviru.

Dobiveni rezultati potvrđuju da prognostičke varijable temeljene na globalnim numeričkim modelima atmosfere predstavljaju vrijedan izvor vremenski unaprijed dostupnih informacija koje učinkovito nadopunjuju povijesne podatke o opterećenju i lokalna meteorološka mjerenja, osobito u kontekstu satno uvjetovanih prognostičkih modela. U tom smislu, empirijski nalazi dodatno podupiru istraživačku pretpostavku da integracija egzogenih prognostičkih meteoroloških informacija može sustavno unaprijediti generalizacijska svojstva hibridnih STLF modela.

5.4.2.5. Operativne implikacije i računalna složenost

S operativnog gledišta, predloženi hibridni DNN-SVR model u satno specijaliziranoj konfiguraciji nudi izravne i mjerljive koristi za upravljanje elektroenergetskim sustavom. U usporedbi s referentnim prognostičkim pristupima, ostvarena su relativna smanjenja pogreške u rasponu od 9,8% do 21,4%, što se u praksi može izravno reflektirati na točnije planiranje proizvodnje, smanjenje potrebnih pričuvnih kapaciteta te učinkovitije vođenje sustava, osobito u uvjetima povećane penetracije varijabilnih obnovljivih izvora energije.

Povećana točnost kratkoročnih prognoza omogućuje pouzdanije odluke u procesima planiranja dan-unaprijed i intradnevnog upravljanja, čime se smanjuju troškovi uravnoteženja i potreba za korektivnim mjerama u stvarnom vremenu. U tom smislu, predloženi hibridni okvir ima jasan potencijal za operativnu primjenu u stvarnim elektroenergetskim sustavima.

S druge strane, primjena satno specijalizirane strategije učenja podrazumijeva povećanu računalnu složenost, budući da je potrebno trenirati 24 odvojena hibridna DNN-SVR modela. Međutim, taj se dodatni trošak pokazuje operativno prihvatljivim u scenarijima povremenog ponovnog treniranja modela (npr. mjesečno ili kvartalno), pri čemu ostvareni dobici u točnosti opravdavaju dodatno računalno opterećenje.

Na korištenoj računalnoj infrastrukturi, ukupno vrijeme treniranja kompletnog skupa od 24 satno specijalizirana hibridna modela iznosi približno 60–90 minuta, uključujući optimizaciju hiperparametara SVR regresijske faze. Takvo vrijeme treniranja usporedivo je s naprednim Transformer-temeljenim modelima, dok je istodobno znatno kraće od vremena potrebnog za treniranje složenijih LSTM Seq2Seq arhitektura, koje u pravilu zahtijevaju 2–3 sata. Za primjene koje zahtijevaju češće ažuriranje modela moguće je razmotriti alternativne arhitekture s drukčijim kompromisom između točnosti i računalne učinkovitosti.

5.4.2.6. Generalizacija i skalabilnost pristupa

Iako je predložena metodologija validirana na podacima hrvatskog elektroenergetskog sustava, sam prognostički okvir osmišljen je s jasnim naglaskom na prenosivost i opću primjenjivost. Strategija satne dekompozicije prognostičkog zadatka primjenjiva je na sve elektroenergetske sustave s izraženim intradnevnim obrascima potrošnje, što obuhvaća većinu stvarnih elektroenergetskih sustava. Dodatno, inženjering značajki temelji se na standardnim meteorološkim

varijablama (temperatura, vlaga, tlak, vjetar) dostupnima na globalnoj razini putem NWP sustava, poput TIGGE arhive, dok arhitektura modela ne sadrži elemente specifične za Hrvatsku.

Primjena predloženog pristupa u drugim europskim državama moguća je bez strukturnih prilagodbi modela, budući da su usporedivi podaci o potrošnji električne energije dostupni putem platforme ENTSO-E Transparency Platform. Jedina nužna prilagodba odnosi se na ponovno treniranje modela kako bi se obuhvatili regionalno specifični obrasci potrošnje, primjerice razlike između sustava s dominantnim utjecajem grijanja ili hlađenja te različite industrijske i društvene strukture potrošnje.

Za veće višeregionalne ili kontinentalne sustave, predložena arhitektura pokazuje povoljna skalabilna svojstva. Satno specijalizirani okvir skalira se linearno s brojem regija, pri čemu bi za sustav s N regija bilo potrebno trenirati $24N$ modela, što je u praksi izvedivo zahvaljujući mogućnosti paralelnog treniranja i izvođenja na suvremenoj GPU infrastrukturi. Takva linearna skalabilnost, u kombinaciji s mogućnošću paralelnog treniranja na suvremenoj GPU infrastrukturi, potvrđuje da predloženi okvir nije samo metodološki utemeljen, već i tehnički izvediv u velikim operativnim sustavima.

Dodatno, okvir se može proširiti prema hijerarhijskim prognostičkim strukturama u kojima se regionalne prognoze agregiraju uz uvažavanje međuregionalnih tokova snage i ograničenja prijenosne mreže. Takav smjer predstavlja prirodno proširenje ovog rada te otvara mogućnosti integracije hibridnog DNN-SVR pristupa u složenije sustave odlučivanja i napredne mehanizme upravljanja elektroenergetskim sustavima.

6. EKSPERIMENTALNA VALIDACIJA I KOMPARATIVNA ANALIZA MODELA ZA KRATKOROČNO PREDVIĐANJE CI- JENA PRIRODNOG PLINA

6.1. Skup podataka i postavke eksperimenta

U ovom poglavlju analizira se kratkoročno predviđanje cijena prirodnog plina na tržištu Henry Hub. Ciljana varijabla jest dnevna spot cijena na čvorištu Henry Hub, a svi podaci prikupljeni su iz baze podataka Bloomberg. Budući da se trgovanje odvija primarno radnim danima, vremenska struktura serije prilagođena je raspoloživosti tržišnih kotacija. Analiza je provedena za dva prognozna horizonta: dan unaprijed i tjedan unaprijed.

Eksperimentalna analiza (ST-NGPF) provodi se u skladu s unificiranim metodološkim okvirom definiranim u Poglavlju 4.. Primjenjuje se SSA-SVR konfiguracija, koja obuhvaća konstrukciju proširenog ulaznog prostora s vremenskim pomacima i sezonskim indikatorima, automatizirani odabir značajki na razvojnim podacima, optimizaciju hiperparametara SVR modela nad validacijskim skupom te završnu evaluaciju na izdvojenom testnom razdoblju. Sljedeće podsekcije opisuju domenski specifičnu implementaciju tog okvira.

6.1.1. Skup ulaznih varijabli i domenska motivacija

Za potrebe modeliranja odabran je prošireni skup ulaznih varijabli koji obuhvaća tržišne cijene, energetske pokazatelje, meteorološke čimbenike te fundamentalne i sezonske varijable.

Sve korištene vremenske serije preuzete su iz Bloomberg baze podataka. Takav odabir varijabli temelji se na ekonomskoj teoriji tržišta energenata i prethodnim empirijskim istraživanjima.

Ključne ulazne varijable uključuju:

- **Cijena prirodnog plina (Henry Hub, označeno kao NG)** – aktualna spot cijena i pripadne diferencije (NG_{df}). Nedavne razine i trend cijene plina važni su pokazatelji zbog snažne autokorelacije, dok diferencija hvata kratkoročni moment kretanja tržišta.
- **Cijene ostalih energenata:** kretanje cijena supstituta i povezanih energenata, čije promjene mogu signalizirati promjene u potražnji za plinom ili u općim tržišnim uvjetima.
 - *Cijena loživog ulja* (New York Harbor, oznaka HO1; označeno kao HO) i njezina diferencija (HO_{df}) – loživo ulje je zamjenjivo s plinom u grijanju (npr. sjeveroistok SAD-a), pa kretanje njegove cijene utječe na potražnju za plinom.
 - *Cijena sirove nafte (WTI; označeno kao WTI)* i njezina diferencija (WTI_{df}) – indikator šireg energetskeg tržišta, povijesno povezan s cijenom plina preko dugoročnih ugovora i konkurencije u energetskeg sektoru.
 - *Cijena ugljena* (Appalachian Mountains, oznaka COALBSGD; označeno kao COAL) i njezina diferencija ($COAL_{df}$) – izravni konkurent plinu u proizvodnji električne energije; kretanje cijene ugljena utječe na *fuel-switching* u termoelektranama.
- **Meteorološki pokazatelji:** meteorološke varijable temeljene na temperaturi na području sjeveroistočnog SAD-a, regije s najvećom potrošnjom plina. Kao što je opisano u Poglavlju 4.2., korišteni su *degree day* pokazatelji definirani pragovima od 20 °C, 16.5 °C i 5 °C [21, 60]: indeksi grijanja (T_h i T_{ah}) rastu pri nižim temperaturama zbog pojačanog korištenja plina za grijanje, dok indeks hlađenja (T_c) raste iznad 20 °C uslijed povećanih potreba za klimatizacijom. Za treniranje modela korištene su povijesne prognostičke temperature.
- **Tržišni (fundamentalni) pokazatelji:** varijable koje reflektiraju ponudu prirodnog plina na tržištu SAD-a.
 - *Broj aktivnih bušotina za plin* (Baker Hughes Gas Rig Count, oznaka BAKEGAS; označeno kao NGRUS) – indikator investicijske i proizvodne aktivnosti; rast broja bušotina sugerira budući rast ponude plina, dok pad signalizira smanjenje buduće ponude.
 - *Dnevna proizvodnja prirodnog plina u SAD-u (NGMPTOLT, mjerena u Bcf/d;*

- označeno kao NGPR) – ukupna isporučena (*marketed*) dnevna proizvodnja plina, čija viša razina znači veću dostupnost plina na tržištu.
- *Uvoz prirodnog plina iz Kanade* (**NAGSCANI**, u Bcf/d; označeno kao NGIC)
 - količina plina koja se dnevno uvozi cjevovodom iz Kanade, važnog vanjskog dobavljača plina za SAD.
 - **Sezonske varijable:** binarne (*dummy*) varijable za kodiranje perioda u tjednu (7 varijabli) i godini (12 varijabli za mjesec). Ove varijable poprimaju vrijednost 1 za pripadajući dan/mjesec, a 0 inače, čime model može naučiti sezonske obrasce poput sustavno većih cijena zimi ili različite volatilnosti radnim danima u odnosu na vikend [60].

Kombinacija navedenih varijabli pruža modelu sveobuhvatan opis tržišnih, fundamentalnih i sezonskih čimbenika koji utječu na kretanje cijene prirodnog plina. Odabir se temelji na ekonomskoj teoriji i empirijskim istraživanjima: vlastita povijest cijene odražava autokorelacijsku strukturu serije, cijene supstituta prenose informacije o konkurenciji energenata, meteorološki pokazatelji kvantificiraju utjecaj vremenskih uvjeta na potražnju, fundamentalni indikatori reflektiraju ravnotežu ponude i potražnje, a sezonske *dummy* varijable omogućuju aproksimaciju ponavljajućih obrazaca [60].

6.1.2. Konstrukcija značajki: vremenske odgode i transformacije

Za sve kontinuirane varijable (cijene i količine) generirane su vremenski pomaknute vrijednosti (lagovi) kako bi se obuhvatila dinamika promjena i autokorelacijska struktura serije. Uključeno je do 30 dana povijesnih vrijednosti za svaku varijablu (*lag 1* do *lag 30*), čime je početni skup proširen na približno 300 potencijalnih ulaza (30 lagova $\times$ desetak vremenskih serija).

Tako proširen skup omogućuje obuhvaćanje suptilnih utjecaja s odgođenim djelovanjem, ali istodobno povećava rizik prenaučenosti. Stoga je implementiran automatski korak odabira značajki (FS) s ciljem reduciranja ulaznog prostora na najrelevantnije prediktore i poboljšanja generalizacijskih svojstava modela.

6.1.3. Definicija eksperimentalnih skupova ulaza

Radi sustavne procjene marginalnog doprinosa pojedinih grupa značajki na točnost predviđanja, definirano je više eksperimentalnih konfiguracija ulaznih varijabli. U zagradama su navedene

skraćenice koje se koriste u tablicama rezultata.

- **Osnovni skup (OSN)** – skup tržišnih i fundamentalnih varijabli povezanih s tržištem prirodnog plina i energenata:
 - cijena prirodnog plina (NG) i diferencirana cijena (NG_{df}),
 - cijena loživog ulja (HO) i diferencirana cijena (HO_{df}),
 - cijena WTI nafte (WTI) i diferencirana cijena (WTI_{df}),
 - cijena ugljena (COAL) i diferencirana cijena ($COAL_{df}$),
 - broj aktivnih bušotina za prirodni plin u SAD-u (NGRUS),
 - dnevna proizvodnja prirodnog plina u SAD-u (NGPR),
 - uvoz prirodnog plina iz Kanade (NGIC, Bcf/d).
- **OSN+DAN** – osnovni skup proširen binarnim indikatorima dana u tjednu.
- **OSN+MJES** – osnovni skup proširen binarnim indikatorima mjeseca u godini.
- **OSN+MET** – osnovni skup proširen temperaturnim pokazateljima (*heating degree days*, *cooling degree days*) za sjeveroistočni dio SAD-a.
- **SVE** – konfiguracija koja uključuje sve prethodno navedene varijable. U slučajevima primjene algoritama za odabir značajki (FS), u model su uključene isključivo varijable odabrane u fazi selekcije.

6.1.4. Odabir značajki i procedure treniranja

Za automatsko određivanje optimalnog podskupa ulaznih varijabli primijenjeni su isti FS algoritmi kao i u STLFI domeni (Odjeljak 4.3.2.): GA&IT, MRMR, ReliefF i Stepwise FS. Broj odabranih varijabli određen je eksperimentalno (5 ili 10 najviše rangiranih značajki), uz procjenu performansi na validacijskom skupu.

Isti podskupovi značajki korišteni su pri treniranju SVR i NN modela, čime je osigurana metodološki dosljedna usporedba. Postupak je proveden isključivo na razvojnom skupu, bez uključivanja informacija iz testnog razdoblja, u skladu sa slijedom FS → HPO → završno treniranje, definiranim u Odjeljku 4.4..

6.1.5. Podjela podataka, metrike i protokol evaluacije

Za potrebe modeliranja korišten je vremenski kontinuiran skup podataka u razdoblju 2010.–2014. godine. Predviđanje je provedeno za horizonte jedan dan unaprijed i jedan tjedan unaprijed.

Podjela podataka provedena je kronološki, bez miješanja uzoraka između skupova, čime je očuvana vremenska struktura serije i izbjegnuto informacijsko propuštanje iz budućih razdoblja. Promatrano razdoblje podijeljeno je na:

- **Skup za treniranje:** 2010.–2012. godine – podaci korišteni za učenje parametara modela.
- **Validacijski skup:** 1. 1. 2013.–31. 12. 2013. – podaci korišteni za odabir značajki, optimizaciju hiperparametara i izbor konačne konfiguracije modela.
- **Testni skup:** 1. 1. 2014.–31. 12. 2014. – potpuno izdvojeni podaci za završnu evaluaciju prediktivne točnosti.

Skup za treniranje i validacijski skup zajedno čine razvojni skup (2010.–2013.), u skladu s terminologijom uvedenom u metodološkom okviru rada.

Takva podjela omogućuje učenje sezonskih i trend-komponenti na višegodišnjem razdoblju, uz zasebnu validacijsku godinu za optimizaciju modela i neovisnu testnu godinu za objektivnu procjenu generalizacijskih svojstava. Za kvantitativnu evaluaciju korištene su MAPE (u postocima) i RMSE (skaliran faktorom 100). Testni skup sadrži 252 promatranja.

6.2. Jednodnevno predviđanje cijene prirodnog plina: rezultati i komparativna analiza

U ovom odjeljku ispituje se utjecaj algoritama za odabir značajki na jednodnevno predviđanje cijene prirodnog plina. Najprije se analiziraju različiti FS pristupi u okviru SVR modela (stepwise, GA, MRMR i Relief), uključujući referentne konfiguracije temeljene na vremenskim odgodama (L5 i L10). Nakon identifikacije optimalne konfiguracije, isti podskup značajki primjenjuje se i na NN model, a performanse se uspoređuju s naivnim pristupom te optimiranim AR i ARIMA modelima. Rezultati su prikazani u Tablicama 6.1, 6.2 i 6.3.

Tablica 6.1: Rezultati SVR modela s odabirom značajki (5 varijabli) - jednostnevna prognoza

	Značajke	OSN		OSN+DAN		OSN+MJES		OSN+MET		SVE	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
SVR (sve)		16.16	2.64	18.78	3.48	23.11	4.02	18.95	3.51	25.17	4.82
SVR SW	NG(1)	14.01	2.21	14.18	2.22	14.42	2.29	14.12	2.21	14.10	2.21
	NG_df(1,8)										
	HO_df(5)										
	NGRUS_df(20)										
SVR MRMR	NG(1,2,4)	14.37	2.28	14.28	2.27	14.51	2.32	14.39	2.29	14.37	2.30
	HO_df(21)										
	BAKG(1)										
SVR GA	NG(1,2)	14.05	2.24	14.31	2.23	14.43	2.34	14.18	2.24	14.20	2.26
	BAKG_df(1,8)										
	COAL(14)										
SVR Relief	NG_df(1-4,6)	15.40	3.92	87.07	16.75	89.51	17.17	79.81	15.50	89.55	17.18
SVR (L5)	NG(1-5)	18.96	2.61	14.25	2.28	14.30	2.27	14.09	2.24	14.19	2.27

* Brojevi u zagradama predstavljaju broj vremenskih odgoda.

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

Tablica 6.2: Rezultati SVR modela s odabirom značajki (10 varijabli) - jednodnevna prognoza

	Značajke	OSN		OSN+DAN		OSN+MJES		OSN+MET		SVE	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
SVR (sve)		16.16	2.64	18.78	3.48	23.11	4.02	18.95	3.51	25.17	4.82
SVR SW	NG(1)	14.13	2.25	13.75	2.18	14.01	2.24	13.90	2.26	13.83	2.25
	NG_df(3,6)										
	HO(29)										
	HO_df(5,11,14)										
	BAKG_df(29)										
	NGRUS_df(17)										
	COAL(30)										
SVR MRMR	NG(1-6,12)	14.31	2.26	14.42	2.28	14.74	2.36	14.18	2.24	14.36	2.31
	NG_df(15)										
	HO(27)										
	BAKG(1)										
SVR GA	NG(1-3,5)	14.26	2.28	14.43	2.31	14.15	2.23	14.15	2.23	14.34	2.29
	BAKG_df(2,3,9-11)										
	COAL(9)										
SVR Relief	NG(1-4)	14.22	2.25	14.17	2.25	14.27	2.24	14.41	2.26	14.37	2.26
	NG_df(1-6)										
SVR (L10)	NG(1-10)	14.76	2.26	14.29	2.24	14.34	2.25	14.59	2.30	14.27	2.26

* Brojevi u zagradama predstavljaju broj vremenskih odgoda.

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

6.2.1. Učinak algoritama za odabir značajki na SVR model

Tablice 6.1 i 6.2 prikazuju rezultate jednodnevnih prognoza SVR modela uz različite FS algoritme. U stupcu *Značajke* navedene su varijable koje je pojedini algoritam prepoznao kao najrelevantnije.

Analiza pokazuje da u pogledu točnosti prednjači *Stepwise* algoritam. S ograničenjem na pet varijabli, Stepwise daje najbolje rezultate u gotovo svim konfiguracijama; jedina iznimka javlja se uz dodane varijable mjeseca, gdje L5 model ostvaruje neznatno bolji MAPE, no razlika je minimalna ($< 0.05\%$).

Kod odabira deset varijabli dolazi do vidljivog porasta točnosti, osobito proširenjem osnovnog skupa danima u tjednu i meteorološkim čimbenicima. SVR s FS-om (10 značajki) postiže MAPE od 2.18% , dok SVR bez FS-a ostaje na 2.64% , što predstavlja relativno smanjenje pogreške od približno 17% . Svi modeli sa selekcijom značajki ostvarili su osjetno bolje rezultate od SVR modela s punim skupom ulaza (SVR (sve)), čime se potvrđuje da je selekcija značajki ključan korak za povećanje točnosti prognoze.

Tablica 6.3: Usporedba odabranih modela za jednodnevnu prognozu (rezultati na testnom skupu)

	5 značajki (FS)		10 značajki (FS)	
	RMSE	MAPE	RMSE	MAPE
SVR (sve)	16.16	2.64	16.16	2.64
SVR (SW FS)	14.01	2.21	13.75	2.18
NN (sve)	17.05	2.85	17.05	2.85
NN (SW FS)	14.50	2.30	14.10	2.24
Naivni (lag 1)	15.00	2.50	15.00	2.50
AR(opt)	14.80	2.40	14.80	2.40
ARIMA(opt)	14.70	2.38	14.70	2.38

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

6.2.2. Komparativna analiza modela na testnom skupu

Tablica 6.3 uspoređuje najbolje konfiguracije modela strojnog učenja s klasičnim modelima vremenskih serija. ARIMA(opt) ostvaruje MAPE od 2.38% (RMSE 14.70), dok SVR bez FS-a

postiže 2.64%. Nakon primjene stepwise algoritma, SVR smanjuje pogrešku na 2.18% (RMSE 13.75), što predstavlja relativno poboljšanje od približno 8% u odnosu na ARIMA. Sličan obrazac uočen je i kod NN: bez FS-a MAPE iznosi 2.85%, a uz stepwise FS pada na 2.24%.

Klasični modeli i naivni pristup (MAPE 2.50%) nadmašuju modele strojnog učenja bez selekcije varijabli, no nakon primjene FS-a modeli strojnog učenja – osobito SVR – postižu najbolju ukupnu točnost.

◦

6.3. Jednotjedno predviđanje cijene prirodnog plina: rezultati i komparativna analiza

U ovom odjeljku analizira se predviđanje cijene prirodnog plina za horizont od sedam dana unaprijed, pri čemu se očekuje veći utjecaj tržišnih i fundamentalnih čimbenika te smanjen doprinos kratkoročnih fluktuacija. Eksperimentalni okvir identičan je prethodno opisanom. Rezultati su prikazani u Tablicama 6.4, 6.5 i 6.6.

6.3.1. Učinak algoritama za odabir značajki na SVR model

Usporedba rezultata u Tablicama 6.4 i 6.5 pokazuje da Stepwise algoritam dosljedno nadmašuje ostale pristupe. Primjena FS-a donosi izrazito smanjenje pogreške: MAPE s 6.88% pada na 4.23% (pet značajki) odnosno 4.31% (deset značajki), što predstavlja relativno poboljšanje od približno 39% odnosno 37%. GA i MRMR ostvaruju umjereno poboljšanje, dok se Relief pokazao nepouzdanim.

Uključivanje mjesečnih varijabli nije unaprijedilo točnost; naprotiv, u većini konfiguracija zabilježeno je blago pogoršanje (npr. SVR SW s deset varijabli u skupu OSN+MJES postiže MAPE od 4.38% naspram 4.31% u osnovnom skupu). Kod jednotjednog predviđanja uočen je veći raspon performansi među FS algoritmima nego u jednodnevnom slučaju, što naglašava osjetljivost duljeg horizonta na kvalitetu selekcije značajki. Kao i u jednodnevnom horizontu, naivni i AR/ARIMA modeli nadmašuju modele strojnog učenja bez FS-a, no nakon primjene FS algoritama razlika je izražena u korist strojnog učenja.

Tablica 6.4: Rezultati SVR modela s odabirom značajki (5 varijabli) - tjedno

	Značajke	OSN		OSN+MJES	
		RMSE	MAPE	RMSE	MAPE
SVR (sve)		39.43	6.88	44.06	7.04
SVR SW	NG(7,28) HO(36) BAKG_df(23) COAL(36)	29.04	4.23	34.19	5.43
SVR MRMR	NG(7,9,25) HO_df(18) COAL(7)	38.29	6.67	38.24	6.67
SVR GA	NG(7) BAKG_df(14,15,22) COAL(18)	32.82	5.86	34.48	6.19
SVR Relief	NG_df(9,10,13,14) HO_df(11)	70.14	14.23	72.63	14.31
	NG(7-11)	33.95	6.70	33.87	6.69

* Brojevi u zagradama predstavljaju broj vremenskih odgoda.

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

Tablica 6.5: Rezultati SVR modela s odabirom značajki (10 varijabli) - tjedno predviđanje

	Značajke	OSN		OSN+MJES	
		RMSE	MAPE	RMSE	MAPE
SVR (sve)		39.43	6.88	44.06	7.04
SVR SW	NG(7,28)	27.82	4.31	28.85	4.38
	HO(22,34)				
	BAKG_df(23,25)				
	NGRUS(23)				
	COAL(27,34)				
SVR MRMR	NG(7-10,13,22)	32.31	4.89	35.36	5.32
	NG_df(24)				
	HO_df(13)				
	NGRUS(30)				
	COAL(13)				
SVR GA	NG(7,10,36)	31.82	4.85	34.86	5.02
	BAKG_df(17,20-25)				
	COAL(16,33)				
SVR Relief	NG_df(7,8,11,13,14)	75.13	15.04	68.22	14.55
	HO(13-17)				
SVR (L10)	NG(7-16)	31.53	4.87	34.86	5.24

* Brojevi u zagradama predstavljaju broj vremenskih odgoda.

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

Tablica 6.6: Usporedba odabranih modela za tjednu prognozu (rezultati na testnom skupu)

	5 značajki (FS)		10 značajki (FS)	
	RMSE	MAPE	RMSE	MAPE
SVR (sve)	39.43	6.88	39.43	6.88
SVR SW	29.04	4.23	27.82	4.31
NN (sve)	37.15	6.33	37.15	6.33
NN SW	30.22	4.73	28.75	4.55
Naïve	32.36	4.89	32.36	4.89
AR(opt)	31.97	4.80	31.97	4.80
ARIMA(opt)	31.89	4.76	31.89	4.76

** MAPE je izražen u postocima, a RMSE je skaliran faktorom 100.

6.3.2. Komparativna analiza modela na testnom skupu

Rezultati iz Tablice 6.6 potvrđuju da primjena FS-a na jednotjednom horizontu dolazi do izražaja još snažnije nego kod jednodnevnog. ARIMA(opt) ostvaruje MAPE od 4.76% (RMSE 31.89), dok SVR bez FS-a postiže znatno lošijih 6.88%. Nakon primjene stepwise algoritma, SVR ostvaruje MAPE od 4.23% (RMSE 29.04), što predstavlja poboljšanje od oko 11% u odnosu na ARIMA(opt). Sličan obrazac uočen je kod NN: bez FS-a MAPE iznosi 6.33%, a uz FS pada na 4.55% (RMSE 28.75).

Naivni model (MAPE 4.89%) i autoregresivni modeli (AR 4.80%, ARIMA 4.76%) nadmašuju SVR i NN bez FS-a, ali zaostaju za njihovim optimiziranim verzijama. Zajednički zaključak oba horizonta jest da klasični modeli ostaju snažna referentna točka, no nakon pravilnog odabira značajki modeli strojnog učenja – osobito SVR – dosljedno nadmašuju tradicionalne pristupe.

6.4. Analiza robusnosti eksperimentalne postavke

Radi provjere stabilnosti rezultata ispitane su brojne alternativne konfiguracije ulaznih varijabli, transformacija i podjela podataka:

- Redukcija ulaznog prostora – uključujući konfiguracije s isključivo cijenom plina i njezinim transformacijama.

- Alternativne transformacije varijabli – logaritamske transformacije, razlike, log-razlike, kvadratni korijeni i njihove kombinacije.
- Varijacije validacijskih i trenirajućih razdoblja – skraćivanje vremenskog horizonta i duljine validacijskog razdoblja.
- Modeliranje po podskupovima – zasebno treniranje po mjesecima ili kalendarskim danima, uz različite duljine prozora.

Nijedna alternativna konfiguracija nije dovela do sustavnog poboljšanja točnosti u odnosu na konačno odabranu postavku. Također, pristup temeljen na vrlo kratkim razdobljima treniranja, koji se u literaturi često preporučuje za SVR, nije rezultirao poboljšanjem. Ovi eksperimenti potvrđuju da odabrana konfiguracija predstavlja stabilno rješenje unutar šireg prostora mogućih varijanti.

6.5. Diskusija i sažetak ključnih nalaza

Ovo istraživanje analiziralo je kratkoročnu predvidljivost spot cijena prirodnog plina na tržištu Henry Hub primjenom unificirane SSA–SVR konfiguracije te usporednom evaluacijom klasičnih modela vremenskih serija (naivni, AR i ARIMA) i modela strojnog učenja (NN i SVR). Primarni cilj bio je ispitati doprinos složenijih modela u odnosu na klasične pristupe te učinak veličine ulaznog prostora na točnost predviđanja, na tržištu poznatom po visokoj volatilnosti.

Rezultati jednodnevnih predviđanja pokazuju da je odabir značajki ključni čimbenik poboljšanja točnosti strojnog učenja. Stepwise metoda dosljedno je ostvarivala najniže pogreške, dok dodatne sezonalne i temperaturne varijable nisu sustavno doprinosile poboljšanju. Bez FS-a, modeli strojnog učenja bili su inferiorniji od AR i ARIMA modela; primjena FS-a uklonila je taj zaostatak. Kod jednodnevnih predviđanja uloga FS-a bila je još izraženija, uz veće razlike među algoritmima i ponovnu superiornost stepwise pristupa.

Usporedba s klasičnim vremenskim serijama potvrđuje da AR i ARIMA modeli predstavljaju snažnu referentnu točku. Bez FS-a, SVR i NN nisu nadmašili ni te pristupe ni naivni model. Međutim, uz pravilnu selekciju značajki modeli strojnog učenja ostvarili su blagu, ali konzistentnu prednost, osobito na jednodnevnom horizontu.

Analiza odabranih značajki pokazuje da se u oba horizonta kao najrelevantnije dosljedno pojavljuju: prošle vrijednosti cijene plina, cijene loživog ulja, proizvodnja plina u SAD-u, broj

aktivnih bušotina te cijene ugljena, čime se potvrđuje stabilnost temeljnih tržišnih determinanti. Rezultati također pokazuju da povećavanje broja ulaznih varijabli ne dovodi nužno do poboljšanja – restriktivniji skup pažljivo odabranih značajki davao je bolje rezultate, podupirući načelo „less is more”.

Nalazi su konzistentni s ranijim istraživanjima: Busse i sur. [18] na njemačkom tržištu također zaključuju da se najtočnija predviđanja postižu ograničenim brojem temeljnih varijabli, a slične zaključke navode Nguyen i Nabney [93] te Salehnia i sur. [112].

Iako su poboljšanja SVR-a uz FS u odnosu na ARIMA u pojedinim slučajevima umjerena, ona su konzistentna, što upućuje na inherentna ograničenja kratkoročnog predviđanja Henry Hub cijena. Sveukupno, ključ uspjeha nije u kompleksnosti modela, već u pažljivoj redukciji ulaznog prostora – pravilno odabrani podskup značajki omogućuje modelima strojnog učenja da iskoriste svoju nelinearnu fleksibilnost i ostvare rezultate bolje od tradicionalnih ARIMA modela čak i na izrazito volatilnom tržištu poput Henry Hub.

7. ZAKLJUČAK I SMJERNICE ZA DALJ-NJA ISTRAŽIVANJA

Ovaj rad bavi se razvojem i sustavnom evaluacijom metodološkog okvira za kratkoročno predviđanje ključnih varijabli u energetske sustavima, s posebnim naglaskom na potrošnju električne energije i cijenu prirodnog plina. Istraživanje je usmjereno na integraciju potpornih vektorskih metoda, kontrolirane konstrukcije ulaznog prostora, automatizirane selekcije značajki i optimizacije hiperparametara u konzistentan i reproducibilan modelni proces.

U radu je pokazano da se strukturirani SVR-bazirani pristupi mogu uspješno primijeniti u tehnički i tržišno različitim kontekstima, dok hibridni modeli koji kombiniraju duboko učenje i SVR regresijsku komponentu predstavljaju metodološku nadogradnju u domeni kratkoročnog predviđanja opterećenja. Dobiveni rezultati potvrđuju postavljene istraživačke hipoteze te naglašavaju važnost sustavne izgradnje modela u odnosu na puko povećanje njihove složenosti.

U nastavku poglavlja sintetiziraju se ključni rezultati, znanstveni doprinosi, metodološke implikacije, ograničenja istraživanja te smjernice za daljnji razvoj prediktivnih pristupa u energetici.

7.1. Sažetak ciljeva

Primarni cilj ovog rada bio je uspostaviti metodološki utemeljen i generički okvir za kratkoročno predviđanje u energetske sustavima, primjenjiv na tehničke (STLF) i tržišne (ST-NGPF) domene. Poseban naglasak stavljen je na razvoj i validaciju SVR-baziranih modela te na ispitivanje njihove nadogradnje kroz integraciju dubokog učenja u kontekstu kratkoročnog predviđanja opterećenja.

Dodatni ciljevi obuhvaćali su analizu utjecaja konstrukcije ulaznog prostora, selekcije

značajki, vremenske dekompozicije modela i integracije egzogenih podataka na konačnu točnost predviđanja. Time je istraživanje bilo usmjereno ne samo na postizanje visoke preciznosti, već i na formalizaciju konzistentnog i reproducibilnog postupka modeliranja.

U tom kontekstu, eksperimentalni dio rada strukturiran je tako da omogući objektivnu usporedbu predloženih modela s referentnim pristupima te provjeru postavljenih istraživačkih hipoteza.

7.2. Sažetak rezultata istraživanja

Empirijsko ispitivanje provedeno je na više stvarnih i međusobno različitih skupova podataka, čime je omogućena sveobuhvatna provjera razvijenog metodološkog okvira u tehnički i tržišno različitim energetske kontekstima. U domeni kratkoročnog predviđanja opterećenja (STLF) SSA–SVR model validiran je na sustavu ISO New England te na sjevernoameričkoj distributivnoj mreži, dok je hibridni DNN–SVR model razvijen i evaluiran na hrvatskom elektroenergetskom sustavu (HEP). U domeni kratkoročnog predviđanja cijena prirodnog plina (ST-NGPF) primijenjen je SSA–SVR model na Henry Hub tržištu.

Na ISO New England skupu podataka SSA–SVR je u satnom predviđanju (24 sata unaprijed) ostvario prosječnu godišnju MAPE od 1,31%, potvrđujući jasnu prednost u odnosu na referentne modele razmatrane u eksperimentalnom protokolu. Rezultati su pokazali stabilnost kroz sve sezonske režime, uz očuvanje robusnosti i u operativno realističnim scenarijima s prognostičkim meteorološkim podacima.

Primjenjivost pristupa potvrđena je i na neovisnom skupu podataka sjevernoameričkog distributivnog operatora, gdje je SSA–SVR demonstrirao dosljedno niske pogreške na kratkoročnim horizontima. Time je potvrđena opća primjenjivost sezonski prilagođene SVR metodologije na sustavima različite strukture opterećenja.

Za hrvatski elektroenergetski sustav razvijen je hibridni DNN–SVR model koji kombinira duboko učenje kao fazu ekstrakcije reprezentacija i SVR kao završnu regresijsku optimizaciju. Na neovisnom testnom skupu satno specijalizirana konfiguracija ostvarila je prosječnu MAPE približno 1,9%, uz statistički potvrđeno poboljšanje u odnosu na samostalni DNN model. Usporedba s naprednim sekvencijskim arhitekturama (LSTM i Transformer-bazirani modeli) pokazala je da DNN–SVR postiže usporedivu ili bolju ukupnu točnost, čime je potvrđena

konkurentnost hibridnog pristupa u odnosu na suvremene duboke modele.

U domeni ST-NGPF, na Henry Hub tržištu prirodnog plina, SSA–SVR model s optimiziranim odabirom značajki ostvario je MAPE od 2,18% za jednodnevno predviđanje, nadmašujući klasične autoregresijske pristupe. Rezultati potvrđuju da strukturirana konstrukcija ulaznog prostora i kontrolirana optimizacija hiperparametara omogućuju stabilna i mjerljiva poboljšanja i u tržišno volatilnim sustavima.

Ukupno gledano, rezultati istraživanja potvrđuju da predloženi SVR-bazirani i hibridni modeli ostvaruju visoku i stabilnu točnost u različitim energetske domenama. Posebna vrijednost rada ogleda se u demonstraciji da jedinstveni metodološki okvir može biti uspješno primijenjen na tehnički determinirane sustave opterećenja i tržišno uvjetovane sustave cijena energenata, čime je potvrđena njegova strukturna generalizabilnost.

7.3. Znanstveni doprinosi rada

Glavni znanstveni doprinosi ovog rada obuhvaćaju metodološke inovacije, modelne nadogradnje i sustavnu empirijsku validaciju u području kratkoročnog predviđanja energetske varijabli.

1. Izvorni znanstveni doprinos predstavlja razvoj unificiranog SSA–SVR metodološkog okvira koji integrira sezonsku prilagodbu, konstrukciju proširenog ulaznog prostora, automatizirani odabir značajki i optimizaciju hiperparametara u jedinstven, formaliziran i reproducibilan postupak modeliranja. Time je uspostavljen generički prediktivni okvir primjenjiv na različite energetske domene (tehničke i tržišne), uz smanjenje potrebe za heurističkim podešavanjem modela.
2. Razvijen je i eksperimentalno validiran hibridni DNN–SVR model za STLFI, koji predstavlja metodološku nadogradnju SVR-baziranog pristupa kroz integraciju dubokog učenja kao faze ekstrakcije reprezentacija i SVR regresije kao završne optimizacijske komponente. Pokazano je da takva arhitektura može ostvariti konzistentno poboljšanje u odnosu na usporedive duboke bazne modele, uz očuvanje robusnosti i operativne primjenjivosti.
3. Uvedena je metodologija satno specijaliziranog modeliranja, čime je omogućeno preciznije prilagođavanje intradnevnom obrascima potrošnje te kontrola pogreške na razini pojedinog sata, što se pokazalo učinkovitijim od jedinstvenog konsolidiranog višesatnog modela.

4. Empirijski je potvrđena vrijednost integracije globalnih numeričkih vremenskih prognoza (NWP) u STLF modele, čime je demonstrirano da uporaba prognostičkih meteoroloških podataka donosi stabilno i mjerljivo poboljšanje točnosti u realnim operativnim uvjetima.
5. Sustavno je kvantificiran doprinos algoritama za odabir značajki u STLF i ST-NGPF domenama, pri čemu je potvrđena hipoteza da povećanje dimenzionalnosti ulaznog prostora ne vodi nužno boljoj točnosti, već da kontrolirana selekcija informativnih varijabli predstavlja ključan čimbenik stabilnosti i generalizacije modela.
6. Provedena je komparativna analiza razvijenih modela s relevantnim referentnim pristupima (klasični ANN, SIWNN, AR, ARIMA te suvremene duboke arhitekture poput LSTM i Transformer-baziranih modela), čime je potvrđena konkurentnost predloženih SVR-baziranih i hibridnih metoda te njihova mjerljiva prednost u odabranim scenarijima i domenama.

7.4. Potvrda postavljenih hipoteza

Rezultati dobiveni u okviru ovog rada pružaju empirijsku potvrdu svih postavljenih znanstvenih hipoteza (Hipoteze 1–3). Potvrde su izvedene kroz usporedne eksperimente u ujednačenom evaluacijskom protokolu, ablacijske analize pojedinih komponenti modela te dodatnu provjeru stabilnosti i statističke značajnosti dobivenih poboljšanja.

Hipoteza 1 pretpostavila je da integracija metode potpornih vektora u završni sloj duboke neuronske mreže može povećati točnost predviđanja u energetske sustavima. U strogo kontroliranim uvjetima, uz identičan skup značajki i istu proceduru treniranja, pokazano je da zamjena linearnog izlaza DNN-a (završnog sloja) SVR regresijskom komponentom dovodi do konzistentnog i statistički značajnog smanjenja pogreške. Time je izravno potvrđena formulacija Hipoteze 1. Na razini interpretacije modela, takva integracija može se promatrati kao povezivanje dubokih reprezentacija naučenih neuronskom mrežom s SVR regresijom temeljenom na jezgri, čime se postiže dodatna stabilnost i preciznost aproksimacije.

Hipoteza 2 pretpostavila je da korištenje modela potrošnje električne energije prilagođenih jednosatnim vremenskim intervalima dana može poboljšati točnost predviđanja. Usporedba satno specijaliziranih modela i jedinstvenog konsolidiranog modela pokazala je sustavno smanjenje pogreške u korist satne dekompozicije. Time je potvrđeno da razdvajanje prognostičkog

zadatka po jednosatnim intervalima omogućuje modelima učinkovitiju prilagodbu intradnevnoj heterogenosti potrošnje te smanjuje složenost pojedinačnog problema učenja.

Hipoteza 3 pretpostavila je da korištenje globalnog prognostičkog modela za vremensku prognozu može poboljšati točnost predviđanja potrošnje električne energije. Empirijska analiza pokazala je da uključivanje NWP-temeljenih prognostičkih meteoroloških podataka kao egzogenih varijabli dovodi do sustavnog smanjenja pogreške u odnosu na modele bez takvih ulaza. Time je potvrđena informacijska vrijednost globalnih meteoroloških prognoza u kontekstu kratkoročnog predviđanja opterećenja.

U cjelini, potvrda postavljenih hipoteza neposredno podupire glavne znanstvene doprinose rada: uspostavu formaliziranog SSA–SVR okvira, razvoj hibridnog DNN–SVR modela te dokazanu učinkovitost satne dekompozicije i kontrolirane konstrukcije ulaznog prostora. Dobiveni rezultati pokazuju da povećanje točnosti proizlazi iz pažljivo strukturirane integracije reprezentacijskih, regresijskih i informacijskih komponenti, a ne isključivo iz povećanja modelne složenosti.

7.5. Integrirana analiza STLTF i ST-NGPF rezultata

Provedena istraživanja omogućuju izdvajanje nekoliko zajedničkih obrazaca, ali i strukturnih razlika između STLTF i ST-NGPF domena, koje proizlaze iz različite prirode promatranih sustava.

- **Selekcija značajki:** U obje domene kontrolirana selekcija ulaznih varijabli pokazala se presudnom za stabilnost i generalizaciju modela. Ograničen i informativan skup značajki rezultira konzistentnijim performansama, dok nekontrolirano proširivanje ulaznog prostora povećava rizik uvođenja šuma i varijabilnosti rezultata. Time se potvrđuje da dimenzionalnost ulaza mora biti usklađena s informacijskim sadržajem podataka.
- **Robusnost SVR metodologije:** SSA–SVR pristup pokazao je stabilne performanse u uvjetima izražene nelinearnosti i heterogenosti, kako u tehnički determiniranoj STLTF domeni, tako i u tržišno uvjetovanom ST-NGPF okruženju. Unatoč različitoj prirodi procesa (fizički sustav nasuprot tržišnoj dinamici), SVR s jezgrom (npr. RBF) zadržava sposobnost aproksimacije složenih nelinearnih odnosa uz dobru robusnost na šum i promjene režima.
- **Modelna kompleksnost i dizajn ulaza:** Rezultati upućuju na to da povećanje arhitekturne složenosti modela (npr. dublje neuronske mreže ili veći broj značajki) samo po sebi ne

garantira bolju točnost. Ključni čimbenici su strukturirana konstrukcija ulaznog prostora, dosljedna optimizacija hiperparametara te stroga validacija. Drugim riječima, kvaliteta modelnog dizajna ima veću težinu od same razine modelne kompleksnosti.

- **Uloga egzogenih varijabli:** U STLTF domeni meteorološki podaci imaju izražen utjecaj na smanjenje pogreške predviđanja, budući da opterećenje elektroenergetskog sustava izravno ovisi o vremenskim uvjetima. U ST-NGPF kontekstu, utjecaj vremenskih varijabli pokazuje se ograničenijim, dok tržišni, fundamentalni i strukturni čimbenici imaju relativno veću ulogu, osobito pri produljenju horizonta predviđanja.

Integrirana interpretacija rezultata pokazuje da, unatoč razlikama u prirodi podataka i dominantnim utjecajnim čimbenicima, uspjeh predviđanja u obje domene proizlazi iz istih metodoloških načela: sezonske prilagodbe, kontrolirane konstrukcije ulaznog prostora, automatizirane selekcije značajki i dosljedne optimizacije modela. Time se potvrđuje da strukturirano i formalizirano modeliranje predstavlja univerzalno primjenjiv okvir u energetske sustavima različite tehničke i tržišne naravi.

7.6. Metodološke i operativne implikacije

Dobiveni rezultati imaju relevantne metodološke i operativne implikacije za razvoj i implementaciju prediktivnih sustava u energetici.

- **Konstrukcija ulaznih varijabli:** Rezultati upućuju na to da strukturirana izgradnja ulaznog prostora (vremenski pomaci, sezonski indikatori, egzogene varijable) ima značajan utjecaj na konačnu točnost modela. Sustavna analiza podataka i identifikacija relevantnih utjecajnih čimbenika pokazuje se važnijom od samog povećanja arhitekturne složenosti modela.
- **Selekcija značajki:** Automatizirani postupci odabira značajki doprinose kontroli dimenzionalnosti, stabilnosti učenja i smanjenju varijabilnosti rezultata između različitih vremenskih razdoblja. U operativnim sustavima njihova integracija omogućuje konzistentnije ažuriranje modela pri promjenama strukture podataka ili ulaznih varijabli.
- **Modularno modeliranje:** Satno uvjetovana dekompozicija modela pokazuje se prikladnom strategijom u sustavima s izraženim intradnevnom obrascima. Takav pristup omogućuje diferencirano upravljanje pogreškom po vremenskim intervalima te smanjuje heterogenost

problema učenja.

- **Integracija egzogenih podataka:** Uključivanje globalnih numeričkih vremenskih prognoza kao egzogenih ulaza povećava robusnost modela i smanjuje osjetljivost na lokalna ograničenja meteoroloških izvora. Ova implikacija dobiva dodatnu važnost u sustavima s rastućim udjelom varijabilnih obnovljivih izvora energije.
- **Kontrola kompleksnosti i validacija:** Rezultati naglašavaju važnost stroge validacije na izdvojenim skupovima podataka te kontrolirane optimizacije hiperparametara. Povećanje složenosti modela opravdano je samo ako je praćeno metodološki dosljednim postupcima selekcije značajki, optimizacije i evaluacije, čime se smanjuje rizik preučenja i degradacije performansi u operativnom okruženju.

Navedene implikacije ukazuju na potrebu uravnoteženog pristupa koji povezuje teorijsku utemeljenost modela s njihovom praktičnom primjenjivošću. Time se uspostavlja metodološki okvir koji omogućuje pouzdano operativno planiranje, upravljanje i donošenje odluka u elektroenergetskim i tržišnim energetske sustavima.

7.7. Ograničenja istraživanja

Rezultate ovog rada potrebno je promatrati u okviru jasno definiranog istraživačkog opsega i metodoloških pretpostavki.

- **Prostorna i tržišna specifičnost:** Analiza kratkoročnog predviđanja cijene prirodnog plina provedena je na Henry Hub tržištu, koje predstavlja referentno i visoko likvidno globalno tržište. Iako takav izbor omogućuje reprezentativnu i metodološki zahtjevnju evaluaciju modela, primjena istog okvira na druga regionalna tržišta može zahtijevati prilagodbu ulaznih varijabli i modelnih konfiguracija zbog različitih regulatornih i strukturnih obilježja.
- **Vremenski horizont predviđanja:** Istraživanje je usmjereno na kratkoročne horizonte (satni, dnevni i jednotjedni), u skladu s operativnim potrebama elektroenergetskih i tržišnih sustava. Produženje metodologije na srednjoročne ili dugoročne horizonte zahtijevalo bi uključivanje dodatnih trendovskih i fundamentalnih komponenti koje nisu dominantne u kratkoročnom kontekstu.
- **Skup usporednih modela:** Usporedbe su provedene s reprezentativnim klasičnim i suvremenim metodama različite razine kompleksnosti. Iako nije obuhvaćen svaki postojeći

algoritam, odabrani skup modela omogućuje pouzdanu procjenu relativne učinkovitosti predloženog pristupa u odnosu na relevantne referentne paradigme.

- **Deterministički okvir:** Razvijeni modeli usmjereni su na točkovne prognoze. Takav pristup odgovara velikom broju operativnih primjena, no eksplicitno modeliranje nesigurnosti (npr. intervalne ili probabilističke prognoze) može predstavljati dodatnu nadogradnju, osobito u tržišno volatilnim okruženjima.
- **Strukturne promjene sustava:** Kao i većina metoda temeljenih na povijesnim podacima, predloženi modeli pretpostavljaju određeni stupanj kontinuiteta obrazaca kroz vrijeme. U uvjetima naglih regulatornih, tehnoloških ili geopolitičkih promjena može biti potrebno prilagoditi ili ponovno trenirati modele kako bi se očuvala razina točnosti.

Navedene granice proizlaze iz definiranog istraživačkog fokusa te ne umanjuju validnost dobivenih rezultata unutar razmatranih domena, već određuju kontekst njihove interpretacije i potencijalne primjene.

7.8. Smjernice za daljnja istraživanja

Na temelju dobivenih rezultata i potvrđene metodološke utemeljenosti razvijenog okvira, mogu se identificirati smjerovi njegova daljnjeg proširenja i primjene:

- **Šira eksternalna validacija:** Iako je primjenjivost SSA–SVR i DNN–SVR pristupa potvrđena na više stvarnih sustava različite prirode, dodatna evaluacija na drugim energetske tržištima i elektroenergetskim mrežama može doprinijeti daljnjoj provjeri opće primjenjivosti metodološkog okvira, osobito u sustavima s drugačijim regulatornim i strukturnim obilježjima.
- **Proširenje vremenskih horizonta:** Razmatranje srednjoročnih i dugoročnih horizonta predviđanja moglo bi uključivati integraciju sporijih trendovskih i fundamentalnih komponenti, čime bi se postojeći kratkoročni okvir prilagodio širem spektru planerskih potreba.
- **Probabilističko proširenje modela:** Nadogradnja determinističkog pristupa na intervalne ili kvantilne prognoze omogućila bi eksplicitno modeliranje nesigurnosti predviđanja, što je osobito relevantno u uvjetima povećane tržišne volatilnosti i upravljanja rizicima.
- **Adaptivni i dinamički modeli:** Razvoj mehanizama za postupno ažuriranje modela, uključujući detekciju promjena u obrascima podataka, mogao bi dodatno povećati otpornost

prediktivnog sustava u uvjetima strukturnih promjena.

- **Integracija dodatnih izvora informacija:** Uključivanje proširenih fizikalnih, ekonomskih i tržišnih indikatora može obogatiti ulazni prostor te omogućiti modelima preciznije hvatanje međusobnih utjecaja između tehničkih i tržišnih čimbenika.
- **Kvantifikacija operativnih učinaka:** Formalizacija veze između poboljšane točnosti predviđanja i operativnih ili financijskih učinaka (npr. optimizacija pričuva, nabave energenata ili upravljanja fleksibilnošću sustava) može dodatno osnažiti implementacijsku dimenziju razvijenog okvira.

Navedeni smjerovi predstavljaju prirodnu nadogradnju i proširenje već validiranog metodološkog pristupa, a ne njegovu korekciju, te otvaraju mogućnost njegove daljnje integracije u složenije i šire energetske sustave.

7.9. Završna sinteza

Ovaj rad sustavno pokazuje da SVR-bazirani modeli, kada su metodološki strukturirani i nadograđeni kontroliranom konstrukcijom ulaznog prostora, predstavljaju teorijski utemeljen i empirijski potvrđen okvir za kratkoročno predviđanje u energetske sustavima. Razvijeni SSA–SVR pristup demonstrirao je robusnost i stabilnost u tehnički i tržišno različitim okruženjima, dok je hibridni DNN–SVR model u STLF domeni pokazao da integracija dubokih reprezentacija i SVR regresijske komponente (kernel pristup) može donijeti dodatno i statistički opravdano poboljšanje točnosti.

Ključni doprinos rada ne ogleda se isključivo u postignutoj razini prediktivne preciznosti, već u uspostavi formaliziranog i reproducibilnog metodološkog okvira koji integrira sezonsku prilagodbu, selekciju značajki, optimizaciju hiperparametara i strukturnu dekompoziciju problema. Time je pokazano da povećanje točnosti proizlazi iz promišljene arhitekture cjelokupnog modelnog procesa, a ne samo iz povećanja složenosti pojedinačne komponente.

Posebna vrijednost rada ogleda se u demonstraciji da jedinstveni metodološki okvir može biti uspješno primijenjen na tehnički determinirane i tržišno volatilne sustave, čime se potvrđuje njegova strukturna generalizabilnost kroz različite energetske domene.

Dobiveni rezultati potvrđuju postavljene istraživačke hipoteze te pokazuju da pažljivo dizajnirani hibridni i SVR-bazirani pristupi mogu učinkovito adresirati nelinearnost, sezonalnost i

heterogenost podataka karakterističnih za elektroenergetske i tržišne sustave. Ujedno je potvrđeno da strukturirana integracija egzogenih informacija i kontrolirana vremenska granularnost modeliranja predstavljaju važne čimbenike uspješnosti.

U konačnici, rad uspostavlja metodološki konzistentan i empirijski verificiran okvir za razvoj naprednih prognostičkih alata u energetici, pružajući čvrstu osnovu za njihovu daljnju nadogradnju i operativnu primjenu u suvremenim elektroenergetskim i tržišnim sustavima.

A MATEMATIČKE OSNOVE METODE POTPORNIH VEKTORA

U ovom privitku dani su detaljni matematički izvodi koji nadopunjuju poglavlje o teorijskim osnovama metode potpornih vektora i algoritama za odabir značajki. Sadržaj je organiziran u četiri dijela: izvod dualne formulacije i KKT uvjeta za linearni SVM, VC-teorija i minimizacija strukturalnog rizika, detaljna izvedba linearne procjene funkcije pomoću SVM-a te specifikacije algoritama za odabir značajki.

A1. Izvod dualne formulacije linearnog SVM-a

1.1.1. Linearno odvojjiv slučaj

Razmotrimo zadani skup podataka za učenje $\{x_k, y_k\}_{k=1}^N$ s ulaznim vektorima $x_k \in \mathbb{R}^n$ i pripadajućim izlaznim oznakama y_k (oznakama klase) pri čemu je $y_k \in \{-1, +1\}$, te linearni klasifikator

$$y(x) = \text{sign}[w^T x + b] . \quad (\text{A1})$$

Kad su podaci dviju klasa linearno separabilni, možemo napisati:

$$\begin{cases} w^T x_k + b \geq +1, & \text{ako je } y_k = +1 , \\ w^T x_k + b \leq -1, & \text{ako je } y_k = -1 , \end{cases} \quad (\text{A2})$$

a ove dvije nejednakosti možemo kombinirati u jedan uvjet:

$$y_k [w^T x_k + b] \geq 1, \quad k = 1, \dots, N . \quad (\text{A3})$$

Formulacija SVM-a provodi se u kontekstu teorije konveksne optimizacije. Opća metodologija jest započeti postavljanjem problema u primarnom prostoru težina kao problema optimizacije s ograničenjima, zatim formulirati Lagrangeovu funkciju, potom izvesti uvjete optimalnosti i na kraju riješiti problem u dualnom prostoru Lagrangeovih multiplikatora. Potonji će se nazivati *potpornim vrijednostima*.

Postavljamo problem optimizacije koji zahtijeva maksimalizaciju margine uz uvjet da su svi primjeri iz skupa za učenje ispravno klasificirani. Time se dobiva sljedeći primarni problem u pogledu w :

$$\begin{aligned} \text{[P]: } \min_{w,b} \quad & J_P(w) = \frac{1}{2} w^T w \\ \text{uz uvjet da } \quad & y_k [w^T x_k + b] \geq 1, \quad k = 1, \dots, N. \end{aligned} \quad (\text{A4})$$

Lagrangeova funkcija za ovaj problem glasi

$$\mathcal{L}(w, b; \alpha) = \frac{1}{2} w^T w - \sum_{k=1}^N \alpha_k (y_k [w^T x_k + b] - 1), \quad (\text{A5})$$

pri čemu su Lagrangeovi multiplikatori $\alpha_k \geq 0$ za $k = 1, \dots, N$. Rješenje odgovara sedlastoj točki Lagrangeove funkcije:

$$\max_{\alpha} \min_{w,b} \mathcal{L}(w, b; \alpha). \quad (\text{A6})$$

Dobiva se

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial w} = 0 \Rightarrow w = \sum_{k=1}^N \alpha_k y_k x_k, \\ \frac{\partial \mathcal{L}}{\partial b} = 0 \Rightarrow \sum_{k=1}^N \alpha_k y_k = 0, \end{cases} \quad (\text{A7})$$

tako da rezultirajući klasifikator glasi

$$y(x) = \text{sign} \left[\sum_{k=1}^N \alpha_k y_k x_k^T x + b \right]. \quad (\text{A8})$$

Uvrštavanjem izraza za w iz (A7) u Lagrangeovu funkciju (A5) dobiva se sljedeći problem

kvadratnog programiranja kao dualni problem u smislu Lagrangeovih multiplikatora α_k :

$$\begin{aligned}
 \text{[D]: } \max_{\alpha} \quad J_D(\alpha) &= -\frac{1}{2} \sum_{k,l=1}^N y_k y_l x_k^T x_l \alpha_k \alpha_l + \sum_{k=1}^N \alpha_k \\
 \text{uz uvjet da } \quad \sum_{k=1}^N \alpha_k y_k &= 0 .
 \end{aligned} \tag{A9}$$

Valja primijetiti da se ovaj problem rješava u vektoru $\alpha = [\alpha_1; \dots; \alpha_N]$, a ne u w . Ovaj QP problem ima nekoliko važnih svojstava:

- **Globalno rješenje:** Matrica kvadratnog člana ciljne funkcije jest pozitivno (polu)definitna, pa je rješenje globalno; jednoznačno je kada je matrica strogo pozitivno definitna [17, 43].
- **Rijetkost rješenja:** Mnoge vrijednosti α_k jednake su nuli — konačni klasifikator ovisi samo o primjerima s nenultim α_k , koji se nazivaju *potporni vektori*. Potporni vektori nalaze se u blizini razdvajajuće hiperravnine.
- **Parametarski i neparametarski aspekt:** Dimenzija dualnog rješenja α raste s brojem primjera N , dok je dimenzija primarnog rješenja w fiksna. Stoga je u visokodimenzionalnim ulaznim prostorima pogodnije rješavati dualni problem.

1.1.2. Linearno neodvojiv slučaj

U linearno neseparabilnom slučaju s preklapajućim distribucijama dviju klasa treba *tolerirati pogrešne klasifikacije*.

Proširenje linearne metode potpornih vektora na neseparabilan slučaj napravili su Cortes i Vapnik 1995. godine [27]. U osnovi, to se postiže uvođenjem dodatnih slack varijabli u formulaciju problema. Kako bi se tolerirale pogrešne klasifikacije, skup nejednakosti mijenja se u

$$y_k [w^T x_k + b] \geq 1 - \xi_k, \quad k = 1, \dots, N, \tag{A10}$$

uz slack varijable $\xi_k > 0$. Kada je $\xi_k > 1$, tada je k -ta nejednakost prekršena u odnosu na odgovarajuću nejednakost iz linearno separabilnog slučaja.

U primarnom prostoru težina optimizacijski problem postaje:

$$\begin{aligned}
 \text{[P]:} \quad & \min_{w, b, \xi} \quad J_P(w, \xi) = \frac{1}{2} w^T w + c \sum_{k=1}^N \xi_k \\
 & \text{pod uvjetom da} \quad y_k [w^T x_k + b] \geq 1 - \xi_k, \\
 & \quad \quad \quad \xi_k \geq 0, \quad k = 1, \dots, N,
 \end{aligned} \tag{A11}$$

gdje je c pozitivna realna konstanta. Zatim treba razmotriti sljedeću Lagrangeovu funkciju:

$$\mathcal{L}(w, b, \xi; \alpha, \nu) = J_P(w, \xi) - \sum_{k=1}^N \alpha_k \left(y_k [w^T x_k + b] - 1 + \xi_k \right) - \sum_{k=1}^N \nu_k \xi_k, \tag{A12}$$

s Lagrangeovim multiplikatorima $\alpha_k \geq 0$, $\nu_k \geq 0$ za $k = 1, \dots, N$. Drugi skup Lagrangeovih multiplikatora potreban je zbog dodatnih slack varijabli ξ_k . Rješenje je određeno sedlastom točkom Lagrangeove funkcije:

$$\max_{\alpha, \nu} \min_{w, b, \xi} \mathcal{L}(w, b, \xi; \alpha, \nu), \tag{A13}$$

čime se dobivaju sljedeći uvjeti:

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial w} = 0 \Rightarrow w = \sum_{k=1}^N \alpha_k y_k x_k, \\ \frac{\partial \mathcal{L}}{\partial b} = 0 \Rightarrow \sum_{k=1}^N \alpha_k y_k = 0, \\ \frac{\partial \mathcal{L}}{\partial \xi_k} = 0 \Rightarrow 0 \leq \alpha_k \leq c, \quad k = 1, \dots, N, \end{cases} \tag{A14}$$

nakon čega se uvrštavanjem (A14) u (A12) dobiva sljedeći dualni QP problem:

$$\begin{aligned}
 \text{[D]:} \quad & \max_{\alpha} \quad J_D(\alpha) = -\frac{1}{2} \sum_{k, l=1}^N y_k y_l x_k^T x_l \alpha_k \alpha_l + \sum_{k=1}^N \alpha_k \\
 & \text{pod uvjetom da} \quad \sum_{k=1}^N \alpha_k y_k = 0, \\
 & \quad \quad \quad 0 \leq \alpha_k \leq c, \quad k = 1, \dots, N.
 \end{aligned} \tag{A15}$$

U usporedbi s linearno separabilnim slučajem (A9), ovaj problem ima dodatna “box” ograni-

čenja.

A2. VC-teorija i minimizacija strukturalnog rizika

1.2.1. Empirijski rizik naspram pogreške generalizacije

Iz linearnih i nelinearnih SVM formulacija jasno je da margina igra važnu ulogu u tim formulacijama. Tu važnost možemo sagledati u širem kontekstu statističke teorije učenja (VC teorije) [130, 131]. Dok se u klasičnoj praksi neuronskih mreža modeli biraju na temelju posebnih validacijskih skupova, glavni cilj VC (Vapnik–Chervonenkisove) teorije jest okarakterizirati pogrešku generalizacije umjesto pogreške na specifičnim skupovima podataka.

Razmotrimo binarni klasifikacijski problem i skup funkcija s podesivim vektorom parametara θ takav da $\{f(x; \theta) : \mathbb{R}^n \rightarrow \{-1, +1\}\}$. Neka je dan skup za učenje $\{(x_k, y_k)\}_{k=1}^N$ s ulaznim vektorima $x_k \in \mathbb{R}^n$ i izlaznim oznakama $y_k \in \{-1, +1\}$. Sljedeća pogreška definirana na skupu za učenje obično se naziva empirijski rizik

$$R_{\text{emp}}(\theta) = \frac{1}{2N} \sum_{k=1}^N |y_k - f(x_k; \theta)| \quad (\text{A16})$$

S druge strane, pogreška generalizacije (ili rizik) definira se kao

$$R(\theta) = \int \left[\frac{1}{2} |y - f(x; \theta)| \right] p(x, y) dx dy \quad (\text{A17})$$

koji mjeri pogrešku za sve ulazno/izlazne uzorke generirane iz temeljnog generatora podataka karakteriziranog vjerojatnosnom gustoćom $p(x, y)$ (koja, nažalost, u praksi nije poznata). Ipak, mogu se izvesti ograde na tu pogrešku generalizacije.


Važan rezultat Vapnika (1979) govori da se može dati gornja ograda na pogrešku generalizacije u vjerojatnosnom smislu [130, 131]. Vapnik je pokazao da za bilo koji vektor parametara θ iz skupa funkcija $\{f(x; \theta) \mid \theta \in \Theta\}$, uz i.i.d. podatke i $N > h$, vrijedi ograda

$$R(\theta) \leq R_{\text{emp}}(\theta) + \sqrt{\frac{h(\ln(2N/h) + 1) - \ln(\eta/4)}{N}} \quad (\text{A18})$$

s vjerojatnošću $1 - \eta$, pri čemu je drugi član tzv. pouzdani član (confidence term) koji ovisi o VC


dimenziji h što karakterizira kapacitet skupa funkcija i kombinatorna je mjera složenosti modela. Važan aspekt ove ograde rizika jest da ne pretpostavlja nikakav specifični oblik za temeljnu distribuciju $p(x, y)$, već samo da su podaci i.i.d. uzorkovani iz te distribucije $p(x, y)$. Osim te gornje ograde na rizik, može se izvesti i donja ograda na $R(\theta)$.

Važan uvid VC teorije jest da najgori slučaj preko svih funkcija koje stroj za učenje može implementirati određuje konzistentnost (slika A1) načela minimizacije empirijskog rizika. Bez ograničenja skupa dopustivih funkcija, minimizacija empirijskog rizika nije konzistentna. Da bi načelo minimizacije empirijskog rizika bilo konzistentno, nužno je i dovoljno da empirijski rizik $R_{\text{emp}}(\theta)$ ujednačeno konvergira riziku $R(\theta)$ u sljedećem smislu: $\lim_{N \rightarrow \infty} P \left[\sup_{\theta \in \Theta} |R(\theta) - R_{\text{emp}}(\theta)| > \epsilon \right] = 0, \forall \epsilon > 0$ [130].



Slika A1: Ako očekivani rizik $R(\theta)$ i empirijski rizik $R_{\text{emp}}(\theta)$ oba konvergiraju na vrijednost $\inf_{\theta} R(\theta)$ kada broj podataka N teži beskonačnosti, tada je proces učenja konzistentan.

VC dimenzija može se objasniti na sljedeći način. Ako se dani skup od N točaka može označiti na svih 2^N mogućih načina i za svaku takvu dodjelu oznaka može se pronaći član skupa $\{f(x; \theta)\}$ koji ispravno pridružuje te oznake, možemo reći da je taj skup točaka *razbijen* (razdvojen) tim skupom funkcija. VC dimenzija skupa funkcija $\{f(x; \theta)\}$ definira se kao najveći broj točaka skupa za učenje koje taj skup funkcija može razbiti. Za linearne razdvajajuće hiperravnine u prostoru $\mathbb{R}^n$ može se pokazati da je VC dimenzija jednaka $n + 1$. Primjerice, uzmimo $N = 4$ točke u $n = 2$ dimenzijskom ulaznom prostoru. Te se točke mogu označiti u $2^4 = 16$ mogućih kombinacija. Nisu svih 16 kombinacija linearno odvojive; na primjer, dobro je poznato da XOR primjeri nisu linearno odvojivi (slika A2). Najviše 3 točke se mogu razdvojiti, ili rečeno terminologijom veze između VC teorije i Popperova rada u filozofiji: četiri točke mogu



Slika A2: Primjer s $N = 4$ točke u $n = 2$ dimenzijskom ulaznom prostoru. Te se točke mogu označiti na $2^4 = 16$ mogućih načina. Najviše 3 točke mogu se razdvojiti pravcima, jer je poznato da posljednja dva slučaja predstavljaju XOR probleme koje nije moguće razdvojiti pravcem. To rezultira VC dimenzijom jednakom 3. Za nelinearne klasifikatore ova VC dimenzija može biti i veća.

opovrgnuti bilo koji linearni zakon za ovaj primjer. U većim dimenzijama, ovaj problem linearne odvojivosti može se povezati i s Coverovim teoremom [14].

Intuitivno bi se očekivalo da modeli s mnogo parametara imaju visoku VC dimenziju, no ta intuicija nije posve točna — lako je konstruirati protuprimjere modela s jednim parametrom i beskonačnom VC dimenzijom [17]. Za nelinearne SVM klasifikatore ne postoje točni izrazi za VC dimenziju h , stoga se koriste gornje ograde. Parametri poput σ RBF jezgre i konstante kazne c ne proizlaze iz QP problema, već se biraju tako da VC ograda (A18) bude minimalna, čime se osigurava dobra generalizacija.

1.2.2. Minimizacija strukturalnog rizika


Kako bi primijenio VC ogradu na klasifikatore metode potpornih vektora, Vapnik uvodi koncept tzv. strukturne minimizacije rizika. Pri tome se razmatra struktura

$$S_i = \{w^T \varphi(x) + b : \|w\|_2^2 \leq c_i\}, \quad c_1 < c_2 < \dots < c_i < c_{i+1} < \dots \quad (\text{A19})$$

koja se sastoji od ugnježđenih skupova funkcija sve veće složenosti. To je ilustrirano na Sl. A3. Koncept je prilično sličan ranije spomenutim kriterijima složenosti i krivuljama kompromisa pristranosti i varijance. U okviru VC teorije mogu se razmatrati skupovi funkcija s rastućom

VC-dimenzijom. Što je VC-dimenzija veća, to pogreška na skupu za učenje može biti manja (empirijski rizik), ali će član pouzdanosti (drugi član u jednadžbi (A18)) rasti. Minimum zbroja ova dva člana tada predstavlja dobro kompromisno rješenje kao ravnoteža između ovih dviju krivulja.

Za klasifikatore metode potpornih vektora može se pronaći gornja ograda na VC-dimenziju kako slijedi. Vapnik je pokazao da hiperravnine koje zadovoljavaju $\|w\|_2^2 < a$ imaju



Slika A3: Princip strukturne minimizacije rizika i ilustracija granice pogreške generalizacije ovisno o VC dimenziji.

VC-dimenziju h koja je s gornje strane omeđena izrazom

$$h \leq \min \left(\lfloor r^2 a^2 \rfloor, n \right) + 1 \quad (\text{A20})$$

gdje oznaka $\lfloor \cdot \rfloor$ označava cijeli dio, a r je radijus najmanje kugle koja sadrži točke $\varphi(x_1), \dots, \varphi(x_N)$ u visokodimenzijskom prostoru značajki.

Parametri metode potpornih vektora koji ne proizlaze iz QP problema, poput vrijednosti σ RBF jezgre, često se odabiru tako da gornja ograda (A20) bude minimalna. Vrijednost $w^T w$ može se izračunati primjenom jezgrenog trika: $w^T w = \alpha^T \Omega \alpha$, gdje je $\Omega_{kl} = y_k y_l K(x_k, x_l)$, a radijus r dobiva se rješavanjem zasebnog konveksnog QP problema.

Vrijedi napomenuti da je ograda (A20) često konzervativna. Strože ograde izvedene su pomoću brojeva pokrivanja, entropijskih brojeva i Rademacherove složenosti [10, 88, 113, 114]. Za dodatno čitanje o VC teoriji i generalizaciji, vidi [5, 29, 58, 137].



A3. Detaljna izvedba linearne procjene funkcije pomoću SVM-a

Razmotrimo regresiju u skupu linearnih funkcija

$$f(x) = w^T x + b \quad (\text{A21})$$

sa N zadanih primjera za učenje s ulaznim vrijednostima $x_k \in \mathbb{R}^n$ i izlaznim vrijednostima $y_k \in \mathbb{R}$. Za minimizaciju empirijskog rizika u smislu Vapnika koristi se funkcija troška

$$R_{\text{emp}} = \frac{1}{N} \sum_{k=1}^N |y_k - w^T x_k - b| \quad (\text{A22})$$



Slika A4: (Gore) Vapnikova ε -neosjetljiva funkcija gubitka za procjenu funkcije; (Dolje) ε -cijev točnosti i točke koje ne mogu postići tu točnost, što motivira uvođenje varijabli odstupanja.

pri čemu se koristi tzv. Vapnikova ε -neosjetljiva funkcija gubitka definirana kao

$$|y - f(x)|_{\varepsilon} = \begin{cases} 0, & \text{ako } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon, & \text{inače} \end{cases} \quad (\text{A23})$$

što je prikazano na slici A4.

Procjena linearne funkcije zatim se provodi formuliranjem sljedećeg primarnog problema za w i b :

$$\begin{aligned}
 \text{[P]: } \min_{w,b} \quad & J_P(w) = \frac{1}{2} w^T w \\
 \text{uz uvjet da } \quad & y_k - w^T x_k - b \leq \varepsilon, \quad k = 1, \dots, N \\
 \quad & w^T x_k + b - y_k \leq \varepsilon, \quad k = 1, \dots, N.
 \end{aligned} \tag{A24}$$

Vrijednost ε u Vapnikovoj ε -neosjetljivoj funkciji gubitka predstavlja razinu točnosti koja se od aproksimacije zahtijeva. Formulacija (A24) odgovara slučaju u kojem bi sve točke skupa za učenje bile unutar ε -cijevi zadane točnosti. Naravno, ako se odabere mala vrijednost ε , određene točke naći će se izvan te ε -cijevi i problem (A24) postat će neizvediv. Stoga se uvode dodatne varijable odstupanja ξ_k, ξ_k^* za $k = 1, \dots, N$. Ovo je donekle slično slučaju klasifikatora s preklapajućim raspodjelama, gdje su također uvedene varijable odstupanja.

Problem (A24) preformulira se u

$$\begin{aligned}
 \text{[P]: } \min_{w,b,\xi,\xi^*} \quad & J_P(w, \xi, \xi^*) = \frac{1}{2} w^T w + c \sum_{k=1}^N (\xi_k + \xi_k^*) \\
 \text{uz uvjet da } \quad & y_k - w^T x_k - b \leq \varepsilon + \xi_k, \\
 \quad & w^T x_k + b - y_k \leq \varepsilon + \xi_k^*, \\
 \quad & \xi_k, \xi_k^* \geq 0, \quad k = 1, \dots, N
 \end{aligned} \tag{A25}$$

Konstanta $c > 0$ određuje do koje se mjere toleriraju odstupanja od željene ε -točnosti.

Lagrangeova funkcija za ovaj problem glasi

$$\begin{aligned}
 \mathcal{L}(w, b, \xi, \xi^*; \alpha, \alpha^*, \eta, \eta^*) = \\
 \frac{1}{2} w^T w + c \sum_{k=1}^N (\xi_k + \xi_k^*) - \sum_{k=1}^N \alpha_k (\varepsilon + \xi_k + y_k - w^T x_k - b) \\
 - \sum_{k=1}^N \alpha_k^* (\varepsilon + \xi_k^* - y_k + w^T x_k + b) - \sum_{k=1}^N (\eta_k \xi_k + \eta_k^* \xi_k^*)
 \end{aligned} \tag{A26}$$

Lagrangeovi multiplikatori $\alpha_k, \alpha_k^*, \eta_k, \eta_k^*$ su pozitivni (≥ 0). Sedlo Lagrangeove funkcije određuje se uvjetom:

$$\max_{\alpha, \alpha^*, \eta, \eta^*} \min_{w, b, \xi, \xi^*} \mathcal{L}(w, b, \xi, \xi^*; \alpha, \alpha^*, \eta, \eta^*) \quad (\text{A27})$$

uz uvjete optimalnosti:

$$\begin{cases} \frac{\partial \mathcal{L}}{\partial w} = 0 \Rightarrow w = \sum_{k=1}^N (\alpha_k - \alpha_k^*) x_k \\ \frac{\partial \mathcal{L}}{\partial b} = 0 \Rightarrow \sum_{k=1}^N (\alpha_k - \alpha_k^*) = 0 \\ \frac{\partial \mathcal{L}}{\partial \xi_k} = 0 \Rightarrow c - \alpha_k - \eta_k = 0 \\ \frac{\partial \mathcal{L}}{\partial \xi_k^*} = 0 \Rightarrow c - \alpha_k^* - \eta_k^* = 0 \end{cases} \quad (\text{A28})$$

Dualni problem je također kvadratni optimizacijski problem:

$$\begin{aligned} [\text{D}]: \quad \max_{\alpha, \alpha^*} \quad J_D(\alpha, \alpha^*) = & -\frac{1}{2} \sum_{k=1}^N \sum_{l=1}^N (\alpha_k - \alpha_k^*)(\alpha_l - \alpha_l^*) x_k^T x_l \\ & - \varepsilon \sum_{k=1}^N (\alpha_k + \alpha_k^*) + \sum_{k=1}^N y_k (\alpha_k - \alpha_k^*) \\ \text{uz uvjet da} \quad & \sum_{k=1}^N (\alpha_k - \alpha_k^*) = 0, \\ & \alpha_k, \alpha_k^* \in [0, c] \end{aligned} \quad (\text{A29})$$

SVM u primarnom prostoru težina za linearnu procjenu funkcije ima oblik $f(x) = w^T x + b$.

Uz $w = \sum_{k=1}^N (\alpha_k - \alpha_k^*) x_k$, ovaj model u dualnom prostoru postaje:

$$f(x) = \sum_{k=1}^N (\alpha_k - \alpha_k^*) x_k^T x + b \quad (\text{A30})$$

pri čemu su α_k, α_k^* rješenje QP problema (A29). Pomak b slijedi iz komplementarnih KKT uvjeta.

Svojstva ovog rješenja usporediva su s onima u slučaju klasifikacije. Rješenje je globalno i jedinstveno. Mnogi elementi vektora rješenja bit će jednaki nuli, što nam ponovno daje svojstvo rijetkosti. U ovom linearnom slučaju problem se može jednako dobro riješiti i u primarnoj i u dualnoj formulaciji. Prva formulacija je parametarska, dok je druga neparametarska. Veličina

dualnog problema ne ovisi o dimenzionalnosti ulaznog prostora, već o broju primjera u skupu za učenje.

A4. Specifikacije algoritama za odabir značajki

1.4.1. Genetski algoritmi s informacijskim kriterijem (GA–IT)

Genetski algoritmi (GA) predstavljaju heurističku optimizacijsku metodu inspiriranu principima prirodne selekcije i evolucijskih procesa. U kontekstu odabira značajki, GA pretražuje prostor mogućih kombinacija ulaznih varijabli s ciljem pronalaska podskupa koji optimizira zadani kriterij prikladnosti.

Kombinacijom genetskih algoritama s kriterijima informacijske teorije (eng. *Information Theory*) definira se funkcija dobrote temeljena na informativnosti značajki. Takav pristup favorizira skupove varijabli koji maksimiziraju količinu informacija o ciljnoj varijabli, uz istodobno minimiziranje međusobne redundancije među značajkama.

Glavne komponente GA–IT pristupa uključuju:

- **Kodiranje značajki** – Svaki podskup značajki reprezentiran je binarnim vektorom (kromosomom), pri čemu vrijednost 1 označava uključivanje, a 0 isključivanje određene značajke.
- **Procjena prikladnosti (fitness funkcija)** – Funkcija prikladnosti kvantificira informativnost odabranog podskupa, najčešće korištenjem entropije ili međusobne informacije između značajki i ciljne varijable.
- **Selekcija roditelja** – Primjenjuju se standardne strategije poput ruletne selekcije (eng. *roulette wheel selection*) ili turnirske selekcije radi odabira najboljih kromosoma.
- **Križanje i mutacija** – Operatori križanja i mutacije omogućuju generiranje novih kombinacija značajki i osiguravaju ravnotežu između eksploracije i eksploatacije prostora rješenja.
- **Zaustavni kriterij** – Algoritam se iterativno ponavlja do ispunjenja kriterija zaustavljanja (npr. maksimalan broj generacija ili izostanak poboljšanja fitness vrijednosti).

Prednost GA–IT pristupa očituje se u sposobnosti pretraživanja velikog i nelinearnog prostora kombinacija značajki, uz smanjenu vjerojatnost zadržavanja u lokalnim optimumima. Genetski

algoritmi pokazali su se učinkovitima u visokodimenzionalnim problemima odabira značajki [119], pri čemu je potrebno voditi računa o njihovoj računalnoj zahtjevnosti.

1.4.2. Minimalna redundancija i maksimalna relevantnost (mRMR)

Metoda mRMR (eng. *Minimum Redundancy Maximum Relevance*) temelji se na teoriji informacija te koristi koncept međusobne informacije (*mutual information*) za identifikaciju značajki koje su istodobno visoko relevantne za ciljnu varijablu i minimalno redundantne međusobno.

Kriterij mRMR može se formalno zapisati kao:

$$S^* = \arg \max_S \left[\frac{1}{|S|} \sum_{x_i \in S} I(x_i, y) - \frac{1}{|S|^2} \sum_{x_i, x_j \in S} I(x_i, x_j) \right], \quad (\text{A31})$$

gdje je:

- S – odabrani skup značajki,
- $I(x_i, y)$ – međusobna informacija između značajke x_i i ciljne varijable y (relevantnost),
- $I(x_i, x_j)$ – međusobna informacija između značajki x_i i x_j (redundancija).

Algoritam započinje odabirom značajke s najvećom pojedinačnom međusobnom informacijom s ciljem, a zatim iterativno dodaje onu značajku koja maksimizira razliku između relevantnosti i redundancije. Na taj se način osigurava da svaka nova značajka doprinosi dodatnoj informaciji o ciljnoj varijabli.

Peng i sur. pokazali su da mRMR kriterij pruža superiorne rezultate u visokodimenzionalnim problemima odabira značajki, osobito u odnosu na metode koje zanemaruju redundanciju među varijablama [102].

1.4.3. Relief metoda odabira značajki

Relief algoritam predstavlja filter metodu odabira značajki koja se temelji na instancijalnom učenju te procjenjuje važnost svake značajke prema njezinu doprinosu razlikovanju sličnih primjera. Temeljna ideja algoritma jest dodijeliti veću težinu onim značajkama koje učinkovito razdvajaju primjere različitih klasa, uz istodobno smanjenje težine značajki koje ne doprinose diskriminaciji.

Relief uzima u obzir lokalnu strukturu podataka analizom najbližih susjeda, što mu omogućuje detekciju značajki uključenih u nelinearne interakcije. Osnovni koraci algoritma su sljedeći:

1. Nasumično odabrati primjer iz skupa podataka.
2. Pronaći najbližeg susjeda iste klase (eng. *nearest hit*) i najbližeg susjeda različite klase (eng. *nearest miss*) prema odabranoj metričkoj udaljenosti (npr. Euklidskoj udaljenosti).
3. Ažurirati težine značajki usporedbom vrijednosti između odabranog primjera, susjeda iste klase i susjeda različite klase. Značajke koje pokazuju veću razliku između klasa, a stabilnost unutar iste klase, dobivaju pozitivno povećanje težine, dok se suprotne značajke penaliziraju.
4. Ponavljati postupak za dovoljan broj nasumično odabranih primjera radi stabilizacije procjene težina.
5. Rangirati značajke prema dobivenim težinama te odabrati podskup najviše rangiranih varijabli.

Relief je posebno prikladan za probleme u kojima postoje složene i nelinearne interakcije među varijablama, budući da procjena važnosti proizlazi iz lokalnih odnosa među instancama. Za razliku od jednostavnih univarijatnih kriterija, Relief može identificirati značajke koje sudjeluju u zajedničkom utjecaju na ciljnu varijablu bez eksplicitne evaluacije svih kombinacija.

Brojna proširenja algoritma, uključujući ReliefF i RRelief, dodatno su unaprijedila njegovu robusnost i primjenjivost na višeklasne i regresijske probleme [74, 128]. Relief i njegove varijante zadržavaju povoljnu računalnu složenost uz istodobnu osjetljivost

1.4.4. StepwiseFS metoda odabira značajki

StepwiseFS predstavlja sekvencijalnu *wrapper* metodu odabira značajki koja se temelji na iterativnom dodavanju ili uklanjanju varijabli iz regresijskog modela prema unaprijed definiranom statističkom kriteriju. Odluka o uključivanju ili isključivanju pojedine značajke donosi se na temelju performansi treniranog modela, čime se odabir izravno povezuje s prediktivnom sposobnošću modela [51].

Postupak može slijediti tri osnovne strategije:

- **Forward Selection** – započinje s praznim modelom te postupno uključuje značajke koje u najvećoj mjeri poboljšavaju model prema odabranom kriteriju (npr. smanjenje pogreške,

statistička značajnost koeficijenta ili informacijski kriterij).

- **Backward Elimination** – započinje s modelom koji uključuje sve dostupne značajke te postupno uklanja one čije uklanjanje najmanje degradira performanse modela, odnosno one koje ne zadovoljavaju kriterij statističke značajnosti.
- **Stepwise Selection** – kombinira prethodna dva pristupa tako da se u svakom koraku može izvršiti dodavanje ili uklanjanje značajke, ovisno o tome koji potez rezultira boljom vrijednošću kriterija optimizacije.

Kriteriji odlučivanja najčešće se temelje na p -vrijednosti (npr. uključivanje ako $p < 0.05$, isključivanje ako $p > 0.10$) ili na informacijskim mjerama poput Akaikeovog informacijskog kriterija (AIC) i Bayesovog informacijskog kriterija (BIC), koji balansiraju dobrotu prilagodbe i složenost modela.

Iako je StepwiseFS metoda intuitivna i računalno učinkovita te široko implementirana u statističkim softverskim paketima, posjeduje određena ograničenja. Budući da se radi o pohlepnom (*greedy*) postupku, ne jamči pronalazak globalno optimalnog podskupa značajki. U prisutnosti multikolinearnosti može doći do nestabilnog izbora varijabli, pri čemu male promjene u podacima mogu rezultirati različitim skupovima odabranih značajki.

Unatoč tim nedostacima, StepwiseFS ostaje praktičan i često primjenjivan pristup, osobito u problemima s umjerenim brojem kandidatskih varijabli, gdje omogućuje brzo reduciranje dimenzionalnosti uz očuvanje interpretabilnosti modela.

1.4.5. Odabir značajki temeljen na algoritmu *Gradient Boosting*

Odabir značajki predstavlja jedan od ključnih koraka u procesu nadziranog učenja, budući da izravno utječe na prediktivnu točnost, robusnost i interpretabilnost modela. Uklanjanjem irelevantnih i redundantnih varijabli moguće je poboljšati generalizacijsku sposobnost modela te smanjiti računalnu složenost procesa treniranja [51]. Jedan od suvremenih i sve češće primjenjivanih pristupa rangiranju i selekciji značajki temelji se na algoritmu *Gradient Boosting* (GB), odnosno na modelima razvijenima unutar te paradigme, poput XGBoost, LightGBM i CatBoost [22, 69, 104].

Modeli gradijentnog pojačanja predstavljaju tzv. *embedded* pristup odabiru značajki, pri čemu se procjena njihove važnosti dobiva kao sastavni dio procesa optimizacije modela.

1.4.5.1. Osnove algoritma *Gradient Boosting*

Gradijentno pojačanje pripada obitelji ansambl metoda koje konstruiraju snažan prediktor kombiniranjem većeg broja slabijih modela, najčešće plitkih stabala odlučivanja. Model se gradi iterativno, pri čemu svako novo stablo nastoji korigirati pogreške prethodno izgrađenog ansambla. Proces treniranja temelji se na optimizaciji funkcije gubitka korištenjem njezina gradijenta, čime se postiže usmjerena redukcija pogreške [44].

Pretpostavimo da model nakon $(m - 1)$ iteracija daje funkciju predikcije $F_{m-1}(x)$. U iteraciji m dodaje se novo stablo $h_m(x)$ koje minimizira ukupni gubitak L . Primjenom Taylorove aproksimacije pokazuje se da je optimalna strategija učiti $h_m(x)$ kao funkciju proporcionalnu negativnom gradijentu gubitka u točkama trenutne predikcije:

$$h_m(x) \approx - \left[\frac{\partial L(y, F(x))}{\partial F(x)} \right]_{F=F_{m-1}}.$$

Model se zatim ažurira prema relaciji

$$F_m(x) = F_{m-1}(x) + \gamma h_m(x),$$

gdje je γ koeficijent učenja (eng. *learning rate*) koji kontrolira doprinos novog stabla postojećem ansamblu. Iterativnim dodavanjem korektivnih modela postupno se smanjuje vrijednost funkcije gubitka. Friedman je pokazao da ovaj pristup predstavlja općeniti i fleksibilni optimizacijski okvir primjenjiv na različite zadatke, ovisno o izboru funkcije gubitka [44].

1.4.5.2. Rangiranje značajki u modelima gradijentnog pojačanja

Kod modela gradijentnog pojačanja (eng. *Gradient Boosting*, GB), tijekom procesa treniranja moguće je pratiti doprinos pojedine značajke ukupnom poboljšanju modela. Svaki put kada se u nekom od stabala ansambla formira čvorište (eng. *split*) koje dijeli podatke prema određenoj značajki, ta značajka pridonosi smanjenju vrijednosti funkcije gubitka. Na taj se način važnost značajki procjenjuje kao nusprodukt optimizacijskog postupka.

U praksi se koristi nekoliko metrika za kvantificiranje važnosti značajki na temelju treniranog GB modela:

- **Gain (dobitak)** – predstavlja ukupno smanjenje vrijednosti funkcije gubitka ostvareno

svim podjelama (čvorištima) u svim stablima ansambla gdje je određena značajka korištena. U regresijskim problemima to može biti smanjenje sume kvadratne pogreške, dok se u klasifikacijskim zadacima često koristi smanjenje logaritamske funkcije gubitka (eng. *log-loss*). Veća vrijednost dobitka implicira da je značajka imala značajan doprinos poboljšanju prediktivne točnosti modela.

- **Frequency (učestalost)** – označava broj pojavljivanja određene značajke kao kriterija dijeljenja u svim stablima ansambla. Iako visoka učestalost može upućivati na čestu korisnost značajke u razdvajanju podataka, sama po sebi ne jamči velik doprinos smanjenju funkcije gubitka.
- **Cover (pokrivenost)** – mjeri broj uzoraka (instanci) koji su obuhvaćeni čvorovima u kojima je određena značajka korištena za podjelu. Drugim riječima, pokrivenost kvantificira koliki je dio skupa podataka bio segmentiran korištenjem te značajke kroz sva stabla ansambla. Veća pokrivenost znači da je značajka utjecala na odluke modela za veći broj opažanja.

Na temelju navedenih metrika moguće je rangirati značajke od najvažnije prema najmanje važnoj. Primjerice, biblioteka XGBoost eksplicitno generira takve mjere važnosti nakon treniranja modela, omogućujući istraživaču identifikaciju varijabli s najvećim doprinosom predikciji [22].

U praktičnoj primjeni često se odabire podskup najviše rangiranih značajki (npr. prvih 10 ili 20 prema vrijednosti dobitka), nakon čega se završni prediktivni model trenira isključivo na tom reduciranim skupu varijabli. Ovakav pristup iskorištava činjenicu da GB modeli implicitno procjenjuju značajnost svake varijable tijekom optimizacije, čime se omogućuje selekcija bez eksplicitnog pretraživanja svih mogućih kombinacija podskupova značajki.

1.4.5.3. Prednosti pristupa temeljenog na gradijentnom pojačanju

Primjena modela gradijentnog pojačanja (GB) u postupku odabira značajki donosi niz prednosti koje ga čine osobito prikladnim za prediktivne zadatke s velikim brojem ulaznih varijabli i složenim međuzavisnostima među podacima.

- **Učinkovitost i skalabilnost** – Implementacije GB algoritama, poput XGBoost-a i LightGBM-a, optimizirane su za rad s velikim skupovima podataka i velikim brojem značajki, koristeći efikasne strukture podataka i paralelizaciju [22, 69]. Time se omogućuje primjena i na probleme s vrlo visokom dimenzionalnošću, gdje bi klasične *wrapper* metode bile računalno zahtjevne ili nepraktične.

- **Robusnost na nelinearnosti i interakcije** – GB modeli implicitno modeliraju nelinearne odnose i interakcije među značajkama kroz strukturu stabala odlučivanja. Posljedično, značajke mogu biti prepoznate kao važne čak i kada njihov doprinos proizlazi iz složenih kombinacija s drugim varijablama, što predstavlja značajnu prednost u odnosu na jednostavnije filter pristupe.
- **Rukovanje nedostajućim vrijednostima** – Suvremene GB implementacije omogućuju rad u prisutnosti nedostajućih podataka bez nužne prethodne imputacije. Tijekom izgradnje stabla algoritam može naučiti optimalan smjer grananja i za slučajeve kada određena značajka nedostaje, čime se zadržava informativnost podataka i smanjuje potreba za dodatnom obradom.
- **Regularizacija i kontrola prenaučivosti** – Okviri gradijentnog pojačanja uključuju mehanizme kontrole složenosti modela, poput ograničenja dubine stabala, minimalnog broja uzoraka u listu, subsamplinga te $L1/L2$ penalizacije. Takvi mehanizmi ograničavaju prekomjernu prilagodbu podacima te osiguravaju stabilniju procjenu važnosti značajki, smanjujući rizik da model favorizira varijable koje odražavaju šum.

U konačnici, FS pristup temeljen na gradijentnom pojačanju predstavlja snažan, fleksibilan i računalno učinkovit način identifikacije relevantnih značajki. Korištenjem ugrađenih mjera važnosti dobivenih tijekom treniranja modela moguće je pojednostavniti ulazni prostor uz minimalan gubitak informativnosti, čime se postiže povoljan omjer između složenosti i prediktivne učinkovitosti modela.

B DETALJNI EKSPERIMENTALNI REZULTATI

Ovaj privitak sadrži detaljne eksperimentalne rezultate, konfiguracije i opise podataka koji dopunjuju analizu iznesenu u Poglavlju 5. Sadržaj je organiziran u četiri tematske cjeline: (i) detaljan opis i priprema referentnih skupova podataka, (ii) proširena usporedba algoritama za odabir značajki, (iii) arhitekture referentnih sekvencijskih i Transformer-baziranih modela te (iv) hiperparametarske postavke svih razmatranih modela.

B1. Detaljni opis i priprema referentnih skupova podataka

2.1.1. ISO New England: meteorološki podaci i njihova obrada

2.1.1.1. Meteorološki podaci i njihova obrada

Povijesni meteorološki podaci korišteni kao ulazne varijable potječu iz prognoza Europskog centra za srednjoročne vremenske prognoze (*European Centre for Medium-Range Weather Forecasts, ECMWF*), konkretno iz MACC projekta (*Monitoring Atmospheric Composition and Climate*). modela rezolucije 1.25° . Dobivene prognoze interpolirane su metodom najmanjih kvadrata (eng. *least squares linear regression*) kako bi se povećala realističnost vremenskih prognoza za regiju Novog Engleskog područja i time unaprijedila preciznost predviđanja opterećenja. Umjesto korištenja stvarnih izmjerenih vrijednosti temperature, u treniranju modela korištene su prognozirane vrijednosti, čime se simulira realno-operativna primjena modela.

Središnji temperaturni podatak za područje ISO-NE predstavlja ponderirani prosjek osam meteoroloških stanica koje su povijesno povezane s potrošnjom električne energije na odgovarajućim

geografskim područjima. Te stanice uključuju:

- Boston, MA (BOS)
- Bridgeport, CT (BDR)
- Burlington, VT (BTV)
- Concord, NH (CON)
- Portland, ME (PWM)
- Providence, RI (PVD)
- Windsor Locks, CT (BDL)
- Worcester, MA (ORH)

Svaka stanica doprinosi ukupnoj procjeni temperature s različitim ponderima za ljetne i zimske mjesece, ovisno o njenoj važnosti u povijesnom energetske profilu regije. Primjerice, Windsor Locks ima najveći ponder (0.277) u obje sezone, dok Bridgeport ima najmanji. Ovi ponderi izvedeni su iz prodajnih podataka ISO New England sustava i reflektiraju stvarne obrasce sezonske potrošnje.

Uz osnovne temperaturne podatke poput suhe temperature zraka (*DryBulb*) i točke rosišta (*DewPt*), dodatno su konstruirani indeksi koji kvantificiraju zahtjeve za grijanjem i hlađenjem (T_c , T_h , T_{ah}), definirani u Odjeljku 4.3.2..

Svaki od ovih temperaturnih indeksa generira 96 ulaznih varijabli (72 za prošla 3 dana i 24 za predviđeni dan), što zajedno čini ukupno 288 temperaturno baziranih značajki. Takva konstrukcija omogućuje modelu istovremeno zahvaćanje kratkoročne dinamike (intradnevne oscilacije) i višednevne akumulacije temperaturnog učinka. U sklopu modela ISO-NE uključena je i varijabla vlažnosti zraka (*Humidity Index*), izračunata kombinacijom temperature zraka i točke rosišta, s ciljem kvantifikacije utjecaja vlažnosti na percipirano toplinsko opterećenje sustava.

2.1.1.2. Sezonalnost i kalendarske značajke (praznici)

U modelima predviđanja potrošnje električne energije posebna pažnja posvećena je uključivanju kalendarskih praznika u ulazne značajke. U skladu s općim metodološkim okvirom definiranim u Poglavlju 4, u ovom eksperimentalnom slučaju primijenjen je pristup eksplicitnog kodiranja sezonalnosti pomoću binarnih indikatorskih varijabli. Takav odabir omogućuje izravno uključivanje kalendarskih informacija u ulazni prostor modela bez potrebe za razdvajanjem

podataka po sezonskim podskupovima ili dodatnim fazama nenadziranog grupiranja, čime se zadržava jedinstvena struktura modela i osigurava operativna konzistentnost predviđanja.

U ovom radu korišten je standardizirani popis američkih praznika, uključujući federalne blagdane poput Dana neovisnosti (*Independence Day*), Božića (*Christmas*), Dana zahvalnosti (*Thanksgiving*), Dana rada (*Labor Day*), ali i dane koji neposredno prethode ili slijede ključne praznike (npr. *Day After Thanksgiving*). Ukupno je u razdoblju promatranja zabilježeno više od 50 pojedinačnih prazničnih datuma.

Ovi dani često odstupaju od standardnih obrazaca potrošnje zbog promjena u radnim navikama stanovništva, zatvaranja institucija i specifičnih industrijskih aktivnosti. Primjerice, na Dan zahvalnosti potrošnja je u prosjeku niža zbog smanjenog industrijskog i komercijalnog opterećenja, dok se u božićnom razdoblju često bilježi povećana potrošnja električne energije u kućanstvima zbog grijanja i dekorativne rasvjete.

Kroz sistematsko uključivanje takvih varijabli model može pravodobno reagirati na devijacije u opterećenju te pouzdano predvidjeti specifične obrasce karakteristične za praznike. Time se dodatno povećava razina automatizacije i robusnosti predikcije.

2.1.2. North-American Utility: meteorološki podaci i ograničenja

Podatke korištene karakterizira snažna sezonska komponenta. Kako je zabilježeno i u ranijim istraživanjima [79], niske vanjske temperature tijekom zimskih mjeseci uzrokuju značajan porast električne potrošnje, uglavnom zbog povećanih zahtjeva za grijanjem. Ova snažna negativna korelacija između temperature zraka i električnog opterećenja naglašava važnost uključivanja meteoroloških varijabli u model predikcije. Sukladno tome, temperatura je i u ovom testnom slučaju uključena kao jedna od glavnih ulaznih varijabli. Za razliku od slučaja ISO New England, kod ovog skupa podataka nije bilo moguće izgraditi indeks vlažnosti zraka zbog nedostatka relevantnih meteoroloških podataka. Međutim, korišteni su osnovni temperaturni podaci koji su služili kao ulazne varijable za model. Ovi temperaturni podaci korišteni su u obliku vremenski pomaknutih vrijednosti (eng. *lagged features*), kako bi se obuhvatio dinamički utjecaj temperature na električno opterećenje u kratkoročnom horizontu.

2.1.2.1. Sličnosti i razlike u odnosu na ISO New England skup podataka

Glavna razlika u odnosu na ISO-NE slučaj leži u strukturi i količini dostupnih podataka. Dok je u slučaju ISO-NE dostupno osam meteoroloških stanica s ponderiranjem sezonskog utjecaja, u North-American Utility primjeru taj aspekt nije bilo moguće implementirati zbog nedostatka sveobuhvatnih vremenskih izvora. Osim toga, razdoblje podataka obuhvaća kasne 1980-e i rane 1990-e, što znači da podaci reflektiraju starije obrasce potrošnje i meteoroloških karakteristika, ali se i dalje mogu koristiti za testiranje robusnosti modela.

Važno je naglasiti da je u oba testna slučaja — i za ISO New England i za North-American Utility — primijenjen istovjetan skup prazničnih dana i sezonskih kalendarskih varijabli, kako je detaljno opisano u poglavlju 5.1.1.1.. Time je osigurana konzistentnost u tretiranju kalendarskih utjecaja kroz oba primjera. Konkretno, korištene su binarne indikatorske varijable za dane u tjednu i mjesece u godini, kao i za praznike (trenutni, prethodni, sljedeći i prekosutrašnji), čime se modelima omogućuje kompenziranje periodičnih i izvanrednih obrazaca u potrošnji električne energije. Takav pristup omogućio je da se u oba skupa podataka pouzdano prepoznaju i modeliraju specifične devijacije u obrascima potrošnje vezane uz praznične i sezonske efekte.

B2. Proširena usporedba algoritama za odabir značajki

U sklopu razvoja predikcijskih modela provedena je sustavna usporedba učinkovitosti pet različitih algoritama za odabir značajki (feature selection, FS): genetskog algoritma u kombinaciji s iterativnim pretraživanjem (GA&IT), algoritma minimalne redundantnosti i maksimalne relevantnosti (MRMR), metode ReliefF, stepwise algoritma (StepwiseFS) te ekspertnog ručnog izbora značajki. Cilj je bio procijeniti njihov utjecaj na performanse SSA-SVR modela. Usporedba je provedena na dvama skupovima podataka — ISO New England i North-American Utility — te za različite vremenske horizonte predviđanja (jednosatno i 24-satno).

Za postupak odabira značajki bilo je dostupno ukupno 456 ulaznih varijabli, uključujući 168 vremenski pomaknutih vrijednosti opterećenja (eng. *lags*), različite temperaturne indekse te skup kalendarskih binarnih varijabli. Svaki FS algoritam bio je konfiguriran da odabere po 20 značajki povezanih s opterećenjem i 20 značajki izvedenih iz temperaturnih varijabli, što je ukupno činilo 40 značajki po modelu.

Za ISO New England skup podataka validacijski period definiran je kao posljednjih 60 dana prije testnog razdoblja, dok je za North-American Utility korišteno razdoblje od 365 dana. Na temelju rezultata postignutih na validacijskom skupu odabran je najučinkovitiji FS algoritam, koji je zatim korišten u konačnom treniranju modela na testnom skupu i za završnu evaluaciju performansi.

Tablica B1: Usporedba performansi različitih algoritama odabira značajki na skupovima podataka ISO New England i North-American Utility (izraženo u MAPE)

Algoritam FS	ISO New England (24h)		North-American (24h)		North-American (1h)	
	Validacija	Test	Validacija	Test	Validacija	Test
GA&IT	1.36%	1.58%	2.15%	2.06%	0.76%	0.75%
MRMR	1.34%	1.56%	2.12%	2.02%	0.79%	0.77%
ReliefF	1.44%	1.67%	2.54%	2.58%	0.76%	0.75%
StepwiseFS	1.15%	1.31%	2.11%	1.99%	0.74%	0.72%
Ekspertni izbor	1.32%	1.51%	2.24%	2.31%	0.75%	0.79%


Tablica B1 prikazuje usporedbu točnosti (MAPE) različitih algoritama odabira značajki (FS) na validacijskom i testnom skupu podataka, za tri prediktivna scenarija:

- (i) 24-satnu prognozu opterećenja za regiju **ISO New England**,
- (ii) 24-satnu prognozu za elektroenergetski sustav u **Sjevernoj Americi**,
- (iii) jednosatnu (1h) prognozu za isti **sjevernoamerički sustav**.

Uspoređeni FS algoritmi su: GA&IT, MRMR, ReliefF, StepwiseFS te ekspertni (ručni) izbor značajki. StepwiseFS algoritam ostvaruje najniže MAPE vrijednosti u svim razmatranim eksperimentalnim konfiguracijama, što je potvrđeno i na validacijskim i na testnim skupovima. Zbog tih rezultata StepwiseFS je odabran za konačnu primjenu, a njegova prednost zadržala se i u fazi testiranja, gdje je pružio najtočnije prognoze u odnosu na sve alternativne metode.

Budući da se radi o satnim modelima, za svaki pojedinačni sat trenira se poseban prediktivni model. Algoritam StepwiseFS kao i ostali pritom odabire značajke iz skupa kandidata koji uključuje povijesne vrijednosti opterećenja s vremenskim pomacima do sedam dana unatrag. Odabrane značajke nisu ograničene samo na najbliže dane, već su raspoređene kroz širi vremenski horizont, što pokazuje da model adaptivno prepoznaje koje su informacije najrelevantnije za pojedini sat.

Primjerice, za jutarnji vršni period (7h) StepwiseFS odabire varijable koje naglašavaju tipičan porast opterećenja u ranim satima, dok za večernji vrh (18h) izdvojeni skup značajki obuhvaća obrasce karakteristične za večernje opterećenje. Primjeri odabranih vremenskih pomaka za ova dva karakteristična sata prikazani su na Slici B1. Time se potvrđuje da se odabrani skup značajki dinamički prilagođava specifičnostima potražnje tijekom dana, čime se postiže veća fleksibilnost i točnost predikcije.



Slika B1: Primjeri vremenskih pomaka (lags) odabranih StepwiseFS algoritmom za sate 7 i 18 na North-American Utility skupu podataka

B3. Arhitekture referentnih sekvencijskih i Transformer-baziranih modela

2.3.1. Referentni sekvencijski LSTM model

Long Short-Term Memory (LSTM) mreže predstavljaju naprednu vrstu rekurentnih neuronskih mreža (RNN) razvijenu s ciljem ublažavanja problema nestajanja gradijenta pri učenju dugih vremenskih sekvenci. Uvođenjem memorijskih ćelija i upravljačkih vrata (ulaznih, izlaznih i zaboravnih), LSTM arhitektura omogućuje selektivno zadržavanje relevantnih informacija kroz vrijeme te učinkovito učenje dugoročnih uzročno-posljedičnih odnosa. Zbog tih svojstava, LSTM modeli se široko primjenjuju u kratkoročnom predviđanju opterećenja (STLF), gdje često nadmašuju klasične regresijske pristupe na dnevnim horizontima predikcije [19].

2.3.1.1. Arhitektura i inženjering značajki

Ulazne varijable obuhvaćaju povijesna opterećenja, meteorološke podatke i kalendarske indikatore. Kako bi se očuvala ciklička priroda vremenskih varijabli, pokazatelji poput sata u danu, dana u tjednu i dana u godini kodirani su sinusnim i kosinusnim transformacijama, čime se omogućuje neprekinuto i glatko modeliranje periodičnih obrazaca u vremenskim nizovima.

2.3.1.2. Sekvencijski LSTM model s dekoderom i mehanizmom pažnje

U radu je primijenjen sekvencijski model temeljen na *sequence-to-sequence* (Seq2Seq) arhitekturi proširenoj mehanizmom pažnje (*attention mechanism*), koji kombinira sposobnost LSTM kodera-dekoder za učenje vremenskih ovisnosti s dinamičkim fokusiranjem na informacijski najrelevantnije dijelove povijesne sekvence [8, 57]. U kontekstu STLFA, takav pristup omogućuje preciznije učenje uzoraka potrošnje i učinkovitije iskorištavanje kontekstualnih informacija [67].

Model je formuliran kao jedinstvena sekvencijska arhitektura koja u jednom prolazu generira predviđanje završnih 24 sati potrošnje električne energije, koristeći ulazni horizont duljine 39 sati. Ulaz u model organiziran je u dvije komplementarne komponente: povijesni ulaz (24 sata prethodnih mjerenja opterećenja, meteoroloških i kalendarskih varijabli) te poznate buduće značajke (39 sati unaprijed poznatih kovarijata, uključujući vremenske prognoze i kalendarske indikatore).

Arhitektura se sastoji od kodera i dekoder s LSTM slojevima od po 128 jedinica po sloju. Mehanizam pažnje primjenjuje se nad izlazima kodera, omogućujući dekoderu selektivno fokusiranje na relevantne vremenske korake iz povijesne sekvence. Model u jednom prolazu generira 24-satnu prognozu dan unaprijed.

Treniranje je provedeno primjenom Adam optimizatora s početnom stopom učenja 10^{-3} i funkcijom gubitka MAE, uz veličinu serije 32. Korišteno je rano zaustavljanje (*early stopping*, strpljenje 20 epoha) te adaptivno smanjenje stope učenja pri stagnaciji validacijske pogreške (faktor 0,5, strpljenje 7, minimalna stopa učenja 10^{-5}). Ulazne značajke standardizirane su primjenom ugrađenih *Normalization* slojeva (z-score transformacija), čiji su parametri procijenjeni isključivo na trenirajućem dijelu skupa podataka, radi stabilnijeg i učinkovitijeg procesa učenja.

2.3.1.3. Eksperimentalna postavka i analiza rezultata

Skup za treniranje obuhvaća razdoblje do kraja 2021. godine, dok je 2022. godina korištena kao neovisni testni skup. Ulazno–izlazni parovi formirani su metodom kliznog prozora uz očuvanje vremenske konzistentnosti, a evaluacija dan–unaprijed provedena je nad sekvencijama koje započinju u 08:00 sati. Uspješnost modela vrednovana je pomoću metrika MAPE i MAE.

Rezultati prikazani u Tablici B2 pokazuju da srednjoročno razdoblje treniranja (2012.–2021.) osigurava najbolju ravnotežu između količine podataka i sezone reprezentativnosti, uz najnižu pogrešku (MAPE = 2.21%, MAE = 46.263). Korištenje duljeg povijesnog razdoblja dovodi do blagog pogoršanja performansi, dok najkraći trenirajući prozor rezultira znatnim padom točnosti zbog ograničenog broja uzoraka i slabije sezone pokrivenosti.

Tablica B2: Utjecaj veličine skupa za treniranje na performanse sekvencijskog LSTM modela

Razdoblje treniranja	Veličina skupa	MAPE	MAE
2006–2021	106,881	2.41	51.11
2012–2021	79,066	2.21	46.26
2018–2021	33,082	3.22	65.53

Napomena: Godina 2022. korištena je isključivo kao neovisni testni skup te nije uključena u proces treniranja modela.

2.3.2. Referentni Transformer modeli

Transformer arhitekture, izvorno predložene za obradu prirodnog jezika [134], postale su snažna opcija za predviđanje vremenskih nizova zahvaljujući sposobnosti modeliranja dugoročnih ovisnosti putem mehanizma samo-pažnje (*self-attention*) i paralelne obrade sekvenci. U kontekstu kratkoročnog predviđanja opterećenja (STLF), ta su svojstva osobito pogodna za višehorizontno predviđanje dan unaprijed te za hvatanje složenih međuodnosa između potrošnje, meteoroloških uvjeta i kalendarskih utjecaja. Kako bi se predloženi hibridni DNN-SVR pristup pozicionirao u odnosu na suvremene sekvencijske modele, implementirano je nekoliko Transformer-baziranih referentnih modela unutar istog eksperimentalnog protokola (zajednički skup značajki, kronološka podjela 80/20 za validaciju u razvojnome razdoblju te evaluacija na izdvojenoj testnoj godini):

- enkoderski Transformer za satno specijalizirano predviđanje s gusto povezanim regresijskim

izlazom;

- dvofazni hibridni model koji kombinira Transformer enkoder kao temeljnu arhitekturu s regresijskim SVR izlazom;
- Temporal Fusion Transformer (TFT) [82], dizajniran za višehorizontno predviđanje uz eksplicitno razdvajanje povijesnih i unaprijed poznatih značajki;
- PatchTST-temeljeni Transformer itemeljen na PatchTST pristupu[97].

Na taj se način obuhvaća spektar Transformer-baziranih pristupa, od satno specijaliziranih enkoderskih modela, preko višehorizontnih arhitektura, do patch-temeljenih sekvencijskih modela s eksplicitnim uvjetovanjem na buduće kovarijate. Svi Transformer-bazirani referentni modeli koriste isti pažljivo odabrani prostor značajki kao i hibridni DNN-SVR pristup: povijesnu potrošnju električne energije, izmjerenu prizemnu temperaturu za lokacije Zagreb i Split, kalendarske varijable i ciklički (sinusno) kodirane vremenske značajke te odabrani podskup numeričkih meteoroloških prognoza (NWP) iz TIGGE arhive, pri čemu su prognostički ulazi ograničeni na varijable identificirane kao relevantne postupkom odabira značajki temeljenim na gradient boostingu.

2.3.2.1. Enkoderski Transformer (Model 1.)

Enkoderski Transformer implementiran je u okviru satno specijaliziranog predviđanja. Za svaki ciljni sat trenira se zaseban model (ukupno 24 modela), pri čemu se koriste klizni ulazni prozori duljine 24 sata koji obuhvaćaju povijesne podatke o potrošnji električne energije, meteorološke varijable, kalendarske značajke te ciklički kodirane vremenske pokazatelje. Arhitektura modela strukturirana je kao enkoderski Transformer za jednokoračno predviđanje, u skladu s pristupima iz relevantne literature [64, 87], gdje se višeglava samo-pažnja koristi za sažimanje vremenskog konteksta, a konačna prognoza izvodi se iz posljednjeg vremenskog koraka ulazne sekvence.

Model se sastoji od dvaju Transformer enkoderskih blokova s višeglavanom samo-pažnjom (četiri glave, dimenzija vektora po glavi iznosi 64), rezidualnim vezama, slojnom normalizacijom i *feed-forward* podslojevima dimenzije 64. Ulazni podaci najprije prolaze kroz standardizacijski sloj, nakon čega se obrađuju u enkoderskim blokovima, dok se izlaz generira gusto povezanim projekcijskim slojem s 64 jedinice i završnim linearnim neuronom primijenjenim na posljednji vremenski korak.

Podskup numeričkih meteoroloških prognoza (NWP) iz TIGGE arhive za svaki ciljni sat određen je postupkom odabira značajki temeljenim na gradient boostingu, čime se uklanjaju nerelevantne varijable i zadržavaju prediktori relevantni za odgovarajući vremenski horizont. Time se postiže satna specijalizacija modela, pri čemu svaki model uči obrasce karakteristične za vlastiti sat predviđanja.

Treniranje modela provedeno je pomoću Adam optimizatora sa stopom učenja 10^{-4} i funkcijom gubitka MAE, uz primjenu kronološke podjele skupa podataka 80/20 za validaciju. Mehanizam ranog zaustavljanja korišten je s vrijednošću *patience* = 20, pri čemu se kao završna verzija modela zadržavaju parametri koji odgovaraju najnižoj validacijskoj pogrešci.

2.3.2.2. Hibridni Transformer enkoder + SVR (Model 2.)

Kako bi se ispitalo može li se regresijski SVR izlaz, koji se pokazao učinkovitim u kombinaciji s DNN značajkama, jednako uspješno primijeniti i na reprezentacije temeljene na Transformer arhitekturi, razvijen je dvofazni hibridni model koji kombinira Transformer enkoder i SVR regresijski sloj, koristeći isti skup ulaznih značajki kao i Model 1.

1. **Predtreniranjem temeljne arhitekture (satna specijalizacija).** Transformer enkoder trenira se na isti način kao u Modelu 1, uz dodatak privremenog gusto povezanog sloja koji generira latentnu reprezentaciju fiksne dimenzije (npr. 64 jedinice). Ugrađeni standardizacijski sloj prilagođava se isključivo na skupu za treniranje, dok se za optimizaciju koriste Adam optimizator (10^{-4}), funkcija gubitka MAE, mehanizam ranog zaustavljanja te kronološka podjela 80/20. Privremeni gusto povezani izlaz služi kao referentni *Transformer (dense head)* model za pojedini sat.
2. **Ekstrakcija latentne reprezentacije.** Nakon završetka treniranja, privremeni izlazni sloj se uklanja, a aktivacije preposljednjeg sloja ekstrahiraju se za sve uzorke razvojnog i testnog skupa koristeći zamrznuti Transformer enkoder.
3. **Odabir SVR modela na recentnom podskupu.** Kako bi se smanjila računalna složenost, hiperparametri SVR modela optimiraju se na najnovijem dijelu razvojnog skupa, koji obuhvaća približno posljednje tri godine podataka (oko 26 280 uzoraka), koristeći jednu kronološku podjelu 80/20. SVR s RBF jezgrom trenira se unutar cjevovoda koji uključuje standardizaciju latentnih reprezentacija. Provedena je kompaktna pretraga mreže hiperparametara (C, ϵ, γ), pri čemu se zadržava konfiguracija s minimalnom validacijskom

MAE pogreškom.

4. **Ponovno treniranje i inferencija.** SVR konfiguracija s najnižom validacijskom MAE pogreškom ponovno se trenira te se uparuje sa zamrznutim Transformer enkoderom za inferenciju na testnom skupu. Rezultati se izvještavaju zasebno za referentni Transformer model s gusto povezanim izlazom i za hibridni Transformer + SVR pristup, primjenjujući isti satno specijalizirani eksperimentalni protokol.

2.3.2.3. Temporal Fusion Transformer (TFT, Model 3.)

Treći, napredniji pristup temelji se na punoj arhitekturi *Temporal Fusion Transformer* (TFT) [82], jednom od najsuvremenijih modela za višehorizontno predviđanje vremenskih nizova. TFT objedinjuje rekurentne slojeve (LSTM), višeglavu pažnju (eng. *multi-head attention*) te mehanizme dinamičkog odabira varijabli (VSN), čime istovremeno postiže visoku točnost i interpretabilnost.

Struktura ulaza za TFT model podudara se s prethodno opisanim sekvencijskim arhitekturama i temelji se na dvokomponentnoj podjeli ulaza: povijesnim vrijednostima (ulaz kodera) i unaprijed poznatim značajkama (ulaz dekodera). Model koristi 24-satnu vremensku sekvencu povijesnih mjerenja i 39-satni horizont poznatih budućih kovarijata. Ulazne značajke uključuju stvarnu potrošnju i meteorološke podatke, vremenske prognoze, kalendarske varijable te ciklički kodirane vremenske pokazatelje (sinusne i kosinusne transformacije). Za procjenu točnosti koristi se samo posljednjih 24 sata horizonta, dok se puni ulaz koristi za kontekstualno modeliranje i temporalnu interpretaciju kroz pažnju i selektivno grananje unutar TFT arhitekture.

Arhitektura TFT modela sastoji se od triju glavnih komponenti:

- **Rekurentni slojevi (LSTM encoder–decoder):** služe za učenje vremenskih ovisnosti između uzastopnih koraka unutar sekvence.
- **Mehanizmi pažnje (multi-head attention):** omogućuju modelu fokusiranje na najvažnije dijelove povijesne i buduće sekvence, povećavajući interpretabilnost i stabilnost prognoze.
- **Dinamički odabir varijabli (Variable Selection Networks, VSN):** adaptivno određuje doprinos svake značajke u svakoj vremenskoj točki, čime se važnost varijabli prilagođava kontekstu.

Nelinearne transformacije, regulacija protoka informacija i rezidualno povezivanje unutar navedenih komponenti ostvareni su pomoću *Gated Residual Networks* (GRN), koje predstavljaju

temeljni građevni blok TFT arhitekture i omogućuju stabilno učenje dubokih vremenskih reprezentacija. U okviru arhitekture svaka komponenta — povijesne i poznate buduće značajke — prolazi kroz zasebnu mrežu za selekciju varijabli, nakon čega se njihova reprezentacija integrira putem LSTM kodera i dekodera.

Na razini dekodera, višeglava pažnja (s četiri glave i dimenzijom vektora 64) omogućuje modelu da dinamički identificira relevantne vremenske korake u povijesti pri generiranju budućih predviđanja.

Konačni izlaz modela je točkasta prognoza potrošnje električne energije, dobivena iz dekoderskog izlaza i optimizirana pomoću funkcije gubitka srednje apsolutne pogreške (MAE).

Model je treniran pomoću Adam optimizatora sa stopom učenja 10^{-3} , validacijskim udjelom od 20% i veličinom serije 32. Tijekom treniranja korišteni su mehanizmi ranog zaustavljanja (eng. *EarlyStopping*, *patience* = 20) i adaptivnog smanjenja stope učenja (eng. *ReduceLROnPlateau*, *factor* = 0.5, *patience* = 5), čime se omogućuje stabilna konvergencija modela i prevencija preučenja. Tijekom procesa praćene su kvantilne i točkaste pogreške, a za konačnu evaluaciju odabrana je verzija modela s najnižom validacijskom pogreškom.

Ključna razlika između TFT-a i pristupa s 24 odvojena enkoderska modela leži u načinu modeliranja višekratne prognoze i uporabi dostupnih značajki. Dok skup odvojenih modela tretira svaki sat kao samostalan problem (uz satnu specijalizaciju), TFT simultano uči i predviđa sve buduće sate unutar jedinstvene arhitekture. Takav zajednički optimizacijski proces omogućuje modelu da izravno hvata međuovisnosti između različitih sati dnevnog ciklusa potrošnje - primjerice, prijelaz jutarnjeg rasta u poslijepodnevnu stabilizaciju - te ih iskoristi za povećanje konzistentnosti i točnosti cjelodnevne prognoze.

2.3.2.4. PatchTST-temeljeni Transformer (Model 4)

PatchTST [97], kao suvremeni patch-temeljeni Transformer model za vremenske nizove, poslužio je kao temelj za implementaciju varijante modela s dekoderskom komponentom i unakrsnom pažnjom, prilagođene višehorizontnom zadatku kratkoročnog predviđanja opterećenja. U PatchTST pristupu vremenska sekvenca se segmentira u lokalne zakrpe (*patches*), koje se zatim tretiraju kao ulazni tokeni Transformer enkodera, čime se omogućuje učinkovitije učenje lokalnih obrazaca te istodobno smanjuje računalna složenost samo-pažnje.

Model koristi dvostruku ulaznu strukturu, konzistentnu s višehorizontnim eksperimentalnim

protokolom: (i) 24-satni prozor povijesnih opažanja (*obs_past*) te (ii) niz unaprijed poznatih budućih kovarijata duljine 39 h (*known_future*), od kojih se posljednjih 24 h koristi za procjenu točnosti.

Enkoder obrađuje standardizirani povijesni tok segmentiran u preklapajuće zakrpe duljine 12 s pomakom 6, koje se projiciraju u latentni prostor dimenzije $d_{\text{model}} = 64$ i zatim prolaze kroz dva Transformer bloka s višeglavanom samo-pažnjom (četiri glave) i *feed-forward* slojevima dimenzije 128. Dekoder koristi buduće kovarijate kao upitni niz (*query sequence*), nad kojim se primjenjuje unakrsna pažnja prema enkodiranim zakrpama, čime se omogućuje uvjetovanje prognoze na poznatim budućim utjecajima.

Model je treniran s Adam optimizatorom (stopa učenja 10^{-3}) uz funkciju gubitka MAE i veličinu serije 32. Primijenjeno je rano zaustavljanje s *patience* = 20 te strategija smanjenja stope učenja (*factor* = 0.5, *patience* = 5, minimalna stopa 10^{-5}).

Kombinacijom patch-reprezentacije i unakrsne pažnje, model omogućuje istodobno učenje povijesnih lokalnih obrazaca i njihovo dinamičko usklađivanje s očekivanim budućim uvjetima, poput vremenskih prognoza i kalendarskih faktora. Ovakva arhitektura balansira između jednostavnosti i snage sekvencijskih Transformer modela, pozicionirajući se kao relevantna referentna točka za usporedbu s predloženim hibridnim DNN-SVR pristupom.

2.3.2.5. Ulazne značajke i dizajn ulaznih tokova kroz modele

PatchTST-temeljeni Transformer, LSTM Seq2Seq + Attention i TFT referentni modeli koriste konzistentnu dvostruku strukturu ulaznih tokova. Tok povijesnih opažanja sastoji se od 24-satnog povijesnog prozora koji uključuje prethodnu potrošnju električne energije, izmjerene prizemne temperature za lokacije Zagreb i Split, indikatore blagdana te šest periodičkih kodiranja izvedenih iz kalendarskih varijabli, čime se ukupno dobiva 10 značajki po vremenskom koraku.

Tok poznatih budućih značajki obuhvaća prognozni horizont od 39 sati te uključuje kalendarske indikatore, periodička vremenska kodiranja, oznake blagdana i odabrani podskup numeričkih meteoroloških prognoza (NWP) iz TIGGE arhive. Ove NWP varijable odabrane su iz izvornog skupa od 364 sirove varijable primjenom algoritma temeljenog na gradient-boost stablima, kako je detaljno opisano u odjeljcima 5.1.5. i 5.1.6.. U ovom istraživanju dobiveni skup obuhvaća 31 NWP varijablu koje predstavljaju vremenski invarijantne meteorološke prediktore za dva grada (Zagreb i Split), uključujući površinsku temperaturu (2t), temperaturu rosišta (2d) i druge

atmosferske veličine uzorkovane na različitim vremenskim horizontima. Time tok poznatih budućih značajki sadrži ukupno 37 značajki po vremenskom koraku.

Suprotno tome, enkoderski Transformer (Model 1) i hibridni Transformer + SVR model (Model 3) koriste jedinstvenu ulaznu strukturu s jednim tokom podataka. Taj tok objedinjuje 24-satni povratni prozor prethodne potrošnje, indikatore blagdana, šest periodičkih vremenskih kodiranja te prilagođeni podskup satno specifičnih NWP značajki dobivenih primjenom algoritma gradient-boost stabala, kako je opisano u odjeljku 5.1.5.. Odabir značajki provodi se neovisno za svaki od 24 sata predviđanja, čime se omogućuje satna specijalizacija prediktora kako u Transformer modelima s gusto povezanim izlazom, tako i u SVR regresijskoj fazi.

Ovako definirani ulazni cjevovodi osiguravaju da svi Transformer-bazirani modeli djeluju unutar konzistentnog vremenskog i kovarijatnog okvira. Dok sekvencijski modeli primjenjuju odabir značajki isključivo na NWP komponente poznatih budućih ulaza, DNN-SVR regresijski model koristi jedinstveni vektorski prikaz značajki koji obuhvaća sve odabrane prediktore, uključujući i zaostale (lag) varijable i prognostičke komponente. Takav pristup, prilagođen arhitekturi pojedinog modela, omogućuje pravednu i reproducibilnu usporedbu između različitih skupina modela.

2.3.2.6. Usporedba performansi Transformer-baziranih modela

Tablica B3 prikazuje vrijednosti MAPE i MAE za razmatrane Transformer-bazirane pristupe, uključujući satno specijalizirane konfiguracije s 24 odvojena modela te višehorizontne modele, gdje je to primjenjivo. Rezultati pokazuju da enkoderski Transformer treniran strategijom zajedničkog ulaznog prozora već postiže konkurentnu točnost. Međutim, zamjena gusto povezanog izlaznog sloja regresijskom SVR fazom (Model 2) dovodi do dodatnog smanjenja pogreške na 2.1012%, čime se nadmašuju sve isključivo Transformer-bazirane varijante, uključujući i Temporal Fusion Transformer (TFT).

PatchTST-temeljeni Transformer model (Model 4) ostvaruje MAPE od 2.1904%, što predstavlja poboljšanje u odnosu na standardne enkoderske Transformer konfiguracije, ali i dalje zaostaje za predloženim hibridnim DNN-SVR pristupom (1.895%) za približno 13.5%. Ovaj rezultat upućuje na to da, unatoč naprednim mehanizmima segmentacije vremenskih nizova i lokalne samo-pažnje, PatchTST-temeljeni Transformer ne uspijeva u potpunosti iskoristiti dostupne prediktivne informacije u usporedbi s arhitekturom koja eksplicitno kombinira duboke

reprezentacije i kernel-temeljenu regresiju.

Ukupno gledano, rezultati potvrđuju da integracija SVR regresijske faze može značajno unaprijediti performanse Transformer enkodera u kontekstu kratkoročnog predviđanja opterećenja, dok istodobno nadmašuje i napredne višehorizontne Transformer arhitekture. Time se dodatno potvrđuje opravdanost hibridnog DNN-SVR pristupa kao robusnog i visoko učinkovitog rješenja za STLF zadatke.

Tablica B3: Usporedba konfiguracija i strategija treniranja Transformer modela.

Konfiguracija / strategija	MAPE	MAE (MW)
24 enkoderska Transformer + SVR	2,1012	43,51
PatchTST-temeljeni Transformer	2,1904	46,00
Temporal Fusion Transformer (TFT)	2,2199	46,65
24 enkoderska Transformer — zajedničko treniranje (gusto povezani izlaz)	2,4355	47,47

2.3.2.7. Utjecaj količine podataka na višehorizontne modele

U nastavku analize Transformer-baziranih pristupa razmotren je utjecaj duljine trenirajućeg razdoblja na performanse višehorizontnog *Temporal Fusion Transformer* (TFT) modela. Cilj ove analize je procijeniti robusnost modela u odnosu na dostupnu količinu povijesnih podataka, uz zadržavanje iste arhitekture, skupa ulaznih značajki i postupka treniranja kao u prethodnoj usporedbi.

Eksperimenti su provedeni na trima trenirajućim razdobljima različite duljine (2006.–2021., 2012.–2021. i 2018.–2021.), dok je 2022. godina korištena isključivo kao neovisni testni skup, čime je omogućena procjena osjetljivosti modela na smanjenje količine i sezonske raznolikosti podataka. Rezultati prikazani u Tablici B4 pokazuju da TFT ostvaruje najnižu pogrešku pri korištenju cjelokupnog povijesnog skupa (MAPE = 2,2199, MAE = 46,65), dok se pri srednjoročnom trenirajućem razdoblju (2012.–2021.) performanse gotovo ne mijenjaju (MAPE = 2,2299, MAE = 46,36). Ovakvo ponašanje potvrđuje da TFT učinkovito iskorištava informaciju i pri umjereno reduciranoj količini podataka, uz zadržavanje stabilne višehorizontne prognoze.

Značajnije pogoršanje točnosti uočeno je tek pri korištenju najkraćeg trenirajućeg razdoblja

(2018.–2021.), gdje dolazi do porasta pogreške (MAPE = 2,7760, MAE = 56,35). Ovaj rezultat upućuje na važnost dulje povijesti koja obuhvaća različite sezonske i operativne režime sustava, osobito u kontekstu višehorizontnog predviđanja.

Tablica B4: Utjecaj veličine skupa za treniranje na performanse TFT modela.

Razdoblje treniranja	Veličina skupa	MAPE	MAE
2006–2021	106,881	2,2199	46,65
2012–2021	79,066	2,2299	46,36
2018–2021	33,082	2,7760	56,35

Napomena: Godina 2022. korištena je isključivo kao neovisni testni skup te nije uključena u proces treniranja modela.

U kontekstu prethodno prikazane usporedbe Transformer-temeljnih modela, ovi rezultati potvrđuju da TFT predstavlja robusno i konkurentno višehorizontno rješenje, s niskom osjetljivošću na umjereno smanjenje količine podataka. Ipak, usporedba s rezultatima iz prethodnog pododjeljka pokazuje da hibridni satno specijalizirani DNN-SVR pristup i dalje ostvaruje najnižu ukupnu pogrešku. Time se dodatno potvrđuje da kombinacija dubokih sekvencijskih ekstraktora značajki i kernel-bazirane regresije, uz satnu specijalizaciju i pažljivo odabrane NWP ulaze, predstavlja posebno učinkovit okvir za operativno kratkoročno predviđanje opterećenja.

B4. Hiperparametarske postavke referentnih modela

Radi preglednosti i transparentnosti eksperimentalnog postupka, u ovom se odjeljku daje sažeti prikaz konačno korištenih hiperparametarskih konfiguracija za sve referentne duboke modele i hibridne pristupe razmatrane u radu. Navedene postavke odnose se na modele koji služe kao polazišne (baseline) arhitekture za usporedbu s predloženim satno specijaliziranim DNN-SVR okvirom, uključujući LSTM Seq2Seq s mehanizmom pažnje, enkoderske Transformer modele, Temporal Fusion Transformer (TFT), PatchTST-temeljeni Transformer te hibridne varijante s regresijskom SVR fazom.

Podešavanje hiperparametara provedeno je na jedinstvenom validacijskom skupu (2021. godina), uz dosljednu primjenu istih kronoloških podjela podataka, istog postupka skaliranja i istih kriterija odabira za sve arhitekture. Time je osigurano da uočene razlike u točnosti

predviđanja proizlaze iz strukturnih svojstava modela i strategije učenja, a ne iz razlika u eksperimentalnom protokolu.

U Tablici B5 prikazani su razmatrani rasponi hiperparametara i konačno odabrane vrijednosti korištene u eksperimentalnoj evaluaciji. Svrha ove tablice nije iscrpno dokumentiranje svih isprobanih kombinacija, već pružanje kompaktnog pregleda konfiguracija koje su korištene za generiranje rezultata prikazanih u prethodnim odjeljcima, čime se omogućuje reproducibilnost i jasna interpretacija usporedbe između različitih modelskih pristupa.

Tablica B5: Hiperparametarske postavke referentnih prognostičkih modela.

Model	Parametar	Raspon pretraživanja	Odabrana vrijednost
LSTM Seq2Seq + Attention	Broj skrivenih jedinica (neurona)	{32, 64, 128, 256}	128
	Broj slojeva	{1, 2, 3}	2
	Dropout	{0.0, 0.1}	0.0
Enkoderski Transformer (Model 1)	Dimenzija skrivenog prostora d_{model}	{32, 64, 128}	64
	Broj glava pažnje	{2, 4}	4
	Broj enkoderskih slojeva	{2, 3}	2
	Dimenzija feed-forward podsloja	{64}	64
	Dropout	{0.0, 0.1}	0.0
Transformer + SVR (Model 2)	Dimenzija skrivenog prostora d_{model}	64	64
	Broj glava pažnje	4	4
	Broj enkoderskih slojeva	2	2
	Parametar regularizacije C	{16, 32, 64, 128, 256}	Satno specifično
	Parametar jezgre γ	{scale, auto}	Satno specifično
	ε -neosjetljivost	{0.05, 0.10, 0.20}	Satno specifično
Temporal Fusion Transformer (TFT, Model 3)	Dimenzija skrivenog prostora d_{model}	{32, 64, 128, 256}	64
	Broj glava pažnje	{2, 4, 8}	4
	Dropout	{0.0, 0.1}	0.0
PatchTST-temeljeni Transformer (Model 4)	Dimenzija modela d_{model}	{64, 128}	64
	Broj glava pažnje	4	4
	Broj enkoderskih slojeva	{2, 3}	2
	Dimenzija feed-forward podsloja	{128, 256}	128
	Duljina zakrpe (<i>patch length</i>)	12	12
	Pomak zakrpe (<i>patch stride</i>)	6	6
Hibridni DNN-SVR	Arhitektura DNN-a	vidi Tablicu 5.7	256×256
	Parametar regularizacije C	{32, 128, 512}	Satno specifično
	Parametar jezgre γ	{scale, auto}	Satno specifično
	ε -neosjetljivost	{0.05, 0.10}	Satno specifično

Napomena: Oznaka *satno specifično* označava da je za svaki sat u danu treniran zaseban model s neovisno optimiranim hiperparametrima (ukupno 24 modela). Arhitektura DNN mreže „ 256×256 ” odnosi se na dva

potpuno povezana skrivena sloja s po 256 neurona. Parametri C , γ i ε predstavljaju hiperparametre SVR modela (koeficijent regularizacije, parametar jezgre i parametar ε -neosjetljivosti), optimirane postupkom pretraživanja mreže parametara za RBF jezgru. Vrijednosti „scale” i „auto” definiraju parametar γ kao $1/(\text{broj značajki} \times \text{Var}(X))$, odnosno $1/\text{broj značajki}$.

LITERATURA

- [1] M. Abumohsen, A. Y. Owda, and M. Owda. Electrical load forecasting using lstm, gru, and rnn algorithms. *Energies*, 16(5):2283, 2023.
- [2] H. Akaike. Statistical predictor identification. *Ann. Inst. Stat. Math.*, 22:203–217, 1970.
- [3] L. Alhmoud, R. Abu Khurma, A. M. Al-Zoubi, and I. Aljarah. A real-time electrical load forecasting in jordan using an enhanced evolutionary feedforward neural network. *Sensors*, 21(18), 2021.
- [4] N. Amjady and F. Keynia. Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy*, 34(1):46–57, 2009.
- [5] M. Anthony and P. Bartlett. *Neural Network Learning: Theoretical Foundations*. Cambridge University Press, New York, 1999.
- [6] A. I. Arvanitidis, D. Bargiotas, A. Daskalopulu, V. M. Laitos, and L. H. Tsoukalas. Enhanced short-term load forecasting using artificial neural networks. *Energies*, 14(22), 2021.
- [7] A. Azadeh, M. Sheikhalishahi, and S. Shahmiri. A hybrid neuro-fuzzy approach for improvement of natural gas price forecasting in vague and noisy environments. In *Proc. Int. Conf. on Trends in Industrial and Mechanical Engineering (ICTIME)*, pages 123–127, Dubai, UAE, 2012.
- [8] D. Bahdanau, K. Cho, and Y. Bengio. Neural machine translation by jointly learning to align and translate. *ArXiv*, 1409, 09 2014.
- [9] E. Banda and K. A. Folly. Short term load forecasting using artificial neural network. In *2007 IEEE Lausanne Power Tech*, pages 108–112, 2007.

- [10] P. L. Bartlett and S. Mendelson. Rademacher and gaussian complexities: risk bounds and structural results. *J. Mach. Learn. Res.*, 3(null):463–482, Mar. 2003.
- [11] H. I. Beloev, S. R. Saitov, A. A. Filimonova, N. D. Chichirova, O. E. Babikov, and I. K. Iliev. Short-term electrical load forecasting based on xgboost model. *Energies*, 18(19), 2025.
- [12] J. Bergstra and Y. Bengio. Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13(10):281–305, 2012.
- [13] M. Beus and D. Pavić. Electricity market design in croatia within the european electricity market—recommendations for further development. *Energies*, 11(2):346, 2018.
- [14] C. M. Bishop. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- [15] S. P. A. Brown and M. K. Yücel. What drives natural gas prices? *The Energy Journal*, 29(2):45–60, 2008.
- [16] W. Buchanan, P. Hodges, and J. Theis. Which way the natural gas price: An attempt to predict the direction of natural gas spot price movements using trader positions. *Energy Economics*, 23:279–293, 02 2001.
- [17] C. J. C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167, 1998.
- [18] S. Busse, P. Helmholz, and M. Weinmann. Forecasting day ahead spot price movements of natural gas – an analysis of potential influence factors on basis of a narx neural network. In D. C. Mattfeld and S. Robra-Bissantz, editors, *Tagungsband der Multikonferenz Wirtschaftsinformatik (MKWI 2012)*, pages 1395–1406. GITO Verlag, February 2012.
- [19] J. S. Caicedo-Vivas and W. Alfonso-Morales. Short-term load forecasting using an lstm neural network for a grid operator. *Energies*, 16(23), 2023.
- [20] E. Ceperic, V. Ceperic, and A. Baric. A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines. *IEEE Transactions on Power Systems*, 28(4):4356–4364, 2013.

- [21] E. Čeperić, S. Žiković, and V. Čeperić. Short-term forecasting of natural gas prices using machine learning and feature selection algorithms. *Energy*, 140:893–900, 2017.
- [22] T. Chen and C. Guestrin. XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 785–794. ACM, 2016.
- [23] Y. Chen, P. Luh, C. Guan, Y. Zhao, L. Michel, M. Coolbeth, P. Friedland, and S. Rourke. Short-term load forecasting: Similar day-based wavelet neural networks. *IEEE Transactions on Power Systems*, 25(1):322–330, Feb 2010.
- [24] V. Cherkassky and F. Mulier. *Learning from Data: Concepts, Theory and Methods*. John Wiley & Sons, New York, 1998.
- [25] V. Cherkassky and X. Shao. Signal estimation and denoising using vc-theory. *Neural Networks*, 14:37–52, 2001.
- [26] F. Chollet. Keras, 2015. Software available from <https://github.com/fchollet/keras>.
- [27] C. Cortes and V. Vapnik. Support vector networks. *Machine Learning*, 20:273–297, 1995.
- [28] P. Craven and G. Wahba. Smoothing noisy data with spline functions: estimating the correct degree of smoothing by the method of generalized cross-validation. *Numerische Mathematik*, 31:377–403, 1979.
- [29] N. Cristianini and J. Shawe-Taylor. *An Introduction to Support Vector Machines*. Cambridge University Press, Cambridge, 2000.
- [30] Croatian Transmission System Operator (HOPS) d.d. Annual financial report 2022. Financial report, HOPS Plc., 2023. Accessed: 15 January 2026.
- [31] F. Cucker and S. Smale. On the mathematical foundations of learning. *Bulletin of the American Mathematical Society*, 39:1–49, 2002.
- [32] L. Debnath and P. Mikusiński. *Introduction to Hilbert spaces with Applications*. Academic Press, 2 edition, 1999.

- [33] A. Deihimi and H. Showkati. Application of echo state networks in short-term electric load forecasting. *Energy*, 39(1):327–340, 2012. Sustainable Energy and Environmental Protection 2010.
- [34] O. Delalleau and Y. Bengio. Shallow vs. deep sum-product networks. In *Proceedings of the 25th International Conference on Neural Information Processing Systems, NIPS'11*, page 666–674, Red Hook, NY, USA, 2011. Curran Associates Inc.
- [35] M. Digi, P. Wanda, Hamzah, I. W. Ordiyasa, and A. Fathinah. Advancing natural gas price predictions with concavelstm. *Techné : Jurnal Ilmiah Elektroteknika*, 23(1):163–174, Apr. 2024.
- [36] G. Dudek. A comprehensive study of random forest for short-term load forecasting. *Energies*, 15(20), 2022.
- [37] Energy Institute Hrvoje Požar (EIHP). Energija u hrvatskoj 2022 / energy in croatia 2022. Technical report, Ministry of Economy and Sustainable Development of the Republic of Croatia, 2023. Annual energy report. Accessed: 15 January 2026.
- [38] ENTSO-E Transparency Platform. ENTSO-E Transparency Platform: Total Load Data. <https://transparency.entsoe.eu/load-domain/r2/totalLoad>, n.d. [Accessed: 2023-01-05].
- [39] M. Espinoza, J. A. Suykens, R. Belmans, and B. D. Moor. Electric load forecasting. *IEEE Control Systems*, 27(5):43–57, 2007.
- [40] European Centre for Medium-Range Weather Forecasts (ECMWF). Tigge database. <https://confluence.ecmwf.int/display/TIGGE/Description>, 2024. Accessed: 2023-01-05.
- [41] S. Fan and L. Chen. Short-term load forecasting based on an adaptive hybrid method. *IEEE Transactions on Power Systems*, 21(1):392–401, Feb 2006.
- [42] S. Fei, C. Liu, Q. Zeng, and Y. Miao. Application of particle swarm optimization-based support vector machine in fault diagnosis of turbo-generator. In *Proceedings of the 2nd International Symposium on Intelligent Information Technology Application (IITA)*, pages 1040–1044. IEEE, 2008.

- [43] R. Fletcher. *Practical Methods of Optimization*. John Wiley & Sons, Chichester and New York, 1987.
- [44] J. H. Friedman. Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 29(5):1189–1232, 2001.
- [45] S. Gao, C. Hou, and B. H. Nguyen. Forecasting natural gas prices using highly flexible time-varying parameter models. *Economic Modelling*, 105:105652, 2021.
- [46] M. Gaur and A. Majumdar. One-day-ahead load forecasting using nonlinear kalman filtering algorithms. In *Proceedings of the International Conference on Recent Trends in Engineering, Science and Technology (SP-CRTPNFE)*, Hyderabad, India, June 2016.
- [47] P. Ghanty and N. Pal. Neurosvm: An architecture to reduce the effect of the choice of kernel on the performance of svm. *Journal of Machine Learning Research*, 10:591–622, 03 2009.
- [48] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, Cambridge, MA, 2016.
- [49] R. Guan, A. Wang, Y. Liang, J. Fu, and X. Han. International natural gas price trends prediction with historical prices and related news. *Energies*, 15(10), 2022.
- [50] O. Gungor, J. Garnier, T. S. Rosing, and B. Aksanli. Lenard: Lightweight ensemble learner for medium-term electricity consumption prediction. In *2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, pages 1–6, 2020.
- [51] I. Guyon and A. Elisseeff. An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3:1157–1182, 2003.
- [52] H. Hahn, S. Meyer-Nieberg, and S. Pickl. Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 199(3):902–907, 2009.
- [53] M. Hasan, Z. Mifta, S. Papiya, P. Roy, P. Dey, N. Salsabil, N.-U.-R. Chowdhury, and O. Farrok. A state-of-the-art comparative review of load forecasting methods: Characteristics, perspectives, and applications. *Energy Conversion and Management X*, 26:100922, 04 2025.

- [54] D. Haussler. Convolution kernels on discrete structures. Technical Report UCSC-CRL-99-10, UCSC, 1999.
- [55] Y. He, J. Deng, and H. Li. Short-term power load forecasting with deep belief network and copula models. In *Proceedings of the 9th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC)*, pages 191–194, 2017.
- [56] J. Heaton. *Introduction to Neural Networks with Java*. Heaton Research, 2008.
- [57] S. Henselmeyer and M. Grzegorzec. Short-term load forecasting using an attended sequential encoder-stacked decoder model with online training. *Applied Sciences*, 11(11), 2021.
- [58] R. Herbrich. *Learning Kernel Classifiers*. MIT Press, Cambridge, Massachusetts, 2002.
- [59] H. S. Hippert, C. E. Pedreira, and R. C. Souza. Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on Power Systems*, 16(1):44–55, 2001.
- [60] T. Hong and S. Fan. Probabilistic electric load forecasting: A tutorial review. *International Journal of Forecasting*, 32(3):914–938, 2016.
- [61] K. Hornik, M. Stinchcombe, and H. White. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5):359–366, 1989.
- [62] S. Hosseiniipoor, S. Hajirezaie, and J. Nejati. Application of arima and garch models in forecasting the natural gas prices. Technical report, The University of Oklahoma, 2016. Available at: https://www.researchgate.net/publication/299595833_Application_of_ARIMA_and_GARCH_Models_in_Forecasting_the_Natural_Gas_Prices.
- [63] C.-W. Hsu, C.-C. Chang, and C.-J. Lin. A practical guide to support vector classification. Technical report, Department of Computer Science, National Taiwan University, 2016. Initial version: 2003, Last updated: May 19, 2016.
- [64] Z. Huang and Y. Yi. Short-term load forecasting for regional smart energy systems based on two-stage feature extraction and hybrid inverted transformer. *Sustainability*, 16(17):7613, 2024.

- [65] M.-H. Jiang and X.-C. Yuan. Construction and application of PSO-SVM model for personal credit scoring. In *Proceedings of the 7th International Conference on Computational Science (ICCS)*, volume 4488 of *Lecture Notes in Computer Science*, pages 158–161. Springer, 2007.
- [66] J. Jin and J. Kim. Forecasting natural gas prices using wavelets, time series, and artificial neural networks. *PLOS ONE*, 10(11):1–23, 11 2015.
- [67] S. Jung, J. Moon, S. Park, and E. Hwang. An attention-based multilayer gru model for multistep-ahead short-term load forecasting. *Sensors*, 21(5), 2021.
- [68] A. Kathirgamanathan, A. Patel, A. S. Khwaja, B. Venkatesh, and A. Anpalagan. Performance comparison of single and ensemble cnn, lstm and traditional ann models for short-term electricity load forecasting. *IET Smart Grid*, 5(6):184–195, 2022.
- [69] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, and T.-Y. Liu. LightGBM: A highly efficient gradient boosting decision tree. In *Advances in Neural Information Processing Systems 30 (NIPS 2017)*, pages 3149–3157, 2017.
- [70] A. Khotanzad, R. Afkhami-Rohani, T. L. Lu, A. Abaye, M. Davis, and D. J. Maratukulam. Annstlf: A neural-network-based electric load forecasting system. *IEEE Transactions on Neural Networks*, 8(4):835–846, 1997.
- [71] A. Khwaja, M. Naeem, A. Venetsanopoulos, and B. Venkatesh. Improved short-term load forecasting using bagged neural networks. *Electric Power Systems Research*, 125:109–122, 08 2015.
- [72] T. Kim and S. Cho. Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182:72–81, Sep 2019.
- [73] D. P. Kingma and J. Ba. Adam: A method for stochastic optimization. *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, 2015.
- [74] K. Kira and L. A. Rendell. A practical approach to feature selection. In *Proceedings of the 9th International Conference on Machine Learning (ICML)*, pages 249–256. Morgan Kaufmann, 1992.

- [75] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, and Y. Zhang. Short-term residential load forecasting based on lstm recurrent neural network. *IEEE Transactions on Smart Grid*, 10(1):841–851, 2019.
- [76] A. Kurtz and K. Kuttruff. Forecasting german natural gas prices using temporal fusion transformers. Master’s thesis, BI Norwegian Business School, Oslo, Norway, 2023. Available at NVA Sikt: <https://nva.sikt.no>.
- [77] J. Lago, F. De Ridder, and B. De Schutter. Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms. *Applied Energy*, 221:386–405, 2018.
- [78] A. J. Landgraf. An ensemble approach to gefcom2017 probabilistic load forecasting. *International Journal of Forecasting*, 35(4):1432–1438, 2019.
- [79] S. Li, P. Wang, and L. Goel. Short-term load forecasting by wavelet transform and evolutionary extreme learning machine. *Electric Power Systems Research*, 122:96–103, 2015.
- [80] W. Li, Z. Wang, Q. Sun, Q. Gao, and F. Yang. Energypatchtst: Multi-scale time series transformers with uncertainty estimation for energy forecasting. In D.-S. Huang, Y. Pan, W. Chen, and B. Li, editors, *Advanced Intelligent Computing Technology and Applications*, pages 319–330, Singapore, 2025. Springer Nature Singapore.
- [81] Y. Li and T. Zhang. Deep neural mapping support vector machines. *Neural Networks*, 93:185–194, sep 2017.
- [82] B. Lim, S. O. Arik, N. Loeff, and T. Pfister. Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*, 37(4):1748–1764, 2021.
- [83] X. Liu, M. Tang, Y. Feng, T. Fang, Z. Wang, and M. Song. Natural gas price prediction based on artificial intelligence models. *PLOS ONE*, 20(12):1–27, 12 2025.
- [84] W. Lu and X. Chen. Short-term load forecasting for power systems with high-penetration renewables based on multivariate data slicing transformer neural network. *Frontiers in Energy Research*, 12, 01 2024.

- [85] X. Lv and X. Shan. Modeling natural gas market volatility using garch with different distributions. *Physica A: Statistical Mechanics and its Applications*, 392(22):5685–5699, 2013.
- [86] P. Manigandan, M. S. Alam, M. Alharthi, U. Khan, K. Alagirisamy, D. Pachiyappan, and A. Rehman. Forecasting natural gas production and consumption in united states-evidence from sarima and sarimax models. *Energies*, 14(19), 2021.
- [87] W. Mao, S. Yu, and W. Chen. Short-term power load forecasting method based on gru-transformer combined neural network model. *Journal of Computing and Information Technology*, 32(1):1–14, 2024.
- [88] S. Mendelson. Rademacher averages and phase transitions in glivenko-cantelli classes. *IEEE Transactions on Information Theory*, 48(1):251–263, 2002.
- [89] J. Mercer. Functions of positive and negative type and their connection with the theory of integral equations. *Philosophical Transactions of the Royal Society of London*, 209:415–446, 1909.
- [90] P. Mishra. Forecasting natural gas price - time series and nonparametric approach. In *Proceedings of the World Congress on Engineering 2012 Vol I (WCE 2012)*, pages 484–489, London, U.K., July 4-6 2012. IAENG.
- [91] M. Mohandes. Support vector machines for short-term electrical load forecasting. *International Journal of Energy Research*, 26(4):335–345, 2002.
- [92] A. Muqtadir, B. Li, Z. Ying, S. Chen, and S. N. Kazmi. Nowcasting the next hour of residential load using boosting ensemble machines. *Scientific Reports*, 15(1):7157, 2025.
- [93] H. T. Nguyen and I. T. Nabney. Short-term electricity demand and gas price forecasts using wavelet transforms and adaptive models. *Energy*, 35(9):3674–3685, 2010.
- [94] T. Nguyen and Y. Liao. Short-term load forecasting based on adaptive neuro-fuzzy inference system. *Journal of Computers*, 6(11):2267–2271, 2011.
- [95] S. Nick and S. Thoenes. What drives natural gas prices? – a structural var approach. *Energy Economics*, 45:517–527, 2014.

- [96] H. Nie, G. Liu, X. Liu, and Y. Wang. Hybrid of arima and svms for short-term load forecasting. *Energy Procedia*, 16:1455–1460, 2012. 2012 International Conference on Future Energy, Environment, and Materials.
- [97] Y. Nie, N. H. Nguyen, P. Sinthong, and J. Kalagnanam. A time series is worth 64 words: Long-term forecasting with transformers. In *International Conference on Learning Representations (ICLR)*, 2023.
- [98] North-American Utility. North-american utility load and temperature data (1988–1992). https://www.ee.washington.edu/class/559/00_archived/, 1992. Hourly load and temperature dataset.
- [99] P.-F. Pai and W.-C. Hong. Forecasting regional electric load based on recurrent support vector machines with genetic algorithms. *Electric Power Systems Research*, 74(3):417–425, 2005.
- [100] T. Panagiotidis and E. Rutledge. Oil and gas markets in the uk: Evidence from a cointegrating approach. *Energy Economics*, 29(2):329–347, 2007.
- [101] M. Panella, F. Barcellona, and R. L. D’Ecclesia. Forecasting energy commodity prices using neural networks. *Advances in Decision Sciences*, 2012:Article ID 289810, 26 pages, 2012.
- [102] H. Peng, F. Long, and C. Ding. Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 27(8):1226–1238, 2005.
- [103] J. Platt. Flat training of support vector machines using sequential minimal optimization. In B. Schölkopf, C. J. C. Burges, and A. J. Smola, editors, *Advances in Kernel Methods – Support Vector Learning*, pages 185–208. MIT Press, 1999.
- [104] L. Prokhorenkova, G. Gusev, A. Vorobev, A. V. Dorogush, and A. Gulin. CatBoost: unbiased boosting with categorical features. In *Advances in Neural Information Processing Systems 31 (NeurIPS 2018)*, pages 6639–6649, 2018.
- [105] Z. Qu, Y. Meng, X. Hou, R. Chi, Y. Ai, and Z. Wu. Integrated energy short-term multivariate load forecasting based on patchtst secondary decoupling reconstruction

- for progressive layered extraction multi-task learning network. *Expert Systems with Applications*, 269:126446, 2025.
- [106] S. H. Rafi, Nahid-Al-Masood, S. R. Deeba, and E. Hossain. A short-term load forecasting method using integrated cnn and lstm network. *IEEE Access*, 9:32436–32448, 2021.
- [107] D. J. Ramberg and J. E. Parsons. The weak tie between natural gas and oil prices. *The Energy Journal*, 33(2):13–35, 2012.
- [108] A. Rebei, M. Amayri, and N. Bouguila. Affinity-driven transfer learning for load forecasting. *Sensors*, 24(17):5802, 2024.
- [109] A. Reis and A. da Silva. Feature extraction via multiresolution analysis for short-term load forecasting. *IEEE Transactions on Power Systems*, 20(1):189–198, 2005.
- [110] D. F. Reiter and M. J. Economides. Prediction of short-term natural gas prices using econometric and neural network models. In *SPE Hydrocarbon Economics and Evaluation Symposium*, Dallas, TX, USA, March 1999. Paper SPE-52960-MS.
- [111] A. Sahed, M. Mekidiche, and K. Hacen. Forecasting natural gas prices using nonlinear autoregressive neural network. *International Journal of Mathematical Sciences and Computing*, 6:37–46, 10 2020.
- [112] N. Salehnia and et al. Forecasting natural gas spot prices with nonlinear modeling using gamma test analysis. *Journal of Natural Gas Science and Engineering*, 14:238–249, 2013.
- [113] B. Schölkopf, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson. Generalization bounds via eigenvalues of the gram matrix. Technical Report Technical Report Series NC2-TR-1999-035, NeuroCOLT, 1999.
- [114] B. Schölkopf and A. Smola. *Learning with Kernels*. MIT Press, Cambridge, MA, 2002.
- [115] B. Schölkopf, A. Smola, R. C. Williamson, and P. L. Bartlett. New support vector algorithms. *Neural Computation*, 12:1207–1245, 2000.
- [116] G. Schwarz. Estimating the dimension of a model. *Annals of Statistics*, 6:461–464, 1978.
- [117] R. Shibata. An optimal selection of regression variables. *Biometrika*, 68:461–464, 1981.

- [118] A. W. Siddiqui. Predicting natural gas spot prices using artificial neural network. In *Proc. 2nd Int. Conf. on Computer Applications & Information Security (ICCAIS)*, pages 1–6, Riyadh, Saudi Arabia, 2019.
- [119] W. Siedlecki and J. Sklansky. A note on genetic algorithms for large-scale feature selection. *Pattern Recognition Letters*, 10(5):335–347, 1989.
- [120] K.-B. Song, Y.-S. Baek, D. H. Hong, and G. Jang. Short-term load forecasting for the holidays using fuzzy linear regression method. *IEEE Transactions on Power Systems*, 20(1):96–101, 2005.
- [121] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(56):1929–1958, 2014.
- [122] M. Su, Z. Zhang, Y. Zhu, D. Zha, and W. Wen. Data-driven natural gas spot price prediction models using machine learning methods. *Energies*, 12(9):1680, 2019.
- [123] J. A. K. Suykens and J. Vandewalle. Training multilayer perceptron classifiers based on a modified support vector method. *IEEE Transactions on Neural Networks*, 10(4):907–912, 1999.
- [124] M. Syukron. A patch-based transformer approach to nonlinear dynamics natural gas price forecasting. (*IJCSAM*) *International Journal of Computing Science and Applied Mathematics*, 11(2):76–82, Dec. 2025.
- [125] J. G. Tamba, S. N. Essiane, E. F. Saponken, and B. J. Dia. Forecasting natural gas: A literature survey. *International Journal of Energy Economics and Policy*, 8(3):216–249, 2018.
- [126] J. W. Taylor. Triple seasonal methods for short-term electricity demand forecasting. *European Journal of Operational Research*, 204(1):139–152, July 2010.
- [127] L. Tian and A. Noore. A novel approach for short-term load forecasting using support vector machines. *International Journal of Neural Systems*, 14(5):329–335, 2004.

- [128] R. J. Urbanowicz, M. Meeker, W. LaCava, R. S. Olson, and J. H. Moore. Relief-Based Feature Selection: Introduction and Review. *Journal of Biomedical Informatics*, 85:189–203, 2018.
- [129] U.S. Energy Information Administration. Factors Affecting Natural Gas Prices, 2025. Accessed on Aug. 31, 2025.
- [130] V. Vapnik. *The Nature of Statistical Learning Theory*. Springer-Verlag, New York, 1995.
- [131] V. Vapnik. *Statistical Learning Theory*. John Wiley & Sons, New York, 1998.
- [132] V. Vapnik and A. Chervonenkis. A note on one class of perceptrons. *Automation and Remote Control*, 25, 1964.
- [133] V. Vapnik and A. Lerner. Pattern recognition using generalized portrait method. *Automation and Remote Control*, 24:774–780, 1963.
- [134] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin. Attention is All You Need. In *Proceedings of the 31st International Conference on Neural Information Processing Systems (NeurIPS)*, pages 5998–6008, Long Beach, CA, USA, 2017. Curran Associates Inc.
- [135] A. I. F. Vaz and L. N. Vicente. A particle swarm pattern search method for bound constrained global optimization. *Journal of Global Optimization*, 39(2):197–219, 2007.
- [136] A. I. F. Vaz and L. N. Vicente. PSwarm: A hybrid solver for linearly constrained global derivative-free optimization. *Optimization Methods and Software*, 24(4-5):669–685, 2009.
- [137] M. Vidyasagar. *A Theory of Learning and Generalization*. Springer-Verlag, 1997.
- [138] C. Villacorta Cardoso and G. Cruz. Forecasting natural gas consumption using arima models and artificial neural networks. *IEEE Latin America Transactions*, 14:2233–2238, 05 2016.
- [139] J. Wang, J. Cao, S. Yuan, and M. Cheng. Short-term forecasting of natural gas prices by using a novel hybrid method based on a combination of the ceemdan-se-and the pso-als-optimized gru network. *Energy*, 233:121082, 2021.

- [140] J. Wang, C. Lei, and M. Guo. Daily natural gas price forecasting by a weighted hybrid data-driven model. *Journal of Petroleum Science and Engineering*, 192:107240, 2020.
- [141] Z. Wang, B. Zhao, H. Guo, L. Tang, and Y. Peng. Deep ensemble learning model for short-term load forecasting within active learning framework. *Energies*, 12(20):3809, 2019.
- [142] Weather Underground. Weather Underground Historical Weather Data. <https://www.wunderground.com/history/>, 2024. Accessed: 2023-01-05.
- [143] M. Wiering, M. {van der Ree}, M. Embrechts, M. Stollenga, A. Meijster, A. Nolte, and L. Schomaker. The neural support vector machine. In *The 25th Benelux Artificial Intelligence Conference (BNAIC)*, 2013. Best paper award.
- [144] A. Yadav, R. Bareth, M. Kochar, M. Pazoki, and R. A. E. Sehiemy. Gaussian process regression-based load forecasting model. *IET Generation, Transmission & Distribution*, 18(5):899–910, 2024.
- [145] S.-F. Yang, S.-W. Choi, and E.-B. Lee. A prediction model for spot lng prices based on machine learning algorithms to reduce fluctuation risks in purchasing prices. *Energies*, 16(11):4271, 2023.
- [146] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson. How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems (NeurIPS)*, volume 27, pages 3320–3328, 2014.
- [147] L. Zhan and Z. Tang. Natural gas price forecasting by a new hybrid model combining quadratic decomposition technology and lstm model. *Mathematical Problems in Engineering*, 2022:1–13, 12 2022.
- [148] G. P. Zhang. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, 50:159–175, 2003.
- [149] W. Zhang and S. Hamori. Do machine learning techniques and dynamic methods help forecast us natural gas crises? *Energies*, 13(9):2371, 2020.
- [150] Z. Zhao, C. Fu, C. Wang, and C. Miller. Improvement to the prediction of fuel cost distributions using arima model, 2018.

- [151] H. Zhou, S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, and W. Zhang. Informer: Beyond efficient transformer for long sequence time-series forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(12):11106–11115, May 2021.
- [152] M. Zou, J. Gu, D. Fang, G. Harrison, S. Djokic, X. Wang, and C. Zhang. Comparison of three methods for a weather based day-ahead load forecasting. In *2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, pages 1–5, 2019.
- [153] E. Čeperić and K. Lenac. An hour-specific hybrid dnn–svr framework for national-scale short-term load forecasting. *Sensors*, 26(3), 2026.

ŽIVOTOPIS

Ervin Čeperić rođen je 16. prosinca 1972. godine u Rijeci. Srednjoškolsko obrazovanje stekao je u Srednjoj školi „Andrije Mohorovičića“ u Rijeci, u programu matematika–informatika, pri čemu je završni razred i maturu djelomično pohađao u Sjedinjenim Američkim Državama, a potom u Rijeci. Diplomirao je na Elektrotehničkom fakultetu u Trstu, smjer automatika. Poslijediplomski magistarski studij završio je 2011. godine na Fakultetu elektrotehnike i računarstva Sveučilišta u Zagrebu, na Zavodu za primijenjeno računarstvo, gdje je obranio znanstveni magistarski rad iz područja kratkoročnog predviđanja opterećenja elektroenergetskih sustava primjenom metode potpornih vektora.

Profesionalnu karijeru započeo je u tvrtki Siemens d.d., gdje je radio na poslovima projektiranja sustava automatskog upravljanja i razvoja softvera za programabilne logičke kontrolere. Od 2003. godine zaposlen je u HEP d.d. u Sektoru za informatiku i telekomunikacije na poslovima planiranja, administriranja i održavanja informacijskih i telekomunikacijskih sustava. Od 2014. godine zaposlen je u HEP Telekomunikacijama d.o.o., gdje obnaša poslove koordinatora, a od 2017. godine rukovoditelja službe u Sektoru za upravljanje i izgradnju mreže, Podružnica Rijeka.

Autor je i koautor više znanstvenih radova iz područja primjene metoda strojnog učenja u elektroenergetskim sustavima. Njegovi radovi objavljeni su u međunarodnim časopisima kao što su IEEE Transactions on Power Systems, Energy, Applied Artificial Intelligence i Sensors. Istraživački interesi usmjereni su na primjenu metoda potpornih vektora, algoritama za odabir značajki i hibridnih modela dubokog učenja u problemima kratkoročnog predviđanja u energetske sustavima.

Popis objavljenih djela

Rad u časopisima

1. Čeperić, E., Čeperić, V., Barić, A., “A Strategy for Short-Term Load Forecasting by Support Vector Regression Machines”, IEEE Transactions on Power Systems, Vol. 28, No. 4, November 2013, str. 4356–4364.
2. Čeperić, E., Žiković, S., Čeperić, V., “Short-term forecasting of natural gas prices using machine learning and feature selection algorithms”, Energy, Vol. 140, 2017, str. 893–900.
3. Kirinčić, V., Čeperić, E., Vlahinić, S., Lerga, J., “Support Vector Machine State Estimation”, Applied Artificial Intelligence, Vol. 33, No. 6, 2019, str. 517–530.
4. Čeperić, E., Lenac, K., “An Hour-Specific Hybrid DNN–SVR Framework for National-Scale Short-Term Load Forecasting”, Sensors, Vol. 26, No. 3, Article 797, 2026.

BIOGRAPHY

Ervin Čeperić was born on December 16, 1972, in Rijeka, Croatia. He completed his secondary education at the “Andrija Mohorovičić” Secondary School in Rijeka, in the mathematics–informatics program, with his final year partly completed in the United States. He received his degree in electrical engineering, with a specialization in automation, from the University of Trieste. In 2011, he completed his postgraduate master’s studies at the Faculty of Electrical Engineering and Computing, University of Zagreb, at the Department of Applied Computing, where he defended his scientific master’s thesis on short-term load forecasting of power systems using support vector machines.

He began his professional career at Siemens d.d., working on the design of automatic control systems for industrial plants and the development of software for programmable logic controllers. Since 2003, he has been employed at HEP d.d. in the Information and Telecommunications Sector, working on planning, administration, and maintenance of information and telecommunication systems. Since 2014, he has been employed at HEP Telecommunications d.o.o., where he first worked as a coordinator and, since 2017, has served as Head of Service in the Network Management and Development Sector, Rijeka Branch.

He is the author and co-author of several scientific papers in the field of machine learning applications in power and energy systems. His work has been published in international journals including IEEE Transactions on Power Systems, Energy, Applied Artificial Intelligence, and Sensors. His research interests include support vector machines, feature selection methods, and hybrid deep learning models for short-term forecasting in energy systems.