

DOI: [10.46793/CIGRE37.D2.03](https://doi.org/10.46793/CIGRE37.D2.03)**D2.03****УПОТРЕБА ВЕШТАЧКИХ НЕУРАЛНИХ МРЕЖА ЗА ПРОГНОЗУ ПОТРОШЊЕ И
ПРОИЗВОДЊЕ ЕЛЕКТРИЧНЕ ЕНЕРГИЈЕ****USE OF ARTIFICIAL NEURAL NETWORKS FOR FORECASTING ELECTRICITY
CONSUMPTION AND PRODUCTION****Nemanja Vojnović*, Mileta Žarković**

Кратак садржај: Прогноза потрошње и производње електричне енергије представља кључни изазов у електроенергетским системима, нарочито са све већим ослањањем на обновљиве изворе енергије. Традиционалне методе предвиђања често нису довољно прецизне због сложености и варијабилности енергетских токова, што захтева примену напредних техника вештачке интелигенције (ВИ). Овај рад истражује могућности коришћења ВИ, посебно вештачких неуралних мрежа, за унапређење тачности прогнозе потрошње и производње електричне енергије. Кроз анализу различитих модела и архитектура неуралних мрежа, извршена је оптимизација параметара како би се пронашла најефикаснија конфигурација за предвиђање на основу временских и енергетских података. Имплементација предложеног приступа реализована је у програмском језику *Python* коришћењем библиотека као што су *TensorFlow* и *Scikit-learn*. Евалуација модела показала је значајна унапређења у прецизности прогноза у поређењу са класичним методама као што су линеарна регресија и метода подршке вектора. Поред теоријске анализе, рад обухвата и експерименталну евалуацију развијених модела кроз обраду података из реалних електроенергетских система. Резултати истраживања доприносе бољем планирању производње, оптимизацији рада мреже и повећању интеграције обновљивих извора енергије у електроенергетски систем.

Кључне речи: вештачка интелигенција, неуралне мреже, прогноза потрошње, електроенергетски систем, *Python*

Abstract: Forecasting electricity consumption and production is a key challenge in power systems, especially with the increasing reliance on renewable energy sources. Traditional forecasting methods are often not sufficiently accurate due to the complexity and variability of energy flows, necessitating the application of advanced artificial intelligence (AI) techniques. This paper explores the potential use of AI, particularly artificial neural networks, to improve the accuracy of electricity consumption and production forecasts. Through the analysis of different models and neural network architectures, parameter optimization was performed to determine the most efficient configuration for forecasting based on temporal and energy data.

* Nemanja Vojnović, Elektrotehnički fakultet u Beogradu, nemanja_vojnovic@outlook.com
Mileta Žarković, Univerzitet u Beogradu- Elektrotehnički fakultet, mileta@etf.rs

The proposed approach was implemented in the Python programming language using libraries such as TensorFlow and Scikit-learn. Model evaluation demonstrated significant improvements in forecast accuracy compared to classical methods such as linear regression and support vector machines. In addition to theoretical analysis, the paper includes an experimental evaluation of the developed models through data processing from real power systems. The research results contribute to better production planning, network operation optimization, and increased integration of renewable energy sources into the power system.

Key words: *neural networks, consumption forecasting, power system, Python, artificial intelligence*

1 УВОД

У ери све веће дигитализације и технолошких иновација електроенергетски сектор се суочава са изазовима који захтевају ефикасна решења за управљање потрошњом и производњом електричне енергије. Са растућим захтевима за одрживим и поузданим снабдевањем електричном енергијом, постаје неопходно прилагодити се новим трендовима и технолошким иновацијама како би се осигурала стабилност и ефикасност електроенергетских система. У овом контексту, примена вештачке интелигенције (ВИ) постаје све значајнија. ВИ, као грана рачунарске науке која се бави развојем интелигентних система способних за самостално учење и прилагођавање, пружа нове могућности за оптимизацију процеса у електроенергетском сектору [1]. Комбинујући огромне количине података са напредним алгоритмима учења, ВИ омогућава анализу и предвиђање комплексних енергетских образаца са високом тачношћу и ефикасношћу. У том светлу, овај рад истражује примену ВИ у предвиђању потрошње и производње електричне енергије, са циљем побољшања тачности и ефикасности управљања електроенергетским системима. Коришћењем модела вештачких неуралних мрежа на подацима доступним из Грчке, анализиране су различите архитектуре мрежа како би се одабрао модел са најбољом генерализујућом способношћу. Резултати су показали високу тачност предикције енергетске потрошње у поређењу са другим методама као што су линеарна регресија и метода подршке вектора [2]. Употреба фази логике у комбинацији са осталим моделима ВИ доприноси побољшању прецизности модела. Коришћење вероватноћа у предикцијама омогућава узимање у обзир неизвесности и варијабилности, што се показало кључним у решавању проблема прогнозирања дугорочне потрошње електричне енергије [3]. Када је доступност велике количине информација проблематична, увиђа се важност развоја хибридног модела за ефикасно управљање потражњом енергије у условима недостатка података и брзих промена у економији и технологији. Овај модел пружа ефикасно решење за прогнозирање будуће потрошње енергије кроз диверзификацију алгоритама и упоређивање са другим моделима предвиђања [4]. Истраживања сугеришу да би се применом модела заснованих на подацима могла постићи оптимална инвестиција и употреба енергетских складишта, што би резултирало економски изводљивим решењима и омогућило већу пенетрацију обновљивих извора енергије у мрежу. Такође, истичу важност одзива на страни потражње и интеграцију електричних возила за транзицију ка паметним мрежама и одрживим технологијама [5].

Променљива производња електричне енергије из обновљивих извора, попут соларних и ветроелектрана, представља изазов за стабилност електроенергетских система због зависности од временских услова и сезонских варијација.

Нагли падови у производњи услед облачности или смањеног ветра могу довести до нестабилности мреже и захтевати брзеприлагођење конвенционалних електрана како би се очувала равнотежа између производње и потрошње. Једно од кључних решења за овај проблем јесте развој ефикасних технологија складиштења енергије, које омогућавају акумулацију вишкова електричне енергије и њено коришћење у тренуцима повећане потрошње. Поред тога, потребно је улагање у флексибилност електроенергетских система и унапређење управљачких стратегија. Интеграција обновљивих извора у енергетске системе игра кључну улогу у енергетској транзицији ка одрживијем моделу са смањеним емисијама гасова са ефектом стаклене баште. Решавање изазова њихове променљивости доприноси поузданости електроенергетске мреже и дугорочној стабилности снабдевања електричном енергијом.

Развој ефикасних техника прогнозе потрошње и производње електричне енергије од виталног је значаја за одрживост и поузданост електроенергетских система. Имплементација ВИ може допринети унапређењу прецизности прогноза, оптимизацији употребе ресурса и бољем балансирању електроенергетског система. Овај рад истражује примену ВИ у прогнози потрошње и производње електричне енергије, са посебним освртом на употребу неуралних мрежа. Кроз анализу постојећих метода и техника, као и кроз практичну имплементацију модела ВИ, рад има за циљ да да основу за коришћење АИ у планирању рада електроенергетских система.

2 ПРОГНОЗА ПОТРОШЊЕ И ПРОИЗВОДЊЕ ЕЛЕКТРИЧНЕ ЕНЕРГИЈЕ

Прогноза потрошње и производње електричне енергије кључна је за стабилно и ефикасно управљање електроенергетским системима. Прецизне прогнозе омогућавају оптимално планирање, смањење трошкова и боље искоришћење ресурса. Са растом обновљивих извора, прогноза постаје још значајнија због њихове променљиве природе. Традиционалне методе користе статистичке моделе и анализу временских серија засноване на историјским подацима. Вештачка интелигенција (ВИ) доноси напредније приступе, омогућавајући прецизније прогнозе кроз дубоке неуралне мреже и аутоматско препознавање образаца. Компаније користе ВИ за предвиђање потрошње у различитим регионима и временским периодима, узимајући у обзир факторе попут временских услова и празника. Произвођачи обновљиве енергије користе ВИ за процену производње на основу метеоролошких података.

Прогноза представља процес предвиђања будућих догађаја или стања на основу расположивих информација и анализе тренутних узорака. У контексту електроенергетике, прогноза се односи на предвиђање потрошње и производње електричне енергије. Ова прогностичка активност је од суштинског значаја за одржавање стабилности, ефикасности и поузданости електроенергетских система. Прогноза омогућава електроенергетским компанијама да планирају адекватне капацитете за производњу електричне енергије у складу са очекиваном потражњом, правовремено предузимање потребних мера за изградњу, одржавање или обнављање инфраструктуре, као и ефикасно управљање електроенергетском мрежом, укључујући балансирање понуде и потражње електричне енергије, управљање оптерећењем система и оптимално коришћење расположивих ресурса. Прецизна прогноза омогућава ефикасније коришћење ресурса, што доприноси смањењу трошкова производње и дистрибуције електричне енергије. Ово може резултирати нижим ценама електричне енергије за крајње кориснике.

Обновљиви извори енергије, попут соларне и ветроенергије, значајно утичу на прогнозу производње због своје променљивости и зависности од временских услова.


Флуктуације у интензитету сунчеве светлости и брзини ветра отежавају прецизну прогнозу и захтевају динамично прилагођавање електроенергетског система како би се одржала равнотежа понуде и потражње. Изазови у прогнози укључују сложено моделовање временских промена, сезонских варијација и географских фактора, као и недостатак дугорочних података. Потребно је развити напредне алгоритме који могу обрађивати велике количине података и прилагођавати се брзим флуктуацијама у производњи. ВИ омогућава ефикасније прогнозе кроз дубоко учење и неуралне мреже, које моделују сложене нелинеарне односе и идентификују скривене обрасце. ВИ прилагођава моделе новим подацима, побољшава тачност прогноза и доприноси стабилнијем и одрживијем електроенергетском систему.

3 ТЕОРИЈСКИ ОСНОВИ ВЕШТАЧКИХ НЕУРАЛНИХ МРЕЖА


Разумевање теоријских основа вештачких неуралних мрежа представља кључан део разумевања примене ВИ у прогнози производње електричне енергије. Вештачке неуралне мреже су инспирисане биолошким неуралним мрежама и представљају сложене системе који могу научити сложене функције из података. У основи, неуралне мреже састоје се од неурона, који су повезани у слојевиту структуру и који обрађују улазне податке како би генерисали излазне информације. Кроз процес учења, неуралне мреже прилагођавају тежине веза између неурона како би минимизирале грешку између стварних и предвиђених вредности. Овај процес омогућава неуралним мрежама да открију скривене обрасце и релације у подацима, што их чини моћним алатима за решавање проблема прогнозе.

3.1 Архитектура неуралних мрежа

Архитектура неуралних мрежа обухвата организацију и структуру неурона и њихових веза унутар мреже. Постоји неколико основних типова архитектуре неуралних мрежа, од којих су најчешће коришћене неуралне мреже са пропагацијом унапред (*feed-forward neural networks*) и неуралне мреже са рекурентним везама (*recurrent neural networks*), слика 1. Неуралне мреже са пропагацијом унапред састоје се од слојева неурона који су повезани тако да информација кружи само у једном смеру, од улазног слоја ка излазном слоју. Ови типови мрежа су често коришћени за проблеме класификације и регресије. С друге стране, неуралне мреже са рекурентним везама имају додатне повратне везе које омогућавају информацији да кружи уназад у мрежи, што их чини погодним за обраду секвенцијалних података као што су временске серије.



Слика 1: Неуронске мреже са пропагацијом унапред и неуронске мреже са рекурентним везама



Слика 2: Слојеви у неуронским мрежама

3.2 Учење неуралних мрежа

Учење неуралних мрежа подразумева прилагођавање тежина веза између неурона ради оптимизације модела. На почетку, тежински фактори су насумично иницијализовани, а улазни подаци се множе са тежинама и прослеђују неуронима. Неурони сабирају ове вредности, примењују активациону функцију и генеришу излаз. У једноставним мрежама тај излаз је коначан, док у сложенијим слојевима служи као улаз за наредни слој, омогућавајући дубљу обраду. Грешка предвиђања (разлика између стварне и предвиђене вредности) користи се за корекцију тежина. Најчешће се мери средњом сумом квадрата грешке (MSE), која се користи и у овом раду.

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

Поред MSE постоје и функције као што су средња процентуална грешка, средња апсолутна грешка и друге. У зависности од типа проблема бира се $Cost$ функција. Учење неуралних мрежа подразумева прилагођавање тежинских фактора помоћу алгоритама пропагације унапред и уназад. Овај процес се понавља кроз више епоха док мрежа не постигне оптималне резултате.

За предвиђање производње и потрошње електричне енергије користе се различите архитектуре неуралних мрежа:

- **RNN (Рекурентне неуралне мреже)** – Погодне за временске серије јер узимају у обзир претходне вредности података. **LSTM** и **GRU** варијанте побољшавају дугорочну меморију модела.
- **CNN (Конволутивне неуралне мреже)** – Иако су примарно за слике, могу се користити за временске серије с више сензора или параметара.
- **RCNN (Рекурентне конволутивне мреже)** – Комбинују **RNN** и **CNN**, омогућавајући обраду комплексних, мултидимензионалних података.
- **DNN (Дубоке неуралне мреже)** – Флексибилне за учење сложених нелинеарних односа у подацима.

Одабир архитектуре зависи од природе података и специфичних захтева проблема.


4 ОПИС МЕТОДОЛОГИЈЕ

За потребе прогнозе производње и потрошње електричне енергије неопходно је сакупити велике количине историјских података из области метеорологије, економије, географије, енергетике и многих других научних области. Чак и када постоје огромне количине историјских података, није реално очекивати прецизно предвиђање тражених вредности јер су и производња и потрошња електричне енергије такође зависни и од људских фактора, као што су политика, социологија, па чак и верски аспект не сме да се занемари. На пример, за време великих празника потрошња електричне енергије се знатно повећава. У оквиру овог рада коришћен је скуп података који обухвата временске прилике, производњу из хидроелектрана, термоелектрана и обновљивих извора, као и потрошњу електричне енергије. Сви подаци су сатне резолуције током једне календарске године. За потребе прогнозе производње коришћени су подаци о временским приликама за одређени сат, као и подаци о производњи електричне енергије и временским условима из претходног сата. Табела са подацима, која је коришћена у овом истраживању, састоји се од 36 колона и 8014 редова, па је пре употребе извршено уређивање података како би били лакше читљиви и обрадиви у програму.


Ни производњу електричне енергије из извора које контролише човек, као што су термоелектране, није лако предвидети, јер је изузетно тешко уочити правила по којима се понаша потрошња. Још је сложеније предвидети производњу електричне енергије из обновљивих извора, као што су ветропаркови и соларне електране, због чега је настала потреба за применом неуралних мрежа. Како ће бити приказано у наставку рада, неуралне мреже могу дати поуздане резултате у задацима предвиђања.

10m_Wind_Speed(m/s)	10m_Wind_Dir	10m_Temp(degC)	2m_Temp(degC)	SWR(W/m**2)	TOTCL(%)	Tot_Prec(mm)	LOWCL(%)	MEDCL(%)	HIGCL(%)	RH(%)
1.497	85.788	3.646	3.05	0	0.095	0	0.095	0	0	76.977
1.548	84.691	3.641	3.656	0	0.044	0	0.044	0	0	75.008
0.947	56.376	3.834	3.902	0	0.06	0	0.06	0	0	71.113
1.146	3.311	3.161	3.261	0	0.076	0	0.076	0	0	75.909
1.051	352.345	3.391	4.004	0	0.024	0	0.024	0	0	74.152
1.121	25.463	3.332	3.491	12.468	0.022	0	0.022	0	0	74.562
0.992	59.422	4.832	5.042	107.745	0	0	0	0	0	63.719
0.37	5.799	6.087	6.448	266.188	0	0	0	0	0	58.118
0.503	300.386	7.443	7.344	380.04	0	0	0	0	0	57.465
0.825	242.052	8.68	8.323	422.565	0	0	0	0	0	55.035
1.383	194.157	9.615	9.061	428.368	0	0	0	0	0	51.487
2.279	182.37	9.573	9.446	361.224	0	0	0	0	0	47.226
2.974	173.882	9.243	9.119	280.957	0	0	0	0	0	48.099
3.032	160.146	8.117	7.757	121.881	0	0	0	0	0	56.933
3.015	143.814	6.135	5.714	1.425	0	0	0	0	0	64.413
2.598	138.691	5.613	5.513	0	0	0	0	0	0	58.545
2.241	139.634	5.547	5.388	0	0	0	0	0	0	58.017
2.081	150.797	5.259	4.941	0	0	0	0	0	0	64.204
2.239	147.958	5.093	4.541	0	0	0	0	0	0	65.327
2.303	137.42	5.145	4.638	0	0	0	0	0	0	60.868
2.34	136.249	4.984	4.516	0	0	0	0	0	0	54.695
2.58	137.935	4.614	4.033	0	0	0	0	0	0	52.427
2.705	142.725	4.09	3.516	0	0	0	0	0	0	50.041
2.673	140.745	4.002	3.482	0	0	0	0	0	0	45.218

Слика 3: Приказ дела табеле са подацима коришћене за израду рада



Слика 4: Приказ производње електричне енергије из термоелектрана у периоду од месец дана



Слика 5: Приказ производње електричне енергије из обновљивих извора


Решење посматраног проблема дато је у облику два програмска кода написана у програмском језику *Python*. Први програмски код проналази и тренира најбољу неуралну мрежу за дати проблем, док други програмски код учитава најбољи модел неуралне мреже и користи га за предвиђање.

Програмски код може се поделити на четири кључна корака:

1. **Учитавање библиотеке:** Програм користи *Pandas* (анализа података), *NumPy* (математичке операције), *Scikit-learn* (машинско учење), *TensorFlow* (неуралне мреже) и *Scikit-optimize* (оптимизација хиперпараметара). Додатне библиотеке попут *Subprocess*, *Pygame* и *Smtplib* проширују функционалност.
2. **Дефинисање параметара:** Корисник подешава **почетне вредности** (нпр. степен учења, број слојева/неурона, активациону функцију), **број понављања оптимизације**, **границе раног заустављања** (током претраге и коначног тренинга), **максималан број епоха** и **величину пакета података**. Такође, дефинишу се **опсези параметара** за оптимизацију и **путање** за податке и модел.
3. **Креирање и тренирање модела:**

- **create_model** – креира модел на основу задатих параметара и
- **fitness** – обучава модел, примењује рано заустављање и чува најбоље параметре и модел.

4. **Обрада грешака:** Програм садржи функцију за хватање грешака која омогућава несметано извршавање и обраду евентуалних проблема током рада. Овим структурираним приступом постиже се ефикасно оптимизовање и тренирање неуралне мреже.



Слика 6: Алгоритам програма

Програм за испис резултата је знатно једноставнији од програма за прављење модела. Прво се увозе све библиотеке као у првом коду. Учитава се модел мреже који је сачуван након завршетка првог програма, као и подаци за предвиђање. Ове податке модел никада није видео нити је био трениран употребом ових података. Врши се урешивање тестирајућег скупа тако што се одстрани редови који нису потпуни, а затим се подаци деле на улазне и излазне исто као у првом коду. Улазни подаци користе се као подаци за предвиђање, док се излазни подаци користе за израчунавање грешке предвиђања. На крају се резултати анализирају, чиме се завршава рад програма за испис резултата.

5 РЕЗУЛТАТИ МЕТОДОЛОГИЈЕ

За потребе евалуације програма, као улазни подаци су коришћене информације о временским приликама, а добијена су четири различита модела:

- Модел за предвиђање производње из термоелектрана
- Модел за предвиђање производње из хидроелектрана
- Модел за предвиђање производње из обновљивих извора
- Модел за предвиђање потрошње електричне енергије

Након завршетка првог програма формиран је модел који најбоље предвиђа производњу из одређеног извора или потрошњу електричне енергије. За потребе статистичке анализе коришћени су следећи метрички параметри:

- Средња вредност процента грешке (*MPE – Mean Percentage Error*)

$$MPE = \frac{1}{n} \sum_{i=1}^n \left(\frac{A_i - F_i}{A_i} \right) * 100\%,$$

- Средња квадратна грешка (*MSE – Mean Squared Error*)

$$MSE = \frac{1}{n} \sum_{i=1}^n (A_i - F_i)^2,$$

- Средња апсолутна грешка (*MAE – Mean Absolute Error*)

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i|,$$

- R^2 оцена

$$R^2 = 1 - \frac{S_{rez}}{S_{tot}}.$$

где су:

MPE – средња вредност процента грешке,

MSE – средња квадратна грешка ,

MAE – средња апсолутна грешка

n – број узорака,

A_i – стварна вредност *i* – тог узорка,

F_i – предвиђена вредност *i* – тог узорка,

S_{rez} – сума квадрата резидуала (остатака), односно квадрата разлике између стварних и предвиђених вредности


S_{tot} – укупна сума квадрата, односно укупна варијација стварних вредности од њиховог просека.

Производња из термоелектрана показала је изузетну прецизност, са *MPE* од 7,05% и R^2 оценом од 0,96, што указује на висок ниво разумевања односа међу променљивама.


Производња из хидроелектрана, која више зависи од временских услова, има MPE од 19,35%, што не задовољава потребну прецизност, док је R^2 оцена 0,88, што додатно потврђује сложеност предвиђања, посебно у регионима са великим хидропотенцијалима. Обновљиви извори енергије, који су у потпуности зависни од временских услова, имају MPE од 51,42%, што указује на значајну непредвидивост, иако R^2 оцена од 0,97 показује да модел добро разуме међузависности променљивих. Потрошња електричне енергије је најпрецизније предвиђена, са MPE од само 0,31%, док је R^2 оцена 0,96 на задовољавајућем нивоу. На слици 7 приказане су предвиђене и стварне вредности производње из термоелектрана. На слици 8 налазе се статистички резултати овог модела. На сликама 9 и 10 представљене су перформансе модела за производњу из хидроелектрана. Слична анализа модела за обновљиве изворе приказана је на сликама 11 и 12. За предикцију потрошње електричне енергије развијен је посебан модел, чије су перформансе дате на сликама 13 и 14. Сумирани статистички подаци (табела 1) указују на изазове предвиђања производње из обновљивих извора.

```
Maksimalna procentualna greška: 199.0635241104869
Minimalna procentualna greška: 0.0
Srednja vrednost procenta greške (MPE): 7.05%
Srednja kvadratna greška (MSE): 12695.257560446269
Procentat greške u odnosu na raspon ciljnih vrednosti: 513.56%
Srednja apsolutna greška (MAE): 87.27990060058472
R2 skor: 0.9610822685858244
```

Слика 7: Производња из термоелектрана



Слика 8: Приказ прецизности резултата за термоелектране




Слика 9: Производња из хидроелектрана

```

Maksimalna procentualna greška: 1321.2599332752147
Minimalna procentualna greška: 6.692451343201754e-06
Srednja vrednost procenta greške (MPE): 19.35%
Srednja kvadratna greška (MSE): 25501.49744126766
Procentat greške u odnosu na raspon ciljnih vrednosti: 800.17%
Srednja apsolutna greška (MAE): 111.15105719265273
R2 skor: 0.8821679518781947

```

Слика 10: Приказ прецизности резултата за хидроелектране



Слика 11: Производња из обновљивих извора


```

251/251 [=====] - 1s 2ms/step
Maksimalna procentualna greška: 16831.947326660156
Minimalna procentualna greška: 0.0
Srednja vrednost procenta greške (MPE): 51.42%
Srednja kvadratna greška (MSE): 972.9439678393611
Procentat greške u odnosu na raspon ciljnih vrednosti: 330.93%
Srednja apsolutna greška (MAE): 18.66225654275036
R2 skor: 0.8717316991609879

```

Слика 12: Приказ прецизности резултата из обновљивих извора

За ефикасног дистрибутера електричне енергије неопходно је што боље предвидети потрошњу електричне енергије, за те потребе је истрениран нови модел чије су перформансе приказане на сликама 13 и 14.



Слика 13: Приказ потрошње електричне енергије

```

Maksimalna procentualna greška: 21.450287441037734
Minimalna procentualna greška: 0.00011737530048076923
Srednja vrednost procenta greške (MPE): 0.32%
Srednja kvadratna greška (MSE): 19261.620537371844
Procentat greške u odnosu na raspon ciljnih vrednosti: 515.57%
Srednja apsolutna greška (MAE): 103.64026691814715
R2 skor: 0.9649136534332428

```

Слика 14: Приказ прецизности резултата потрошње електричне енергије

Ова анализа показује да су модели за производњу из временски зависних извора тежи за предикцију, док потрошња електричне енергије, иако такође зависна од временских услова, може бити прецизно предвиђена. Сумирањем свих статистичких података на једно место (табела 1), види се захтевност предвиђања производње из обновљивих извора електричне енергије.

Табела 1: Анализа резултата рада програма

	термоелектране	хидроелектране	обновљиви извори	потрошња
<i>MPE</i> (%)	7.05	19.35	51.42	0.32
<i>MSE</i>	12695.26	25501.49	972.94	19261.62
<i>MAE</i>	87.28	111.15	19.66	103.64
R^2	0.9611	0.8822	0.9717	0.9649

За поређење модела коришћени су *MPE* и R^2 , јер омогућавају релативну процену прецизности, док су *MSE* и *MAE* изостављени због зависности од апсолутних вредности, што отежава директно поређење међу моделима. Програм је дизајниран тако да аутоматски одређује број улазних чворова, при чему је потребно само дефинисати назив колоне са излазним подацима. Овај приступ омогућава креирање модела за различите примене, не само за анализу производње и потрошње електричне енергије. Повећањем базе података побољшава се прецизност модела, док програм самостално обрађује све потребне кораке, чинећи га прилагодљивим и вишефункционалним.

6 ЗАКЉУЧАК

Примена вештачких неуронских мрежа на прогнозу производње електричне енергије из термоелектрана и из хидропотенцијала се показала као веома поуздана метода, док је ситуација код прогнозе производње из обновљивих извора нешто лошија. Могући разлози за лоше перформансе модела су недостатак довољне количине података, као и сама сложеност односа између тих података. Код прогнозе потрошње електричне енергије примењена метода је дала изненађујуће добре резултате и има потенцијала, већ сада, да се користи у комерцијалним условима.

Резултати истраживања показују да примена вештачке интелигенције доноси задовољавајуће резултате у предвиђању производње електричне енергије. Међутим, као што је истакнуто, један од главних изазова је тачност података о временским приликама, који су кључни за прецизна предвиђања. Ограничења у доступности прецизних временских података могу ограничити тачност предвиђања у реалном свету. Ипак, уз напредак технологије, као што су сателитски снимци и супер-рачунари, може се очекивати да ће се ови изазови поступно превазићи, што ће довести до побољшања тачности предвиђања у будућности.

Овај рад истиче значај примене вештачке интелигенције у електроенергетском сектору, али истовремено указује на важност даљег развоја технологија и методологија како би се постигла још већа прецизност у предвиђању производње електричне енергије.

7 ЛІТЕРАТУРА

- [1] Guillermo Escrivá-Escrivá, Carlos Álvarez-Bel, Carlos Roldán-Blay, Manuel Alcázar-Ortega, New artificial neural network prediction method for electrical consumption forecasting based on building end-uses, *Energy and Buildings* (43) (2011) 3112–3119.
- [2] L. Ekonomou, Greek long-term energy consumption prediction using artificial neural networks, *Energy* (35) (2010) 512–517.
- [3] Lei Tang, Xifan Wang, Xiuli Wang, Chengcheng Shao, Shiyu Liu, Shijun Tian, Long-term electricity consumption forecasting based on expert prediction and fuzzy Bayesian theory, *Energy* (167) (2019) 1144e1154.
- [4] Sasan Barak, S. Saeedeh Sadegh, Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm, *Electrical Power and Energy Systems*, (82) (2016) 92–104.
- [5] Mahdi Sharifzadeha, Alexandra Sikinioti-Locka, Nilay Shaha, Machine-learning methods for integrated renewable power generation: A T comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression, *Renewable and Sustainable Energy Reviews*, (108) (2019) 513–538.