

DOI: [10.46793/CIGRE37.B5.06](https://doi.org/10.46793/CIGRE37.B5.06)**B5.06****ДЕТЕКЦИЈА, КЛАСИФИКАЦИЈА И ЛОКАЛИЗАЦИЈА КВАРОВА У ПРЕНОСНИМ
ВОДОВИМА КОРИШЋЕЊЕМ ВЕШТАЧКИХ НЕУРАЛНИХ МРЕŽА****FAULT DETECTION, CLASSIFICATION AND LOCALIZATION IN POWER
TRANSMISSION LINES USING ANN****Živko Sokolović, Miletta Žarković***

Kratak sadržaj: Prenosni vod predstavlja ključnu opremu za siguran i pouzdan prenos energije u svakom elektroenergetskom sistemu. Da bi se povećala pouzdanost i sigurnost dalekovoda, potrebno je simulirati različite vrste kvarova kako bi se minimizirao njihov uticaj i otkrili i rešavali što je brže moguće. Cilj ovog rada je da pruži tačnu metodu za detekciju, klasifikaciju i lokalizaciju kvarova na prenosnim vodovima koristeći veštačke neuronske mreže (ANN). Prenosni sistem modelovan je u DIgSILENT PowerFactory, simulirajući kako normalne tako i režime sa kvarom. Tri vrste kvarova su razmatrane za simulaciju: jednofazni kvar sa zemljom, dvofazni kratki spoj i trofazni kratki spoj. Svaki kvar je simuliran na 110 kV prenosnim vodovima sa rezolucijom od 5%. Pored režima sa kvarom, izvršen je i normalni režim korišćenjem analize tokova snaga, pri čemu je opterećenje sistema variralo. Podaci o naponima i strujama iz ovih simulacija korišćeni su za obuku i testiranje ANN modela. Predloženi model postigao je tačnost od 100% u detekciji vrsta kvarova, tačnost od 94% u identifikaciji voda na kome je kvar nastao, i srednju apsolutnu grešku (MAE) od 1,15 u preciznom određivanju tačne lokacije kvara. Ovi rezultati pokazuju efikasnost modela u tačnom prepoznavanju i lokalizaciji kvarova na prenosnim vodovima, što značajno doprinosi pouzdanosti i stabilnosti rada elektroenergetskih sistema.

Ključне речи: вештачке neuralne мреже, prenosni vod, DIgSILENT, klasifikација и локализација квара

Abstract: Power transmission line is key equipment in secure and reliable power flow in each power system. To enhance the reliability and security of transmission lines, it is essential to simulate various types of faults to minimize their impact and enable their rapid detection and resolution. The objective of this paper is to provide an accurate method for detection, classification and localization of faults occurring in power transmission lines using Artificial Neural Network (ANN). Power transmission system was modelled in DIgSILENT PowerFactory, simulating both normal and fault scenarios. Three types of faults were considered for simulation: single-phase-to-ground fault, two-phase short circuit, and three-phase short circuit.

*Živko Sokolović, Nikola Tesla Institute of Electrical Engineering, sokoloviczivko98@gmail.com
Miletta Žarković, Univerzitet u Beogradu -Elektrotehnički fakultet, miletta@etf.rs

Each fault was simulated across the 110 kV power lines with a resolution of 5%. In addition to the fault scenarios, normal scenario was carried out using a load flow analysis, where the system's load was varied. Voltage and current data from these simulations were utilized to train and test the ANN model. The proposed model achieved an accuracy of 100% in detecting fault types, a fault classification accuracy of 94% for identifying the fault line, and a mean absolute error (MAE) of 1.15 in pinpointing the exact fault position. These results demonstrate the model's effectiveness in accurately identifying and localizing faults in power transmission lines, significantly contributing to the reliability and stability of power grid operations.

Key words: ANN, transmission line, DIgSILENT, fault classification and localization

1 UVOD

Elektroenergetski sistem sastoji se od tri ključna podsistema: proizvodnje, prenosa i distribucije. Električna energija se prenosi od proizvodnje do distribucije električne energije kroz visokonaponske vodove prenosnog elektroenergetskog sistema. Prenosni vod je sistem visokonaponskih provodnika koji omogućavaju prenos električne energije na velike udaljenosti od elektrana do transformatorskih stanica, odakle se energija distribuira krajnjim korisnicima. Zbog izloženosti spoljnim uslovima, termičkim i mehaničkim naprezanjima, prenosni vodovi su podložni različitim vrstama kvarova [1]. Pouzdano funkcionisanje elektroenergetskog sistema ima ključnu ulogu u održavanju stabilnosti industrije i svakodnevnog života. Kvarovi u elektroenergetskom sistemu mogu izazvati značajne poremećaje i finansijske gubitke. Stoga je obezbeđivanje nesmetanog i sigurnog prenosa energije od suštinskog značaja za očuvanje ekonomskih aktivnosti jedne zemlje [2].

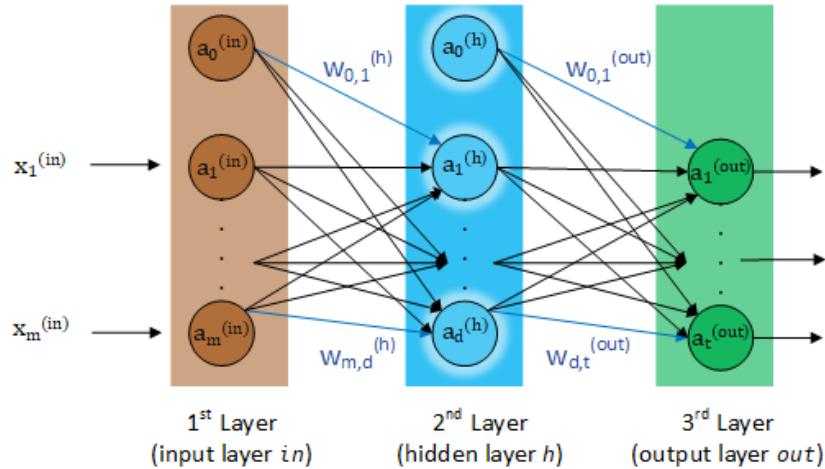
Za efikasnu zaštitu elektroenergetske mreže, neophodno je brzo detektovati i precizno locirati kvarove, a potom izolovati deo mreže u kvaru [3]. U praksi, ovu operaciju obavljaju releji i prekidač. Konvencionalne metode zaštite prenosnih vodova, poput distantne zaštite [4] i zaštite na bazi putujućih talasa [5], dugo su korišćene za detekciju i lokalizaciju kvarova u elektroenergetskim sistemima. Ove metode se oslanjaju na analizu struja, napona i impedansi kako bi identifikovale kvar i aktivirale odgovarajuće zaštitne mehanizme. Iako su pouzdane i efikasne u mnogim slučajevima, konvencionalne tehnike suočavaju se s određenim ograničenjima, poput problema sa detekcijom visokoimpedansnih kvarova [6], različitih problema koji se javljaju usled visoke integracije obnovljivih izvora energije [7], osetljivosti na intermitene promene opterećenja i oscilacije sistema.

Sa napretkom tehnologije, sve više se istražuju i primenjuju metode zasnovane na veštačkoj inteligenciji (*Artificial Intelligence*), uključujući mašinsko učenje i duboko učenje [8-10]. AI algoritmi mogu značajno unaprediti zaštitu prenosnih vodova. Stoga, ovaj rad se fokusira na primeni veštačkih neuralnih mreža za brzu i pouzdanu detekciju, klasifikaciju i lokalizaciju kvarova u prenosnim vodovima elektroenergetskog sistema.

Ostatak ovog rada je organizovan na sledeći način. Poglavlje 2 izlaže teoretska objašnjenja o funkcionisanju neuralnih mreža. Poglavlje 3 obezbeđuje metodologiju. Poglavlje 4 se bavi analizom dobijenih rezultata. Poglavlje 5 zaključuje rad i daje potencijalne smernice za buduća istraživanja.

2 VEŠTAČKE NEURALNE MREŽE

Veštačke neuronske mreže (ANN) su računarski modeli inspirisani strukturu i funkcijama bioloških neuronskih mreža. One su osnovni gradivni element u razvoju AI. Model ANN obično se sastoji od tri glavna sloja: ulaznog, skrivenog i izlaznog. Ulagi sloj prima podatke ili signale iz spoljnog okruženja, kao što su struja ili napon u elektroenergetskim sistemima. Skriveni sloj obrađuje ulazne podatke izdvajajući obrasce povezane s analiziranim procesom ili sistemom. Na kraju, izlazni sloj generiše i prikazuje konačne prognoze ili rezultate modela. Ovi slojevi rade zajedno, pri čemu podaci prolaze i transformišu se kroz svaki sloj [3]. Slika 2.1 prikazuje osnovnu strukturu ANN, naglašavajući protok podataka kroz ove slojeve.



Slika 2.1: Veštačka neuralna mreža

Broj skrivenih slojeva može biti povećan formirajući „duboku“ neuralnu mrežu za učenje složenijih karakteristika. Na prethodnoj slici x_1, x_2, \dots, x_m označavaju ulaze. Težinski koeficijenti su označeni sa $w_{i,j}^{(l)}$ ukazujući vezu između neurona (jedinica) i u sloju $l - 1$ i neurona j u sloju l . Dodatno, $a_i^{(l)}$ predstavlja aktivaciju neurona i u sloju l . Član $a_0^{(l)}$ se odnosi na “bias” jedinicu u sloju l i postavljena je na vrednost 1.

Operacija unapred (*forward propagation*) u svakom neuronu može biti napisana kao matematički izraz koji računa izlaz na osnovu ulaza, težina i aktivacione funkcije. Za jedan neuron u skrivenom sloju h , izlaz može biti proračunat na sledeći način [11]:

$$z_1^{(h)} = a_0^{(in)} w_{0,1}^{(h)} + a_1^{(in)} w_{1,1}^{(h)} + \dots + a_m^{(in)} w_{m,1}^{(h)} \quad (2.1)$$

$$a_1^{(h)} = \phi(z_1^{(h)}) \quad (2.2)$$

gde $z_1^{(h)}$ označava „net“ ulaz, dok je $\phi(\cdot)$ aktivaciona funkcija. Aktivacione funkcije su ključne komponente neuralnih mreža koje uvode nelinearnost u model, omogućavajući učenje složenih obrazaca i veza u podacima. Česte aktivacione funkcije uključuju *sigmoid*, *tanh*, *rectified linear unit (relu)*.

Nakon prolaska unapred kroz mrežu i dobijanja izlaza, sledeći korak je izračunavanje greške pomoću funkcije gubitka L , koja se potom minimizira. Dugo vremena istraživači su se borili da nađu adekvatan način treniranja neuralne mreže, ali bez uspeha.

Međutim, 1986. godine je objavljen algoritam propagacije greške unazad (*backpropagation*), koji omogućava mreži da prilagođava težine slojeva kako bi minimizovala ovu funkciju gubitka. Ovaj algoritam može biti opisan sledećim skupom jednačina:

$$\delta^{(out)} = a^{(out)} - y \quad (2.3)$$

$$\delta^{(h)} = W^{(out)} \delta^{(out)} \odot \frac{\partial \phi(z^{(h)})}{\partial z^{(h)}} \quad (2.4)$$

$$\frac{\partial}{\partial w_{i,j}^{(out)}} L(W) = a_i^{(h)} \delta_j^{(out)} \quad (2.5)$$

$$\frac{\partial}{\partial w_{i,j}^{(h)}} L(W) = a_i^{(in)} \delta_j^{(h)} \quad (2.6)$$

$$w_{i,j}^{(l)} = w_{i,j}^{(l)} - \eta \frac{\partial}{\partial w_{i,j}^{(l)}} L(W) \quad (2.7)$$

Kod propagacije greške, greška se prostire od izlaznog sloja sve do ulaznog sloja. Jednačina 2.3 računa vektor greške za izlazni sloj $\delta^{(out)}$, gde je y vektor stvarnih vrednosti. Jednačina 2.4 računa grešku za skriveni sloj $\delta^{(h)}$, gde $W^{(out)}$ predstavlja matricu težina izlaznog sloja i član $\frac{\partial \phi(z^{(h)})}{\partial z^{(h)}}$ je izvod aktivacione funkcije. Simbol \odot označava operaciju množenja. Jednačine 2.5 i 2.6 računaju parcijalne izvode funkcije gubitka L u odnosu na težine w . Konačno, težine su ažurirane u jednačini 2.7, gde je η stopa obučavanja.

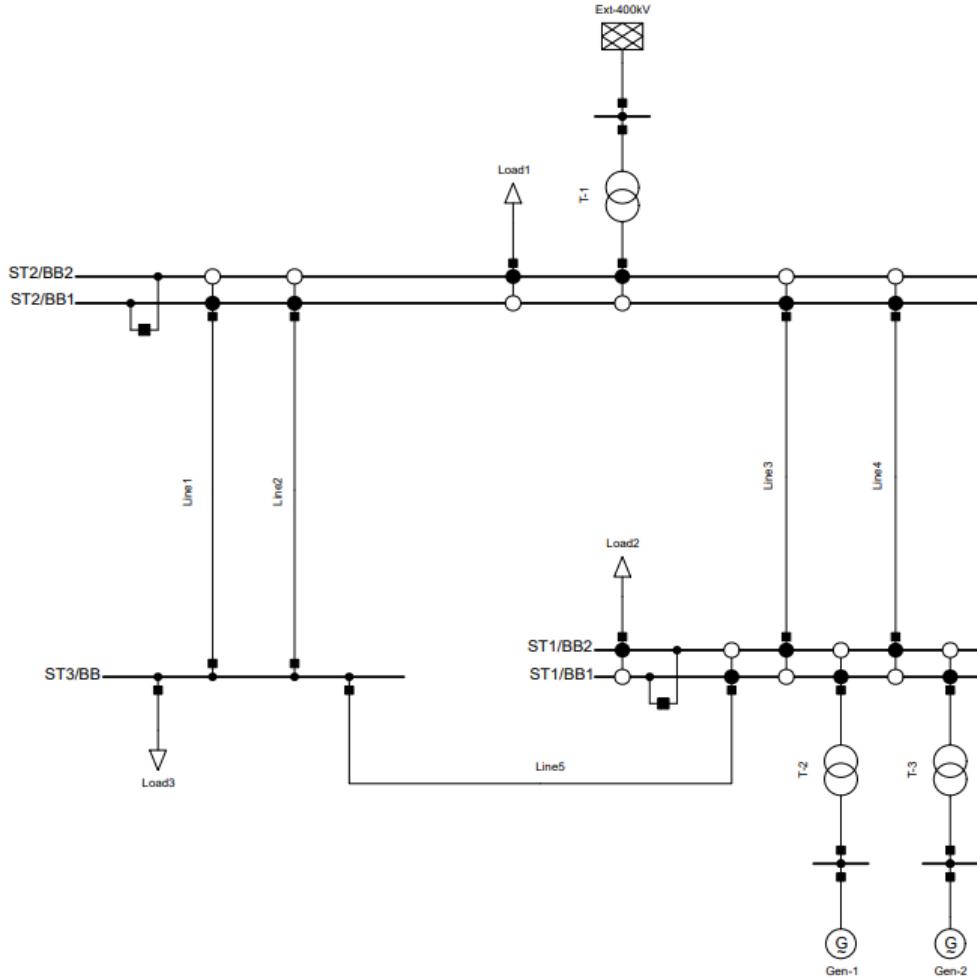
3 METODOLOGIJA

3.1 Model prenosne mreže

Prenosna mreža 110 kV je modelovana u *Digsilent PowerFactory* softveru koji služi kao alat za analizu elektrenergetskih sistema, kao što je prikazano na slici 3.1. Model uključuje sve neophodne komponente kao što su sabirnice, transformatori, generatori, opterećenja, prenosni vodovi i ekvivalent 400 kV mreže. Tabela 3.1 rezimira ključne električne parametre prenosnih vodova gde se kvarovi javljaju, uključujući poduznu direktnu i nultu rezistansu i reakstansu, kao i dužine vodova.

Tabela 3.1: Parametri vodova

Naziv	Dužina [km]	R ₁ [Ohm/km]	X ₁ [Ohm/km]	R ₀ [Ohm/km]	X ₀ [Ohm/km]
Line1	50	0.19	0.36	0.34	1.58
Line2	50	0.19	0.36	0.34	1.58
Line3	15	0.15	0.40	0.31	1.11
Line4	15	0.15	0.40	0.31	1.11
Line5	25	0.15	0.40	0.31	1.11



Slika 3.1: Model prenosne mreže

3.2 Generisanje podataka

U cilju treniranja i testiranja ANN za detekciju, klasifikaciju i lokalizaciju kvarova u prenosnim vodovima, neophodni su podaci koji su formirani iz simulacija u Digsilent-u. Izvršeni su proračuni tokova snaga i proračun kratkih spojeva u cilju generisanja podataka. Tri tipa kvara su simulirana prilikom proračuna kratkih spojeva: jednofazni kvar sa zemljom (*spgf*), dvofazni kratki spoj (*2psc*), trofazni kratki spoj (*3psc*). Svaki od navedenih kvarova je simuliran duž prenosnih vodova, variranjem lokacije kvara od početka do kraja voda sa korakom od 5%. Ovaj pristup osigurava generisanje obimne baze podataka pokrivači različite pozicije kvara duž vodova.

Pored scenarija sa kvarom, u razmatranje je uzet i normalni režim rada mreže. Ovaj normalni scenario je izvršen proračunom tokova snaga, gde je sistemsko opterećenje varirano u različitom opsegu kako bi se reflektovale tipične promene u zahtevima za električnom energijom. Ovakvi podaci pomažu ANN modelu da razlikuje normalna radna stanja i stanja sa kvarom. Za svaki od gore pomenutih scenarija, podaci o faznim naponima i strujama su detektovani i skladišteni u jedinstvenu bazu podataka. Baza podataka sadrži 24 ulazne promenljive koje opisuju stanje sistema u slučaju normalnih režima i režima sa kvarom. Pored toga, postoje tri izlazne promenljive koje daju informaciju o prisustvu i karakteristikama kvara, kao što je opisano u tabeli 3.2.

Ceo proces simulacije i izvlačenja podataka iz Digsilent modela bio je potpomognut adekvatnom skriptom napisanom u Python-u, jer Digsilent-ov interfejs omogućava komunikaciju sa Python interfejsom. Generisana baza podataka sadrži ukupno 618 primera, odnosno tačaka podataka, koja je onda korišćena za treniranje i testiranje neuralne mreže.

Tabela 3.2: Opis baze podataka

	Promenljiva	Opis	Vrednost
Ulaz	Ua1, Ub1, Uc1	Fazne RMS vrednosti napona na sabirnici 1	
	Ua2, Ub2, Uc2	Fazne RMS vrednosti napona na sabirnici 2	Realan broj (kV)
	Ua3, Ub3, Uc3	Fazne RMS vrednosti napona na sabirnici 3	
	Ia1, Ib1, Ic1 Ia2, Ib2, Ic2	Fazne RMS vrednosti struja na početku voda 1 Fazne RMS vrednosti struja na početku voda 2	Realan broj (kA)
	Ia3, Ib3, Ic3	Fazne RMS vrednosti struja na početku voda 3	
	Ia4, Ib4, Ic4	Fazne RMS vrednosti struja na početku voda 4	
	Ia5, Ib5, Ic5	Fazne RMS vrednosti struja na početku voda 5	
Izlaz	Fault	Tip kvara	spgf, 2psc, 3psc, ili <i>no-fault</i>
	Line	Vod pogođen kvarom	Line1, Line2, ..., Line5, ili <i>NONE</i> ¹
	Position	Lokacija kvara kao procenat dužine voda	0%, 5%, ..., 100%, ili <i>NONE</i> ¹

¹U slučaju normalnog režima bez kvara

3.3 Preprocesiranje podataka

U elektroenergetskim sistemima, promenljive kao što su napon i struja mogu biti različitih magnituda. Promenljive sa velikim vrednostima mogu da dominiraju u procesu obučavanja, što potencijalno može da pogorša performanse modela. Stoga, navedeni podaci trebaju biti skalirani. Najčešće korišćeni metod za skaliranje podataka je *Z-score* normalizacija. Ovaj metod transformiše svaku ulaznu promenljivu tako da srednja vrednost bude 0, dok je standardno odstupanje jednako 1. Jednačina *Z-score* normalizacije je:

$$z = \frac{x - \mu}{\sigma} \quad (3.1)$$

gde je z standardizovana vrednost, x je originalna vrednost. Srednja vrednost ulazne promenljive je označena sa μ , dok je σ standardno odstupanje.

Baza podataka je podeljena u dva skupa: 70% podataka je upotrebljeno za obuku modela, dok je preostalih 30% rezervisano za testiranje, čime je osiguran dovoljan broj podataka za obučavanje modela i njegovu evaluaciju.

3.4 Modelovanje i optimizacija neuralne mreže

Neuralna mreža je konstruisana koršćenjem *TensorFlow* biblioteke u Python-u koja je specijalno opremljena za kreiranje različitih arhitektura neuralnih mreža. Ona obezbeđuje jednostavnost i fleksibilnost u izradi složenijih modela sa više izlaza, kao što je slučaj u ovom radu. Unapredna (*feed-forward*) neuralna mreža je dizajnirana da istovremeno rukuje sa zadacima klasifikacije i regresije sa tri izlazna sloja, po jedan za svaki zadatak. Izlazne promeljive poput tipa kvara i voda pogodenog kvarom predstavljaju zadatak klasifikacije, dok je tačna pozicija kvara regresioni zadatak.

U cilju što bolje generalizacije modela nad testirajućim skupom podataka izvršena je optimizacija ključnih hiperparametara. U tabeli 3.3 prikazane su vrednosti hiperparametara koji su istraženi tokom optimizacije ANN modela.

Tabela 3.3: Istraženi prostor hiperparametara

Hiperparametar	Istražene vrednosti
Broj slojeva	1, 2, 3
Broj neurona po sloju	32, 64, ..., 512
Aktivaciona funkcija	ReLU, tanh
Stopa obučavanja	0.01, 0.001, 0.0001

3.5 Indeksi evaluacije

Da bi smo procenili performanse modela, kao indeksi su razmatrani tačnost i srednja apsolutna greška (Mean Absolute Error). Tačnost i MAE su definisani na sledeći način:

$$Accuracy = \frac{\text{broj tačnih predviđanja}}{\text{ukupan broj predviđanja}} * 100 \% \quad (3.1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.2)$$

gde y_i , \hat{y}_i i n označavaju stvarnu vrednost, predviđenu vrednost i ukupan broj tačaka podataka, respektivno.

4 REZULTATI

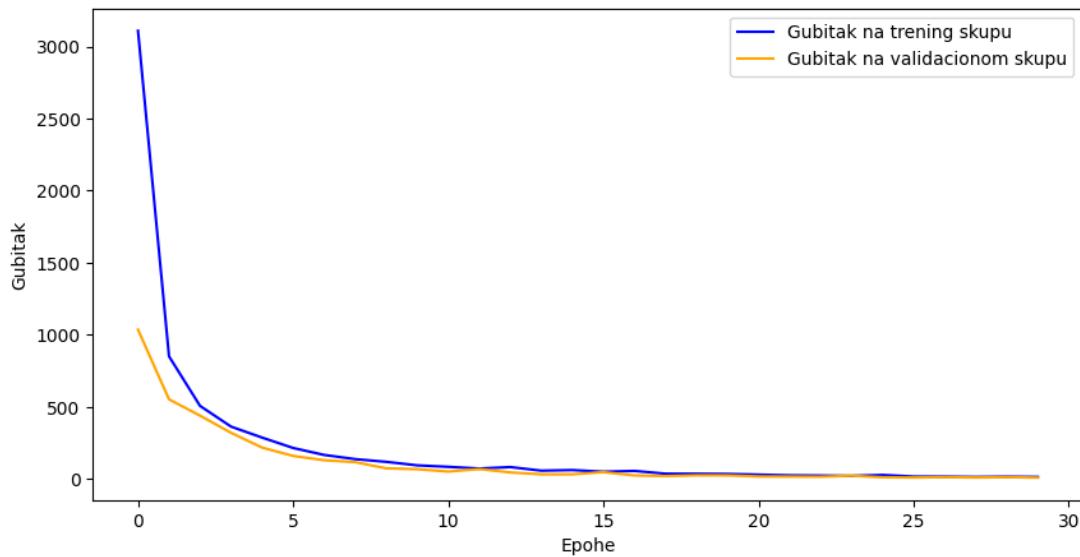
U tabeli 4.1 su prikazani rezultati dobijeni procesom optimizacije hiperparametara neuralne mreže. U procesu optimizacije za obuku modela korišćeno je 80 % celokupnog skupa podataka za obučavanje, dok je validacija izvršena na preostalih 20% ovog skupa u cilju procenjivanja performansi modela.

Podebljan red u tabeli odgovara najboljoj kombinaciji hiperparametara na osnovu funkcije gubitka na validacionom skupu čija vrednost iznosi 10,73, što je najmanja vrednost u poređenju sa ostalim kombinacijama hiperparametara.

Nakon određivanja optimalnih hiperparametara, finalni model neuralne mreže je formiran i ponovo treniran korišćenjem celog skupa podataka za obučavanje.

Za validaciju, skup podataka za testiranje je iskorišćen tokom procesa treniranja modela. Rezultati treniranja su prikazani na slici 4.1. Plavom bojom je označen gubitak trenirajućeg skupa, dok je žutom bojom označen gubitak testirajućeg skupa. Na horizontalnoj osi su označene epohe u procesu treniranja, pri čemu je maksimalan broj epoha postavljen na 30.

Konačno, evaluacija modela je izvršena preko dva ključna indeksa, rezultati su rezimirani u tabeli 4.2. Model postiže tačnost od 100% u klasifikaciji tipa kvara, 94 % tačnost po pitanju voda pogodenog kvarom i MAE od 1.15 za procenu tačne pozicije kvara. Vizuelni prikaz tačnih i predviđenih vrednosti modela na testirajućem skupu sa 20 nasumičnih uzoraka je ilustrovan na slici 4.2. Ovi rezultati ukazuju na visok stepen pouzdanosti modela.



Slika 4.1: Gubitak modela tokom treninga i validacije

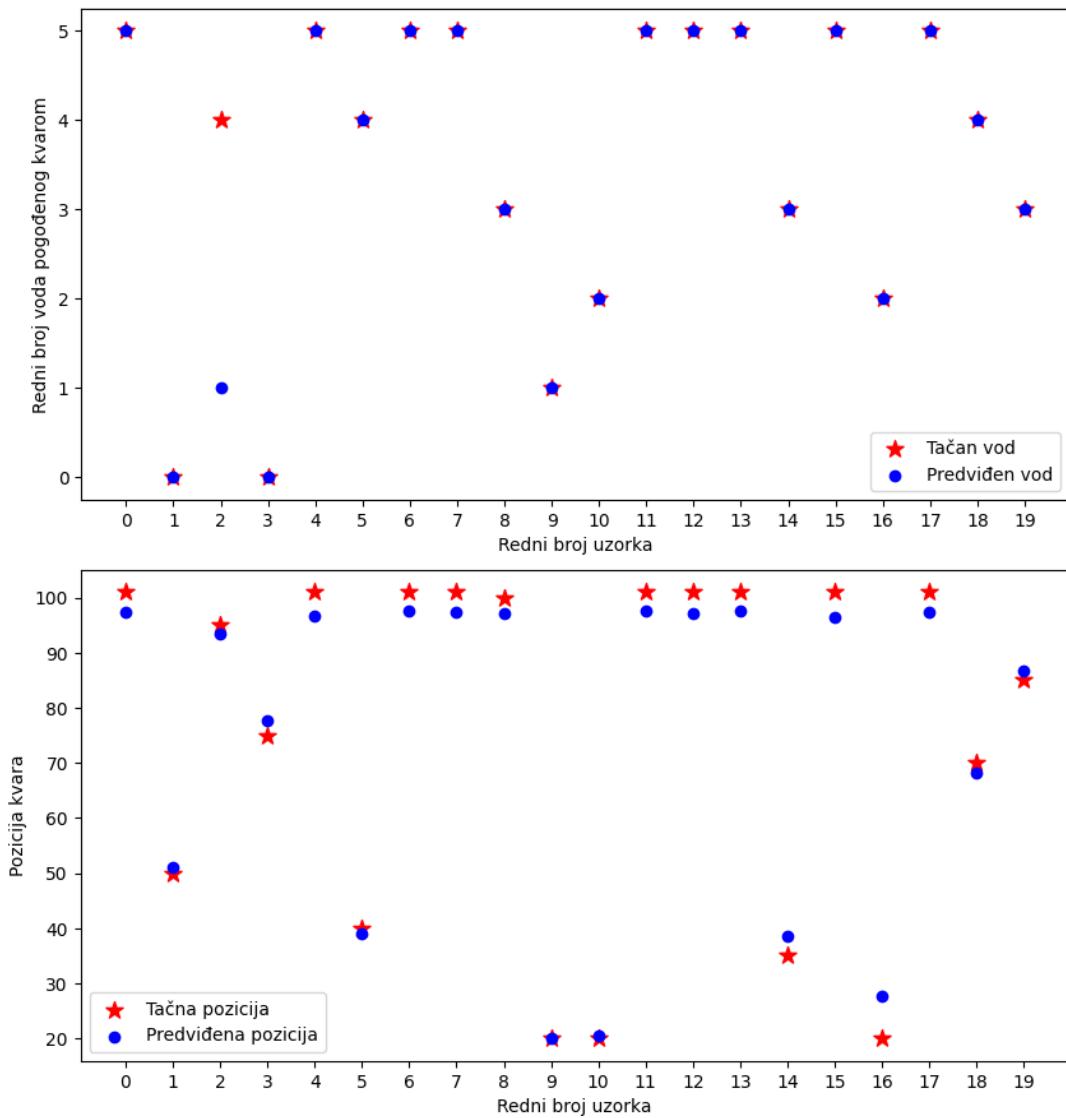
Tabela 4.1: Podešavanje hiperparametara

Broj skrivenih slojeva	Broj neurona u 1. sloju	Broj neurona u 2. sloju	Broj neurona u 3. sloju	Aktivaciona funkcija	Stopa obučavanja	Rezultat
2	96	32		tanh	0.01	157.41
1	416			tanh	0.001	601.21
2	160	32		relu	0.0001	5441.57
2	448	224		relu	0.0001	1405.16
3	256	192	32	tanh	0.0001	5658.48
2	256	192		relu	0.01	50.77
3	320	96	160	tanh	0.01	60.24
3	352	384	480	tanh	0.01	108.79
3	320	128	192	relu	0.01	12.5
3	480	480	320	tanh	0.001	810.42
2	288	384		relu	0.01	10.73
1	160			tanh	0.0001	6118.92
1	352			tanh	0.0001	5972.51
3	224	96	512	tanh	0.001	89.34

Broj skrivenih slojeva	Broj neurona u 1. sloju	Broj neurona u 2. sloju	Broj neurona u 3. sloju	Aktivaciona funkcija	Stopa obučavanja	Rezultat
3	320	448	32	relu	0.01	26.29
3	64	32	416	tanh	0.01	19.35
2	160	512		tanh	0.01	12.28
2	448	256		relu	0.0001	1611.64

Tabela 4.2: Rezultati evaluacije

Metod	Accuracy (tip kvara)	Accuracy (vod pogoden kvarom)	MAE (pozicija kvara)
ANN	100%	94%	1.15



Slika 4.2: Uporedni prikaz tačnih i predviđenih vrednosti za redni broj voda pogodenog kvarom i poziciju kvara

5 ZAKLJUČAK

Ovaj rad je uspešno primenio optimizovanu veštačku neuralnu mrežu za detekciju, klasifikaciju i lokalizaciju kvarova u dalekovodima. Model je treniran na vrednostima napona i struje izdvojenim iz DIgSILENT PowerFactory simulacija, pri čemu je pokazao značajne prednosti zahvaljujući svojoj jednostavnosti i smanjenim računarskim zahtevima, što ga čini idealnim za upotrebu u realnom vremenu i okruženjima sa ograničenim resursima. Optimizacija hiperparametara neuralne mreže značajno je poboljšala performanse modela.

Rezultati su pokazali visoku tačnost u klasifikaciji tipa kvara i identifikaciji pogođenog dalekovoda. Za predikciju tačne lokacije kvara, model je postigao MAE od 1,15, što potvrđuje njegovu preciznost i primenljivost u određivanju položaja kvara duž dalekovoda.

U budućem radu fokus bi mogao biti proširen na istraživanje upotrebe konvolucionih neuronskih mreža (CNN) i rekurentnih neuronskih mreža sa dugoročnim pamćenjem (LSTM) za detekciju, klasifikaciju i lokalizaciju kvarova u prenosnim vodovima.

6 LITERATURA

- [1] N. A. M. Leh, F. M. Zain, Z. Muhammad, S. A. Hamid and A. D. Rosli (2020). Fault Detection Method Using ANN for Power Transmission Line. 2020 10th IEEE International Conference on Control System, Computing and Engineering. <https://doi.org/10.1109/ICCSCE50387.2020.9204921>
- [2] Goni, M. O. F., Nahiduzzaman, M., Anower, M. S., Rahman, M. M., Islam, M. R., Ahsan, M., Haider, J., & Shahjalal, M. (2023). Fast and accurate fault detection and classification in transmission lines using extreme learning machine. e-Prime - Advances in Electrical Engineering, Electronics and Energy, 100107. <https://doi.org/10.1016/j.prime.2023.100107>
- [3] Priyanka, K., & Deepa, K. (2024). Deep learning techniques for transmission line fault classification - A comparative study. Ain Shams Engineering Journal, 15(2), 102427. <https://doi.org/10.1016/j.asej.2023.102427>
- [4] A. M. Abdullah and K. Butler-Purry, “Secure transmission line distance protection during wide area cascading events using artificial intelligence,” *Electric Power Systems Research*, vol. 175, p. 105914, Oct. 2019, doi: [10.1016/j.epsr.2019.105914](https://doi.org/10.1016/j.epsr.2019.105914).
- [5] M. Abdul Baseer, “Travelling Waves for Finding the Fault Location in Transmission Lines,” *Journal Electrical and Electronic Engineering*, vol. 1, p. 1, Apr. 2013, doi: [10.11648/j.jeee.20130101.11](https://doi.org/10.11648/j.jeee.20130101.11).
- [6] El Sayed Tag Eldin, Doaa khalil Ibrahim, Essam M. Aboul-Zahab, and Saber M. Saleh, “High Impedance Faults Detection in EHV Transmission Lines Using the Wavelet Transforms,” in *2007 IEEE Power Engineering Society General Meeting*, Jun. 2007, pp. 1–7. doi: [10.1109/PES.2007.385458](https://doi.org/10.1109/PES.2007.385458).
- [7] J. C. Quispe and E. Orduna, “Transmission line protection challenges influenced by inverter-based resources: a review,” *Protection and Control of Modern Power Systems*, vol. 7, Dec. 2022, doi: [10.1186/s41601-022-00249-8](https://doi.org/10.1186/s41601-022-00249-8).

- [8] R. Fan, T. Yin, R. Huang, J. Lian, and S. Wang, “Transmission Line Fault Location Using Deep Learning Techniques,” in 2019 North American Power Symposium (NAPS), Oct. 2019, pp. 1–5. doi: [10.1109/NAPS46351.2019.9000224](https://doi.org/10.1109/NAPS46351.2019.9000224).
- [9] M. Najafzadeh, J. Poujadi, A. Daghagh, J. Beiza, and T. Abedinzade, “Fault Detection, Classification and Localization Along the Power Grid Line Using Optimized Machine Learning Algorithms,” *Int J Comput Intell Syst*, vol. 17, no. 1, p. 49, Mar. 2024, doi: [10.1007/s44196-024-00434-7](https://doi.org/10.1007/s44196-024-00434-7).
- [10] N. Q. Minh, N. T. Khiem, and V. H. Giang, “Fault classification and localization in power transmission line based on machine learning and combined CNN-LSTM models,” *Energy Reports*, vol. 12, pp. 5610–5622, Dec. 2024, doi: [10.1016/j.egyr.2024.11.061](https://doi.org/10.1016/j.egyr.2024.11.061).
- [11] Raschka, S., & Mirjalili, V. (2019). Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow 2. Packt.