

# Procena mesta nastanka kvara na električnom vodu primenom veštačkih neuralnih mreža

## Fault Location on Extra-High Voltage Transmission Lines Using Neural Networks

Milorad Zakić<sup>\* \*\*\*</sup>, Goran Kvašev<sup>\*\*</sup>

<sup>\*</sup> Saturn Electric d.o.o. Beograd

<sup>\*\*</sup> Elektrotehnički fakultet Univerziteta u Beogradu

**Rezime -** U ovom radu je obrađena jedna relativno nova metoda za procenu mesta nastanka kvara na vodu, koja se bazira na primeni neuralnih mreža. Kako bi se izvršila provera efikasnosti ove metode, u programskom paketu MATLAB/Simulink je formiran model jednostavnog EES-a, koji čine dve visokonaponske mreže (ekvivalentirane Tevenenovim generatorom) povezane 100 km dugačkim dalekovodom. Pomoću ovog programskega paketa su simulirani različiti tipovi kvarova na različitim pozicijama na vodu. Vrednosti faznih struja i međufaznih napona koje generišu ovi kvarovi predstavljaju podatke koji se dovode na ulaz neuralne mreže. Na osnovu ovih ulaznih veličina i izlazne vrednosti koja je jednak stvarnom rastojanju mesta kvara od početka voda (odnosno pozicije lokatora kvara), moguće je izvršiti obučavanje neuralne mreže. Obučavanje neuralne mreže je izvršeno pomoću softverskog alata *nntool* (eng. *Neural Network Toolbox*), koji je sastavni deo programskog paketa MATLAB.

**Ključne reči** - lokacija kvara, dalekovod, neuralne mreže, MATLAB/Simulink

**Abstract -** This paper deals with the application of neural networks to fault location on extra-high voltage (EHV) transmission lines. A relatively simple power system, consisting of two 220 kV power grids connected with one transmission line, has been modelled using MATLAB/Simulink software. Simulating different fault scenarios (fault types, locations, resistances, and inception angles), the proposed neural network fault locator was trained using various sets of terminal line data (line-to-line voltages and phase currents). Feedforward networks have been employed along with the backpropagation algorithm. An analysis of the neural networks with a varying number of hidden layers and neurons per hidden layer has been performed in order to validate the choice of the neural networks in each step. All analyses were carried out using Neural Network Toolbox.

**Index Terms** - Fault location, Transmission line, Neural networks, MATLAB/Simulink

**K**ada se dogodi kvar na vodu, reagovaće sistem relejne zaštite da isključi vod iz pogona. Koliko će vod biti van pogona zavisi od kompleksnosti kvara i brzine lociranja kvara. Distantni zaštitni uređaji novije generacije sadrže funkciju lokacije kvara, koja je od izuzetnog značaja zbog toga što su kvarovi na vodovima često vizuelno neprimetni. Većina zaštitnih uređaja locira mesto kvara na vodu na osnovu proračuna impedanse do mesta kvara [1].

U ovom radu je obrađena jedna relativno nova metoda za procenu mesta nastanka kvara na vodu, koja se bazira na primeni neuralnih mreža. Ova metoda je sve popularnija, uzimajući u obzir da se pomoću iste kvar locira sa manjom greškom i značajno brže u odnosu na metodu merenja impedanse do mesta kvara. Uopšteno govoreći, princip lokacije kvara na vodu primenom neuralnih mreža se zasniva na tome da se neuralna mreža obučava na osnovu unapred poznatih ulaznih i izlaznih podataka. Izlazni podatak je rastojanje mesta kvara od pozicije lokatora kvara, dok je vektor ulaznih podataka definisan efektivnim vrednostima faznih struja i međufaznih napona voda. Nakon završenog procesa obučavanja, neuralna mreža se testira tako što, na osnovu datih ulaznih podataka, ista na svom izlazu daje procenjene vrednosti rastojanja mesta kvara od lokatora kvara. Razlika procenjene i stvarne vrednosti lokacije kvara mora biti manja od unapred definisane minimalne vrednosti.

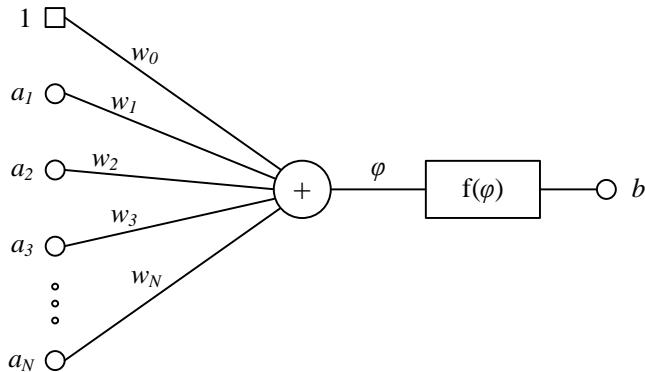
### II UVOD U NEURALNE MREŽE

Neuralna mreža se može opisati kao skup jednostavnih procesora organizaciono podeljenih u više slojeva (eng. *layers*). U zavisnosti od izabrane strukture neuralne mreže, veze između ovih procesora (koje su inspirisane vezama između bioloških elementarnih neurona, te otuda i naziv neuralna mreža) mogu biti realizovane na različite načine. Generalno, postoje dva osnovna tipa struktura neuralnih mreža. Prvi tip mreža su takozvane *feedforward* neuralne mreže, kod kojih se izlazi iz procesora ne vraćaju kao ulazi u procesore koji pripadaju istom sloju ili prethodnim slojevima. Drugi tip strukture neuralne mreže je *feedback* neuralna mreža, koje imaju osobinu da se izlazi iz procesora vraćaju kao ulazi u procesore koji pripadaju istom sloju ili prethodnim slojevima [2]. Uzimajući u obzir to da je u isto vreme i veoma efikasna i veoma jednostavna, u ovom radu će se koristiti samo prvi tip strukture neuralnih mreža, te će se iz

tog razloga isti detaljnije obraditi. Međutim, da bi se to učinilo, najpre je potrebno objasniti model procesorskog elementa.

#### A. Model procesorskog elementa

Klasičan model jednog procesorskog elementa [2], koji je deo neuralne mreže, prikazan je na slici 1.



Slika 1. Model procesorskog elementa

Veličine  $a_1, a_2, a_3, \dots, a_N$  predstavljaju vrednosti dobijene na izlazima iz procesora koji pripadaju prethodnom sloju, dok  $\varphi$  predstavlja sumu ovih veličina prethodno pomnoženih težinskim koeficijentima  $w_1, w_2, w_3, \dots, w_N$  i težinskog koeficijenta  $w_0$ :

$$\varphi = \sum_{i=1}^N w_i a_i + w_0 \quad (1)$$

U izrazu (1) težinski koeficijent  $w_0$  označava aktivacioni prag (eng. *bias*) procesorskog elementa, dok težinski koeficijenti  $w_1, w_2, w_3, \dots, w_N$  predstavljaju snagu sinapsi kojima se ka posmatranom procesorskom elementu prenose pobudni signali sa procesorskih elemenata iz prethodnog sloja neuralne mreže. Ukoliko je vrednost težinskog koeficijenta veća od 0, sinapsa je eksitorna, dok je u slučaju negativne vrednosti koeficijenta sinapsa inhibirajuća. Ako između dva procesorska elementa neuralne mreže ne postoji veza, vrednost odgovarajućeg težinskog koeficijenta je jednaka nuli.

Cilj uvođenja takozvanog *bias* elementa, koji je nezavisan od izlaza iz procesorskih elemenata prethodnog sloja, jeste značajno brža konvergencija vrednosti koja se dobija na izlazu iz neuralne mreže ka odgovarajućoj željenoj vrednosti (štaviše, u nekim slučajevima je ova konvergencija nemoguća ukoliko se ne uvedu *bias* elementi).

Izlaz iz posmatranog procesorskog elementa je jednak vrednosti takozvane aktivacione funkcije ili funkcije prenosa:

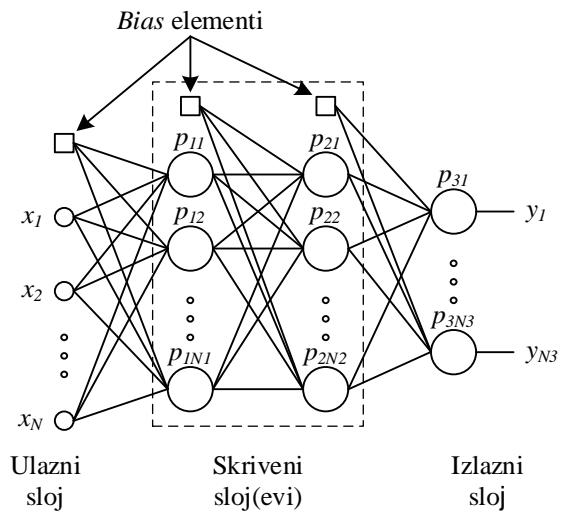
$$b = f(\varphi) = f\left(\sum_{i=1}^N w_i a_i + w_0\right) \quad (2)$$

U ovom radu je za tip aktivacione funkcije izabrana unipolarna sigmoidna funkcija, koja je definisana jednačinom [2]:

$$f(\varphi) = \frac{1}{1 + e^{-\lambda\varphi}} \quad (3)$$

#### B. Feedforward neuralne mreže

*Feedforward* neuralna mreža je relativno jednostavan tip neuralne mreže, kod koje je prenos (pobudnog) signala usmeren od ulaznih ka izlaznim čvorovima (procesorskim elementima) mreže. Na slici 2 je prikazana struktura višeslojne *feedforward* neuralne mreže. Uopšteno govoreći, ova mreža se sastoji od tri sloja. Prvi sloj je ulazni sloj, koji čine ulazni podaci, odnosno veličine koje se dovode na ulaz neuralne mreže. Nakon ulaznog sloja slede jedan ili više skrivenih slojeva, koji su ključni za obučavanje neuralne mreže. Broj skrivenih slojeva, kao i broj procesorskih elemenata svakog skrivenog sloja, se određuju u toku procesa obučavanja mreže i menjaju sve dok razlike između vrednosti na izlazu iz neuralne mreže i očekivanih izlaznih vrednosti ne bude ispod unapred definisane minimalne vrednosti. Gledano iz perspektive korisnika neuralne mreže ovo predstavlja nedostatak iste, zato što ne postoji jasno definisano uputstvo pomoću kojeg se može barem približno odrediti konfiguracija skrivenih slojeva. Međutim, gledajući šиру sliku, nedefinisana konfiguracija skrivenih slojeva se može uzeti i kao prednost neuralnih mreža, jer se na taj način problematika generalizuje, što znači da se neuralne mreže mogu koristiti u mnogobrojnim primenama. Konačno, treći sloj predstavlja izlazni sloj, odnosno vrednosti na izlazu iz neuralne mreže [2].



Slika 2. Struktura višeslojne feedforward neuralne mreže

Konkretno, na slici 2 je prikazana struktura dvoslojne neuralne mreže. Broj ulaznih podataka, odnosno veličina koje se dovode na ulaz neuralne mreže, jednak je N. Dalje, broj procesorskih elemenata prvog i drugog skrivenog sloja je N1 i N2, respektivno. Na kraju, broj izlaznih signala iz neuralne mreže je jednak N3. Ulaz svakog procesorskog elementa prvog skrivenog sloja je povezan sa elementima ulaznog sloja (ulaznim podacima), dok je ulaz svakog procesorskog elementa drugog skrivenog sloja povezan sa izlazima svih procesorskih elemenata prvog skrivenog sloja, kao i sa *bias* elementom ovog sloja. Veze između ovih elemenata su definisane odgovarajućim težinskim koeficijentima.

Vrednosti izlaznih signala iz procesorskih elemenata i-tog sloja se određuju na osnovu sledećeg izraza [2]:

$$\mathbf{p}_i = f_i(\mathbf{W}_i \mathbf{g}_{i-1}) \quad (4)$$

gde su:

$\mathbf{p}_i = [p_{i1} \ p_{i2} \ \dots \ p_{iN_i}]^T$  – vektor izlaznih signala i-tog sloja

$\mathbf{W}_i = \begin{bmatrix} w_{i10} & \dots & w_{i1N_{i-1}} \\ \vdots & \ddots & \vdots \\ w_{iN_{i-1}0} & \dots & w_{iN_iN_{i-1}} \end{bmatrix}$  – matrica težinskih koeficijenata između i-1 i i-tog sloja

$$\mathbf{g}_{i-1} = \begin{cases} \mathbf{X}, & i = 1 \\ [\mathbf{p}_{i-1}], & i = 2, 3, \dots, N_i \end{cases}$$

U prethodnom izrazu,  $\mathbf{X}$  označava vektor ulaznih veličina, a  $f_i$  aktivacionu funkciju procesorskih elemenata i-tog sloja.

Vektor izlaznih veličina, odnosno vrednosti koje se dobijaju na izlazu iz neuralne mreže, određen je sa [2]:

$$\mathbf{y} = \mathbf{p}_3 = [y_1 \ y_2 \ \dots \ y_{N_3}]^T \quad (5)$$

Proces obučavanja neuralne mreže je sledeći: na osnovu ulaznih podataka se pomoću izraza (4) računaju izlazni signali iz procesorskih elemenata svakog sloja. Zatim se, u slučaju da vrednosti dobijene na izlazu iz neuralne mreže ne odgovaraju željenim, težinski koeficijenti preračunavaju. Na koji način će se vršiti proračun novih vrednosti težinskih koeficijenata zavisi od tipa obučavanja neuralnih mreža, odnosno od toga koji se podaci koriste za obučavanje neuralnih mreža (da li i ulazni i izlazni podaci, samo ulazni podaci ili samo ulazni podaci sa odgovarajućim izlaznim bitovima).

### C. Obučavanje neuralnih mreža

Neuralna mreža se obučava u cilju sticanja željenog znanja. Prilikom procesa obučavanja težinski koeficijenti se preračunavaju sve dok razlika između rezultata dobijenih na izlazu iz neuralne mreže i željenih rezultata ne bude zadovoljavajuća. Po okončanju ovog procesa neuralna mreža poseduje sposobnost generalizacije, odnosno generisanja zadovoljavajućih izlaza i za ulazne signale koji se ne koriste u procesu obučavanja. Postoje dva tipa obučavanja neuralnih mreža: strukturalno i parametarsko obučavanje.

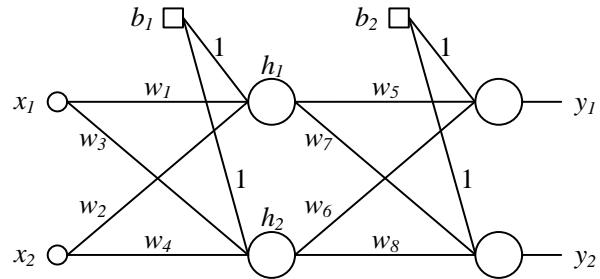
Pod strukturalnim obučavanjem podrazumeva se promena broja skrivenih slojeva, kao i broja procesorskih elemenata svakog skrivenog sloja, sve dok se ne dobiju željeni rezultati. Ova vrsta obučavanja neuralne mreže predstavlja možda i najteži zadatak za korisnika iste, zato što ne postoji jasno definisano uputstvo koje se tiče optimalnog izbora strukture neuralne mreže. Uopšteno govoreći, korisnik treba da iznova i iznova menja strukturu neuralne mreže sve dok ne dobije željene rezultate. Struktura neuralne mreže ne sme da bude ni previše jednostavna ni previše komplikovana. U slučaju previše jednostavne strukture (eng. *underfitting*), odnosno premalog broja procesorskih elemenata, neuralna mreža neće biti u mogućnosti da daje željene rezultate. Sa druge strane, ako je struktura neuralne mreže isuviše komplikovana, velike su šanse da će model neuralne mreže biti previše prilagođen (eng. *overfitting*). To znači da će neuralna mreža prilikom procesa obučavanja davati vrlo dobre rezultate, dok će rezultati prilikom procesa testiranja iste, sa do tada nepoznatim ulaznim podacima, biti loši.

Parametarsko obučavanje predstavlja preračunavanje vrednosti težinskih koeficijenata u cilju postizanja željenih performansi. Razlikuju se sledeći tipovi parametarskog obučavanja: obučavanje sa nadzorom (*supervised* obučavanje), obučavanje sa podsticajem (*reinforcement* obučavanje) i samoobučavanje (*unsupervised* obučavanje). Kod obučavanja sa nadzorom, neuralna mreža se obučava tako što su prilikom svakog preračunavanja težinskih koeficijenata unapred poznati i ulazni i izlazni podaci. Na osnovu toga se može znati da li su, pri određenim vrednostima težinskih koeficijenata, rezultati dobijeni na izlazu iz neuralne mreže adekvatni. U slučaju obučavanja sa podsticajem, neuralna mreža dobija informacije o tome kakav izlaz generiše i to najčešće u vidu jednog bita (dobar ili loš). Kod samoobučavanja su poznati samo ulazni podaci, te se stoga ovaj tip obučavanja ne može koristiti u slučaju *feedforward* strukture neuralne mreže.

S obzirom na to da je tema rada procena mesta nastanka kvara na vodu primenom neuralnih mreža, te da su poznati i ulazni podaci (merene vrednosti napona i struja) i izlazni podaci (stvarno rastojanje od mesta kvara do lokatora kvara), ovde će se koristiti prvi tip obučavanja, odnosno obučavanje sa nadzorom. Jedan od najčešćih korišćenih algoritama za obučavanje neuralne mreže, koji se koristi kod ovog tipa obučavanja, jeste takozvani algoritam za obučavanje propagacijom greške unazad (eng. *backpropagation*), koji će biti objašnjen u nastavku [2].

#### 1) Algoritam propagacije greške unazad

Na slici 3 je prikazana neuralna mreža na koju se dovode dve ulazne veličine i koja daje dva izlazna podatka. Takođe, ova neuralna mreža sadrži jedan skriveni sloj sa dva procesorska elementa.



Slika 3. Struktura jednostavne feedforward neuralne mreže

Kako bi proračun bio što jednostavniji, prepostavimo da *bias* elementi imaju konstantne vrednosti, jednake redom  $b_1$  i  $b_2$ . Usvaja se da su sve aktivacione funkcije, na osnovu kojih se određuje izlazna vrednost procesorskih elemenata u skrivenom i izlaznom sloju, oblika unipolarne sigmoidne funkcije. Neka su početne vrednosti težinskih koeficijenata jednake  $w_1^{(1)}, w_2^{(1)}, \dots, w_8^{(1)}$ . Cilj je odrediti vrednosti ovih težinskih koeficijenata nakon jedne propagacije greške unazad:  $w_1^{(2)}, w_2^{(2)}, \dots, w_8^{(2)}$ .

Vrednosti koje dolaze na ulaz u procesorske elemente skrivenog sloja su:

$$\begin{aligned} h_1^{in} &= x_1 \cdot w_1^{(1)} + x_2 \cdot w_2^{(1)} + b_1 \\ h_2^{in} &= x_1 \cdot w_3^{(1)} + x_2 \cdot w_4^{(1)} + b_1 \end{aligned} \quad (6)$$

Na osnovu vrednosti koje su dobijene pomoću izraza (6), uzimajući u obzir da je aktivaciona funkcija oblika unipolarne sigmoidne funkcije, određuju se vrednosti na izlazu iz procesorskih elemenata skrivenog sloja:

$$\begin{aligned} h_1^{out} &= \frac{1}{1 + e^{-\lambda h_1^{in}}} \\ h_2^{out} &= \frac{1}{1 + e^{-\lambda h_2^{in}}} \end{aligned} \quad (7)$$

Vrednosti koje dolaze na ulaz u procesorske elemente izlaznog sloja su:

$$\begin{aligned} y_1^{in} &= h_1^{out} \cdot w_5^{(1)} + h_2^{out} \cdot w_6^{(1)} + b_2 \\ y_2^{in} &= h_1^{out} \cdot w_7^{(1)} + h_2^{out} \cdot w_8^{(1)} + b_2 \end{aligned} \quad (8)$$

Konačno, vrednosti na izlazu iz procesorskih elemenata izlaznog sloja su:

$$\begin{aligned} y_1^{out} &= \frac{1}{1 + e^{-\lambda y_1^{in}}} \\ y_2^{out} &= \frac{1}{1 + e^{-\lambda y_2^{in}}} \end{aligned} \quad (9)$$

Kako je cilj ovog algoritma za obučavanje neuralnih mreža minimiziranje razlike između željenih i generisanih izlaza mreže, uvodi se kriterijumska funkcija obučavanja (funkcija greške) kojom se, nakon propagacije ulaznog vektora  $\mathbf{X} = [x_1 \ x_2]$  kroz neuralnu mrežu, određuje koliko je izlaz mreže blizak željenom izlazu:

$$E_{total} = \frac{1}{2} \sum_{n=1}^N (T_n - y_n^{out})^2 \quad (10)$$

gde  $T_n$  označava željene vrednosti, a  $N$  ukupan broj izlaza iz neuralne mreže.

Ako se usvoji da su očekivane (željene) vrednosti na izlazu iz neuralne mreže  $T_1$  i  $T_2$ , tada je funkcija greške određena sa:

$$E_{total} = E_1 + E_2 = \frac{1}{2}(T_1 - y_1^{out})^2 + \frac{1}{2}(T_2 - y_2^{out})^2 \quad (11)$$

Sada se propagacijom ukupne greške vrši preračunavanje težinskih koeficijenata. Prvo će se izvršiti proračun novih vrednosti koeficijenata  $w_5, \dots, w_8$ .

Greška procene vrednosti težinskog koeficijenta  $w_5$  je:

$$w_5^{error} = \frac{\partial E_{total}}{\partial w_5} \quad (12)$$

Kako ukupna greška  $E_{total}$  nije funkcija težinskog koeficijenta  $w_5$ , parcijalni izvod dat u (12) će se odrediti na sledeći način:

$$w_5^{error} = \frac{\partial E_{total}}{\partial w_5} = \frac{\partial E_{total}}{\partial y_1^{out}} \cdot \frac{\partial y_1^{out}}{\partial y_1^{in}} \cdot \frac{\partial y_1^{in}}{\partial w_5} \quad (13)$$

Vrednost težinskog koeficijenta  $w_5$  nakon jedne propagacije greške unazad je jednaka:

$$w_5^{(2)} = w_5^{(1)} - \eta \cdot w_5^{error} \quad (14)$$

Parametar  $\eta$  je tzv. koeficijent obučavanja, čija se vrednost može birati u opsegu (0,1).

Nove vrednosti težinskih koeficijenata  $w_6, w_7$  i  $w_8$  se računaju na sličan način.

Zatim se vrši proračun novih vrednosti koeficijenata  $w_1, \dots, w_4$ . Greška procene vrednosti težinskog koeficijenta  $w_1$  je:

$$w_1^{error} = \frac{\partial E_{total}}{\partial w_1} \quad (15)$$

Opet, kako ukupna greška  $E_{total}$  nije funkcija težinskog koeficijenta  $w_1$ , parcijalni izvod dat u (15) će se odrediti na sledeći način:

$$\begin{aligned} w_1^{error} &= \frac{\partial E_{total}}{\partial w_1} = \frac{\partial E_{total}}{\partial h_1^{out}} \cdot \frac{\partial h_1^{out}}{\partial h_1^{in}} \cdot \frac{\partial h_1^{in}}{\partial w_1} \\ \frac{\partial E_{total}}{\partial h_1^{out}} &= \frac{\partial E_1}{\partial y_1^{out}} \frac{\partial y_1^{out}}{\partial y_1^{in}} \frac{\partial y_1^{in}}{\partial h_1^{out}} + \frac{\partial E_2}{\partial y_2^{out}} \frac{\partial y_2^{out}}{\partial y_2^{in}} \frac{\partial y_2^{in}}{\partial h_1^{out}} \end{aligned} \quad (16)$$

Vrednost težinskog koeficijenta  $w_1$  nakon jedne propagacije greške unazad je jednaka:

$$w_1^{(2)} = w_1^{(1)} - \eta \cdot w_1^{error} \quad (17)$$

Princip određivanja vrednosti težinskih koeficijenata  $w_2, w_3$  i  $w_4$  nakon jedne propagacije greške unazad je analogan opisanom principu određivanja nove vrednosti težinskog koeficijenta  $w_1$ .

## 2) Proces obučavanja neuralne mreže

Kompletan proces obučavanja neuralne mreže obuhvata dve faze: fazu obučavanja i fazu testiranja neuralne mreže. Generalno, preporuka je da se koriste različiti ulazni podaci za obučavanje i testiranje neuralne mreže.

U procesu obučavanja neuralne mreže, najpre se uvedu (proizvoljne) početne vrednosti težinskih i bias koeficijenata. Nakon toga se na ulaz neuralne mreže dovede prvi vektor ulaznih i izlaznih veličina. Kada se na osnovu izraza (11) odredi ukupna greška, propagacijom greške unazad se vrši preračunavanje vrednosti težinskih i bias koeficijenata. Posle toga se na ulaz neuralne mreže dovodi drugi vektor ulaznih i izlaznih veličina i ponovo se vrši preračunavanje vrednosti ovih koeficijenata. Ovaj proces se ponavlja se svim ostalim vektorima ulaznih i izlaznih veličina. Kada se završi propagacija svih ulaznih vektora tada je završena jedna epoha obučavanja neuralne mreže.

Ukupna funkcija greške nakon jedne epohe je jednaka:

$$E = \frac{1}{2} \sum_{p=1}^P \sum_{n=1}^N (T_{p,n} - y_{p,n}^{out})^2 \quad (18)$$

gde  $N$  označava ukupan broj izlaza neuralne mreže, a  $P$  broj parova podataka (ulaz-izlaz) koji se koriste za obučavanje neuralne mreže.

Ako nakon završene epohe važi da je funkcija greška  $E$  manja od unapred definisane maksimalno dozvoljene greške  $E_{max}$ , tada se proces obučavanja neuralne mreže završava. U slučaju da ovaj uslov nije ispunjen, započinje se nova epoha u kojoj se na ulaze

neuralne mreže ponovo dovode svi vektori ulaznih i izlaznih veličina (namenjeni za obučavanje neuralne mreže).

Ono što je bitno naglasiti jeste da je poželjno da se paralelno sa procesom obučavanja odvija i proces validacije neuralne mreže. Proses validacije je bitan zbog potencijalnog „preprilagođenja“ neuralne mreže. Naime, može se desiti da funkcija greške, nakon određenog broja epoha, kod procesa obučavanja nastavi da opada, dok kod procesa validacije počinje da raste. Dalji nastavak procesa obučavanja bi samo trošio resurse procesora računara, dok bi pri testiranju neuralne mreže izlazni podaci bili sve manje tačniji. Zbog toga se u ovom slučaju prekida proces obučavanja neuralne mreže i pristupa se promeni konfiguracije iste (menja se broj skrivenih slojeva i broj procesorskih elemenata u slojevima).

Kada se uspešno (paralelno) završe procesi obučavanja i validacije, nastupa proces testiranja neuralne mreže. Neuralna mreža se testira sa potpuno novim, do tada nepoznatim, ulaznim podacima.

### III PRIMENA NEURALNIH MREŽA U PROCENI MESTA NASTANKA KVARA NA VODU

#### A. Model elektroenergetskog sistema

Za potrebe dobijanja ulaznih podataka, u programskom paketu MATLAB/Simulink je modelovan jednostavan elektroenergetski sistem (EES). Ovaj EES čini nadzemni vod, koji je na oba kraja povezan na 220 kV mrežu. Obe visokonaponske mreže na koje je povezan vod su ekvivalentirane Tevenenovim ekvivalentom. Nadzemni vod je ekvivalentiran zamenskom „ $\pi$ “ šemom.

Parametri elemenata EES-a su sledeći:

##### Nadzemni vod:

- tip provodnika: Al/Fe  $2 \times 240/40 \text{ mm}^2$
- poduzni parametri voda:
  - parametri direktnog redosleda:  $r = 0,06 \Omega/\text{km}$ ,  $x = 0,316 \Omega/\text{km}$
  - parametri nultog redosleda:  $r_0 = 0,28 \Omega/\text{km}$ ,  $x_0 = 1,1 \Omega/\text{km}$
  - poduzna susceptansa voda:  $b = 3,65 \mu\text{S}/\text{km}$
- dužina voda:  $l = 100 \text{ km}$

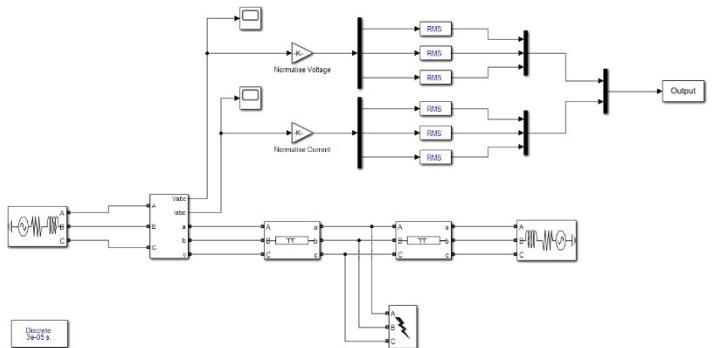
##### Ekvivalent 220 kV mreže 1:

- početni fazni stav napona faze A:  $\theta_A = 0$
- snaga trofaznog kratkog spoja:  $S_{3\text{ph}} = 300 \text{ MVA}$
- odnos ekvivalentne reaktanse i rezistanse:  $X/R = 11$

##### Ekvivalent 220 kV mreže 2:

- početni fazni stav napona faze A:  $\theta_A = -30^\circ$
- snaga trofaznog kratkog spoja:  $S_{3\text{ph}} = 200 \text{ MVA}$
- odnos ekvivalentne reaktanse i rezistanse:  $X/R = 9$

Model EES-a je prikazan na slici 4. Kako bi se simulirao kvar na nadzemnom vodu, isti je ekvivalentiran sa dve zamenske „ $\pi$ “ šeme vezane na red. Tako, na primer, ako se simulira kratak spoj na 5 km od položaja lokatora kvara, zamenske šeme voda se podese tako da je dužina leve sekcijske voda jednaka 5 km, a dužina desne sekcijske voda jednaka 95 km. U nastavku će se objasniti postupak formiranja ulaznih podataka, koji će se koristiti za obučavanje neuralne mreže.



**Slika 4.** Elektroenergetski sistem modelovan u programskom paketu MATLAB/Simulink

Da bi se formirao vektor ulaznih podataka, najpre je potrebno simulirati kvar na vodu (određenog tipa i na određenom položaju na vodu). Nakon izvršene simulacije, kvar generiše odgovarajuće talasne oblike napona i struje, koji se najpre mere a zatim i skaliraju (normalizuju). Skaliranje se vrši deljenjem svih odbiraka signala napona i struja sa nominalnim vrednostima međufaznog napona i fazne struje voda, respektivno. Ovo skaliranje je poželjno, zato što se na taj način značajno skraćuje vreme koje je potrebno za obučavanje neuralne mreže. Nakon toga se iz normalizovanih talasnih oblika napona i struje računaju efektivne vrednosti sva tri međufazna napona i sve tri fazne struje.

#### B. Procena mesta nastanka kvara na vodu

Kako bi kvalitet obučavanja neuralne mreže bio što bolji, odnosno kako bi ista na svom izlazu davala što tačnije rezultate, neophodno je formirati što veći broj vektora ulaznih podataka. Osim toga, treba imati u vidu da svaka vrsta kvara (koju čine tip i mesto kvara) generiše jedinstvene talasne oblike napona i struja. Zbog toga nije bitan samo broj ulaznih vektora, već je sa ovim ulaznim podacima potrebno „pokriti“ što veći broj potencijalnih kvarova, različitog tipa i položaja na vodu.

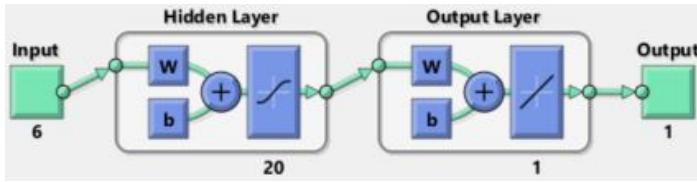
S obzirom na to da je nemoguće napraviti jednu strukturu neuralne mreže (topologiju) sa određenim brojem skrivenih slojeva i brojem procesorskih elemenata po sloju), koja će davati podjednako dobre rezultate za sve tipove kvarova, potrebno je formirati četiri različite topologije neuralne mreže (kako bi se pokrila sva četiri tipa kvara).

Iz tog razloga se i problematika procene mesta nastanka kvara na vodu deli na četiri odvojena problema, koji razmatraju sledeća četiri tipa kvarova na vodu: jednofazni kratki spoj sa zemljom, dvofazni kratki spoj sa zemljom, dvofazni kratki spoj i trofazni kratki spoj. U nastavku će se izvršiti procena mesta nastanka kvara na vodu pri jednofaznom kratkom spoju, s obzirom da je ovaj tip kvara najkritičniji po pitanju tačnosti procene pozicije kvara. Princip procene mesta nastanka kvara na vodu pri ostalim tipovima kvara je analogan.

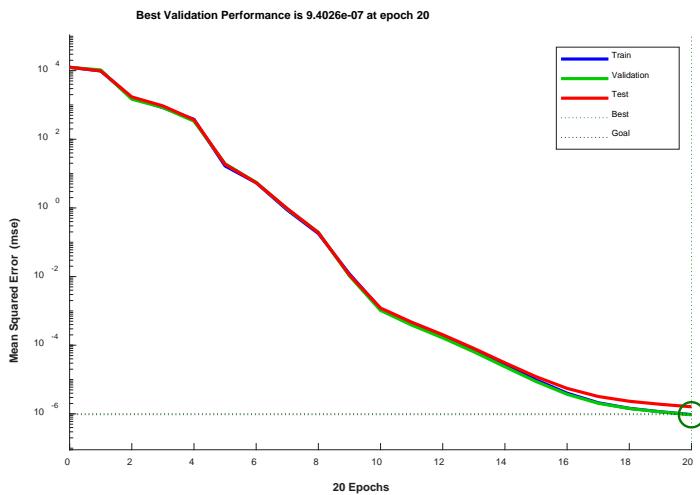
Kao što je već naglašeno, kako bi se obuka neuralne mreže izvršila što kvalitetnije, potrebno je „pokriti“ što veći broj potencijalnih kvarova. Zbog toga će se izvršiti simulacije jednofaznih kratkih spojeva na svaka 2% dužine voda (tj. nakon svaka 2 km). Osim toga, na svakoj poziciji će se simulirati

jednofazni kratki spojevi preko prelaznih otpora sledećih vrednosti:  $0,25\Omega$ ,  $0,5\Omega$ ,  $0,75\Omega$ ,  $1\Omega$ ,  $5\Omega$ ,  $10\Omega$ ,  $25\Omega$  i  $50\Omega$ . Svaki od ovih kvarova generiše različite vrednosti međufaznih napona i faznih struja, koje će se dovoditi na ulaz neuralne mreže. Ukupan broj vektora ulaznih podataka, koji će se koristiti za obučavanje neuralne mreže, jednak je  $1176$  ( $3 \times 49 \times 8$ ).

Kada se formiraju vektori ulaznih veličina i odgovarajućih izlaznih podataka, prelazi se na proces obučavanja neuralne mreže. U ovom procesu je od suštinske važnosti izabrati odgovarajuću topologiju neuralne mreže, kao i odgovarajuće aktivacione funkcije procesorskih elemenata. Generalno, ne postoji posebno pravilo po kojem bi se mogao vršiti adekvatan izbor topologije neuralne mreže, već je potrebno pokušavati sa različitim topologijama sve dok se ne dobiju povoljni rezultati. Ovde se pod „povoljan rezultat“ podrazumeva da, nakon određenog broja epoha, funkcija greške i kod procesa obučavanja i kod procesa validacije opadne ispod unapred definisane maksimalne vrednosti.



Slika 5. Struktura neuralne mreže koju čine: sloj sa 6 ulaznih veličina, skriveni sloj sa 20 procesorskih elemenata i izlazni sloj sa jednim procesorskim elementom

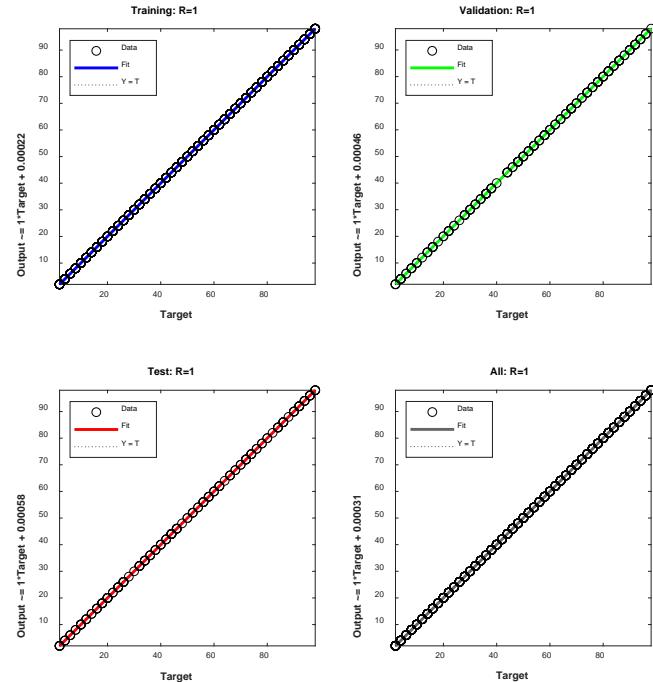


Slika 6. Vrednosti srednjih kvadratnih grešaka procene pri procesima obučavanja, validacije i testiranja neuralne mreže

Primenom softverskog alata *Neural Network Toolbox* (nnntool) su se, u cilju dobijanja odgovarajuće strukture, testirale različite strukture neuralne mreže [3]. Nakon testiranja više topologija, izabrana je struktura neuralne mreže sa jednim skrivenim slojem, koji sadrži 20 procesorskih elemenata. Aktivacione funkcije procesorskih elemenata skrivenog sloja su sigmoidnog tipa, dok je karakteristika aktivacione funkcije izlaznog procesorskog elementa linearна. Struktura ove neuralne mreže je prikazana na slici 5.

Kao mera kvaliteta obučavanja neuralne mreže izabrana je srednja kvadratna greška (eng. *Mean Squared Error*), koja definiše funkciju greške procene nakon jedne epohe, i koja je definisana izrazom (18). Vrednosti srednjih kvadratnih grešaka procene pri procesima obučavanja, validacije i testiranja neuralne mreže nakon 20 epoha su prikazane na slici 6. Sa slike se vidi da su početne vrednosti ovih funkcija greške (pri početnim vrednostima težinskih i bias koeficijenata) reda  $10^4$ . Nakon svake epohe vrednosti funkcija greške se smanjuju, a nakon 20 epoha ove vrednosti su reda  $10^{-7}$ .

Vrednosti funkcija greške ukazuju na to da je obuka neuralne mreže izvedena prilično dobro. Ipak, poželjno je izvršiti dodatna ispitivanja performansi neuralne mreže. Jedan od najjednostavnijih načina da se to uradi jeste da se ispita odnos procenjenih i očekivanih (stvarnih) vrednosti na izlazu iz neuralne mreže. Na slici 7 je prikazan odnos ovih vrednosti za svaka od tri procesa (obučavanja, validacije i testiranja) ponaosob. U idealnom slučaju, ovi odnosi definišu pravu koja sa x-osom zaklapa ugao od  $45^\circ$ . S obzirom na prikazane karakteristike zavisnosti procenjenih i očekivanih vrednosti, može se zaključiti da je i ovaj test pokazao da je obuka neuralne mreže izvedena kvalitetno.



Slika 7. Odnosi procenjenih i očekivanih (stvarnih) vrednosti na izlazu iz neuralne mreže kod procesa obučavanja, validacije i testiranja neuralne mreže

Uobičajena praksa je da se performanse neuralne mreže ispituju i pomoću takozvane „matrice konfuzije“ (eng. *Confusion matrix*). Međutim, ovde se neće izvršiti ispitivanje performansi neuralne mreže na ovaj način, zbog toga što primena istog ima više smisla u slučajevima kada neuralna mreža ima više od jednog izlaza, pri čemu svaki izlaz može da ima dve vrednosti – 1 (tačno) i 0 (netačno).

Princip obučavanja neuralne mreže primenom softverskog alata *Neural Network Toolbox* se sastoji u tome da se iz skupa vektora

ulaznih i izlaznih podataka odvoji određeni broj za obučavanje (najčešće 70% od ukupnog broja vektora podataka), validaciju (15%) i testiranje (15%). Dakle, ovde se za potrebe testiranja neuralne mreže koristi 15% od ukupnog broja ulaznih podataka, pri čemu izlazni podaci nisu poznati. Međutim, iako izlazni podaci nisu poznati, ove vrednosti se na osnovu dostupnih parova vektora ulaznih i izlaznih podataka (koji se koriste u procesima obučavanja i validacije neuralne mreže) mogu proceniti sa veoma visokom tačnošću.

**Tabela 1.** Stvarne i procenjene pozicije kvara, u slučaju kvarova koji nisu simulirani za potrebe obučavanja neuralne mreže

Faza pogodena kvarom	Prelazni otpor	Stvarna pozicija kvara [km]	Procenjena pozicija kvara [km]	Apsolutna greška procene [m]	Relativna greška procene [%]
A	0,6 Ω	5	4,99920	0,80309	0,01606
		23	22,99883	1,17350	0,00510
		61	60,99842	1,57796	0,00259
		77	76,99810	1,89588	0,00246
	7 Ω	5	4,99999	0,00928	0,00019
		23	22,99862	1,37855	0,00599
		61	60,99865	1,34574	0,00221
		77	76,99824	1,76023	0,00229
	23 Ω	5	4,99618	3,82427	0,07654
		23	22,99944	0,55962	0,00243
		61	60,99957	0,43481	0,00071
		77	76,99886	1,14250	0,00148
	55 Ω	5	5,05169	51,69090	1,02324
		23	23,08798	87,97761	0,38105
		61	61,09553	95,52846	0,15636
		77	77,08532	85,32064	0,11068
B	0,6 Ω	5	5,00081	0,81097	0,01622
		23	23,00095	0,95126	0,00414
		61	61,00000	0,00302	0,00000
		77	76,99956	0,44303	0,00058
	7 Ω	5	5,00139	1,38593	0,02771
		23	23,00102	1,01618	0,00442
		61	61,00029	0,28626	0,00047
		77	76,99941	0,58810	0,00076
	23 Ω	5	4,99628	3,71705	0,07440
		23	22,99790	2,10387	0,00915
		61	60,99807	1,93424	0,00317
		77	76,99809	1,90632	0,00248
	55 Ω	5	4,93315	66,84993	1,35512
		23	22,96254	37,46074	0,16314
		61	60,97096	29,03945	0,04763
		77	76,96055	39,44690	0,05126
C	0,6 Ω	5	4,99961	0,38658	0,00773
		23	22,99996	0,03714	0,00016
		61	61,00044	0,43966	0,00072
		77	76,99944	0,56138	0,00073
	7 Ω	5	4,99992	0,08055	0,00161
		23	23,00018	0,18184	0,00079
		61	61,00078	0,78373	0,00128
		77	76,99968	0,32045	0,00042
	23 Ω	5	4,99853	1,46863	0,02938
		23	22,99833	1,66915	0,00726
		61	60,99785	2,14931	0,00352
		77	76,99676	3,24177	0,00421
	55 Ω	5	4,85803	141,97303	2,92244
		23	22,87105	128,95233	0,56382
		61	60,91184	88,15653	0,14473
		77	76,93237	67,63055	0,08791

U nastavku sledi objašnjenje. Neka su poznati vektori ulaznih i izlaznih podataka u slučaju jednofaznih kratkih spojeva na

rastojanju 4 km, 6 km, 10 km, 12 km i 14 km od početka voda, pri prelaznom otporu od  $10 \Omega$ . Takođe, neka je u slučaju jednofaznog kratkog spoja na rastojanju 8 km od početka voda, pri prelaznom otporu od  $10 \Omega$ , poznat vektor ulaznih podataka, a vrednost izlaznog podatka nepoznata. Jasno je da je nepoznata vrednost izlaznog podatka, na osnovu datog ulaznog vektora podataka i pomenutih poznatih parova vektora ulaznih i izlaznih podataka, moguće proceniti sa izuzetno malom greškom procene. Međutim, postavlja se pitanje sa kolikom tačnošću se, sa dostupnim parovima vektora ulaznih i izlaznih podataka, može proceniti rastojanje mesta kvara od početka voda pri kratkom spoju preko prelaznog otpora čija je vrednost različita od  $10 \Omega$ . Da bi se dobio odgovor na to pitanje, testiraće se odziv neuralne mreže za kvarove čija se rastojanja mesta kvara i vrednosti prelaznih otpora razlikuju od onih koji su korišćeni za potrebe obučavanja neuralne mreže. Rezultati su dati u tabeli 1. Na osnovu rezultata dobijenih iz prethodne tabele, može se zaključiti da su pri kvarovima koji nisu simulirani za potrebe obučavanja neuralne mreže greške procene mesta nastanka kvara veće u odnosu na one dobijene pri procesu testiranja neuralne mreže. Takođe, najveća greška procene se dobija u slučaju kratkih spojeva u blizini krajeva voda, što se objašnjava smanjenim brojem vektora ulaznih i izlaznih podataka potrebnih za obučavanje neuralne mreže. Ipak, s obzirom na to da je najveća relativna greška procene mesta nastanka kvara na vodu manja od 3%, zaključuje se da i u ovim slučajevima neuralna mreža procenjuje poziciju kvara sa vrlo visokom tačnošću.

#### IV ZAKLJUČAK

Cilj rada je da se ispita tačnost procene mesta nastanka kvara na vodu primenom neuralnih mreža. Model elektroenergetskog sistema je modelovan u programskom paketu MATLAB/Simulink. Izvršena je procena mesta nastanka kvara na vodu pri jednofaznom kratkom spoju, obziru da je ovaj tip kvara najkritičniji po pitanju tačnosti procene pozicije kvara. Obučavanje neuralne mreže je izvršeno primenom softverskog alata nnntool (Neural Network Toolbox). Na osnovu formirane strukture neuralne mreže, kao i posebnog skupa vektora ulaznih podataka (koji su korišćeni za testiranje neuralne mreže), procenjena je greška procene. Uzimajući u obzir sve dobijene rezultate, može se zaključiti da je tačnost procene mesta nastanka kvara na vodu primenom neuralnih mreža izuzetna, pod pretpostavkom da se koristi njena odgovarajuća struktura, kao i odgovarajući broj vektora ulaznih i izlaznih podataka.

#### LITERATURA/REFERENCES

- [1] Đurić, M., Stojanović, Z. *Relejna zaštita*, Akadembska misao, Beograd, 2014.
- [2] Galushkin, A. I. *Neural Networks Theory*, Springer, Berlin Heidelberg, 2007.
- [3] Beale, M. H., Hagan, M. T., Demuth, H. B. *Neural Network Toolbox™ User's Guide*, Mathworks, 2018.

#### AUTORI/AUTHORS

**msr Milorad Zakić** - master inženjer elektrotehnike i računarstva, Saturn Electric d.o.o. Beograd, milorad.zakić@saturnelectric-sr.com, ORCID [0000-0001-9583-9519](https://orcid.org/0000-0001-9583-9519)

**dr Goran Kvačev** - vanredni profesor, Elektrotehnički fakultet Univerziteta u Beogradu, kvascev@etf.bg.ac.rs, ORCID [0001-8642-0361](https://orcid.org/0001-8642-0361)