

Ljupko Teklić, mag.ing.el.  
HEP-OPS d.o.o.  
ljupko.teklic@hops.hr

Dr.sc. Božidar Filipović-Grčić, dipl.ing.el.  
Sveučilište u Zagrebu  
Fakultet elektrotehnike i računarstva  
bozidar.filipovic-grcic@fer.hr

Ivan Pavičić, dipl.ing.el.  
HEP-OPS d.o.o.  
ivan.pavicic@hops.hr

## PREPOZNAVANJE KVAROVA U PRIJENOSNOM SUSTAVU UPOTREBOM UMJETNIH NEURONSKIH MREŽA

### SAŽETAK

U radu se obrađuje prepoznavanje kvarova u prijenosnom elektroenergetskom sustavu pomoću umjetne neuronske mreže (ANN). Analiziran je jednofazni kratki spoj na 110 kV dalekovodu preko različitih impedancija na mjestu kvara i pri različitim opterećenjima. U programu EMTP-RV izrađen je model za proračun tokova snaga i kratkog spoja te su izračunate struje i naponi na oba kraja dalekovoda za vrijeme kvara. Rezultati proračuna iskorišteni su za učenje ANN u programskom paketu Matlab s ciljem određivanja mjesta kvara i impedancije na mjestu kvara. Neuronska mreža je trenirana pomoću "back propagation" (BP) algoritma. Rezultati proračuna pokazuju da je neuronska mreža učinkovita pri procjeni lokacije kvara na dalekovodu i impedancije na mjestu kvara za različita opterećenja elektroenergetskog sustava.

**Ključne riječi:** lokacija kvara, dalekovodi, Feed Forward neuronske mreže, umjetna neuronska mreža

## ARTIFICIAL NEURAL NETWORK APPROACH FOR LOCATING FAULTS IN POWER TRANSMISSION SYSTEM

### SUMMARY

This paper deals with the fault location recognition in transmission power system using artificial neural network (ANN). Single-phase to ground fault on 110 kV transmission line was analyzed with various fault impedances and different power flow conditions. A model for calculation of load flow and short circuit was developed using EMTP-RV software in order to obtain the voltages and currents at both line ends. Calculation results were used for training ANN in Matlab in order to obtain correct fault location and fault impedance, even for those cases that ANN has never encountered before. The network was trained with back propagation algorithm. Test results show that this approach provides robust and accurate location of faults for a variety of power system operating conditions even with resistance in the fault path and gives a accurate fault impedance assessment.

**Key words:** Fault Location, Transmission Lines, Feed Forward Neural Network, Artificial Neural Network (ANN)

## 1. UVOD

Dalekovod je sastavni dio elektroenergetskog sustava i njegova zaštita posebno je važna za osiguranje stabilnosti sustava i kako bi se smanjila oštećenja opreme koja se mogu pojaviti uslijed kratkog spoja. Struje kratkog spoja izazivaju mehanička i toplinska naprezanja koja su potencijalno štetna za visokonaponsku opremu.

Zaštita dalekovoda ima tri glavne zadaće: otkrivanje, klasifikaciju i određivanje mjesta kvara. Brzo i precizno određivanje mjesta kvara potrebno je za omogućavanje brzog popravka i ponovnog vraćanja dalekovoda u pogon kako bi se poboljšala pouzdanost i raspoloživost napajanja. Točnim lociranjem kvara se vrijeme potrebno za održavanje ili popravak dalekovoda može svesti na minimum. Međutim, identifikacija kvara nije uvijek lagan zadatak. Ako dođe do kvara, potrebno ga je izolirati što je brže moguće da bi se očuvala stabilnost ostatka sustava. Zaštitni releji koji se koriste za otkrivanje, klasificiranje i lociranje kvara na dalekovodu obično kao ulazne signale koriste napone i struje. U slučaju kvara relej će poslati signal za isključivanje prekidača kako bi se isključio štitičeni dalekovod.

Postoje različite vrste algoritama za pronalazjenje kvarova na dalekovodima koji se temelje na:

- određivanju fazora struje i napona iz kojih se preko impedancije određuje lokacija kvara,
- rješavanju diferencijalnih jednadžbi dalekovoda,
- metodi putnih valova koja koristi podatke s jednog ili oba kraja dalekovoda.

Neki zaštitni releji mogu imati problema s otkrivanjem kvara zbog visoke impedancije kvara i istosmjerne komponente struje kratkog spoja. Pristup koji koristi putne valove ima problema sa otkrivanjem kvarova koji se nalaze vrlo blizu trafostanice i ako je kut napona u trenutku nastanka kvara blizu nuli (ili jednak nuli).

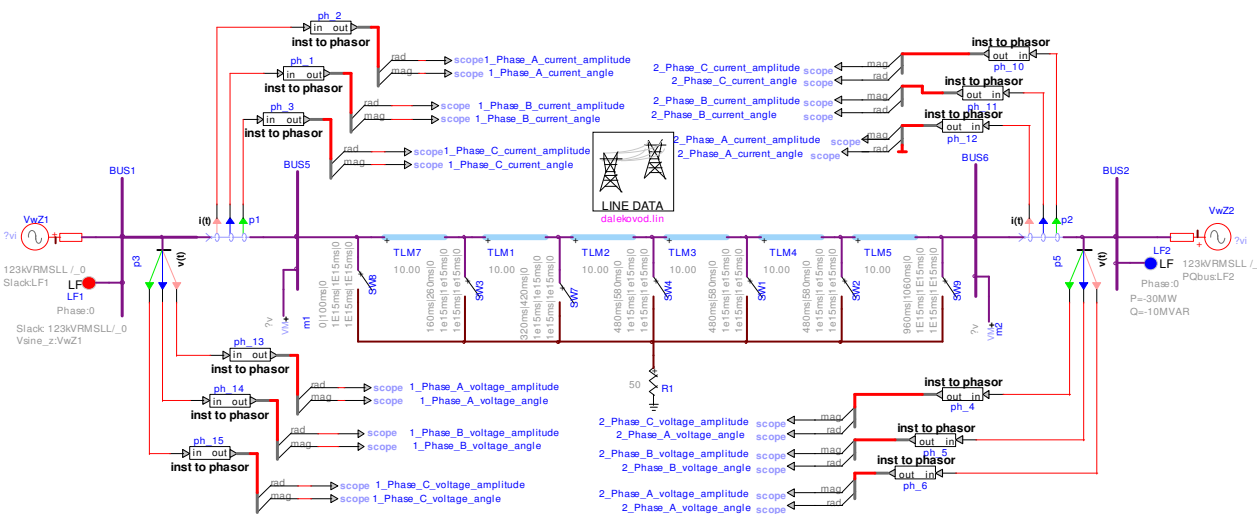
Jedan od alata koji se može primijeniti u sustavu zaštite elektroenergetskog sustava su umjetne neuronske mreže (ANN). ANN [1] je moćan alat u raspoznavanju uzoraka, klasifikaciji i generalizaciji što je korisno za analize energetskog sustava jer se ANN može naučiti s off-line podacima [2] - [5]. ANN također ima odlične karakteristike kao što su otpornost na smetnje, robusnost i neosjetljivost na pogreške. Ovaj rad opisuje primjenu ANN za prepoznavanje kvarova u prijenosnoj elektroenergetskoj mreži.

## 2. MODEL ELEKTROENERGETSKOG SUSTAVA

Mali dio hrvatskog prijenosnog sustava koji se sastoji od jednog 110 kV dalekovoda koji povezuje dvije transformatorske stanice (TS) korišten je kao model za proračune tokova snaga i kratkog spoja (slika 1). Proračun je proveden programu za analizu prijelaznih elektromagnetskih pojava EMTP-RV [6] i određeni su iznosi i kutovi napona i struja na oba kraja dalekovoda za vrijeme jednopolnog kvara. Rezultati proračuna korišteni za učenje ANN.

Za primjer je uzet 110 kV dalekovod dug 60 km s jednim zaštitnim užetom kojim se prenosi snagu iz TS1 do TS2. Položaj vodiča na stupovima prikazan je u tablici I, a karakteristike vodiča prikazane su u tablici II.

Korišten je model dalekovoda s konstantno distribuiranim parametrima u EMTP-RV. Skin efekt je uzet u obzir u proračunima, a za otpor tla je uzeta vrijednost od 250  $\Omega$ m.



Slika 1. Model za proračun tokova snaga i kratkog spoja u programu EMTP-RV

Tablica I. Pozicije vodiča na stupovima

Vodiči	Horizontalna udaljenost (m)	Visina iznad tla (m)	Visina iznad tla u provjesu (m)
Faza A	3,8	28,8	10
Faza B	-3,3	32,6	12,2
Faza C	2,8	28,8	14,4
Zaštitno uže	0	37,7	20,778

Tablica II. Karakteristike vodiča

Vodiči	Fazni vodiči	Zaštitno uže
Presjek (mm <sup>2</sup> )	240	120
Vanjski promjer (mm)	31	22
DC otpor (Ω/km)	0,119	2,85

Parametri nadomjesne mreže izračunati su iz struja jednopolnog i trojnopolnog kratkog spoja korištenjem sljedećih izraza [7]:

$$Z_d = \frac{c \cdot U_n}{\sqrt{3} \cdot I_{sc3}} \quad (1)$$

$$Z_0 = \frac{c \cdot U_n}{\sqrt{3}} \cdot \left( \frac{3}{I_{sc1}} - \frac{2}{I_{sc3}} \right) \quad (2)$$


Gdje je:

$I_{sc1}$ ,  $I_{sc3}$  – jednopolna i trojnopolna struja kratkog spoja;

$U_n$  – nazivni napon;

$c$  – faktor = 1.1.

Aktivne mreže u TS 1 i TS 2 modelirane su Theveninovim ekvivalentima [8].



Slika 2. Theveninov ekvivalent aktivne mreže

Theveninova matrica impedancija  $\mathbf{Z}$  određena je sljedećim izrazom:

$$[\mathbf{Z}]_{TH} = [\mathbf{R}]_{TH} + j\omega[\mathbf{L}]_{TH} = \begin{bmatrix} R & 0 & 0 \\ 0 & R & 0 \\ 0 & 0 & R \end{bmatrix} + j\omega \begin{bmatrix} L_S & L_m & L_m \\ L_m & L_S & L_m \\ L_m & L_m & L_S \end{bmatrix} \quad (3)$$

Matrice  $\mathbf{R}$  i  $\mathbf{L}$  određuju se preko Fortescueove transformacijske matrice  $\mathbf{A}$  iz nadomjesne impedancije aktivnih mreža direktnog, inverznog i nultog sustava:

$$[Z]_{TH} = [A] \cdot [Z_{012}] \cdot [A]^{-1} \quad [A] = \begin{bmatrix} 1 & 1 & 1 \\ 1 & a^2 & a \\ 1 & a & a^2 \end{bmatrix} \quad (4)$$

Nulte i direktne impedancije nadomjesne mreže prikazane su u Tablici III.

Tablica III. Nulte i direktne impedancije nadomjesnih mreža u TS1 i TS2

TS	Direktna komponenta ( $\Omega$ )		Nulta komponenta ( $\Omega$ )	
	$R_d$	$X_d$	$R_0$	$X_0$
1	5,12	14,96	7,30	27,09
2	7,74	29,72	6,24	31,75

U EMTP-RV-u su generirane velike količine podataka korištenih za učenje ANN, uzimajući u obzir kvar na 0 km, 10 km, 20 km, 30 km, 40 km, 50 km i 60 km dalekovoda. Analizirane su impedancije na mjestu kvara od 0  $\Omega$ , 10  $\Omega$ , 25  $\Omega$  i 50  $\Omega$ . Također, u obzir su uzeti različiti tokovi snaga kroz dalekovod.

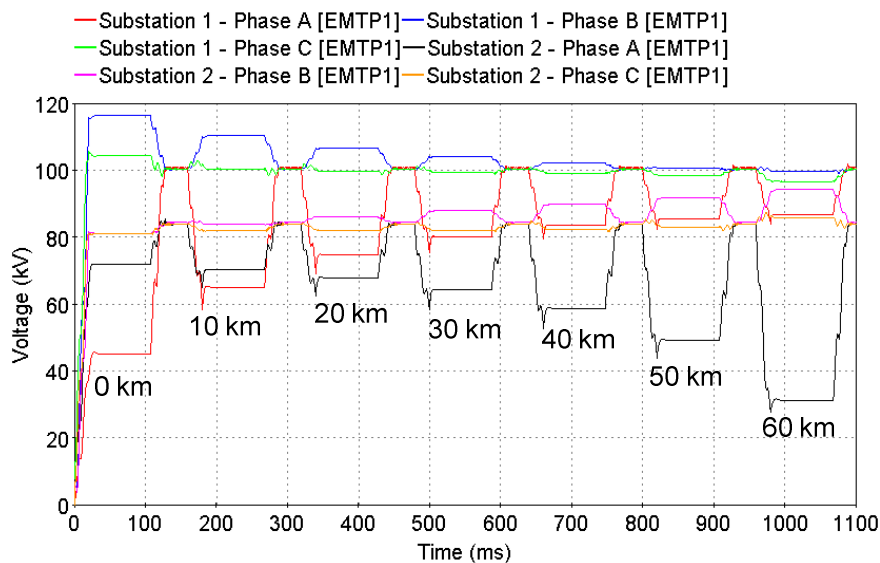
U prvom koraku napravljeni su proračuni tokova snaga uz promjene radne snage (0 - 100 MW) i jalove snage (10 - 30 MVar). Rezultati trofaznog proračuna tokova snaga (naponi na početku i na kraju dalekovoda prije nastanka kvara) korišteni su kao ulazni podaci za proračun struja kratkog spoja. Za različite impedancije na mjestu kvara i pri različitim opterećenjima simulirano je 7 kratkih spojeva na dalekovodu kao što je prikazano u Tablici IV.

Tablica IV. Analizirane lokacije i vrijeme trajanja kvara

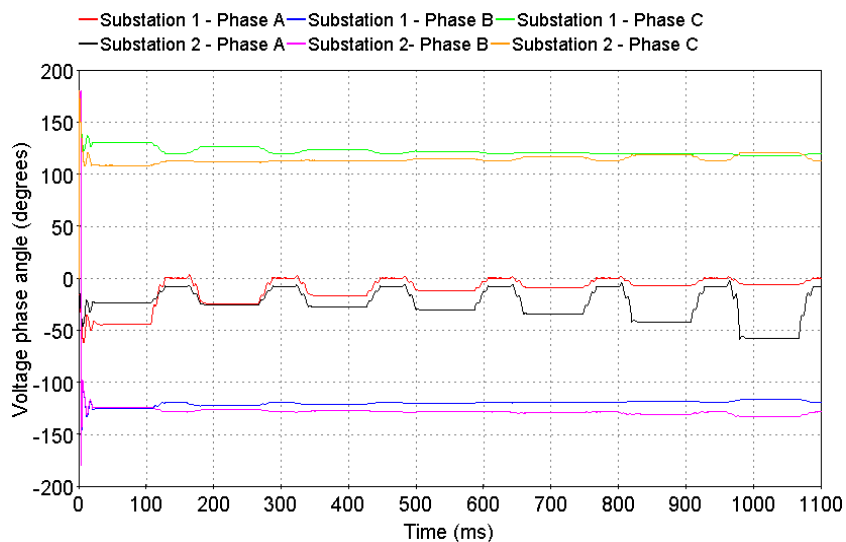
Lokacija kvara (km)	0	10	20	30	40	50	60
Početak kvara (ms)	0	160	320	480	640	800	960
Kraj kvara (ms)	100	260	420	580	740	900	1060

Prvi harmonici trenutnih vrijednosti napona i struja transformirani su u polarne koordinate predstavljajući amplitude i kutove fazora. Tako preračunate vrijednosti napona i struja u stacionarnom stanju korištene su kao ulazni parametri za ANN.


Slike 3 - 6 prikazuju rezultate proračuna u slučaju jednopolnog kratkog spoja u fazi A preko impedancije na mjestu kvara 10  $\Omega$  pri opterećenju od 100 MW i 30 MVar. Prikazane su iznosi i kutovi napona i struja na krajevima dalekovoda.



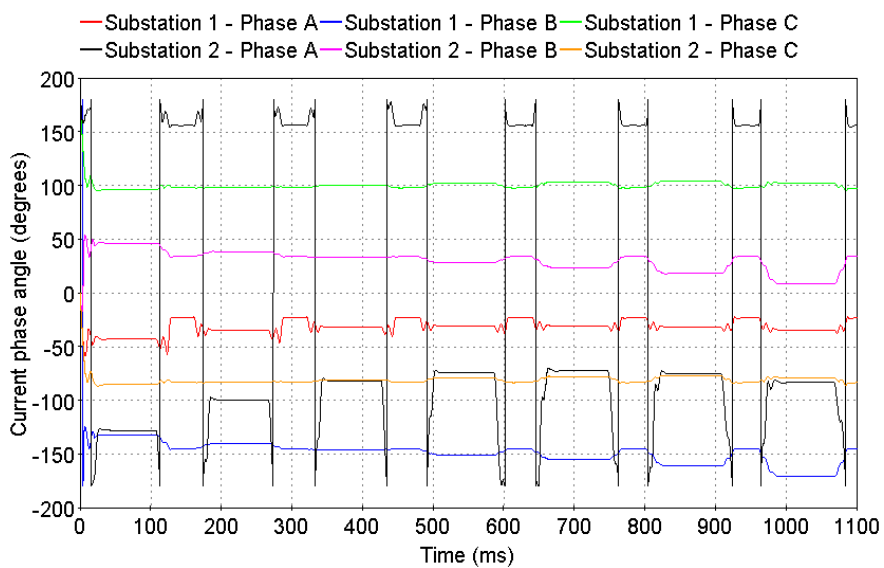
Slika 3. Amplitude fazora napona



Slika 4. Kutovi fazora napona




Slika 5. Amplitude fazora struja



Slika 6. Kutovi fazora struja


### 3. MODEL ANN

Feed-forward mreže [1] često imaju jedan ili više skrivenih slojeva neurona s sigmoidnom funkcijom nakon čega se nalazi izlazni sloj neurona s linearnom funkcijom. Višestruki slojevi neurona s nelinearnom prijenosnom funkcijom omogućuju mreži da nauči nelinearne odnose između ulaznih i izlaznih vektora. Linearni izlazni sloj se najčešće koristi za rješavanje problema prilagodbe funkcija. U ovom radu ANN koristi (BP) algoritam učenja propagacijom unatrag i algoritam smanjenjem gradijenta za minimiziranje pogreške. Za optimizaciju arhitekture mreže koristi se Levenberg-Marquardt (Trainlm) optimizacijska tehnika. Izbor broja skrivenih neurona u BP mreži je teško odrediti. Točnost predviđanja BP mreže povećava s brojem skrivenih neurona. Ako je broj neurona u skrivenom sloju malen, mreža ne može dobro učiti i točnost mreže počinje opadati. Ako je broj neurona velik, vrijeme učenja se povećava i mreža postaje neučinkovita. Struktura BP ANN prikazana je na slici 7.



Slika 7. Struktura BP ANN

Model BP ANN prikazan je na slici 8.



Slika 8. Model BP ANN

### 4. UČENJE I TESTIRANJE ANN ZA ODREĐIVANJE LOKACIJE KVARA


Neural Network Toolbox, dio programskog paketa Matlab, korišten je za postavljanje ANN topologije, učenje i računanje ogovarajućih težinskih faktora. Rezultati proračuna u EMTP-RV-u korišteni su kao ulazni vektori za ANN.

#### 4.1. Učenje ANN

Ulazni podaci podijeljeni su u tri dijela: jedan se koristi za učenje (zove trening set koji se sastoji od 80% podataka), jedan za potvrđivanje (zove validacijski set, sastoji se od 10% podataka), a jedan za ispitivanje (test set koji se sastoji od 10% podataka). Podaci u setovima za treniranje i provjeru se nasumično unose u ANN.


U prvom sloju mreže, ulazni podaci se množe težinskim faktorima i pridodaje im se iznos praga. Ako su ulazni podaci iznosom veliki, težinski faktori moraju biti vrlo mali, kako bi se spriječilo zasićenje prijenosne funkcije. Zbog toga se koristi normalizacija ulaznih podataka prije nego što ih se primjeni na mrežu. Općenito, normalizacija se primjenjuje i na ulazne i na ciljane vektore. Na ovaj način, rezultat mreže uvijek upada u normalizirani raspon. Većina funkcija izrade mreže u toolboxu, uključujući i funkcije za višeslojne mreže, kao što su feed-forward-net, automatski obavljaju pred-procesiranje ulaznih i izlaznih veličina kako bi bile pogodnije za obradu. ANN je formirana kao što je prikazano na slici 8 i unesen je set od 112 vektora. Svaki vektor se sastoji od 24 elemenata koji sadrže amplitude i kutove fazora struja i

napona sa oba kraja dalekovoda. Ciljani skup podataka sastoji se od 112 vektora i sadrže lokaciju kvara i impedanciju na mjestu kvara. Broj skrivenih neurona određen je eksperimentalno i postavljen na tri. Ponašanje mreže tijekom učenja prikazano je na slici 9.



Slika 9. Ponašanje neuronske mreže tijekom učenja

Slika 9. prikazuje smanjenje srednje kvadratne pogreške (MSE) tijekom vremena. Kao rezultat učenja generiran je histogram pogreške koji pokazuje razliku između ciljanih i izlaznih podataka (slika 10). Plavi stupci predstavljaju podatke korištene za učenje, zeleni stupci podatke za validaciju i crveni stupci podatke korištenje za ispitivanje. Histogram može biti pokazatelj točaka za koje mreža daje znatno lošije rezultate od većine podataka.



Slika 10. Histogram pogreške

#### 4.2. Testiranje ANN

Testiranje je provedeno na 24 seta podataka (vektora) koji se razlikuju od podataka korištenih za učenje mreže. Korištene su različite snage, mjesta kvarova i iznosi impedancije na mjestu kvara. Rezultati testiranja ANN prikazani su u tablicama V i VI.

Tablica V. Rezultati testiranja ANN – lokacija kvara

Snaga na dalekovodu	$FL_{Test}$ (km)	$FL_{ANN}$ (km)	$Error_{FL}$ (%)	$Error_{FLT}$ (%)
0	5	6,065	21,30	1,77
	5	4,345	13,10	1,09
73 MW, 24 MVar	5	4,004	19,92	1,66
90 MW, 27 MVar	5	6,243	24,86	2,07
0	15	16,270	8,47	2,12
	15	14,323	4,51	1,13
73 MW, 24 MVar	15	15,537	3,58	0,90
90 MW, 27 MVar	15	18,014	20,09	5,02
0	25	24,705	1,18	0,49
	25	24,459	2,16	0,90
73 MW, 24 MVar	25	25,799	3,20	1,33
90 MW, 27 MVar	25	28,193	12,77	5,32
0	35	34,561	1,25	0,73
	35	34,280	2,06	1,20
73 MW, 24 MVar	35	36,083	3,09	1,80
90 MW, 27 MVar	35	37,065	5,90	3,44
0	45	45,046	0,10	0,08
	45	45,516	1,15	0,86
73 MW, 24 MVar	45	45,903	2,01	1,50
90 MW, 27 MVar	45	46,044	2,32	1,74
0	55	55,142	0,26	0,24
	55	56,080	1,96	1,80
73 MW, 24 MVar	55	55,771	1,40	1,29
90 MW, 27 MVar	55	53,877	2,04	1,87

Tablica VI. Rezultati testiranja ANN – impedancija kvara

Snaga na dalekovodu	$FR_{Test}$ ( $\Omega$ )	$FR_{ANN}$ ( $\Omega$ )	$Error_{FR}$ (%)
0	7	8,491	21,30
	33	33,060	0,18
73 MW, 24 MVar	40	40,363	0,91
90 MW, 27 MVar	60	57,078	4,87
0	7	6,861	1,98
	33	32,668	1,01
73 MW, 24 MVar	40	40,685	1,71
90 MW, 27 MVar	60	57,616	3,97
0	7	6,231	10,99
	33	33,986	2,99
73 MW, 24 MVar	40	40,067	0,17
90 MW, 27 MVar	60	58,326	2,79
0	7	6,074	13,23
	33	33,643	1,95
73 MW, 24 MVar	40	41,234	3,09
90 MW, 27 MVar	60	58,650	2,25
0	7	6,662	4,84
	33	33,336	1,02
73 MW, 24 MVar	40	40,911	2,28
90 MW, 27 MVar	60	57,996	3,34
0	7	7,550	7,86
	33	32,775	0,68
73 MW, 24 MVar	40	41,070	2,67
90 MW, 27 MVar	60	55,830	6,95



Oznake u tablicama:

$FL_{Test}$  – lokacija kvara korištena za testiranje ANN;

$FL_{ANN}$  - rezultat ANN lokatora kvara;

$FR_{Test}$  – iznos impedancije kvara korišten za testiranje ANN;

$FR_{ANN}$  – rezultat impedancije kvara procijenjen od strane ANN.

Postotna pogreška lociranja kvara izračunata je korištenjem sljedećeg izraza:

$$Error_{FL}(\%) = \frac{|FL_{ANN} - FL_{Test}|}{FL_{Test}} \cdot 100 \quad (5)$$

Maksimalna postotna pogreška lociranja kvara preko ANN iznosi manje od 25 %.

Postotna pogreška lociranja kvara s obzirom na duljinu dalekovoda  $d$  određena je sljedećim izrazom:

$$Error_{FLT}(\%) = \frac{|FL_{ANN} - FL_{Test}|}{d} \cdot 100 \quad (6)$$

Maksimalna postotna pogreška lociranja kvara preko ANN s obzirom na duljinu dalekovoda iznosi manje od 6 %.

Maksimalna postotna pogreška procjene impedancije na mjestu kvara određena je sljedećim izrazom:

$$Error_{FR}(\%) = \frac{|FR_{ANN} - FR_{Test}|}{FR_{Test}} \cdot 100 \quad (7)$$

Maksimalna postotna pogreška procjene impedancije na mjestu kvara korištenjem ANN iznosi manje od 22% i javlja se prilikom nisko impedantnih kvarova. U većini slučajeva pogreška je iznosila manje od 10%.

## 5. ZAKLJUČAK

Ovaj rad opisuje primjenu neuronske mreže (ANN) za određivanje mjesta kvara i procjenu impedancije na mjestu kvara u prijenosnoj mreži. U programskom paketu EMTP-RV izrađen je model elektroenergetskog sustava i provedeni su proračuni tokova snaga i kratkog spoja. Iznosi i kutovi fazora napona i struja na krajevima dalekovoda za različite slučajeve kvara korišteni su kao ulazni vektori za učenje ANN. Analizirane su različite lokacije kvara, tokovi snaga i iznosi impedancije na mjestu kvara. Za predmetnu problematiku korištena je ANN s "back propagation" algoritmom.

U većini slučajeva postotna pogreška lociranja kvara i procjene impedancije je manja od 10%. Srednja vrijednost postotne pogreške pri određivanju za lociranje kvara iznosi 6,6%. Srednja vrijednost postotne pogreške pri određivanju impedancije na mjestu kvara iznosi 4,3%. Rezultati proračuna pokazuju da je neuronska mreža učinkovita pri procjeni lokacije kvara na dalekovodu i impedancije na mjestu kvara za različita opterećenja elektroenergetskog sustava.

## 6. LITERATURA

- [1] Mark Hudson Beale, Martin T. Hagan, Howard B. Demuth, "Neural Network Toolbox™ 7, User's Guide", September 2010.
- [2] Xiangning Lin, Peng Mao, Hanli Weng, Bin Wang, Z Q Bo and A Klimek, "Study on Fault Location for High Voltage", The 14th International Conference on Intelligent System Applications to Power Systems, ISAP 2007 November 4 - 8, 2007, Kaohsiung, Taiwan.
- [3] M. Tarafdard Hagh, K. Razi, and H. Taghizadeh, "Fault Classification and Location of Power Transmission Lines Using Artificial Neural Network", The 8<sup>th</sup> International Power Engineering Conference IPEC 2007.
- [4] P. K. Dash, A. K. Pradhan, and G. Panda, "A Novel Fuzzy Neural Network Based Distance Relaying Scheme", IEEE Transactions on Power Delivery, Vol. 15, No. 3, July 2000.

- [5] Anamika Jain, A. S. Thoke, R. N. Patel, "Double Circuit Transmission Line Fault Distance Location using Artificial Neural Network", 2009 World Congress on Nature & Biologically Inspired Computing (NaBIC 2009).
- [6] EMTP-RV, documentation, [Online]. Available: [www.emtp.com](http://www.emtp.com)
- [7] J. C. Das, Power System Analysis: "Short-Circuit, Load Flow and Harmonics", Marcel Dekker, 2002.
- [8] J. Arrillaga, C.P. Arnold: "Computer Analysis of Power systems", John Wiley & Sons, 1995.