

DOLOČANJE OKVARJENEGA IZVODA V RAZDELILNI TRANSFORMATORSKI POSTAJI OB VISOKO OHMSKEM ZEMELJSKEM STIKU Z UPORABO UMETNE INTELIGENCE

Bogomil JELENC

POVZETEK

Umetna nevronska omrežja (ANN) postajajo zelo uporabna za podporo dispečerjev pri vodenju obratovanja distribucijskih elektroenergetskih sistemov. Ta članek obdela pristop pri določanju okvarjenega izvoda v razdelilni transformatorski postaji (RTP) pri zemeljskem stiku (tudi visokoohmskem) z uporabo nevronske mreže s povezavami naprej (feed forward artificial neuron network). Nevronska mreža je naučena z t.i. nadzorovano metodo z uporabo algoritma povratnega napredovanja (backpropagation). Za učenje so bili uporabljeni posnetki realne okvare. Rezultati so pokazali izjemno natančnost pri določanju okvare in okvarjenega izvoda.

ABSTRACT

Recent developments indicate that Artificial Neural Networks (ANNs) may be appropriate for assisting dispatchers in operating electric power systems. This paper presents approach to detection defective feeder during phase to earth fault (also high impedance faults) in electrical distribution system –substation using feed-forward artificial neural network (ANN).

In the ANN algorithm, the standard back-propagation technique with a sigmoid activation function is used. The proposed neural network, was trained by real data recorded with Disturbance recorder during actual fault.

Performance study results show that the proposed algorithm performs very well in detecting the phase to earth fault and locating faulty feeder.

1. UVOD

V distribucijskih razdelilnih transformatorskih postajah 110kV/ 10, 20,35 kV je v Sloveniji še vedno prisoten problem selektivnega iskanja zemeljskih stikov z visoko prehodno upornostjo (t.i. visoko ohmskih zemeljskih stikov- ZS. VON). Zaradi množice problemov kot so: problematika ozemljevanja ničlišča energetskega transformatorja 110kV /SN, problematike ozemljil v distribucijskih transformatorskih postajah SN/NN in problematike zaščitnih instrumentnih transformatorjev elementi zaščite izvodov ne zmorejo dovolj natančnosti za zanesljivo določanje okvarjenega izvoda in selektivnega izklopa le tega. Tako

sev praksi mnogokrat ob nastopu ZS.VON aktivira nad tokovna zaščita ozemljitvenega upora. Le ta je časovno zakasnjena 2 min (upori so dimenzionirani za obratovanje v tem intervalu). V tem času je torej potrebno z koračnim izklapljanjem in ponovnim priklapljanjem "zdravih" izvodov poiskati okvarjen izvod.

Glavnina zaščitnih relejev v elektroenergetskih sistemih temelji na prepoznavanju vzorcev pripadajočih napetostnih in tokovnih signalov. Najenostavnejši pristop je preseganje pred nastavljene vrednosti. Omenjeno pomeni, da se lahko razvoj adaptivnih zaščit obravnava kot problematika prepoznavanja in klasificiranja vzorcev. Umetna inteligenca vključno z umetnimi nevronskimi mrežami je izjemno močno orodje ravno na področju prepoznavanja in klasificiranja vzorcev. Umetne nevronske mreže imajo odlične lastnosti kot so posplošitvena sposobnost, imunost na prisotnost šumov, robustnost in visoko tolerantnost na pojav napak v mreži sami. Posplošitvena sposobnost pomeni sposobnost pravilno obdelovati nove, nepoznane vzorce, torej za nove nepoznane vrednosti vhodov generirati pravilne izhode.

V članku predstavljena umetna nevronska mreža izloči vpliv fizikalnih sistemskih spremenljivk kot sta prehodna upornost na mestu zemeljskega stika in impedanca vira napajanja. Predstavljena umetna nevronska mreža je naučena z kontrolirano metodo in sicer s podatki posnetih parametrov v realnem okolju ob dejanskem zemeljskem stiku. Posnete so napetosti in tokovi v vseh fazah vseh izvodov, residualna napetost v zvezdišču napajalnega transformatorja in residualni tokovi v vsakem posameznem izvodu.

Nevronska mreža je nato testirana z drugim setom podatkov, ki je prav tako posnetek realne situacije v distribucijskem elektroenergetskem omrežju. Predstavljena sta dva testa različno naučene nevronske mreže.

2. NAPETOSTNE IN TOKOVNE RAZMERE OB ENOPOLNEM ZEMELJSKEM STIKU

Enopolni zemeljski stik je izrazito nesimetrična okvara. Posledica vsake nesimetrične okvare je, da vsota tokov in napetosti v trifaznem sistemu več ni enaka nič. Z drugimi besedami to pomeni, da se pojavita preostala (residualna) napetost U_0 in preostali tok I_0 . Preostala napetost in tok predstavljata vsoto napetosti ozir. tokov, ki zaradi nesimetrije več ni enaka nič.

Preostali tok ima tipično kapacitivni karakter zaradi kapacitivne komponente toka zemeljskega stika I_c , ki je posledica dozemne kapacitivnosti tako kablov kot daljnovodov.

Zaključevanje tega toka preko okvarne zanke teče preko navitij sekundarja energetskega napajalnega transformatorja, vodnikov, prehodne upornosti mesta okvare nato preko zemlje in končno nizko ohmskega upora preko katerega je ozemljeno zvezdišče sekundarja energetskega napajalnega transformatorja.

Zaradi okvare se v zdravih izvodih pojavi kapacitivna komponenta toka enopolnega zemeljskega stika I_c kot prispevek tega izvoda zaradi polnjenja in praznjenja naboja posamezne faze preko dozemne kapacitivnosti.

V okvarjenem izvodu pa se poleg kapacitivne komponente toka enopolnega zemeljskega stika I_c tega izvoda pojavi še ohmska komponenta, ki se zaključuje preko ozemljitvenega upora.

2.1 Tranzientno stanje zemeljskega stika

Fizikalno se ob nastanku enopolnega zemeljskega stika pričneta dva procesa:

- Praznjenje naboja okvarjene faze se prične, ko napetost okvarjene faze ob stiku z zemljo prične upadati in se naboj dozemne kapacitivnosti te faze prične prazniti
- Polnjenje nabojev preostalih- neokvarjenih faz ozir. njune dozemne kapacitivnosti zaradi dvigovanja napetosti v njih ali drugače povedano, dvigovanje napetosti v zdravih fazah povzroči polnjenje naboja – kapacitivnosti zdravih faz.

Oba procesa se končata v stacionarnem stanju zemeljskega stika.

Pomembni parametri, ki vplivajo na potek procesa polnjenja/praznjenja nabojev so:

- Dozemna kapacitivnost (zdravih) faz,
- velikost naboja pred pričetkom zemeljskega stika v okvarjeni fazi - trenutek nastanka zemeljskega stika glede na trenutno vrednost napetosti,
- trenutna vrednost medfazne napetosti zdravih faz do okvarjene (U_{21} , U_{31})
- stresan flusk ozir. induktivnost napajalnega transformatorja,
- linijska impedanca posamezne faze,
- impedanca zemeljskega stika na mestu le tega vključno z upornostjo zemlje

Ker so opisani parametri, ki vplivajo na proces praznjenja/polnjenja naboja faz, snovno geometrijske lastnosti in so relativno konstantni je karakteristično obnašanje ob zemeljskem stiku dinamično odvisno od trenutka nastanka zemeljskega stika – trenutne vrednosti napetosti.

Pri tem lahko nastopita dva ekstrema- robna primera:


- a) Vrednost fazne napetosti okvarjene faze je v trenutku nastanka zemeljskega stika minimalna ali blizu minimuma. V tem primeru je vrednost naboja okvarjene faze blizu nič in posledično tudi praznilni tok.
- b) Vrednost fazne napetosti okvarjene faze je v trenutku nastanka zemeljskega stika maksimalna. V tem primeru je velikost naboja okvarjene faze maksimalna, posledično praznilni tok maksimalen.

2.2 Stacionarno stanje zemeljskega stika

Po prehodnem pojavu torej vzpostavitvi porušenega napetostnega trikotnika zaradi zemeljskega stika ene faze, tranzientno stanje zemeljskega stika preide v stacionarno. V stacionarnem stanju je napetost v okvarjeni fazi nič ozir. realno blizu nič. Posledično je tok zemeljskega stika te faze $\approx 0A$ in to v vseh izvodih.

Fizikalno sliko v stacionarnem stanju prikazujejo naslednji kazalčni diagrami. Na diagramu a) je prikazan napetostni trikotnik ob zemeljskem stiku, na diagramu b) tokovne in

napetostne razmere v izvodih kjer ni zemeljskega stika, diagram c) pa prikazuje tokovne in napetostne razmere v okvarjenem izvodu.



Slika 1: Kazalčni diagrami zemeljskega stika za neokvarjene in okvarjen izvod

Medtem, ko se med okvaro v zdravih izvodih kapacitivna komponenta toka okvare zaključuje v smeri "od zbiralnic v izvod" se na okvarjenem izvodu v okvarjeni fazi celotni okvarni tok zaključuje v smeri od izvoda proti zbiralnicam in je tako njegov fazni kot le malo manjši od 180° glede na residualno napetost U_0 .


Omenjeno pomeni, da tok enopolnega zemeljskega stika v okvarjenem izvodu zaostaja za residualno napetostjo za $\approx 180^\circ$ v zdravih izvodih pa zaradi kapacitivnega karakterja prispevka toka enopolnega zemeljskega stika tega izvoda le ta residualno napetost prehiteva

za $\approx 90^\circ$. Natačno takšne razmere izmerijo tudi zaščitni merilni transformatorji ozir. merilni elementi v vsakem posameznem izvodu.

Omenjeno dejstvo kaže karakteristični lastnosti in je osnova za ločevanje vzorcev ozir. za razvrščanje v smislu ali je v konkretnem izvodu zemeljski stik ali pa ta izvod zgolj prispeva kapacitivno komponento torej v njem ni zemeljskega stika. Pri zemeljskih stikih v realnih distribucijskih omrežjih je ta razločitev bistvena za dispečerja kot je opisano v uvodu. Govorimo torej o razvrščanju podatkov, vektorjev v dve skupini, ki sta bistveno različni po faznem kotu. Dodatni parameter razvrščanja pa je prav gotovo velikost kazalca samega, ki nosi podatek o prisotnosti okvare.

3. NEVRONSKE MREŽE

Umetne nevrnske mreže imajo v angleščini naziv Artificial neural network. S tem se želi poudariti, da gre za neživo nevrnsko omrežje. Osnova nevrnskim mrež namreč izhaja iz posnemanja delovanja bioloških možganov. Le ti delujejo popolnoma drugače kot klasični algoritmi- digitalni računalniki. Medtem, ko se v polprevodniškem elementu dogodki vrstijo koračno v rangi nanosekunde (10^{-9} s) se v nevronih to odvija nekaj razredov počasneje v rangi milisekunde (10^{-3} s). Po drugi strani pa se zaradi enormnega števila nevrnskih celic in ogromnega števila medsebojnih povezav med njimi, operacije v nevrnskih mrežah odvijajo paralelno in ne koračno kot v digitalnih polprevodniških sistemih. Omenjeno povzroči, da so možgani enormno bolj učinkovita struktura za obdelavo informacij. To velja tudi energetske gledano kjer se le energetska učinkovitost ocenjuje na cca. 10^{-16} Joulov na operacijo v sekundi medtem, ko je ta vrednost za najboljše digitalne računalnike cca. 10^{-6} Joulov na operacijo na sekundo. Možgani so zelo kompleksen, nelinearen, paralelen računalnik (sistem za procesiranje informacij). Le ta je strukturiran kot tri stopenjski sistem na sliki 2 katerega jedro so možgani – Nevronska mreža. Receptorji prevajajo dražljaje v električne impulze, ki prenašajo informacije v nevrnsko mrežo medtem, ko aktuatorji pretvarjajo električne impulze iz nevrnske mreže v ustrezne odzive sistema.




Slika 2: Blok diagram biološke nevrnske mreže

Osnovni gradniki Nevronske mreže so nevroni. Ker umetne nevrnske mreže posnemajo delovanje bioloških je osnovni del umetne nevrnske mreže umetni nevron.

3.1 Umetni nevron


Umetni nevron je poenostavljen model biološkega nevrona. Zgradbo biološkega nevrona prikazuje slika 3. Na vhode nevrona preko sinaps prispejo signali iz drugih nevronov in/ali receptorjev. Vsaka sinapsa ima svoj značilni količnik, ki se imenuje utež.



Slika 3: Biološki nevron

Signal se v sinapsi poveča za toliko krat, kolikor znaša njena utež w_i . V jedru nevrona se vsi ojačani signali najprej seštejejo, nato pa se rezultatu prišteje še konstanta w_0 imenovana prag.

Nazadnje se na izhodu nevrona rezultat še omeji (limitira) s pomočjo prenosne funkcije. To velja za veliko večino nevronov, ki jih imenujemo linearna pragovna enota (angleško Linear Threshold Unit, LTU). Redkeje srečamo tudi drugačne nevrone.



Slika 4: Zgradba umetnega nevrona

pri čemer je:

- w_0 : prag nevrona,
- w_1 do w_2 : uteži sinaps
- $f_{prenosna}$: prenosna funkcija


Z enačbo se nevron lahko opiše:

$$O_j = f_{prenosna}(w_0 + \sum_{i=1}^n x_i \cdot w_{ij}) \quad (1)$$

i = zaporedna številka vhoda nevrona

j = zaporedna številka učnega vzorca

Nevroni se razlikujejo tudi v načinu limitiranja izhodnega signala. Linearni limiter signala pravzaprav sploh ne spremeni. Trdi limiter da na izhod samo vrednost 0 ali 1. Vmesna različica med linearnim in trdim limiterjem je odsekovno linearni limiter. Najpogosteje se uporablja sigmoidni limiter, saj ima sigmoidna funkcija dobro lastnost, da je zvezno odvedljiva, sicer pa je sigmoida po obliki zelo podobna odsekovno zvezni limiterski funkciji. Odvedljivost je koristna lastnost, kadar moramo med učenjem nevronske mreže računati gradient učne napake, ki temelji na parcialnih odvodih funkcije učne napake.



Slika 5: Sigmoidna prenosna funkcija

4. OPIS UPORABLJENE NEVRONSKE MREŽE


Za izbiro modela nevronske mreže sem izbral nevronske omrežje z enim vhodnim slojem, enim skritim slojem in enim izhodnim slojem. Izkušnje so namreč pokazale, da ni razloga za uporabo več kot enega skritega sloja. En sloj namreč lahko aproksimira katerokoli funkcijo, ki stalno preslikava iz enega končnega prostora v drugega. Določitev števila skritih nevronov je samo majhen delček problema. Določiti je namreč tudi potrebno, koliko nevronov bo v posameznem sloju. Oboje je potrebno pazljivo izbrati.

Število vhodnih in izhodnih parametrov je ob določitvi problema bolj ali manj jasno. Manj jasno pa je določiti- izbrati število skritih slojev in števila nevronov v vsakem od njih. V splošnem ima večina nevronske mreže en skrit sloj prav tako pa je zelo redko, da ima nevronska mreža več kot dva skrita sloja. Za prvi poizkus sem izbral en skrit sloj nevronov. Takoj zatem se je bilo potrebno odločiti o ustreznem številu nevronov v njem. Izbira premajhnega števila nevronov povzroči premalo naučenost (underfitting) po drugi strani izbira prevelikega števila nevronov povzroča prekomerno naučenost (overfitting).

Obstaja več praktičnih priporočil – pravil za izbiro števila nevronov v skitem sloju. Če omenim najpogostejše:

1. Število nevronov v skitem sloju naj bo med velikostjo vhodnega in izhodnega sloja.
2. Število nevronov v skitem sloju naj bo enako vsoti velikosti vhodnega in izhodnega sloja ozir. vhodov in izhodov plus ena

3. Število nevronov v skritem sloju naj bo manjše od dvakratnika velikosti vhodnega sloja



Slika 6: Uporaba Biasa v nevronske omrežju

Slika 6 prikazuje nevronske mrežo, ki sem jo kreiral. Mreža ima tri vhode (efektivni vrednosti I_0 in U_0 ter fazni kot med njima ϕ_0) torej obdelujem vektorja residualne napetosti in toka.

V skritem sloju ima 6 nevronov, v izhodnem pa dva. Rezultat je lahko katerokoli število med 0 in 1. Mreža je bila učena po t.i. nadzorovani metodi, kjer sem v sete realnih posnetih podatkov (nadzorovano) vpisal vrednost izhoda (0 ali 1) za vsak posamezen karakteristični podatek in s tem določil kateri vrednosti predstavljajo zemeljski stik in katere ne. Učenje nevronske mreže se je izkazalo za najbolj občutljiv del procesa tega projekta. Tudi tukaj je očitno prisotna analogija iz biološkega sveta kjer je učenje prav tako eden najpomembnejših in občutljivih procesov bioloških nevronov - možganov.

5. PRIPRAVA PODATKOV

Uporabil sem podatke realnega defekta, zemeljskega stika posnetega z disturbance recorderjem v okviru enote REF 541 proizvajalca ABB. Enota REF 541 predstavlja terminal z združenimi funkcijami zaščite, vodenja, meritev in disturbance rekorderja za distribucijsko omrežje ozir. izvode v napajalni RTP. Posnete oscilografije so posledica realnih okvar-zemeljskih stikov v distribucijskem omrežju Elektro Maribor. Posnete so v RTP 110/20kV Ptuj- Breg, 10.05.2012 ob 16:51:02, ko se je v omrežju- na izvodu: 20 kV DV Sela zgodil zemeljski stik. Omenjeni daljnovod se napaja iz TR 110/20kV z močjo 31,5 MVA, zvezdiščem ozemljenim preko nizko ohmskega upora. Tok zemeljskega stika je znašal v okvarjenem izvodu 28A, v zdravih pa vse od 23A v enem izvodu, preko 8A v drugem do 3,4 A. Frekvenca vzorčenja je 2kHz ozir. 40 vzorcev za analogne signale ter 100Hz ozir. 10ms za digitalne signale. Po Shanonovem teoremu se tako teoretično lahko zajema $40/2-1 = 19$. Harmonik. Zaradi nizkoprepustnega analognega filtra na vhodu (anti- aliasing filtering) in

zaradi dejstva, da je v bližini polovične frekvence vzorčenja le to nenatančno so odčitavanja REF natančna do 13. harmonika. Oscilografije so istočasno posnete na vseh srednjenapetostnih izvodih tega transformatorja.

Za reševanje zastavljenega problema so ključni trije podatki, residualni tok posameznega izvoda, residualna napetost v zvezdišču transformatorja in fazni kot med njima. V ta namen se lahko ostali podatki (vsi fazni tokovi, fazne napetosti, vsi posneti digitalni kanali) vsakega izvoda opustijo.

Ker so v oscilografiji zajete trenutne vrednosti za vsak odtipek, teh pa je 40/ periodo je seveda potrebno najprej izračunati efektivno vrednost in ustrezne kote residualne napetosti in toka za vsak odtipek posebej. Zaradi uporabe sigmoidne funkcije v nevronske mreži je bilo potrebno podatke tudi normalizirati. Normalizacija podatkov pomeni, da je potrebno vse vrednosti preslikati v interval med 0 in 1 kar sem naredil s pomočjo enačbe 2 za preslikavo podatkov na t.i., enotino bazo.

Enačba 2: Normalizacija podatkov na enotino bazo:

$$X_n = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (2)$$

kjer so:

X - podatek, ki se normalizira

X_n - normaliziran podatek

$X_{\min}$ - minimalna vrednost X

$X_{\max}$ - maksimalna vrednost X

6. UČENJE IN TESTIRANJE NEVRONSKE MREŽE

Po pripravi množice podatkov za učenje in testne množice podatkov sledi učenje nevronske mreže. Nevronska mreža je konfigurirana z dvema izhodoma. Pri tem vrednost na prvem izhodu pove ali zemeljski stik je prisoten ali ne (vrednost 1 ali 0), vrednost na drugem izhodu pa pove ali je v tem konkretnem izvodu ali ne (vrednost 1 ali 0). Tako so na razpolago 4 različne kombinacije, pri čemer je samo kombinacija 0 1 napačna ozir. nelogična in neuporabna saj bi pomenila, da zemeljskega stika v sistemu ni je pa prisoten na obravnavanem izvodu.


Za učenje nevronske mreže sem uporabil metodo povratno napredovanje z momentom (Backpropagation With Momentum). Ta metoda je veliko bolj konvergenčna kot sam Backpropagation algorithm. Moment, ki ga dodamo bistveno poveča hitrost učenja nevronske mreže in izboljša učinkovitost učenja.

Za samo učenja sta bistvena naslednja podatka:

- Stopnja učenja (Learning rate) je procedura, ki oceni relativni prispevek vsake uteži k skupni napaki. Pravilna izbira te vrednosti je izjemno pomembna pri iskanju pravega globalnega minimuma napake. Če je vrednost premajhna je napredek učenja zelo

počasen. Če je vrednost previsoka bo učenje sicer potekalo dosti hitreje vendar lahko povzroči oscilacije med relativno slabimi rešitvami (overfitting).

- Stopnja momenta(Momentum rate) je prav tako pomembna za povečanje konvergence še bolj pa za izogibanje lokalnim minimumom. Osnovna ideja momenta je stabilizacija sprememb uteži nevronov s tem, ko se uteži ne spreminjajo radikalno temveč se zmanjševanje gradienta napake zagotavlja s kombinacijo ozir. z upoštevanjem deleža prejšnje spremembe uteži.




Parametri učenja:

max napaka: 0,01

learning rate 0,2

Momentum: 0,9

Slika 7: Diagram napake poizkus učenja 1



Parametri učenja:

max napaka: 0,01

learning rate 0,2

Momentum: 0,7

Slika 8 :Diagram napake poizkus učenja 2

V nadaljevanju prikazujem samo del rezultatov testiranja nevronske mreže. Najpomembnejši je podatek o skupnem kvadratnem pogrešku, ki je v obeh primerih učenja v okvirih zahtevanega torej manjši od 1%. Pravzaprav je rezultat v poizkusu učenja 2 idealen saj kaže, da nevronska mreža 100% brez vsake napake razdeli vhodne vrednosti v pravo

skupino ozir. za vsak podatek na vhodu natančno pove ali je zemeljski stik in ali je v tem izvodu torej idealno razločuje podatke.

Test mreže - poizkus učenje1	Test mreže -poizkus učenje2
Input: 0; 0; 0,5005; Output: 0,0455; 0; Desired output: 0; 0; Error: 0,0455; 0;	Input: 0; 0; 0,4378; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0; 0; 0,4378; Output: 0,0284; 0,0001; Desired output: 0; 0; Error: 0,0284; 0,0001;	Input: 0,124; 0; 0,0175; Output: 1; 1; Desired output: 1; 1; Error: 0; 0;
Input: 0; 0; 0,1868; Output: 0,0169; 0,0103; Desired output: 0; 0; Error: 0,0169; 0,0103;	Input: 0,16; 0,056; 0,021; Output: 1; 1; Desired output: 1; 1; Error: 0; 0;
Input: 0; 0; 0,9652; Output: 0,1294; 0; Desired output: 0; 0; Error: 0,1294; 0;	Input: 0,167; 0,205; 0,1162; Output: 1; 1; Desired output: 1; 1; Error: 0; 0;
Input: 0; 0; 0,0114; Output: 0,0786; 0,3939; Desired output: 0; 0; Error: 0,0786; 0,3939;	Input: 0,206; 0,245; 0,244; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,124; 0; 0,0175; Output: 0,9143; 0,9445; Desired output: 1; 1; Error: -0,0857; -0,0555;	Input: 0,251; 0,245; 0,2651; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,16; 0,056; 0,021; Output: 0,9932; 0,9882; Desired output: 1; 1; Error: -0,0068; -0,0118;	Input: 0,356; 0,238; 0,2633; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,191; 0,15; 0,0558; Output: 0,9982; 0,9783; Desired output: 1; 1; Error: -0,0018; -0,0217;	Input: 0,405; 0,238; 0,2465; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,178; 0,18; 0,0826; Output: 0,9981; 0,9426; Desired output: 1; 1; Error: -0,0019; -0,0574;	Input: 0,445; 0,247; 0,2234; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,206; 0,245; 0,244; Output: 0,9993; 0,041; Desired output: 1; 0; Error: -0,0007; 0,041;	Input: 0,477; 0,268; 0,1992; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,251; 0,245; 0,2651; Output: 0,9996; 0,018; Desired output: 1; 0; Error: -0,0004; 0,018;	Input: 0,499; 0,301; 0,1789; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,445; 0,247; 0,2234; Output: 0,9999; 0,0142; Desired output: 1; 0; Error: -0,0001; 0,0142;	Input: 0,511; 0,441; 0,1577; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,477; 0,268; 0,1992; Output: 0,9999; 0,0192; Desired output: 1; 0; Error: -0,0001; 0,0192;	Input: 0,498; 0,534; 0,1722; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,669; 0,675; 0,256; Output: 1; 0,0047; Desired output: 1; 0; Error: -0; 0,0047;	Input: 0,905; 0,955; 0,2554; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,828; 0,691; 0,2353; Output: 1; 0,0067; Desired output: 1; 0; Error: -0; 0,0067;	Input: 0,998; 0,921; 0,256; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,854; 0,71; 0,2265; Output: 1; 0,0078; Desired output: 1; 0; Error: -0; 0,0078;	Input: 1; 0,925; 0,2477; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,905; 0,955; 0,2554; Output: 1; 0,0056; Desired output: 1; 0; Error: -0; 0,0056;	Input: 0,998; 0,932; 0,2447; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,998; 0,921; 0,256; Output: 1; 0,0058; Desired output: 1; 0; Error: -0; 0,0058;	Input: 0,992; 0,94; 0,243; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,992; 0,94; 0,243; Output: 1; 0,0069; Desired output: 1; 0; Error: -0; 0,0069;	Input: 0,982; 0,949; 0,2424; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,963; 0,97; 0,244; Output: 1; 0,0068; Desired output: 1; 0; Error: -0; 0,0068;	Input: 0,972; 0,959; 0,2429; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,986; 0,981; 0,2606; Output: 1; 0,0055; Desired output: 1; 0; Error: -0; 0,0055;	Input: 0,963; 0,97; 0,244; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,894; 0,994; 0,252; Output: 1; 0,0059; Desired output: 1; 0; Error: -0; 0,0059;	Input: 0,986; 0,981; 0,2606; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,805; 1; 0,2564; Output: 1; 0,0053; Desired output: 1; 0; Error: -0; 0,0053;	Input: 0,977; 0,976; 0,2584; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,643; 0,601; 0,3082; Output: 1; 0,0028; Desired output: 1; 0; Error: -0; 0,0028;	Input: 0,938; 0,99; 0,2553; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,524; 0,518; 0,2659; Output: 1; 0,0039; Desired output: 1; 0; Error: -0; 0,0039;	Input: 0,918; 0,991; 0,2532; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,257; 0,508; 0,267; Output: 0,9999; 0,0047; Desired output: 1; 0; Error: -0,0001; 0,0047;	Input: 0,894; 0,994; 0,252; Output: 1; 0; Desired output: 1; 0; Error: 0; 0;
Input: 0,224; 0,499; 0,2866; Output: 0,9998; 0,0041; Desired output: 1; 0; Error: -0,0002; 0,0041;	Input: 0,041; 0; 0,2974; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0,062; 0,061; 0,3922; Output: 0,7515; 0,0018; Desired output: 1; 0; Error: -0,2485; 0,0018;	Input: 0,038; 0; 0,2542; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0,034; 0; 0,1959; Output: 0,0488; 0,0167; Desired output: 0; 0; Error: 0,0488; 0,0167;	Input: 0,034; 0; 0,1959; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0,031; 0; 0,1414; Output: 0,0598; 0,0461; Desired output: 0; 0; Error: 0,0598; 0,0461;	Input: 0,031; 0; 0,1414; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0; 0; 0,1436; Output: 0,0218; 0,0234; Desired output: 0; 0; Error: 0,0218; 0,0234;	Input: 0; 0; 0,1436; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0; 0; 0,1616; Output: 0,0194; 0,0164; Desired output: 0; 0; Error: 0,0194; 0,0164;	Input: 0; 0; 0,1616; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0; 0; 0,1512; Output: 0,0207; 0,0201; Desired output: 0; 0; Error: 0,0207; 0,0201;	Input: 0; 0; 0,1512; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Input: 0; 0; 0,131; Output: 0,0239; 0,0305; Desired output: 0; 0; Error: 0,0239; 0,0305;	Input: 0; 0; 0,131; Output: 0; 0; Desired output: 0; 0; Error: 0; 0;
Total Mean Square Error: 0.007522828258067818	Total Mean Square Error: 0.0

Input vrednosti predstavljajo vrednosti na vhodu, Output vrednosti so izračunani podatki nevronske mreže na izhodu, Desired output so kontrolne vrednosti izhodov, Error je absolutna napaka na izhodu. Vse omenjene vrednosti se računajo za vsak vhodni podatek posebej. Na koncu je izračunana skupna srednja kvadratna napaka za vse izračunane izhode. V primeru učenja 1, kjer se je učenje nevronske mreže končalo, ko je le to doseglo 1% napako je srednja

kvadratna napaka testnega poizkusa 0,7% medtem, ko je v primeru učenja 2, kjer se je nevronska mreža naučila v stopnji 0% napake tudi testni set podatkov dal enake rezultate, torej 0% napako izhoda ozir. nevronske mreže.

7. LITERATURA

- [1] Bojan Grčar, Uvod v zaščito elementov elektroenergetskih sistemov, Univerza v Mariboru, FERI, 1999
- [2] Jože Voršič, Tine Zorič, Miran Horvat, Izračun obratovalnih stanj v elektroenergetskih omrežjih, FERI 2003
- [3] SIST HD637 S1: Power installations exceeding 1 kV a.c., CENELEC 1999
- [4] Dommel, H.W., Digital computer solutions of electromagnetic transients in single and multi phase networks, IEEE Trans. On Power Apparatus and Systems, Vol. 88, No.2, str. 734-741 (April 1969)
- [5] Prof. dr. Peter Žunko, Doc. dr. Grega Bizjak, prof. dr. Rafael Mihalič, prof. dr. Igor Papič, as. Mag. matej B. Kobav, Uroš Kerin, mag. Jože Bizjak, Renato Čučić, Franc Leskovec, Analiza ozemljitvenih razmer v razdelilnem omrežju Slovenije, Fakulteta za elektrotehniko Univerze v Ljubljani, 2007
- [6] Rado Isaković, mag. Primož Hrobat, mag. Drago Bokal, mag. Stane Vižintin, mag. Leon Valenčič, Tomaž Živic, mag. Rudi Vončina, Preučitev obratovanja SN omrežja glede različnega tretiranja nevtralne točke. Študija 1839, EIMV, 2007
- [7] Seppo Hanninen, Single phase earth faults in high impedance grounded networks, Characteristics, indication and location, Technical research centre of Finland Espoo 2001
- [8] Gernot DRUML, QU2 Algorithm for detecting earth faults, A.Eberle GmbH&CoKG., 2009
- [9] Mohamed F. Abdel- Fattah, Matti Lethonen, A new Transient Impedance Basec Algorithm for earth Fault Detection in Medium Voltage Networks, Helsinki university of Technology, International Conference in Power System transients, Kyoto, Japan, June 2009
- [10] M. Lethonen, T.hakola, Neutral Earthing and Power System Protection- Earthing Solutions and Protective Relaying in medium voltage distribution networks, Vassa, Finland, FIN-65101, 1996
- [11] John McCarty, [http://en.wikipedia.org/wiki/John_McCarthy_\(computer_scientist\)](http://en.wikipedia.org/wiki/John_McCarthy_(computer_scientist)) , 12. 8. 2012
- [12] Ian H. Witten, Eibe Frank, Mark A. Hall, Data Mining: Practical Machine Learning Tools and Techniques, Third Edition, The Morgan Kaufmann Series in Data Management Systems
- [13] Feed forward neural network, http://en.wikipedia.org/wiki/Feed-forward_neural_networks, 12. 3. 2013
- [14] Recurrent neural network, http://en.wikipedia.org/wiki/Recurrent_neural_networks, 12. 3. 2013
- [15] Perceptron, <http://en.wikipedia.org/wiki/Perceptron>, 12. 3. 2013

- [16] John Peter Jesan, Donald M. Lauro: Human Brain and Neural Network behavior a comparison, Ubiquity, Volume 2003 Issue November
- [17] McCulloch, W. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 7:115 – 133
- [18] Russell, Ingrid. "The Delta Rule". University of Hartford, November 2012
- [19] Davida E. Rumelhart, Geoffrey E. Hinton in Ronald J. Williams, Learning representations by back-propagating errors, Nature, October 1986
- [20] Simon Haykin, NEURAL NETWORKS, A Comprehensive foundation, McMaster University, Hamilton, Ontario, Canada, 1994