

# Uporaba umetne inteligence v distribucijskem elektroenergetskem sistemu

Bogomil Jelenc<sup>1</sup>, Jože Pihler<sup>2</sup>

<sup>1</sup>Elektro Maribor, d. d., Vetrinjska ul. 2, 2000 Maribor, Slovenija

<sup>2</sup>Univerza v Mariboru, Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova ul. 17, 2000 Maribor, Slovenija

E-pošta: bogomil.jelenc@elektro-maribor.si

**Povzetek.** Umetna nevronska omrežja (ANN) postajajo zelo uporabna za podporo dispečerjev pri vodenju obratovanja distribucijskih elektroenergetskih sistemov. Odlično se izkažejo predvsem pri prepoznavanju vzorcev, kar pa je pravzaprav osnova delovanja zaščitnih naprav v sistemih. Ta članek obdela pristop pri določanju okvarjenega izvoda v razdelilni transformatorski postaji (RTP) pri zemeljskem stiku, tudi visokohmskem, z uporabo nevronske mreže s povezavami naprej (feed forward artificial neuron network). Nevronska mreža je naučena s 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.

**Ključne besede:** nevronska mreža, umetni nevron, distribucijsko omrežje, zemeljski stik, oscilografija

## Detecting a faulty feeder by using an artificial neural network

Recent developments indicate that the Artificial Neural Networks (ANNs) may be useful assisting the power system dispatchers at their work. The paper presents an approach to detection of a faulty feeder during a phase to earth fault (also a high impedance fault) in a power distribution system using a feed-forward ANN.

In the proposed ANN algorithm, the standard back-propagation technique with a sigmoid activation function is used. ANN is trained with real data obtained with a disturbance recorder during an actual fault.

The study results show that the proposed algorithm performs excellently in detecting the phase to earth faults and locating the faulty feeder.

**Keywords:** neural network, ANN, distribution network, feeder, oscillography

## 1 UVOD

V distribucijskih razdelilnih transformatorskih postajah 110 kV/ 10, 20,35 kV je v Sloveniji še vedno prisoten problem selektivnega iskanja zemeljskih stikov z visoko prehodno upornostjo t. i. visokohmskih 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 [4]. Tako se v praksi pogosto ob nastopu ZS.VON aktivira nadtokovna zaščita ozemljitvenega upora. Le-ta je časovno zakasnjena za 2 min (upori so dimenzionirani za obratovanje v tem intervalu). V tem času je torej treba s koračnim izklapljanjem in ponovnim priklapljanjem "zdravih" izvodov poiskati okvarjen izvod.

Večina zaščitnih relejev v elektroenergetskih sistemih temelji na prepoznavanju vzorcev pripadajočih napetostnih in tokovnih signalov. Najpreprostejši pristop je preseganje prednastavljene 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 pri prepoznavanju in klasificiranju 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 s 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 oziroma preizkusa naučenosti iste nevrnske mreže, ki pa je bila učena na različen način. Preizkus naučenosti pokaže natančnost in kakovost rezultatov nevrnske mreže na neodvisnem oziroma novem setu podatkov.

## 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 ni več enaka nič. Z drugimi besedami to pomeni, da se pojavita preostala (residualna) napetost  $U_0$  in preostali tok  $I_0$  [1]. Preostala napetost in tok pomenita vsoto napetosti oziroma tokov, ki zaradi nesimetrije ni več enaka nič. Preostali tok ima tipično kapacitivno naravo zaradi kapacitivne komponente toka zemeljskega stika  $I_c$ , ki je posledica dozemne kapacitivnosti tako kablov kot daljnovodov.

Zaključevanje tega toka v okvarni zanki teče prek navitij sekundarja energetskega napajalnega transformatorja, vodnikov, prehodne upornosti mesta okvare, nato prek zemlje in končno nizkoohmskega upora, prek 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 prek 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 prek ozemljitvenega upora [2],[3].

### 2.1 Tranzientno stanje zemeljskega stika

Fizikalno se ob nastanku enopolnega zemeljskega stika začeta dva procesa[5]:

- Praznjenje naboja okvarjene faze se začne, ko napetost okvarjene faze ob stiku z zemljo začne upadati in se naboj dozemne kapacitivnosti te faze začne 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 polnjenja/praznjenja, nabojev so:

- dozemna kapacitivnost (zdravih) faz,
- velikost naboja pred začetkom 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 oziroma 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 [4], [5].


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 oziroma realno blizu nič. Posledično je tok zemeljskega stika te faze  $\approx 0A$ , in to v vseh izvodih [3].

Fizikalno sliko v stacionarnem stanju prikazujejo naslednji kazalčni diagrami. Na sliki 1 a) je prikazan napetostni trikotnik ob zemeljskem stiku, 1 b) tokovne in napetostne razmere v izvodih, kjer ni zemeljskega stika, 1 c) pa prikazuje tokovne in napetostne razmere v okvarjenem izvodu. Diagrami obravnavajo primer treh izvodov, daljnovodov ali kablovodov, napajanih iz istih zbiralnic oziroma napajalnega energetskega transformatorja. Zemeljski stik je prisoten samo na enem od njih. Takšna situacija je najpogostejša v realnem sistemu [2], s to razliko, da je v realnem sistemu izvodov več, kar pa ne vpliva na fizikalno sliko, saj so razmere v izvodih, kjer ni okvare, identične.



Slika 1: Kazalčni diagrami zemeljskega stika za:

- a) napetosti v sistemu
- b) neokvarjene izvode
- c) 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 celoten tok okvare zaključuje v smeri od izvoda proti zbiralnicam in je tako njegov fazni kot le malo manjši od  $180^\circ$  glede na residualno napetost  $U_0$ . [2]


Omenjeno pomeni, da tok enopolnega zemeljskega stika v okvarjenem izvodu zaostaja za residualno napetostjo za  $\approx 180^\circ$ , v zdravih izvodih pa zaradi kapacitivne narave prispevka toka enopolnega zemeljskega stika tega izvoda le-ta residualno napetost prehiteva za  $\approx 90^\circ$ . Natančno takšne razmere izmerijo tudi zaščitni merilni transformatorji oziroma merilni elementi v vsakem posameznem izvodu.

Omenjeno dejstvo kaže karakteristični lastnosti in je podlaga za ločevanje vzorcev oziroma 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 se v angleščini imenujejo Artificial Neural Network. S tem se želi poudariti, da gre za neživo nevrnsko omrežje. Osnova nevrnskih 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 velikanskega števila medsebojnih povezav med njimi operacije v nevrnskih mrežah odvijajo vzporedno in ne koračno, kot v digitalnih polprevodniških sistemih. Omenjeno povzroči, da so možgani enormno učinkovitejša struktura za obdelavo informacij. To velja tudi energetske gledano, kjer se energetska učinkovitost ocenjuje na pribl.  $10^{-16}$  Joulov na operacijo v sekundi, medtem ko je ta vrednost za najboljše digitalne računalnike pribl.  $10^{-6}$  Joulov na operacijo na sekundo. Možgani so zelo kompleksni, nelinearni, vzporedni računalniki (sistem za procesiranje informacij). Le-ta je strukturiran kot tristopenjski sistem, katerega jedro so možgani – nevrnska 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 [8].




Slika 2: Blok diagram biološke nevrnske mreže

Osnovni gradniki nevrnske 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 nevrna. Zgradbo biološkega nevrna prikazuje slika 3. Na vhode nevrna prek sinaps prispejo signali iz drugih nevronov in/ali receptorjev. Vsaka sinapsa ima svoj značilni količnik, ki se imenuje utež. Pri biološkem nevrnu so sinapse napetostno odvisni ionski kanalčki, ki so lahko za nekatere ione bolj ali manj prepustni, spet za druge ione pa so lahko tudi neprepustni.



Slika 3: Biološki nevron

Signal se v sinapsi poveča za tolikokrat, kolikor znaša njena utež  $w_i$ . V jedru nevrna se vsi ojačeni signali najprej seštejejo, nato pa se rezultatu prišteje še konstanta  $w_0$ , imenovana prag (bias). Pomen praga je razložen v naslednjem poglavju. Nazadnje se na izhodu nevrna 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 nevrne [6],[7],[8].

Zgradba umetnega nevrna, prikazana v blokdiagramu, je predstavljena na sliki 4. Razvidno je, da zvesto posnema biološki nevron.



Slika 4: Zgradba umetnega nevrna,

pri čemer je:

$w_0$ : prag nevrna,

$w_1$  do  $w_2$ : uteži sinaps,

$f_{prenosna}$ : prenosna funkcija.

Nevron se lahko opiše tudi z enačbo:


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

pri čemer pomeni:

$i$  = zaporedna številka vhoda nevrna,

$j$  = 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 nevrnske mreže računati gradient učne napake, ki temelji na parcialnih odvodih prenosne funkcije glede na prispevke učne napake. Odvod sigmoidne funkcije je zaradi verižnega pravila parcialnega odvajanja zelo priročen za izražanje napake izhoda kot funkcije spremembe uteži in spremembe vhoda, kar privede do vpeljave pojmov stopnja učenja in moment učenja, opisanih v poglavju 6.[8]



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 treba, koliko nevronov bo v posameznem sloju. Oboje je treba skrbno 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. Na splošno 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 treba odločiti o ustreznem številu nevronov v njem. Izbira premajhnega števila nevronov povzroči premajhno naučenost (underfitting), po drugi strani izbira prevelikega števila nevronov povzroča preveliko naučenost (overfitting) [8].

Obstaja več praktičnih priporočil – pravil za izbiro števila nevronov v skritem sloju. Omenjam najpogostejše:

1. Število nevronov v skritem sloju naj bo med velikostjo vhodnega in izhodnega sloja.
2. Število nevronov v skritem sloju naj bo enako vsoti velikosti vhodnega in izhodnega sloja oziroma vhodov in izhodov plus ena.
3. Število nevronov v skritem sloju naj bo manjše od dvakratnika velikosti vhodnega sloja



Slika 6: Uporaba praga oziroma bias nevrona v nevronske mreži

Na sliki 6 sta v vhodnem in skritem sloju prikazana dva dodatna nevrona. Pravimo jima "bias" nevrona in služita za vzporedni premik prenosne funkcije po osi  $x$  levo ali desno, odvisno od predznaka. Če pogledamo enačbo 1, vidimo, da govorimo o pragu oziroma členu  $w_0$ . Pomembnost uporabe praga je razvidna iz slike 5. Vrednost prenosne funkcije na izhodu pri vrednosti vhoda  $x=0$  je namreč prav tako enaka nič. Z vpeljavo

teh nevronov oziroma praga pa je lahko vrednost prenosne funkcije pri  $x=0$  različna od nič.

Slika 6 sočasno prikazuje nevronske mreže, ki sem jo kreiral. Mreža ima tri vhode (efektivni vrednosti  $I_0$  in  $U_0$  ter fazni kot med njima  $\varphi_0$ ), torej obdelujem vektorja residualne napetosti in toka. V skritem sloju ima šest 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 katere 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.

Nevronska mreža je kreirana, učena in testirana z odprtokodnim programskim paketom Java Neural Network Framework Neuroph, v 2.92.

#### 5 PRIPRAVA PODATKOV

Uporabil sem podatke realnega defekta, zemeljskega stika, posnetega z disturbance recorderjem v okviru enote REF 541 izdelovalca ABB. Enota REF 541 je terminal z združenimi funkcijami zaščite, vodenja, meritev in disturbance rekorderja za distribucijsko omrežje oziroma izvode v napajalni RTP.

Posnete oscilografije so posledica realnih okvar – zemeljskih stikov v distribucijskem omrežju Elektra Maribor. Posnete so v RTP 110/20 kV Ptuj-Breg, 10.05.2012 ob 16:51:02, ko se je v omrežju – na izvodu: 20 kV DV Videm zgodil zemeljski stik. Omenjeni daljnovod se napaja iz TR 110/20kV z močjo 31,5 MVA, zvezdiščem, ozemljenim prek nizkoohmskega upora. Tok zemeljskega stika je znašal v okvarjenem izvodu 28 A, v zdravih izvodih pa v intervalu od 23 A (kablovod) do 3,4 A (daljnovod).

Frekvenca vzorčenja je 2 kHz oziroma 40 vzorcev za analogne signale ter 100 Hz oziroma 10 ms za digitalne signale. Po Shannonovem 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 sočasno posnete na vseh sredjenapetostnih 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 preostali podatki (vsi fazni tokovi, fazne napetosti, vsi posneti digitalni kanali) vsakega izvoda opustijo.

Oscilografije so standardizirane s standardom IEEE C37.111-2011 -COMTRADE (COMmon format for

TRAnsient Data Exchange for power systems), ki omogoča izmenjavo posnetih podatkov med različnimi platformami. Standard je poznan tudi kot IEC 60255-24 Ed.2. Bistvo standarda je podatkovna datoteka ASCII, v kateri so podatki, ter konfiguracijska datoteka CFG, v kateri so definirani vsi drugi podatki, od časa do konstant posameznega snemanega kanala.

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

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

Enačba 2: Normalizacija podatkov na enotino bazo

Pri tem pomenijo:

$X$  – 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 je zemeljski stik v sistemu prisoten ali ne (vrednost 1 ali 0), vrednost na drugem izhodu pa pove, ali je zemeljski stik v tem konkretnem izvodu ali ne (vrednost 1 ali 0). Tako so na voljo štiri različne kombinacije izhodov, pri čemer je samo kombinacija (0, 1) napačna oziroma 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, imenovano povratno napredovanje z momentumom (Backpropagation With Momentum). Ta metoda je veliko bolj konvergenčna kot sam algoritem povratnega napredovanja (Backpropagation algorithm). Moment, ki ga dodamo, bistveno poveča hitrost učenja nevronske mreže in izboljša učinkovitost učenja. [8]

Za samo učenje sta bistvena naslednja podatka:

- Stopnja učenja (Learning rate) je postopek, 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 prevelika, bo učenje sicer potekalo veliko hitreje,

vendar lahko povzroči oscilacije med relativno slabimi rešitvami (overfitting) ali pa končanje v lokalnem minimumu.

- 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 oziroma z upoštevanjem deleža prejšnje spremembe uteži.



Slika 7: Diagram napake, poizkus učenja 1

Parametri učenja nevronske mreže v prvem poizkusu so bili naslednji:


max napaka: 0,01

learning rate 0,2

Momentum: 0,9

Prej navedeni parametri povedo, da je učenje uspešno končano, ko je napaka, torej razlika med vrednostjo izhoda in želeno vrednostjo izhoda, manjša od 1 %. Ravno primerjanje vsake vrednosti izhoda z želeno vrednostjo izhoda da tej metodi njeno ime (nadzorovana metoda učenja).

Relativni prispevki napak uteži se upoštevajo v 20-odstotnem deležu (learning rate). Stopnja momenta pa je bila postavljena tako, da se sprememba uteži v aktualni iteraciji upošteva v 90-odstotnem deležu, 10-odstotno pa spremembo uteži aktualne iteracije, odvisno od predznaka, duši ali pospešuje sprememba uteži prejšnje iteracije. Poizkus učenja 1 je tako v 110 iteracijah dosegel napako na izhodu pod 1 %.



Slika 8: Diagram napake, poizkus učenja 2

Parametri učenja nevronske mreže v drugem poizkusu so bili naslednji:

max napaka: 0,01  
learning rate 0,2  
Momentum: 0,7

Zaradi zmanjšanja radikalnosti sprememb uteži v aktualni iteraciji na 70 % (poizkus učenja 1 je uporabljal 90-odstotno) se je pričakovano povečalo število iteracij. Poizkus učenja 2 se je tako uspešno končal po 200 iteracijah. Pomembnejše je, da je poizkus učenja 2 dosegel naučenost 100-odstotno ali z drugimi besedami, da nevronska mreža brez napake prepoznava vzorec. Omenjeno se je potrdilo tudi na testu tako naučene mreže, podatki so v Prilogi.

## 7 SKLEP

V Prilogi prikazujem zgolj del rezultatov testiranja nevronske mreže. Prikazani so namreč samo karakteristični primeri različnih vhodov in dobljeni izhodi. 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-odstotno brez vsake napake razdeli vhodne vrednosti v pravo skupino oziroma za vsak podatek na vhodu natančno pove, ali je zemeljski stik v sistemu in ali je prisoten v konkretnem izvodu, torej idealno razločuje podatke v dve množici. To pa je bila osnovna ideja predstavljenega članka.

Input vrednosti so 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. Pri učenju 1, kjer se je učenje nevronske mreže končalo, ko je le-to doseglo manj kot 1-odstotno 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-odstotne napake tudi testni set podatkov dal enake rezultate, torej 0-odstotno napako izhoda oziroma nevronske mreže. Enako točne rezultate daje nevronska mreža tudi na vseh naprej testiranih vzorcih.

## LITERATURA

- [1] Bojan Grčar, Uvod v zaščito elementov elektroenergetskih sistemov, Univerza v Mariboru, FERi, 1999.
- [2] 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.
- [3] Seppo Hanninen, Single phase earth faults in high impedance grounded networks, Characteristics, indication and location, Technical research centre of Finland Espoo 2001.
- [4] Gernot DRUML, QU2 Algorithm for detecting earth faults, A.Eberle GmbH&CoKG., 2009.
- [5] 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.
- [6] Feed forward neural network, [http://en.wikipedia.org/wiki/Feed-forward\\_neural\\_networks](http://en.wikipedia.org/wiki/Feed-forward_neural_networks), 12. 3. 2013.
- [7] Recurrent neural network, [http://en.wikipedia.org/wiki/Recurrent\\_neural\\_networks](http://en.wikipedia.org/wiki/Recurrent_neural_networks), 12. 3. 2013.
- [8] Simon Haykin, NEURAL NETWORKS, A Comprehensive foundation, McMaster University, Hamilton, Ontario, Canada, 1994.

**Bogomil Jelenc** je diplomiral leta 1995 na Fakulteti za elektrotehniko, računalništvo in informatiko Univerze v Mariboru. Zaposlen je na Elektru Maribor, d. d. Njegova raziskovalna področja zajemajo problematiko obratovanja in daljinskega vodenja distribucijskega elektroenergetskega omrežja.

**Jože Pihler** je v letu 1987 diplomiral, leta 1991 magistriral in v letu 1995 doktoriral na Univerzi v Mariboru, Fakulteti za elektrotehniko, računalništvo in informatiko s področja elektrotehnike. Deset let je bil zaposlen v Tovarni stikalnih naprav v Mariboru. Od leta 1988 je bil raziskovalec in asistent, trenutno je profesor na Fakulteti za elektrotehniko, računalništvo in informatiko in vodja Laboratorija za energetiko. Njegovo področje delovanja so električne naprave in postroji, proizvodnja električne energije in visokonapetostna tehnika. Prof. Pihler je član mednarodnih organizacij CIGRE in IEEE, aktivno deluje v mednarodni standardizaciji IEC in nacionalni standardizaciji SIST.

## PRILOGA

Test mreže - poizkus učenja 1	Test mreže -poizkus učenja 2
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: 0,477; 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