energija 2

ČASOPIS HRVATSKE ELEKTROPRIVREDE

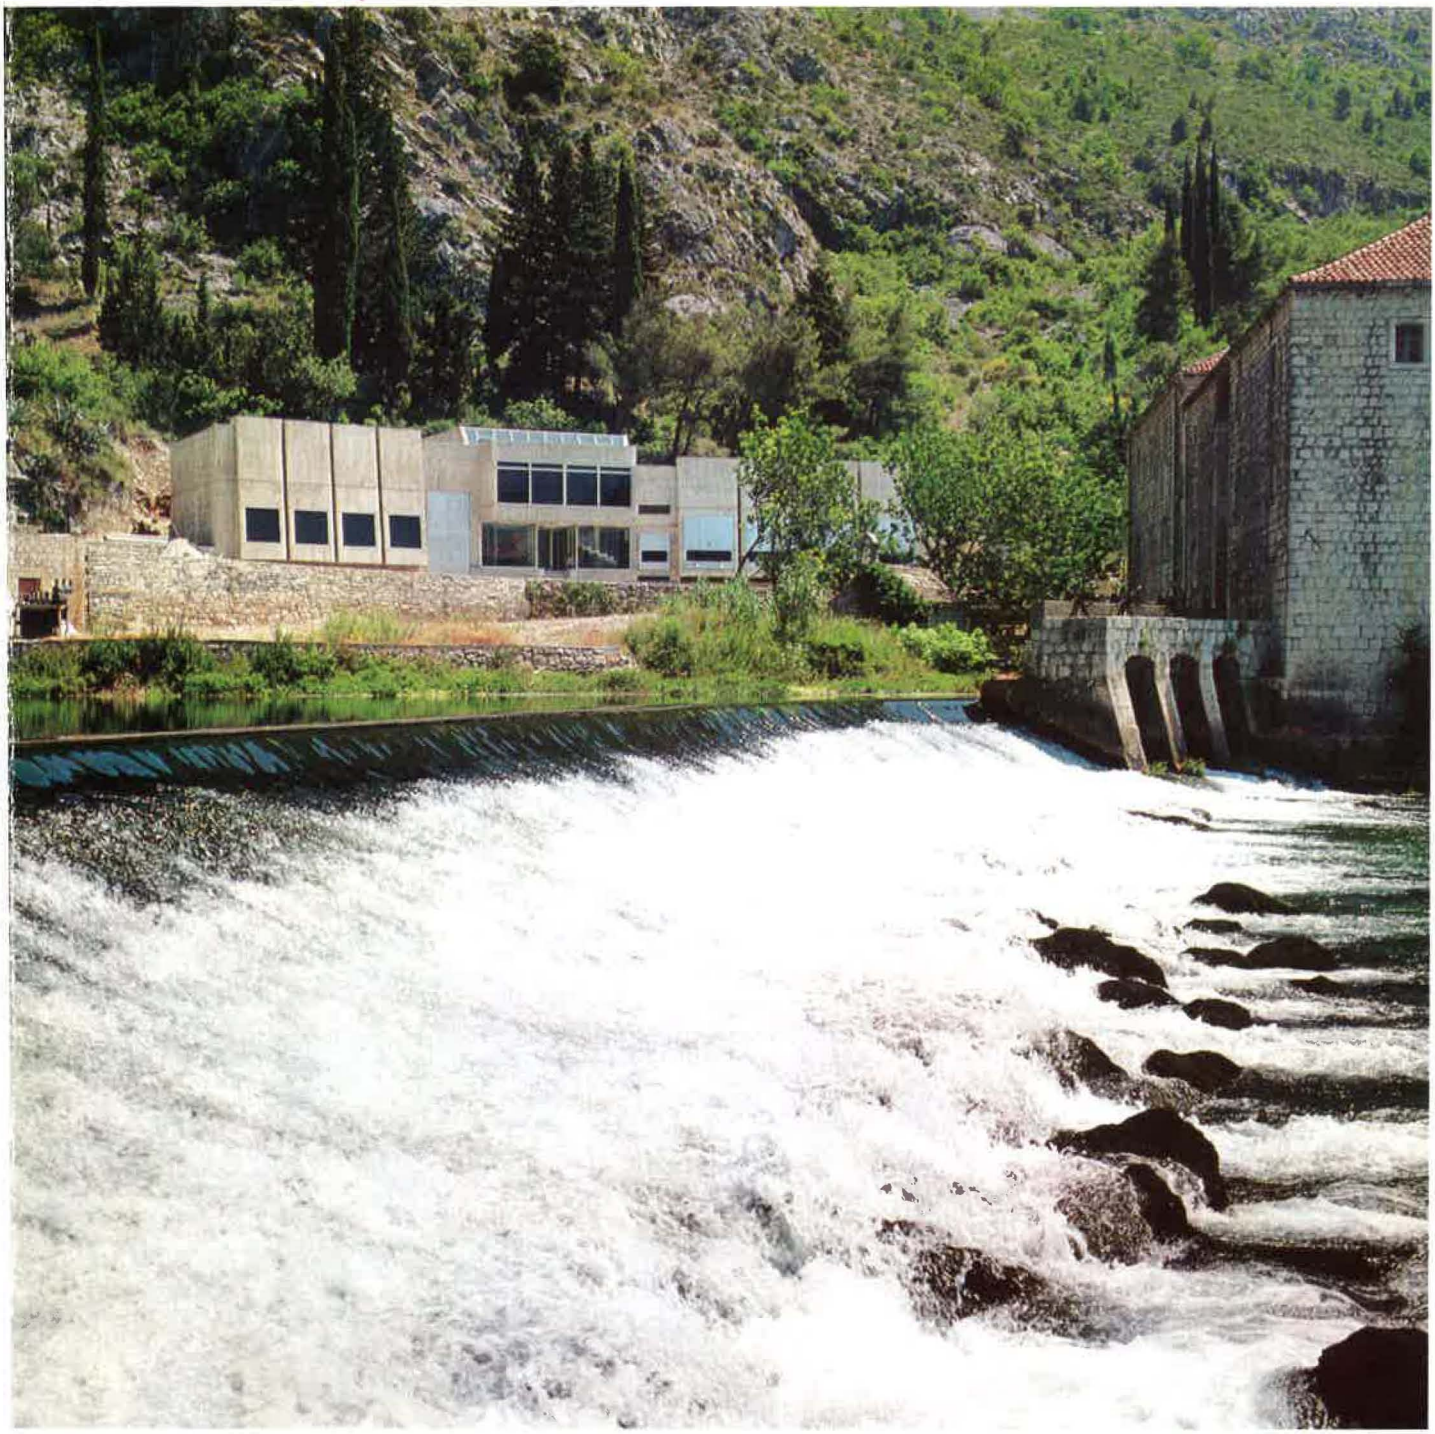

ɔK 621.31 ENJAAC 47 (2) 81–176 ISSN 0013-7448
ɴERGIJA • GODINA 47 • BROJ 2 • STRANA 81–176 • ZAGREB, TRAVANJ 1998.

UDK 621.31 ENJAAC 47 (2) — (1998) 81 - 176 ISSN 0013-7448

ČASOPIS
HRVATSKE ELEKTROPRIVREDE

energija

Godište 47 (1998) Zagreb Br. 2

IZDAVAČI – PUBLISHER

Hrvatska elektroprivreda

POMOĆ U IZDAVANJU

Ministarstvo znanosti, tehnologije i informatike

IZDAVAČKI SAVJET – THE PUBLISHING COUNCIL

Mr. sc. Branko *Grgić*, dipl. ing. (predsjednik), HEP Split – Adrijano *Fišer*, dipl. ing., HEP Rijeka – Marijan *Kalea*, dipl. ing., HEP Osijek – Damir *Karavidović*, dipl. ing., HEP Osijek – Mr. sc. Mladen *Mandić*, dipl. oec., HEP Zagreb – dr. sc. Vladimir *Mikuličić*, dipl. ing., FER Zagreb – dr. sc. Niko *Malbaša*, dipl. ing., Ekonerg, Zagreb

UREDNIČKI ODBOR - EDITORIAL BOARD

Glavni urednik - Editor-in-chief: dr. sc. Zorko *Cvetković*, dipl. inž.
Urednik - Editor: Zdenka *Jelić*, prof.

Urednici rubrika – Contributing Editors: »Energetski sistemi«, dr. sc. Goran *Granić*, dipl. ing. – »Hidroelektrane«, Vladimir *Prizl*, dipl. ing. – »Termoelektrane i toplane«, Ivan *Vučetić*, dipl. ing. – »Prijenos električne energije«, mr. sc. Zdenko *Tonković*, dipl. ing. – »Razvoj, distribucija i potrošnja električne energije«, Mladen *Ježić*, dipl. ing. i Dasenko *Baldasari*, dipl. ing. – »Ekonomsko poslovanje i tarifna politika«, dr. sc. Jure *Šimović*, dipl. ecc., mr. sc. Mladen *Mandić*, dipl. ecc. i Marijan *Magdić*, dipl. ecc. – »Ekologija«, dr. sc. Niko *Malbaša*, dipl. ing. – »Informatika«, Nikola *Lastrić*, dipl. ing. – Tehnički urednik – Technical Editor: Branko *Mališ* – Lektor – Lingvistic Adviser: Šimun *Čagalj*, prof. – Metrološka recenzija – Metrologic review: mr. sc. Mladen *Zeljko*, dipl. ing.

Redakcija završena 1998 – 03 – 01

SADRŽAJ

Budući razvoj hrvatske veleprijenosne mreže (Okrugli stol HK CIGRE) 83
Klečina F.: INIS - međunarodni nuklearni informacijski sustav (Pregledni članak) 101
Hladki N.: Pokretni uređaj za obradu opasnog organskog otpada - PUTO (Stručni članak) 107
Kovaček P. - Kufner D. - Filipan V.: Obnova hidrogeneratora u HE Varaždin (Stručni članak) 117
Koželj M.: Hipotetske nesimetrije u strujama dalekovoda 400, 220 i 110 kV u Sloveniji (Izvorni znanstveni članak) 123
Kuzle I. - Plavšić T. - Tešnjak S.: Primjena neuronskih mreža za sekundarnu regulaciju napona i jalove snage (Izvorni znanstveni članak) 133
Domac J. - Rukavina T.: Proračun troškova proizvodnje biomase na plantažama brzorastućeg drveća u Hrvatskoj primjenom programa BIOCOST (Prethodno priopćenje) 141
Čabrajac S. - Musulin B. - Kraić Z. - Jaman N.: Obnavljanje svojstava transformatorskog ulja (Stručni članak) 147
Vijesti iz elektroprivrede 153
Iz strane stručne literature 164

Fotografija na omotnoj stranici
PUMPNE STANICE NA OMBLI

Časopis je ubilježen u Ministarstvu kulture i prosvjete – Sektor informiranja pod brojem 161 od 12. 11. 1992, a prema mišljenju istog ministarstva oslobođen je plaćanja poreza na promet (rješenje 532-03-1/5-92 od 3. studenoga 1992).

Uredništvo i uprava:
Zagreb, Ulica grada Vukovara 37
Telefoni 6125-641 i 6125-111/641, telefax 6170-438
Godišnje izlazi 6 brojeva. Godišnja pretplata za pojedince iznosi 300,00 kn, a za poduzeća i ustanove 480,00 kn (za studente 70,00 kn). Cijena pojedinog broja u prodaji 50,00 kn.
Za inozemstvo $ 95 godišnje.
Žiro račun kod ZAP, Zagreb – Hrvatska elektroprivreda (za »Energiju«) broj 30101-604-495
Tisak – Print: ZRINSKI d.d., Čakovec
Naklada 1000 primjeraka

PRIMJENA NEURONSKIH MREŽA ZA SEKUNDARNU REGULACIJU NAPONA I JALOVE SNAGE

Mr. sc. Igor Kuzle - Tomislav Plavšić - prof. dr. sc. Sejid Tešnjak, Zagreb

UDK 621.3.072.8:621.316.728
IZVORNI ZNANSTVENI ČLANAK

Opisana je primjena umjetnih neuronskih mreža (UNM) za automatsku sekundarnu regulaciju napona i jalovih snaga. Sekundarni (U-Q) regulator, jedne regulacijske zone, je realiziran primjenjujući unaprijednu višeslojnu neuronsku strukturu (višeslojni perceptron). Regulator se sastoji od dvije povezane neuronske mreže (NN I i NN II), a svaka od njih sadrži dva skrivena sloja s po 5 neurona u prvom i 15 neurona u drugom skrivenom sloju. Za regulacijska sredstva korištene su regulacijske elektrane i kondenzatorske baterije, s težištem na maksimalnoj uporabi kondenzatorskih baterija. Rad regulatora je ispitan na primjeru modificirane IEEE test mreže s 14 čvorišta i dobiveni su zadovoljavajući rezultati, a regulator je održavao napon pilot-čvorišta unutar područja ± 1% od postavne vrijednosti.

Ključne riječi: napon, jalova snaga, sekundarna (U-Q) regulacija, pilot-čvorište, umjetne neuronske mreže, višeslojni perceptron, algoritam povratnog rasprostiranja.

1. UVOD

Temeljni zadatak regulacije napona i jalove snage (*U-Q* regulacija) u stacionarnom (normalnom) pogonu je održavanje napona unutar propisanih ograničenja u svim čvorištima EES-a. To se ostvaruje održavanjem ravnoteže između proizvodnje i potrošnje jalove snage u sustavu, uključujući i odgovarajuće gubitke.
Postoji veći broj različitih regulacijskih sredstava koja se koriste u (*U-Q*) regulaciji [1], a mogu se podijeliti u dvije osnovne skupine:

1. Sredstva za proizvodnju/potrošnju jalove snage (sinkroni generatori, kompenzatori i motori, kondenzatorske baterije, prigušnice, statički kompenzacijski sustavi).
2. Sredstva za preraspodjelu tokova jalove snage (regulacijski transformatori, kondenzatori i prigušnice s diskretnim upravljanjem).

U današnjim EES-ima problem (*U-Q*) regulacije je sve značajniji, prvenstveno zbog utjecaja na stabilnost napona čitavog sustava, kao i zbog utjecaja na gubitke jalovih snaga (i gubitke općenito) u sustavu. Pri tome se najčešće primjenjuje (*U-Q*) regulacija s više hijerarhijski odvojenih razina [1,2], kako bi se ostvarila što bolja koordinacija regulacijskih sredstava u sustavu. Osim toga, na taj se način pokušava povećati učinkovitost primarnih (*U-Q*) regulatora koji često, zbog svoje neosjetljivosti, ne reagiraju na male poremećaje u sustavu, što za posljedicu može imati značajne promjene napona u nekim čvorištima EES-a (pogotovo ako su ta čvorišta električki udaljenija od čvorišta s regulacijskim uređajima), pa čak i slom napona u sustavu. Primarna regulacija je lokalnog karaktera, a provodi se na razini jedinica. Djelovanje na promjenu postavnih vrijednosti primarnih regulatora naziva se sekundarna regulacija napona i jalovih snaga i provodi se na dijelu mreže. Koordinacija djelovanja svih sekundarnih regulatora s ciljem optimiranja raspodjele tokova jalovih snaga u cijelom sustavu predstavlja tercijarnu regulaciju napona i jalovih snaga. Tercijarna regulacija provodi se za jedan elektroenergetski sustav kao cjelinu. Iako se sekundarnom regulacijom postižu značajna poboljšanja, njezin glavni nedostatak je što se najčešće izvodi ručno, pa se pojavljuju relativno velika vremenska kašnjenja u izvođenju pojedinih regulacijskih naredbi. Osim toga, dolazi do dodatnog opterećivanja operatera jer je najčešće potrebno izvesti podešenja u više koraka, dok se ne ostvari odgovarajuća koordinacija regulacijskih sredstava.
Zbog poboljšanja učinkovitosti cijelog sustava regulacije uočena je potreba za koordiniranom i automatiziranom (U-Q) regulacijom na višim hijerarhijskim razinama. Težnja je razvoj decentralizirane strategije upravljanja temeljene na automatskoj sekundarnoj regulaciji napona i jalovih snaga u okviru pojedinih regija EES-a [2]. Iako je ovakva koncepcija (U-Q) regulacije već primijenjena u nekim EES-ima [3,4,5,6], još uvijek nije na zadovoljavajući način riješen problem opisa nelinearne prirode EES-a, tj. ulazno-izlazna ovisnost izvedenih sekundarnih regulatora je linearna. Takva aproksimacija zadovoljava u 80-90 % pogonskih slučajeva, ali u ostalom broju slučajeva regulator neće dati ispravan odziv što se može odraziti na naponsku stabilnost sustava. Rješenje tog problema je u uporabi nekih od metoda umjetne inteligencije, jer se njima omogućava zadovoljavajuće rješavanje nelinearnih problema.
U svijetu se umjetne neuronske mreže trenutno najviše primjenjuju [7], za prognoziranje potrošnje [8,9], procjenu pogonske sigurnosti EES-a [10,11,12,13], otkrivanje kvarova u prijenosnom sustavu [14], za nadzor i vođenje sustava [15,16]. Ovim radom se njihova primjena proširuje i na sekundarnu regulaciju napona i jalovih snaga.

2. OPĆENITO O UMJETNIM NEURONSKIM MREŽAMA

2.1. Svojstva i struktura

Umjetna neuronska mreža (UNM) je veliki paralelno ra-

spodijeljeni procesor s ugrađenim svojstvom pohranjivanja i naknadnog korištenja iskustvenog znanja. Znanje se u neuronskoj mreži pohranjuje u međuneuronskim vezama (sinaptičkim težinama), a "ugrađuje" se u mrežu u tzv. procesu učenja neuronske mreže. Učenje se temelji na iteracijskom procesu tijekom kojeg mreža nastoji podesiti svoje parametre kako bi što bolje nadomjestila (tj. opisala) zadanu ovisnost izlaznog signala o ulaznom signalu. Model neurona predočen je na slici 1. Izlazni signal k-tog neurona računa se prema:

$$y_k = \varphi(\sum_{j=1}^{p} w_{kj} \cdot x_j - \theta_k) \qquad (1)$$

gdje su:

x_j (j=1, ..., p) ulazni signali
w_{kj} (j=1, ..., p) sinaptičke težine neurona k
θ_k step funkcija neurona *k* tzv. bias
$\varphi(\cdot)$ aktivacijska ili prijenosna funkcija i
y_k izlazni signal neurona *k*.

Bias θ_k se može promatrati kao dodatna sinaptička težina sa stalnom ulaznom vrijednošću$\varphi(\cdot)$, odnosno kao pomak grafa prijenosne funkcije $\varphi(\cdot)$ u desno za vrijednost θ_k. Vrijednost bias-a može biti stalna tijekom proračuna ili se može mijenjati zajedno s vrijednostima ostalih sinaptičkih težina. Prijenosna funkcija $\varphi(\cdot)$ određuje izlaz neurona. Da bi se u strukturu neurona uvela nelinearnost, najčešće se koristi sigmoidna prijenosna funkcija (2):

$$\varphi(x) = \frac{1}{1+\exp(-a \cdot x)} \qquad (2)$$

Sigmoidna funkcija je strogo rastuća, diferencijabilna, neprekidna funkcija, koja ima asimptote, a parametar a određuje nagib prijenosne funkcije.

Pri korištenju umjetnih neuronskih mreža pokušava se matematičkim modelom što bolje kopirati biološka struktura živčanog sustava te tako razvijeni model primijeniti za rješavanje različitih problema koji se klasičnim postupcima ne mogu riješiti zadovoljavajućom brzinom i točnosti. Glavne značajke UNM su:

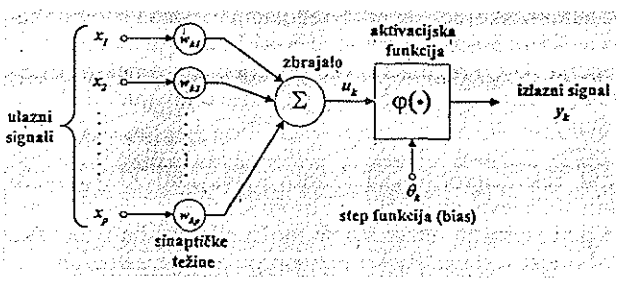

Slika 1. Model neurona

1. sposobnost zaključivanja o nepoznatoj ulazno-izlaznoj ovisnosti iz predočenih podataka
2. sposobnost poopćenja (eng. generalization), odnosno davanja prihvatljivog izlaznog signala za ulazne podatke koji nisu korišteni tijekom procesa učenja
3. nelinearnost
4. paralelna struktura, koja omogućuje veliku brzinu izvođenja proračuna.

Neuronska mreža sastoji se od neurona međusobno povezanih sinaptičkim vezama. Neuroni su poslagani u slojeve, gdje je broj neurona izlaznog sloja određen brojem izlaznih podataka mreže, dok broj unutarnjih slojeva (skriveni slojevi) i broj neurona svakog skrivenog sloja nije fiksan i određuje se po potrebi. Na slici 2 predočena je UNM razvijena korištenjem unaprijedne višeslojne strukture (višeslojni perceptron).

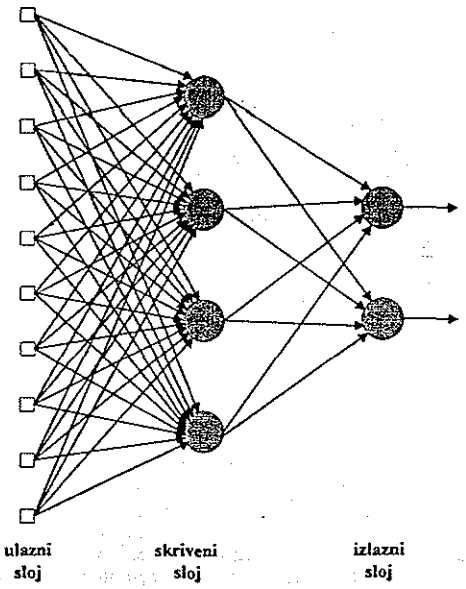

Slika 2. Model unaprijedne mreže (višeslojni perceptron)

2.2. Algoritam povratnog prostiranja

Najčešće korišteni algoritam za učenje UNM je algoritam povratnog prostiranja (eng. back propagation). Značajka mu je dvostruki prolaz kroz mrežu: *prolaz unaprijed* (eng. forward pass) i *povratni prolaz* (eng. backward pass). Učenje se izvodi na taj način da se mreža opskrbi parom ulaznih podataka i željenog (ili željenih) odziva. Na temelju ulaznih podataka mreža proračunava konačne odzive y_j *(j=1,...,c)*; gdje je c-broj neurona izlaznog sloja; koji se zatim uspoređuje sa željenim odzivima. Razlika svakog para proračunati odziv-željeni odziv daje signal greške e_j, a trenutni zbroj svih kvadratnih grešaka izlaznog sloja mreže u n-toj iznosi:

$$\xi(n) = \frac{1}{2}\sum_{j=1}^{c} e_j^2(n) \qquad (3)$$

Zbrajanjem $\xi(n)$ *(n=1,...,N)*; gdje je *N* - ukupan broj uzoraka u ispitnom skupu te normiranjem prema veličini *(N)* ispitnog skupa, računa se srednja kvadratna greška:

$$\xi_{SR} = \frac{1}{N}\sum_{n=1}^{N}\xi(n) \qquad (4)$$

Trenutni zbroj kvadratnih grešaka $\xi(n)$ i srednja kvadratna greška ξ_{SR} funkcije su svih parametara neuronske mreže (sinaptičkih težina i biasa). Derivacija trenutnog zbroja kvadratnih grešaka po pripadnim sinaptičkim težinama $\partial\xi(n)/\partial w_{ji}(n)$ ($w_{ji}(n)$ je sinaptička težina između izlaznog neurona j i skrivenog neurona i) prostire se povratnim putem kroz mrežu, unutar koje se određenom iteracijskom metodom namještaju parametri mreže s ciljem minimiziranja ξ_{SR}, [17]:

$$\begin{aligned} w_{kj}(n+1) &= w_{kj}(n) + \Delta w_{kj}(n) \\ \theta_k(n+1) &= \theta_k(n) + \Delta\theta_k(n) \end{aligned} \qquad (5)$$

Nakon prolaska signala greške kroz mrežu, mreža se opskrbljuje novim parom ulaz -željeni odziv, a čitav se postu-

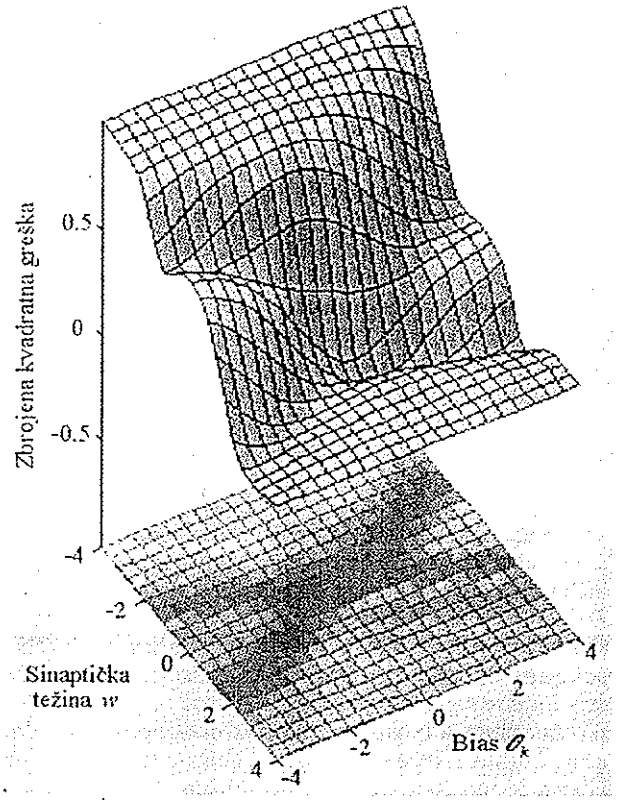

Slika 3. Trodimenzionalna površina greške višeslojne neuronske mreže

pak ponavlja. Nakon što je mreža opskrbljena svim parovima ulaz - željeni odziv koji su na raspolaganju (ispitni skup), ostvarena je jedna epoha unutar procesa učenja. Epohe se ponavljaju sve dok se ne postigne zadovoljavajuća točnost proračuna, nakon čega je unutarnja struktura neuronske mreže tako podešena da joj omogućuje rješavanje zadanog problema.

Algoritam povratnog prostiranja, čije se izvođenje temelji na obrascu učenja pod nadzorom, najnesigurniji je, i teorijski najmanje dorađen upravo na polju konvergencije. Ovaj algoritam ovisi o gradijentu površine greške u višedimenzionalnom prostoru čiji su parametri vrijednosti sinaptičkih težina i biasa neuronske mreže (slika 3). Algoritam je po prirodi stohastički i ima svojstvo vrlo spore konvergencije. Osim spore konvergencije, značajan je i problem koji se odnosi na postojanje lokalnih minimuma duž površine greške. Ako pogonska točka algoritma dođe u lokalni minimum površine greške, može se desiti da se proračun zaustavi iako postoji drugi skup vrijednosti sinaptičkih težina za koji je ξ_{SR} manja, tj. iako postoji globalni minimum funkcije. Postignuto je stanje neželjeno, pogotovo ako je lokalni minimum znatno iznad globalnog. Ovaj se problem nastoji izbjeći uvođenjem momentuma, tj. proračunom krivulje greške sa samo jednim minimumom ili nekim drugim izmjenama samog algoritma [17]. Iako se ne može sa sigurnošću tvrditi da će algoritam povratnog prostiranja konvergirati za svaki problem kod kojeg se primijeni, mogu se definirati kriteriji zaustavljanja algoritma.

Smatra se da je algoritam povratnog prostiranja konvergirao kada je Euklidova norma vektora gradijenta dostigla dovoljno malu vrijednost, tj. kada je apsolutna vrijednost promjene srednje kvadratne greške po epohi dovoljno mala (0.1-1% po epohi). Dakle, algoritam povratnog prostiranja bit će zaustavljen pri vrijednosti vektora sinaptičkih težina w_{kon} kada je $|g(w_{kon})| = \varepsilon$, gdje je ε dovoljno mala vrijednost gradijenta g, ili, $\xi_{SR}(w_{kon}) = \tau$ gdje je τ dovoljno mala vrijednost srednje kvadratne greške.

2.3. Levenberg-Marquardtova metoda

Klasičan algoritam povratnog prostiranja koristi optimizacijsku metodu najstrmijeg pada (eng. steepest descent) gradijenta višedimenzionalne površine greške za namještanje svojih parametara, s ciljem minimiziranja funkcije srednje kvadratne greške (SR. Korištenje Levenberg - Marquardtove optimizacijske metode [18,19] znatno poboljšava algoritam i ujedno rješava problem konvergencije algoritma. Levenberg - Marquardtova metoda predstavlja aproksimaciju Newton - Gaussove metode. S obzirom da je cilj pronaći rješenje x' za koje je kvadratna funkcija $F(x)$ minimizirana, u svakom se koraku dx u nekoj točki p procjenjuju Hessian-ova matrica H i gradijent g:

$$dx = x - p = -H^{-1} g \tag{6}$$

Hessian-ova matrica H predstavlja matricu drugih parcijalnih derivacija funkcije F:

$$H = \nabla^2 F \tag{7}$$

a g je gradijent funkcije F:

$$g = \nabla F \tag{8}$$

Levenberg - Marquardtovo pravilo namiještanja glasi:

$$dx = -(H+\mu I)^{-1} g = -(J^T J + \mu I)^{-1} J^T e \tag{9}$$

gdje je J Jacobi-eva matrica derivacija svake greške prema svakoj sinaptičkoj težini, e je vektor greške, I je jedinična matrica, a μ Levenberg - Marquardtov (LM) parametar. Ako je LM parametar velik ($\mu \to \infty$), izraz (9) će aproksimirati u metodu najstrmijeg pada, a ako je LM parametar mali ($\mu = 0$) izraz (9) će postati Gauss-Newtonova jednadžba. Pri tome će se vlastita vrijednost matrice H povećavati u ovisnosti o μ.

S obzirom da je Gauss-Newtonova metoda brža i puno točnija blizu minimuma greške, cilj Levenberg - Marquardtove metode je što brže prijeći u Gauss-Newtonovu metodu. Nakon svakog uspješnog koraka dx (smanjivanje greške), LM parametar se smanjuje, a nakon svakog neuspješnog koraka povećava.

3. IZVEDBA SEKUNDARNOG U-Q REGULATORA

Pri realizaciji sekundarnog U-Q regulatora poštivane su sljedeće postavke:

1. regulacijska sredstva kojima upravlja zonski regulator napona i jalove snage su regulacijske elektrane i kondenzatorske baterije
2. regulacija se u maksimalnoj mjeri koristi kondenzatorskim baterijama, uz ograničenje sklopnih djelovanja baterija na četiri puta dnevno, zbog vijeka trajanja baterija
3. udjeli regulacijskih elektrana u regulaciji (q_{ri}) su promjenjivi, a udjeli kondenzatorskih baterija (q_{rkb}) su fiksni i ovise o kapacitetu pojedine baterije.

Na ovim se postavkama temelji priprema podataka potrebnih za učenje neuronske mreže, da bi se ostvario željeni način sekundarne regulacije EES-a, tj. jedne regulacijske zone. Jednom istrenirana i provjerena neuronska mreža opisuje samo onaj sustav čiji su podaci korišteni u procesu učenja. Za bilo koji drugi sustav potrebno je, ponovo cjelovito analizirati moguća pogonska stanja tog sustava kao i poželjne načine regulacije, te zatim pripremiti podatke potrebne za učenje neuronske mreže. Priprema podataka za učenje mreže je ujedno i najveći problem pri korištenju neuronskih mreža. Osim prikupljanja podataka, potrebna je i njihova obrada te priprema kako bi ih UNM bila sposobna naučiti. Tek nakon toga slijedi izbor optimalne unutarnje strukture neuronske mreže.

Primijenjena shema automatske sekundarne regulacije napona i jalove snage za jednu regulacijsku zonu predočena je na slici 4 [2]. Na temelju mjerenja napona VP u karakterističnom čvorištu mreže (pilot čvorište) čiji napon reprezentira naponsko stanje čitave zone, i podataka o uključenosti kondenzatorskih baterija u zoni p, udjelu regulacijskih elektrana u sekundarnoj regulaciji q_r, kao i referentnoj vrijednosti napona pilot čvorišta V_{Pref} zonski regulator računa regulacijski signal za regulacijske elektrane N_G, odnosno za kondenzatorske baterije NC. Signal NG jedinstven je za sve regulacijske elektrane u zoni, a signal N_C za sve kondenzatorske baterije u zoni. Regulacijski signali šalju se do svakog regulacijskog sredstva u zoni gdje se u primarnom regulatoru jalove snage na osnovi podataka o referentnoj vrijednosti proizvodnje jalove snage, trenutnoj proizvodnji jalove snage Q_{TR} i umnoška regulacijskog signala s udjelom određenog regulacijskog sredstva u regulaciji q_r, formira signal (u koji se uz signal o postavnoj vrijednosti napona U_0, uvodi u primarni regulator napona regulacijskog sredstva, kojim se podešava napon s ciljem ostvarivanja željene proizvodnje jalove snage, a time i uklanjanja nastalog poremećaja u zoni.

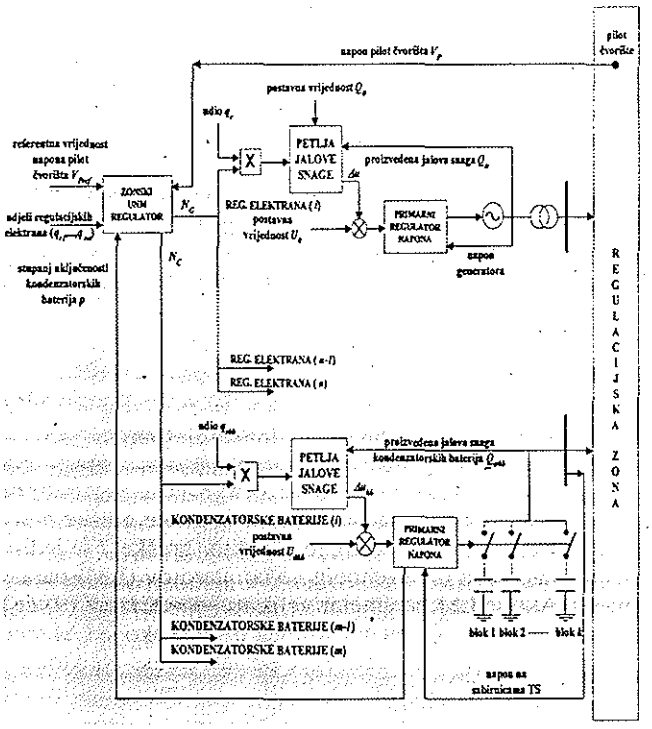

Slika 4. Shema sekundarne U-Q regulacije jedne zone

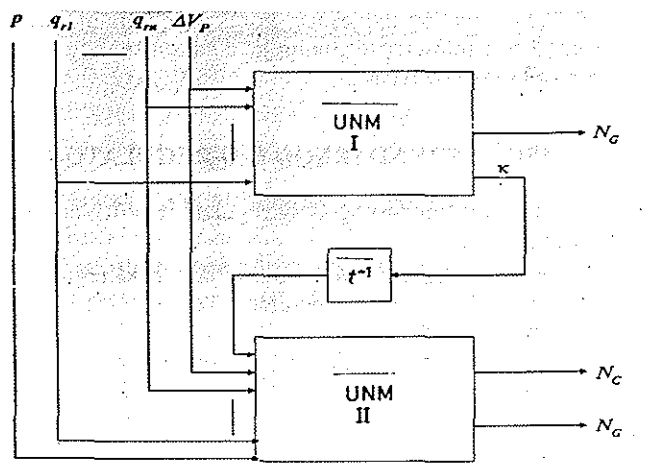

Slika 5. Struktura sekundarnog zonskog UNM regulatora

Zonski UNM regulator (slika 5) sadrži dvije višeslojne neuronske mreže (UMN I i UNM II) koje su međusobno odvojene sklopom za vremensko zatezanje. Njihova veza ostvaruje se signalom (koji prolazi kroz sklop za vremensko zatezanje, a funkcija mu je pokretanje proračuna druge neuronske mreže (UNM II). Ulazni signali su zajednički i istodobno dolaze do obje neuronske mreže, ali se proračun druge mreže pokreće nakon pojave signala (iz prve mreže, tj. nakon vremenskog kašnjenja. Jedan od ulaza u obje neuronske mreže predstavlja odstupanje napona pilot čvorišta od njegove referentne vrijednosti ΔV_P, a na ostale ulaze dovode se iz glavnog dispečerskog centra signali o trenutnom udjelu regulacijskih elektrana u sekundarnoj (U-Q) regulaciji ($q_{r1},...,q_{rn}$), gdje je n trenutni broj regulacijskih elektrana u zoni. Broj elektrana koje sudjeluju u sekundarnoj (*U-Q*) regulaciji može se mijenjati tijekom dana u ovisnosti o stanju i opterećenju u sustavu. Osim ovih podataka potrebno je na ulaz UNM II dovesti i podatak o trenutnoj uključenosti kondenzatorskih baterija p, kako bi, u slučaju da kondenzatorske baterije nemaju dovoljno snage za vraćanje napona unutar željenih granica, bilo omogućeno kombiniranje proizvodnje jalove snage regulacijskih elektrana i kondenzatorskih baterija. U primjeru je taj signal jedinstven za sve kondenzatorske baterije u zoni, ali je moguće i najvjerojatnije da sve kondenzatorske baterije nisu uključene u jednakom postotku, pa se u zonski regulator mogu dovoditi i signali o uključenosti svake kondenzatorske baterije posebno ($p_1,...,p_m$) gdje je *m* broj kondenzatorskih baterija u zoni.

Promjena opterećenja na nekim sabirnicama uzrokovat će promjenu vrijednosti napona pilot čvorišta što će za posljedicu imati djelovanje zonskog regulatora. U zonskom regulatoru prvo će se proračunati regulacijski signal N_G koji će se proslijediti do postojećih regulacijskih elektrana unutar zone kako bi se na taj način što brže popravila razina napona u mreži. Nakon toga se računa regulacijski signal N_C koji se prosljeđuje do kondenzatorskih baterija kako bi one preuzele na sebe potrebnu proizvodnju jalove snage (ako imaju mogućnost, tj. ako im kapacitet nije u potpunosti iskorišten). Nakon povratnog signala o uključenju kondenzatorskih baterija, regulacijskim elektranama će se poslati signal za smanjenje proizvodnje jalove

snage, za onu vrijednost snage proizvodnje jalove snage koju će preuzeti kondenzatorske baterije. Smanjena proizvodnja jalove snage elektrana uzrokovat će smanjenje gubitaka prijenosa snage u sustavu, jer su elektrane obično udaljenije od potrošačkih čvorišta od kondenzatorskih baterija koje se ugrađuju što je moguće bliže opterećenju. Osim smanjenja gubitaka, na taj se način osigurava dovoljno pričuve jalove snage potrebne za eliminaciju mogućih kasnijih poremećaja ili kvarova.
Realizacijom zonskog regulatora s dvije neuronske mreže omogućena je regulacija napona i jalove snage samo regulacijskim elektranama, samo kondenzatorskim baterijama ili kombinacijom proizvodnje regulacijskih elektrana i kondenzatorskih baterija.

4. ISPITIVANJE REGULATORA

Opisani princip regulacije ispitan je na primjeru modificirane IEEE test mreže sa 14 čvorišta (slika 6) [20]. Modifikacija IEEE test mreže sastojala se iz svođenja čitave mreže na jednu naponsku razinu (110kV), dodavanja transformatora 110/10 kV za vezu prema kondenzatorskim baterijama, i dodavanja treće kondenzatorske baterije (C3). Iz originalne sheme izostavljeni su regulacijski transformatori (jer nije predviđena njihova primjena u predloženoj shemi regulacije), a dodani su blok transformatori za sve tri elektrane. Broj čvorišta se, uslijed navedenih izmjena, povećao s 14 na 18. Pri regulaciji su korištene dvije regulacijske elektrane (čvorišta 15 i 16) i tri kondenzatorske baterije (čvorišta 7, 14 i 17).
Ispitivanje se sastojalo iz tri faze. Prvo je proračunom tokova snaga izvedena analiza stanja mreže čime su utvrđene vrijednosti napona svih čvorišta u mreži. Kao bilančno čvorište postavljeno je čvorište 0. Takovo stanje u mreži uzeto je kao referentno stanje, s obzirom na sve kasnije proračune, a proizvodnja jalove snage regulacijskih elektrana također je uzeta kao referentna. Za pilot čvorište određeno je, prema kriteriju najveće početne struje tropolnog kratkog spoja (IK3''), čvorište 8.

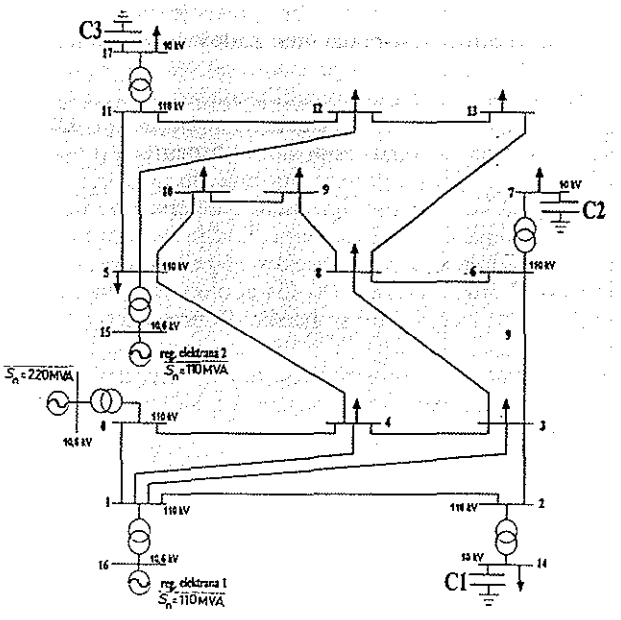

Slika 6. Shema modificirne IEEE test mreže

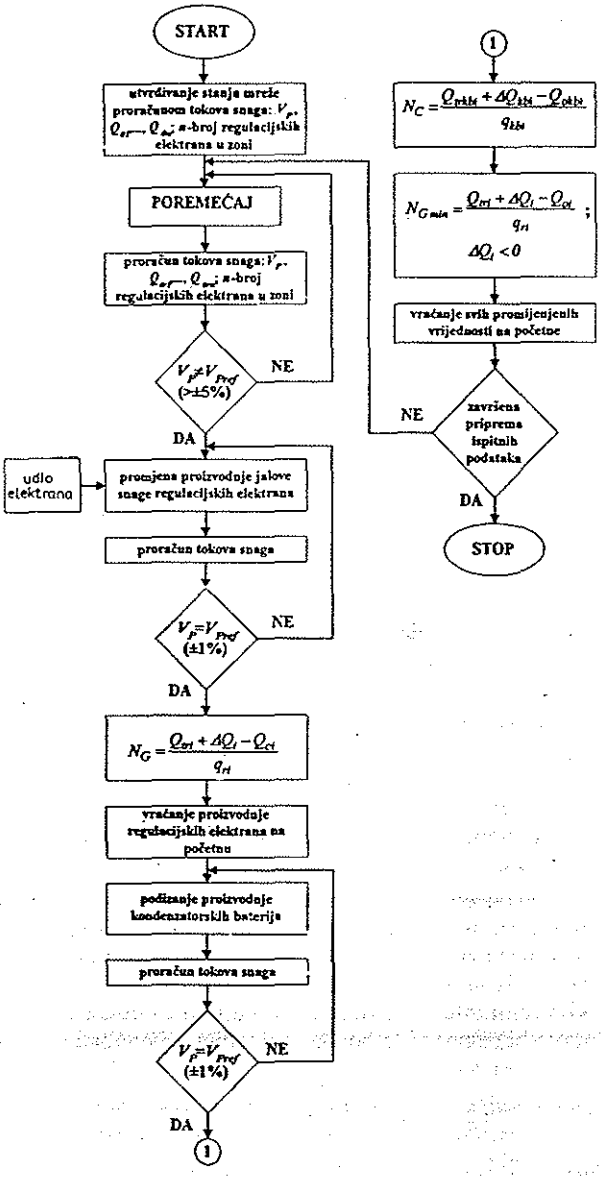

Slika 7. Dijagram toka pripreme ispitnih podataka potrebnih za učenje neuronske mreže

Druga faza sastojala se od prikupljanja parova ulazno-izlaznih podataka, korištenjem proračuna tokova snaga, potrebnih za učenje neuronske mreže. Pri tome je, s obzirom da se radi o sekundarnoj regulaciji, poštovano sljedeće:

- promjene opterećenja na P-Q sabirnicama zone su relativno malene i uzrokuju promjenu napona pilot čvorišta od 0 do -5%
- u trenutku promjene opterećenja napon pilot čvorišta je blizu referentne vrijednosti ((1%), tj. nije ispitivan rad regulatora u početnim uvjetima nekog već postojećeg poremećaja, jer je svrha regulatora da ukloni posljedice poremećaja što je prije moguće.

Prethodno navedene pretpostavke nisu nepromjenjive i mogu se mijenjati, što utječe na količinu ulaznih podataka i potrebnu pripremu za učenje. U sam algoritam je moguće ugraditi mnogo više slučajeva no što je opisano, npr. veće granice promjene opterećenja odnosno napona pilot čvorišta, uključivanje slučajeva promjene napona pilot čvo-

rišta uslijed ispada određenih vodova, korištenje koeficijenata osjetljivosti, itd.

Ova je faza izvođena postupno (slika 7), a jedan korak, odnosno proračun jednog para ulaz-izlaz, za obje mreže, sastojao se iz sljedećeg:

1. promijenjeno je opterećenje određenog čvora i zatim je izračunato novonastalo stanje u mreži
2. u skladu s promjenom napona pilot čvorišta izvedena je promjena proizvodnje jalove snage regulacijskih elektrana i zatim ponovo utvrđeno stanje mreže. Ova je točka ponavljana sve dok se napon pilot čvorišta nije približio svojoj referentnoj vrijednosti u granicama (0.1%.
3. na osnovi podataka o potrebnoj proizvodnji jalove snage regulacijskih elektrana i proizvoljno odabranih udjela elektrana u regulaciji, pristupilo se proračunu regulacijskog signala N_G prema izrazu [2]:

$$\Delta Q_i = Q_{0i} - Q_{tri} + N_G \cdot q_{ri} \qquad (10)$$

odnosno

$$N_G = \frac{Q_{tri} + \Delta Q_i - Q_{0i}}{q_{ri}} \qquad (11)$$

gdje je:

ΔQ_i - potrebno povećanje proizvodnje jalove snage i-te elektrane

Q_{0i} - referentna vrijednost proizvodnje jalove snage i-te elektrane

Q_{tri} - proizvodnja jalove snage i-te elektrane prije djelovanja regulacije

q_{ri} - udjele i-te elektrane u regulaciji.

Nakon početnog izračunavanja regulacijskog signala, koji nije bio jednak za obje elektrane s obzirom na različite udjele i vrijednosti referentne, trenutne i potrebne proizvodnje jalove snage svake od elektrana, pristupilo se kombiniranju proizvodnje jalove snage obiju elektrana kako bi se pronašla ona kombinacija vrijednosti u brojniku izraza (11) koja će uz postavljene udjele elektrana dati jedinstveni regulacijski signal za obje elektrane, pazeći pri tome da napon pilot čvorišta ostane u željenim granicama.

Time je dobiven jedan ulazno-izlazni par podataka potrebnih za učenje prve neuronske mreže (UNM I)

4. proizvodnja jalove snage elektrana zatim se vraćala na početnu vrijednost (prije djelovanja regulacije), a pristupilo se podizanju proizvodnje kondenzatorskih baterija sve dok napon pilot čvorišta nije ponovo došao unutar željenih granica. Prema (11) proračunat je jedinstveni regulacijski signal za sve tri kondenzatorske baterije N_C, s tim da je pretpostavljeno da su udjeli svih kondenzatorskih baterija jednaki (q_{kbi}=0.33) te da su njihove postavne i trenutne vrijednosti snage proizvodnje (Q_{0kbi}, Q_{trkbi}) jednake nuli.

Ponovo je prema (11) izračunat signal NG, s ciljem da se iznos proizvodnje jalove snage elektrana, koji je povećan djelovanjem regulacije u prethodnom koraku, umanji za iznos kondenzatorskim baterijama proizvedene jalove snage. Na taj se način osigurava određena pričuva jalove snage u sustavu. Iznos potrebne proizvodnje jalove snage elektrana nije se posebno računao već se koristila vrijednost iz prethodnog proračuna tokova snaga (proračun s povećanom proizvodnjom kondenzatorskih baterija).

Na taj se način dobio jedan ulazno-izlazni par podataka potreban za učenje druge neuronske mreže (UNM II): .

5. sve vrijednosti mijenjane tijekom prethodno opisanog proračuna (opterećenje sabirnica, proizvodnja jalove snage regulacijskih elektrana i kondenzatorskih baterija) vraćene su na početne. Povratak na točku 1.

Podaci su prikupljani za tri moguća odnosa regulacijskih elektrana s obzirom na udio u regulaciji: (0.6, 0.4), (0.5, 0.5) i (0.4, 0.6), a za svaki je odnos proračunato 15 parova ulazno-izlaznih podataka. Svaki od 15 parova obuhvaća promjenu napona pilot čvorišta u rasponu od 0 do -5%, a vrijednosti unutar tog raspona koje nisu bile uključene u učenje UNM, korištene su pri ispitivanju ispravnosti djelovanja sekundarnog regulatora.

Treća faza uključivala je odabir optimalne unutrašnje strukture za svaku od neuronskih mreža (UNM I i UNM II) i učenje mreža podacima pripremljenim u drugoj fazi.

Veličina neuronske mreže, odnosno složenost njene strukture, ima velik utjecaj na konačnu sposobnost poopćavanja mreže, tj. sposobnost rješavanja zadanog problema. Pri korištenju algoritma povratnog prostiranja broj skrivenih slojeva i broj skrivenih neurona ima posebno velik utjecaj na konačne sposobnosti mreže. Neuronske mreže s prevelikim brojem skrivenih neurona u odnosu na veličinu ispitnog skupa nastoje memorirati podatke za učenje što vodi ka lošem poopćavanju, iako će mreža relativno brzo minimizirati srednju kvadratnu grešku proračuna. Male UNM nastoje podesiti svoje težine kako bi što bolje oponašale nepoznatu funkciju ulaz-izlaz, ali ako su premale u odnosu na veličinu ispitnog skupa ne mogu naučiti zadani problem, odnosno nisu sposobne minimizirati srednju kvadratnu grešku. Zadatak se, stoga, svodi na odabir mreže koja će biti dovoljno velika da nauči zadani problem, a dovoljno mala da dobro poopćava.

5. REZULTATI

Odabir optimalne neuronske strukture započet je s najjednostavnijom mrežom, a broj skrivenih neurona je zatim postupno povećavan uz istodobno praćenje sposobnosti poopćavanja mreže test-podacima. Zadovoljavajući rezultati za obje mreže (greška je manja od 4% od vrijednosti regulacijskih signala dobivenih proračunom tokova snaga) dobiveni su uporabom troslojne strukture (sl. 8), s 15 neurona u prvom skrivenom sloju i 5 neurona u drugom skrivenom sloju. Za prijenosnu funkciju neurona skrivenih slojeva korištena je sigmoidna funkcija, a za neurone izlaznog sloja linearna funkcija. Kod prve mreže postignuta je srednja kvadratna greška od 1% (50 do 500 epoha), a kod druge mreže 0.1% (54 epohe). Rezultati ostvareni s UNM I predočeni su na slici 9 (prosječno odstupanje prikazanih krivulja je 3.7%), a rezultati ostvareni s UNM II na slici 10 (prosječno odstupanje krivulja je 1.7%). Navedena odstupanja nisu konačna, i dužim učenjem mreže ili poboljšavanjem skupa ispitnih podataka (proširenje skupa ili korištenje reprezentativnijih podataka) mogu se dovesti unutar granica od ±1%.

6. ZAKLJUČAK

Razrađena je metodologija za automatsku sekundarnu regulaciju napona i jalove snage korištenjem neuronskih

mreža. Razvijen je sekundarni zonski regulator uporabom dvaju neuronskih mreža čime se ostvarila mogućnost U-Q

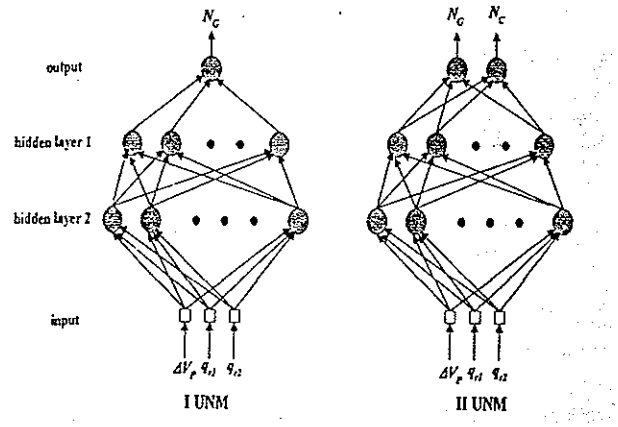

Slika 8. Prikaz ostvarene UNM strukture prve i druge neuronske mreže

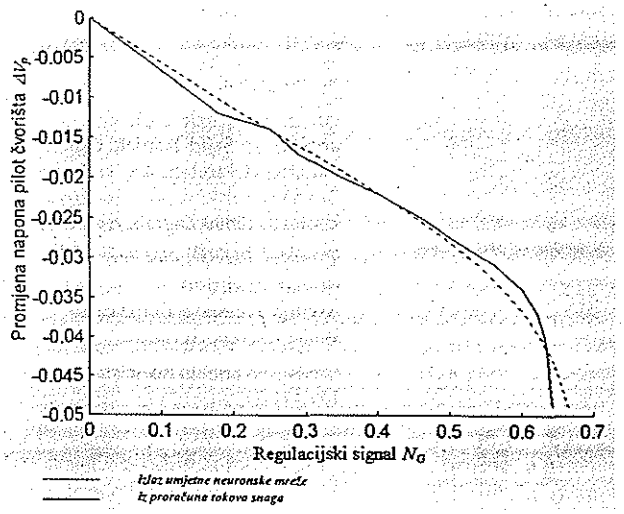

Slika 9. Ovisnost regulacijskog signala N_G o promjeni napona pilot čvorišta ΔV_p

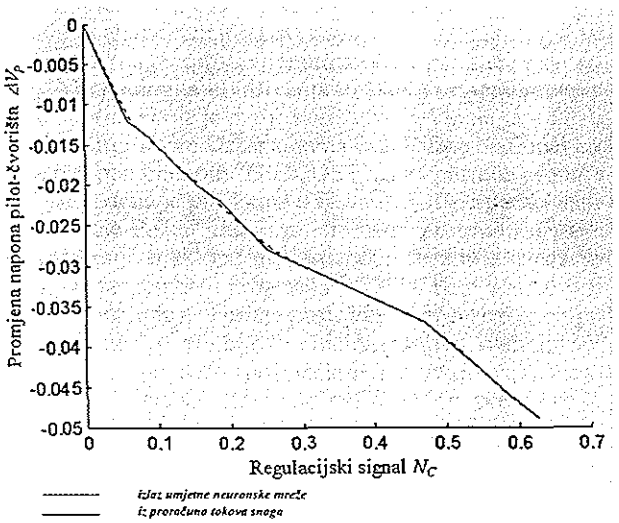

Slika 10. Ovisnost regulacijskog signala N_c o promjeni napona pilot čvorišta ΔV_p

regulacije korištenjem regulacijskih elektrana i/ili kondenzatorskih baterija. Regulator je ispitan na primjeru modificirane IEEE test mreže s 14 čvorišta, koja je predstavljala jednu regulacijsku zonu. Dobiveni su zadovoljavajući rezultati, a regulacijski signali N_G i N_C odstupali su od vrijednosti regulacijskih signala dobivenih proračunom tokova snaga, N_{G0} i N_{C0}, unutar ±4%. Ova odstupanja nemaju značajnijeg utjecaja na ispravnost rada regulatora jer i regulacijski signali N_G, N_C i N_{G0}, N_{C0} vraćaju napon pilot čvorišta unutar postavljenih ograničenja od ±1%.

Nedostatak opisane metodologije je nemogućnost primjene razvijenog sekundarnog regulatora na neki drugi EES ili dio sustava, jer jednom provjerena i istrenirana neuronska mreža svojstvena je samo za onaj elektroenergetski sustav čiji su podaci korišteni u procesu učenja.

Za bilo koji drugi EES potrebno je cijeli opisani postupak izvesti od početka. Pri tome će novi regulator najčešće imati drugačiju neuronsku strukturu, od ovdje razvijenog, jer odabir optimalne UNM strukture ovisi o opsegu podataka koji se koriste za učenje, tj. o veličini i složenosti EES-a za koji se razvija regulator.

Pri procjeni mogućnosti primjene neuronskih mreža za rješavanje nekog problema treba biti svjestan prednosti, ali i nedostataka UNM u odnosu na ostale metode, a posebno je značajno ocijeniti prikladnost primjene neuronskih mreža za rješavanje razmatranog problema.

Cilj daljnjeg razvoja je povećanje univerzalnosti izložene metodologije što će se ostvariti automatiziranjem postupka pronalaženja ulazno-izlaznih podataka potrebnih za učenje neuronske mreže. Time bi se olakšala praktična primjena.

LITERATURA

[1] S. TEŠNJAK: "(U-Q) regulacija u EES-u", FER-ZVNE, Zavodska skripta, 1991.

[2] S. TEŠNJAK, I. KUZLE, N. PULJIĆ: "Prijedlog rješenja automatske sekundarne regulacije napona i jalove snage u EES-u Hrvatske", Drugo savjetovanje Hrvatskog komiteta CIGRE, Primošten 14.-18. svibnja 1995., Ref. 39.07

[3] J.P. PAUL, J.Y. LEOST, J.M. TESSERON: "Survey of the Secondary Voltage Control in France: Present Realization and Investigations", IEEE Transactions on Power Systems, Vol. 2, No. 2, May 1987, pp. 505-511

[4] G. BLANCHON, N. GIRARD, Y. LOGEAY, F. MESLIER: "New Developments in Planning of Reactive Power Compensation Devices, IEEE Transactions on Power Systems. Vol. 2, No. 3, August 1987, pp. 764-771

[5] J.P. PIRET, J.P. ANTONIE, M. STUBBE, N. JANSSENS, J.M. DELINCE: "The Study of a Centralised Voltage Control Method Applicable to the Belgian System", CIGR..., Paris, Session-1992, Ref. 39-201

[6] V. ARCIDIACONO, S. CORSI, R. CHINNICI, U. BAZZI, M. MOCENIGO, G. MORESCHINI: "The Regional Voltage Regulator for ENEL's Dispachers", CIGR..., Paris, Session-1996, Ref. 39-304

[7] V.S.S. VANKAYALA, N.D. RAO: "Artificial Neural Networks and Their Applications to Power Systems - A Bibliographical Survey", Electric Power Systems Research, Vol. 28, 1993, pp. 67-79

[8] D. SRINIVASAN, A.C. LIEW, C.S. CHANG: "A Neural Network Short-Term Load Forecaster", Electric Power Systems Research, Vol. 28, 1994, pp. 227-234

[9] A.A. GIRGIS, S. VARADAN: "Unit Commitment Using Lo-

ad Forecasting Based on Artificial Neural Networks", Electric Power System Research, Vol. 32 , 1995, pp. 213-217

[10] D. NIEBUR, A.J. GERMOND: "Power System Static Security Assassment Using the Kohonen Neural Network Classifier", IEEE Transactions on Power Systems, Vol. 7, No. 2, 1992, pp. 865-872

[11] Y. ZHANG, O.P. MALIK, G.S. HOPE, G.P. CHEN: "Application of an Inverse Input/Output Mapped ANN as a Power System Stabilizer", IEEE Transactions on Energy Conversion, Vol. 9, No. 3, 1994, pp. 433-439

[12] H. MORI, Y. TAMARU, S. TSUZUKI: "An Artificial Neural-Net Based Technique for Power System Dynamic Stability with Kohonen Network IEEE Transactions on Power Systems, Vol. 7, No. 2, 1992, pp. 856-864

[13] D. SALATINO, R. SBRIZZAI, M. TROVATO, M. LaSCALA: "Online Voltage Stability Assessment of Load Centers by Using Neural Networks", Electric Power System Research, Vol. 32, 1995, pp. 165-173

[14] M. KEZUNOVIĆ, I. RIKALO, D.J. ŠOBAJIĆ: "High-Speed Fault Detection and Classification with Neural Networks", Electric Power System Research, Vol. 34, 1995, pp. 109-116

[15] C.T. SU, C.T. LIN: "Application of a Neural Network and Heuristic Model for Voltage-Reactive Power Control", Electric Power System Research, Vol. 34, 1995, pp. 143-148

[16] S. MILANIČ, I. ŠKRJANC, R. KARBA: "Survey of Some Neural Network Applications in Control Problems", Elektrotehniški Vestnik, Vol. 62, No. 3-4, 1995, pp. 171-181,

[17] S. HAYKIN: "Neural Networks-A Comprehensive Foundation", IEEE PRESS, 1994.

[18] W.H. PRESS, B.P. FLANNERY, S.A. TEUKOLSKY, W.T. VETTERLING: "Numerical Recipes - The Art of Scientific Computing", Cambridge University Press, 1989.

[19] T.R. CUTHBERT: "Optimization Using Personal Computers - with Applications to Electrical Networks", John Wiley & Sons, 1987.

[20] "IEEE 14-bus Test System", IEE Proceedings - Generation, Transmission and Distribution, Vol. 143, No. 5, 1996, str. 390

NEURAL NETWORK APPLICATION FOR THE SECONDARY CONTROL OF VOLTAGE AND REACTIVE POWER

The application of Artificial Neural Network (ANN) for the automatic secondary control of voltage and reactive power is described. Secondary var control of a single control zone is realized by the use of multi-layer neural structure (multi-layer perceptron). The regulator is composed of two connected neural networks (NN I and NN II), each of them with two hidden layers of 5 neurals in the first and 15 in the second layer. As control devices, control power plants and capacity batteries have been used, most frequently the capacity batteries. Regulator operation has been tested using modificated IEEE test network having 14 nodes and the results obtained are satisfactory. The regulator kept the voltage of the pilot node within ± 1% of the referent value.

DIE ANWENDUNG VON NEURONEN - NETZEN AN DIE SEKUNDÄRREGELUNG DER SPANNUNG UND DER BLINDLEISTUNG

Beschrieben ist die Anwendung der Methode künstlicher Neuronennetze (UNM1) an die automatische Sekundärregelung von Spannung und Blindleistung. Der sekundäre (U-Q1) Regler einer Regulationszone ist mittels einer mehrschichtigen Neuronenstruktur zustandegebracht worden (mehrschichtiges Perceptron). Der Regler besteht aus zwei untereinander verbundenen Neuronennetzen (NN I und NN II1), wovon jedes in zwei Schichten je 5 Neuronen in der ersten und 15 Neuronen in der zweiten Schicht verborgen beinhaltet. Als Regelungsmittel sind Regulationskraftwerke und Kondensatoren-Batterien genutzt worden, wobei der Schwerpunkt an der überwiegenden Nutzung von Kondensatoren-Batterien lag. Die Wirkung von Reglern ist am Beispiel eines angepassten IEEE2) Versuchs-Netzes mit 14 Knotenpunkten geprüft worden, wobei der Regler die Spannung des Leitknotenpunktes innerhalb der Abweichungen von ±1 % des Stellwertes festhielt; also mit zufriedenstellenden Ergebnissen.

1) Abkürzungen in kroatisch 2) Institute of Electrical and Electronical Engineers.

Naslov pisaca:

mr. sc. Igor Kuzle, dipl. ing.
prof. dr. sc. Sejid Tešnjak, dipl. ing.
Fakultet elektrotehnike i računarstva
Zavod za visoki napon i energetiku
Unska 3, 10000 Zagreb, Hrvatska

Tomislav Plavšić, dipl. ing.
Brodarski institut
Avenija Većeslava Holjevca 20
10000 Zagreb, Hrvatska

Uredništvo primilo rukopis:
1997-11-21