**Prikazivanje radova za savetovanja i simpozijume**
**format 21x29,7cm/A4 prema SRPS ISO 353 (za štampu)**

# PROGNOZA NET POZICIJA PRIMENOM NEURALNIH MREŽA

**DUŠAN PREŠIĆ*,**
**ANDREJ TASIĆ**

**CENTAR ZA KOORDINACIJU SIGURNOSTI SCC D.O.O. BEOGRAD**

**BEOGRAD**

**REPUBLIKA SRBIJA**

***Kratak sadržaj — Proces usklađivanja spojenog mrežnog modela (Common Grid Model Alignment – CGMA) je skup procedura kojima se inicijalne procene net pozicija zona trgovanja obrađuju tako da se kao rezultat dobije skup izbalansiranih net pozicija na pan-evropskom nivou. Proces se radi za one vremenske horizonte za koje ne postoje tržišne vrednosti net pozicija – od dva dana unapred do godinu dana unapred. Pored zadatka da kontrolišu CGMA proces, agenti za usklađivanje (Alignment Agents) mogu biti nominovani od strane TSO-a i za prognoziranje net pozicija. Za očekivati je da inicijalne procene net pozicija budu tačnije ukoliko se prognoza vrši na regionalnom nivou.***

***U radu su opisane teorijske osnove načina funkcionisanja neuralnih mreža, kao i način njihove primene na problem prognoze net pozicija. Takođe, na osnovu prikupljenog seta ulaznih podataka izvršeni su proračuni za testni period od godinu dana, gde su prognozirane satne vrednosti net pozicija za zone trgovanja Srbije, Bosne i Hercegovine, Crne Gore i Bugarske. Prognoze su rađene za vremenski horizont od dva dana unapred. Na kraju, prikazano je nekoliko indikatora koji govore o kvalitetu prognoze na godišnjem nivou.***

***Ključne reči — Net pozicija, Prognoza, Neuralna mreža, Regionalni koordinator sigurnosti, CGMA proces.***

## 1 UVOD

Net pozicija je definisana kao suma uvoza i izvoza električne energije zone trgovanja (*bidding zone*) za sve vremenske periode definisane u sferi tržišta električne energije [1]. Ako je algebarska suma net pozicija svih zona trgovanja date oblasti jednaka nuli, onda se smatra da su net pozicije izbalansirane, a individualni mrežni modeli međusobno usklađeni. Uloga CGMA procesa je balansiranje preliminarno određenih net pozicija na pan-evropskom nivou za vremenske horizonte za koje ne postoje tržišni podaci (od dva dana unapred pa sve do godinu dana unapred).

* Vojvode Stepe 412, 11000 Beograd, dusan.presic@scc-rsci.com

Pravnu osnovu za sprovođenje CGMA procesa predstavljaju evropske regulative 2015/1222 [1], 2016/1719 [2] i 2017/1485 [3]. U skladu sa CGMA metodologijom [4], TSO-i su u obavezi da svakodnevno pripremaju i dostavljaju (u satnoj rezoluciji) ulazne pretprocesne podatke za CGMA algoritam (Pre-Processing Data – PPD), koji se sastoje od određenog seta podataka gde najbitniju ulogu igraju preliminarne net pozicije (Preliminary Net Position – PNP).

TSO-i individualno određuju PNP-e koristeći sopstvene metodologije, na osnovu najboljih prognoza proizvodnje i potrošnje električne energije (kao i tokova na DC vodovima). Pored individualnih pristupa za prognozu PNP-a, TSO-i ovaj posao mogu dodeliti svojim agentima za usklađivanje, odnosno regionalnim koordinatorima sigurnosti (Regional Security Coordinator – RSC) koji u njihovo ime vrše datu funkciju. U tom slučaju, u cilju koordiniranog određivanja net pozicija, od RSC-a se očekuje da razviju regionalni pristup za prognozu PNP-a, dok se od TSO-a očekuje da obezbede potrebne ulazne podatke za datu prognozu.

Vremenska serija predstavlja niz vrednosti određene veličine, izmerene u jednakim vremenskim intervalima, pri čemu su date vrednosti uređene hronološki [5]. Modeli vremenskih serija ispituju uticaj istorijskih vrednosti jedne pojave na njenu buduću vrednost [5]. Neuralne mreže predstavljaju novu generaciju sistema za informaciono procesiranje, koje se između ostalog mogu koristiti za prognozu vremenskih serija (u ovom slučaju net pozicija zona trgovanja).

U radu su najpre ukratko prikazane teorijske osnove neuralnih mreža, sa posebnim akcentom na arhitekturu neuralnih mreža bez povratne sprege. Naredno poglavlje opisuje korišćeni algoritam za prognozu net pozicija, gde glavnu ulogu u procesu predikcije igra upravo dizajnirana neuralna mreža. Na kraju su prikazani rezultati prognoze net pozicija, korišćenjem prethodno opisanog postupka, za zone trgovanja Srbije, Bosne i Hercegovine, Crne Gore i Bugarske.

## 2 TEORIJSKE OSNOVE NEURALNIH MREŽA

Neuralna mreža predstavlja matematički model čija slojevita struktura podseća na umreženu strukturu neurona u mozgu. Osnovni gradivni element neuralne mreže je neuron. Struktura neurona je takva da on može primati ulaz i izlaz na osnovu kojih će menjati svoje interno stanje (proces treniranja), a onda na osnovu nove vrednosti ulaza i uspostavljenog internog stanja kreirati odgovarajući izlaz. [6]

U okviru neuralne mreže neuroni su struktuirani u slojeve, pri čemu se izdvajaju ulazni, izlazni i skriveni sloj, kao što je prikazano na Slici 1. Neuroni između susednih slojeva su povezani težinskim faktorima. Da bi neuralna mreža bila funkcionalna, neophodno je prvo izvršiti njeno treniranje. U radu se proces treniranja neuralne mreže vrši pomoću metode *Levenberg-Marquardt backpropagation*, gde se na osnovu ulaznih podataka i odgovarajućih izlaza definišu težinski faktori [7]. U nizu iteracija dolazi do korekcije težinskih faktora u cilju smanjenja greške koju neuralna mreža pravi.

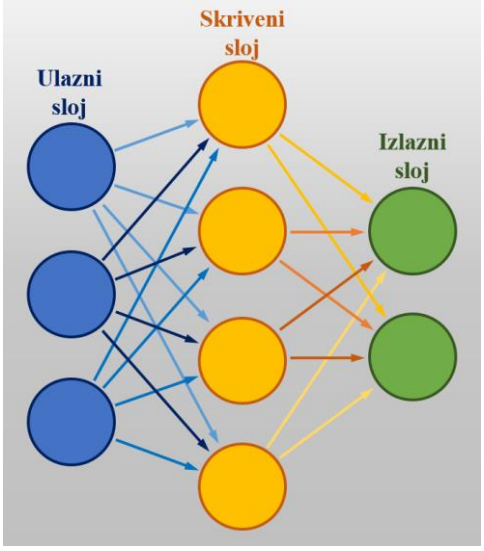


**Slika 1. Uprošćeni prikaz neuralne mreže**

Neuralne mreže se mogu podeliti na osnovu različitih kriterijuma, ali jedna od osnovnih podela proizilazi iz razlika u arhitekturi i veza između neurona, gde se neuralne mreže dele na [6]:

- neuralne mreže bez povratne sprege (*feed-forward* ili autoregresivne) – izlaz zavisi samo od ulaza;
- neuralne mreže sa povratnom spregom (*feed-back* ili rekurentne) – izlaz zavisi od ulaza i/ili od prethodnih vrednosti izlaza.

Pored toga, neuralne mreže se često dele i na jednoslojne i višeslojne, u zavisnosti od toga koliko skrivenih slojeva imaju [6]. U ovom radu će se za potrebe prognoze net pozicija koristiti višeslojna plitka neuralna mreža bez povratne sprege, čiji je blok dijagram predstavljen na Slici 2.

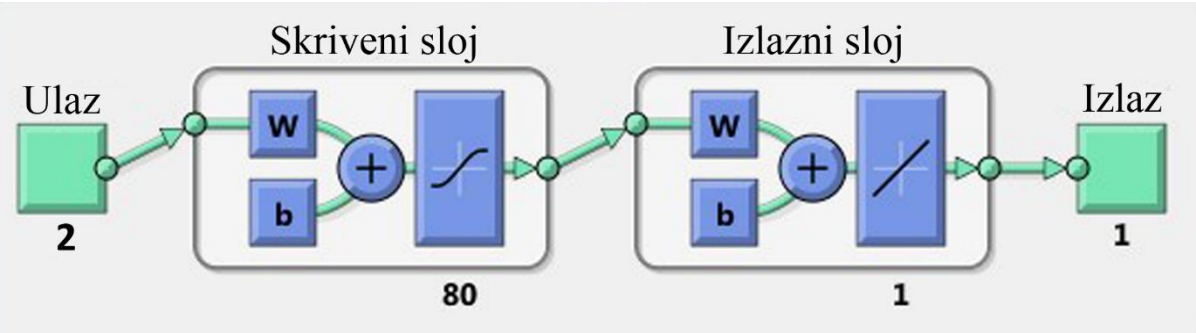


**Slika 2. Blok dijagram višeslojne plitke neuralne mreže**

Neuralna mreža sa Slike 2. sastoji se od jednog skrivenog i jednog izlaznog sloja, gde je sa *W* (*weight*) predstavljena matrica težinskih faktora datih slojeva, a sa *b* (*bias*) matrica-kolona slobodnih članova [6]. Transfer funkcija skrivenog sloja je sigmoid funkcija (*hyperbolic tangent sigmoid transfer function)*, dok je transfer funkcija izlaznog sloja linearna. Arhitektura mreže je takva da se na ulaz dovode 2 seta podataka, skriveni sloj ima 80 neurona, a izlazni sloj samo jedan neuron.

## 3 ALGORITAM ZA PROGNOZU NET POZICIJA

Pošto je teško naći značajniju međusobnu korelaciju između net pozicija susednih zona trgovanja u regionu Jugoistočne Evrope [8], algoritam za prognozu net pozicija je razvijan tako da se sprovodi individualno za svaku zonu trgovanja. Iako ovaj individualni pristup suštinski ne predstavlja „koordinirani proces određivanja net pozicija od strane RSC-a“ (kao što se CGMA metodologijom specificira), rezultati ovog rada potvrđuju da se on ipak može koristiti za prognozu net pozicija zona trgovanja datog regiona, bez obzira na njihove specifičnosti (veličina proizvodnje, potrošnje, uvoza, izvoza i dr.), pa se u tom opštem smislu može smatrati kao „regionalni pristup“.

Ulazni podaci za predviđanje net pozicija su istorijske satne vrednosti realizovanih net pozicija i prosečnih temperatura vazduha datih zona trgovanja. Bilo je pokušaja da se za prognozu net pozicija koriste i drugi meteorološki parametri (brzina vetra, oblačnost i dr.), kao i srednja satna potrošnja i proizvodnja zone trgovanja, ali korišćenje tih ulaznih podataka je samo povećalo grešku prognoze. Ulazne podatke je potrebno sakupiti minimalno za 2 godine da bi valjana prognoza mogla da se sprovede.

U ovom radu se predlaže algoritam za prognozu net pozicija koji se zasniva na formiranju nelinearnog regresionog modela – neuralne mreže. Pored toga, drugi bitan aspekt algoritma se ogleda u pretprocesiranju ulaznih podataka, kada se kreiraju X i Y šabloni kojima se uspostavlja veza između sadašnjih $(i)$ i budućih $(i+\tau)$ vrednosti net pozicija. Istorijski sati čiji su ulazni podaci slični specificiranom se favorizuju odgovarajućim težinskim faktorima u okviru neuralne mreže, tako da više utiču na prognozu budućih vrednosti. Algoritam za prognozu net pozicija se sastoji od sledećih koraka:

- Dekompozicija vrednosti vremenske serije net pozicija u X i Y šablone;
- Prognoza vrednosti Y šablona korišćenjem neuralne mreže;
- Prevođenje prognoziranog Y šablona u vrednosti net pozicija.

### 3.1 Dekompozicija vrednosti vremenske serije net pozicija

Pretprocesiranje ulaznih podataka pojednostavljuje prognoziranje vremenskih serija time što eliminiše nestacionarnost u medijani i varijansi, pri tom filtrirajući trend i sezonske cikluse na periodima dužim od dnevnih [9]. U ovom radu se pretprocesiranje ulaznih podataka sprovodi tako što se uvode ulazni X i izlazni Y šablon.

Neka je sa $NP_i = \left[np_{i,1}\ np_{i,2}\ \cdots\ np_{i,24}\right]^T$ dat vektor satnih vrednosti pomerenih (*offset*) net pozicija za *i*-ti dan ($i = 1, 2, \ldots, N$) od ukupno $N$ dana za koje postoje istorijski podaci. Ulazni šablon $X_i = \left[x_{i,1}\ x_{i,2}\ \cdots\ x_{i,24}\right]^T$ predstavlja normalizovane vrednosti pomerenih net pozicija za *i*-ti dan, koje se proračunavaju na osnovu jednačine [9]:

$$x_{i,t} = \frac{np_{i,t} - \overline{np}_i}{\sqrt{\sum_{k=1}^{24}\left(np_{i,k} - \overline{np}_i\right)^2}} \tag{1}$$

, gde su:

$np_{i,t}$ i $np_{i,k}$ – vrednost pomerene net pozicije *i*-tog dana i *t*-tog (odnosno *k*-tog) sata;

$\overline{np}_i$ – srednja vrednost pomerene net pozicije u *i*-tom danu.

Pomerena vrednost net pozicija se dobija tako što se na originalnu realizovanu vrednost net pozicije doda vrednost godišnjeg vršnog opterećenja date zone trgovanja (Instantaneous Peak Load – IPL). Na taj način se grafik realizovanih vrednosti net pozicija tokom vremena translatorno pomera dalje od apscise, u pozitivan domen ordinante, čime se rešava problem deljenja vrednostima bliskim ili jednakim nuli prilikom normalizacije. U suprotnom, datom normalizacijom se ne postiže željena dekompozicija signala (odstranjivanje nestacionarnosti u medijani i varijansi).

Izlazni šablon $Y_i = \left[y_{i,1}\ y_{i,2}\ \cdots\ y_{i,24}\right]^T$ predstavlja normalizovane vrednosti pomerenih net pozicija za $(i + \tau)$ dan, gde $\tau$ označava horizont prognoze u danima. Proračunom Y šablona kvantifikuje se sličnost između pomerenih net pozicija *i*-tog dana sa pomerenim net pozicijama za $(i + \tau)$ dan. Komponente izlaznog šablona se računaju prema jednačini [9]:

$$y_{i,t} = \frac{np_{i+\tau,t} - \overline{np}_i}{\sqrt{\sum_{k=1}^{24}\left(np_{i,k} - \overline{np}_i\right)^2}} \tag{2}$$

### 3.2 Prognoza vrednosti Y šablona korišćenjem neuralne mreže

Nakon formiranja X i Y šablona pomerenih net pozicija, može se pristupiti prognoziranju budućih vrednosti Y šablona korišćenjem neuralne mreže sa arhitekturom objašnjenom u poglavlju 2. U svakoj iteraciji se istovremeno prognoziraju 24 vrednosti Y šablona za $(i + \tau)$ dan, pri čemu se *i*-ti dan smatra „današnjim danom“ sa stanovišta simulacije.

Istorijske vrednosti temperature vazduha i X šablona za *i*-ti dan se dovedu na ulaz neuralne mreže, dok se na izlazu obezbede odgovarajuće istorijske vrednosti Y šablona. Zatim se izvrši treniranje neuralne mreže, čime se definišu težinski faktori između neurona. Dovođenjem vrednosti temperature vazduha i X šablona za *i*-ti dan na ulaz neuralne mreže proračunava se 24 prognoziranih vrednosti Y šablona za $(i + \tau)$ dan.

Pre nego što se krene na prognozu sledećeg dana testnog perioda, izvrši se ažuriranje istorijskih baza temperature, X i Y šablona tako što se postojeći podaci prošire za realizovane vrednosti temperatura vazduha, X i Y šablona. Tek onda se može započeti prognoza Y šablona za naredni dan u testnom periodu, sprovodeći isti postupak kao u prethodnoj iteraciji.

### 3.3 Prevođenje prognoziranog Y šablona u vrednosti net pozicija

U poslednjem koraku se prognozirane vrednosti Y šablona prevode u prognozirane vrednosti net pozicija na osnovu inverzije jednačine (2). Postupak prevođenja prognoziranog Y šablona u vrednosti net pozicija, uz poništavanje primenjenog pomeraja, dat je sledećom jednačinom:

$$np_{i,t+\tau} = \left[ y_{i,t} \cdot \sqrt{\sum_{k=1}^{24} \left( np_{i,k} - \overline{np}_i \right)^2} + \overline{np}_i \right] - IPL \tag{3}$$

## 4 PRIMER PRIMENE ALGORITMA ZA PROGNOZU NET POZICIJA

Za potrebe testiranja opisanog algoritma za prognozu net pozicija prikupljene su realizovane satne vrednosti net pozicija za zone trgovanja Srbije (RS), Bosne i Hercegovine (BA), Crne Gore (ME) i Bugarske (BG). Pored toga, preuzeti su podaci o temperaturi vazduha većih gradova datih zona trgovanja iz Pan-evropske klimatske baze (Pan-European Climate Database – PECD). Usrednjavanjem istih vremenskih oznaka za više dostupnih gradova u datoj zoni trgovanja, dobijene su prosečne temperature vazduha za svaku zonu trgovanja. Svi podaci su prikupljeni za vremenski period od 01.01.2015. do 31.12.2016.

Na osnovu prikupljenih podataka, prognozirane su satne vrednosti net pozicija datih zona trgovanja za 365 dana 2016. godine, pri čemu je vršena prognoza za dva dana unapred ($\tau = 2$). Kao što je već objašnjeno, istorijska baza podataka se postepeno ažurirala realizovanim vrednostima kako bi se kroz jednogodišnji testni proračun verno simulirao potencijalni dnevni proces.

Treniranje neuralne mreže, odnosno proračunavanje težinskih faktora, se sprovodilo za svaki novi dan u testnom periodu, tako da je ukupno kreirano 365 neuralnih mreža sa istom strukturom – 2 ulaza, 80 neurona u skrivenom sloju i 1 izlaz. Broj skrivenih neurona je određen na osnovu analize osetljivosti proračuna, gde se došlo do zaključka da više od 80 neurona u skrivenom sloju ne obezbeđuje značajno smanjenje godišnje greške prognoze, a vremenski značajno produžava proračun. Takođe, autori su pokušali da na ulaz neuralne mreže dovedu više kombinacija različitih ulaznih podataka, pri čemu se izdvajaju pokušaji da na ulazu budu:

- net pozicije samostalno;
- net pozicije i proizvodnja;
- net pozicije, proizvodnja i potrošnja;
- net pozicije i meteorološki podaci (temperatura vazduha i brzina vetra);
- net pozicije, proizvodnja, potrošnja i meteorološki podaci; i dr.

U svim tim pokušajima, najbolje se pokazala kombinacija sa 2 ulaza na koje se dovode vrednosti X šablona net pozicija i temperatura vazduha, pri čemu su na izlazu vrednosti Y šablona net pozicija. Za datu kombinaciju veličina na ulazu i izlazu dobijale su se najmanje godišnje greške prognoze.

Dodatni izazov prilikom sprovođenja proračuna bio je odabir adekvatnog indikatora kvaliteta prognoze net pozicija, koji bi omogućio upoređivanje grešaka prognoze kako za različite konfiguracije neuralnih mreža i kombinacije ulaznih veličina, tako i za različite setove podataka datih zona trgovanja. Korišćenje srednje apsolutne procentualne greške (Mean Absolute Percentage Error – MAPE), kao jednog od najčešće korišćenih relativnih pokazatelja kvaliteta prognoze vremenskih serija, nije bilo moguće zbog toga što se dobijaju nerealne vrednosti grešaka kada realizovane vrednosti net pozicija imaju vrednosti bliske nuli.

Upravo da bi se omogućilo poređenje kvaliteta prognoze između različitih zona trgovanja, ali i da bi vrednost relativne greške nedvosmisleno i kvantitativno razumljivo oslikavala koliko prognozirane vrednosti odstupaju od realizovanih, autori su uveli indikator kvaliteta prognoze, koji je dat jednačinom:

$$RE_1 = \frac{\sum_{t=1}^{N} |NP_t^F - NP_t^T|}{FR_{MIN}} \cdot 100\% \tag{4}$$

, gde su:

$RE_1$ – suma apsolutnih grešaka prognoze normalizovana u odnosu na minimalnu vrednost opsega za usklađivanje PNP-a;

$NP_t^F$ – prognozirana vrednost net pozicije za sat *t*;

$NP_t^T$ – realizovana vrednost net pozicije za sat *t*;

$FR_{MIN} = 0{,}02 \cdot IPL$ – minimalna vrednost opsega za usklađivanje PNP-a (minimalna oblast u kojoj je dozvoljeno pomeranje vrednosti PNP-a, kako bi se kroz CGMA proces dobile izbalansirane net pozicije) [4];

$N$ – ukupan broj sati u testnom periodu.

Drugi značajni relativni indikator kvaliteta prognoze određen je na osnovu algoritma za prognozu net pozicija koji je predložio NORDIC RSC u okviru drugog aneksa CGMA metodologije [4], a dat je kroz jednačinu:

$$RE_2 = \frac{MAE}{MANP} = \frac{\frac{\sum_{t=1}^{N}|NP_t^F - NP_t^T|}{N}}{\frac{\sum_{t=1}^{N}|NP_t^T|}{N}} = \frac{\sum_{t=1}^{N}|NP_t^F - NP_t^T|}{\sum_{t=1}^{N}|NP_t^T|} \cdot 100\% \quad (5)$$

, gde su:

$MAE$ – srednja apsolutna greška (Mean Absolute Error);

$MANP$ – srednja vrednost apsolutnih net pozicija (Mean Absolute Net Position).

Na osnovu datih jednačina (4) i (5), Tabela I prikazuje proračunate vrednosti relativnih grešaka prognoze za sve 4 zone trgovanja prilikom testnog perioda, kao i njima odgovarajuće vrednosti IPL-a za 2016. godinu. $RE_1$ greška se kreće u opsegu od oko 20% za BG, do približno 300% za ME zonu trgovanja. Na primer, za slučaj RS-a može se zaključiti da dati algoritam za prognozu net pozicija ima prosečnu apsolutnu grešku koja iznosi oko polovine minimalnog opsega za usklađivanje, što je okvirno 70MW. To znači da RS net pozicija, u najgorem slučaju prognoze i balansiranja PNP-a (kada maksimalna očekivana greška i maksimalno pomeranje net pozicije za potrebe balansiranja imaju isti predznak), može da odstupa od realizovane net pozicije za vrednost $FR_{MIN}$ (pod uslovom da se u CGMA procesu specificira simetrično pomeranje PNP-a u okviru $FR_{MIN}$). U BG slučaju je to odstupanje manje ($0{,}7 \cdot FR_{MIN}$), dok je u BA i ME slučaju znatno veće.

**Tabela I Vrednosti IPL-a i relativnih grešaka prognoze net pozicija za date zone trgovanja**

| Greška\TSO | BG | RS | BA | ME |
|---|---|---|---|---|
| ***IPL [MW]*** | 7105 | 6958 | 2142 | 576 |
| $\boldsymbol{RE_1}$**[%]** | 21,5 | 52,88 | 166,87 | 295,44 |
| $\boldsymbol{RE_2}$**[%]** | 4,18 | 17,21 | 15,98 | 24,98 |

Sa druge strane, $RE_2$ greška ima vrednosti od približno 4% za BG, preko 17% i 16% za RS i BA (respektivno), pa sve do okvirno 25% za ME zonu trgovanja. Prosečna vrednost $RE_2$ greške za date 4 zone trgovanja je 15,6%. Poređenjem vrednosti $RE_2$ greške u slučaju zona trgovanja iz Tabele I sa 12 zona trgovanja za koje je NORDIC RSC prikazao testne rezultate [4], može se zaključiti da kvalitet algoritma za prognozu net pozicija koji je opisan u ovom radu ne odstupa značajno od kvaliteta NORDIC pristupa. Minimalna greška u njihovoj prognozi je 9%, najveća 41%, dok prosečna relativna greška prognoze net pozicija po zonama trgovanja iznosi oko 20%.

Iz Tabele I se može uočiti da postoji trend smanjenja relativnih grešaka sa povećanjem IPL vrednosti zone trgovanja. To se može opravdati činjenicom da zone trgovanja sa većim opterećenjem imaju stabilniju proizvodnju, pa samim tim vrednosti uvoza i izvoza prema susednim zonama trgovanja se manje menjaju, pružajući sigurniju prognozu. Ovaj trend delimično narušava RS zona trgovanja, što se može objasniti činjenicom da, zahvaljujući svojoj geografskoj poziciji, predstavlja značajnu tranzitnu oblast – veće promene uvoza/izvoza čine da prognoza net pozicija bude manje izvesna.

Slika 3. prikazuje raspodelu grešaka prognoze net pozicija za 4 zone trgovanja. Poređenjem datih histograma, može se uočiti da su grafici raspodele BG i RS grešaka (prikazani na Slici 3.a) i Slici 3.b), respektivno), odnosno BA i ME grešaka prognoze net pozicija (prikazani na Slici 3.c) i Slici 3.d), respektivno) veoma slični, što odgovara odnosima $RE_1$ greške.

Histogrami kvalitetnijih BG i RS prognoza imaju dva istaknuta pika, koji su gotovo simetrično postavljeni u odnosu na nultu-grešku, dok se u oblasti nule uočava udolina. To ukazuje da prognoza često greši, ali da odstupanja nisu značajna (inače bi relativne greške bile velike). Takođe, uočava se da RS prognoza često procenjuje net pozicije koje su manje od realizovanih, što značajno povećava relativnu grešku, za razliku od BG prognoze koja je simetrična, a odstupanja nisu značajna.

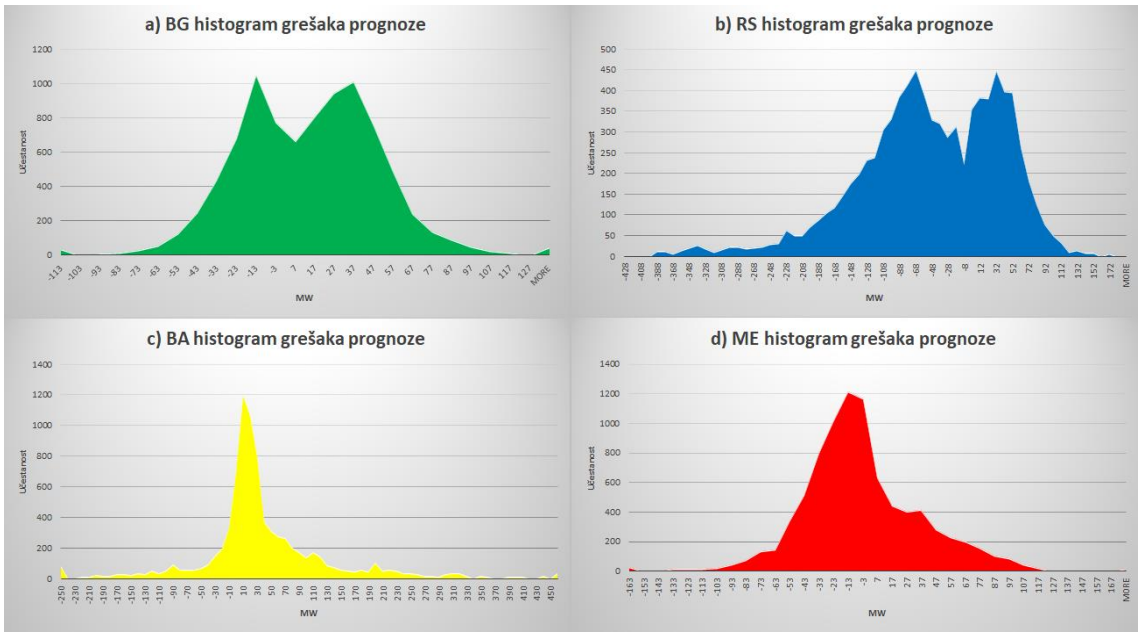


**Slika 3. Histogram grešaka prognoze net pozicija za date zone trgovanja**

Nasuprot BG i RS histograma, BA i ME histogrami imaju jedan istaknut pik lociran u oblasti nulte-greške. To znači da najveći broj sati ima grešku blisku nuli, ali relativne greške rastu jer su date zone trgovanja relativno male (pa je samim tim manja i bazna vrednost kod proračuna relativnih grešaka). Kao i kod RS histograma, kod BA i ME grafika se uočava nesimetričnost grešaka prognoze – u BA slučaju su net pozicije često veće od realizovanih, dok su kod ME češće manje od realizovanih.

## 5 ZAKLJUČAK

U radu su pokazani rezultati primene algoritma za prognozu net pozicija u slučaju nekoliko zona trgovanja različitih veličina. Došlo se do zaključka da veće zone trgovanja imaju manju godišnju grešku prognoze, što se opravdava činjenicom da date zone trgovanja imaju manju potrebu za uvozom/izvozom. Sa druge strane, detektovan je izuzetak od pomenutog pravila u slučaju RS, jer je data zona trgovanja veoma tranzitna zbog velikog broja suseda, pa otud i izražena promenljivost net pozicija.

Na osnovu analize histograma grešaka prognoze net pozicija za različite zone trgovanja, uočene su određene pravilnosti oblika grafika u zavisnosti od veličine zona trgovanja. Naime, veće zone trgovanja (BG i RS) su imale dva uočljiva, simetrična pika, dok su manje zone trgovanja (BA i ME) imale samo po jedan pik. Takođe, primećene su određene nesimetrije u izgledu histograma pojedinih zona trgovanja, što govori o tome u koju stranu greši prognoza net pozicija. Tako je primećeno da je veliki broj RS i ME grešaka negativan (što znači da prognoza podbacuje ciljane vrednosti), za razliku od BA histograma gde se vidi da je veći broj grešaka pozitivan (što znači da prognoza prebacuje ciljane vrednosti). Najbolji rezultati prognoze net pozicija dobijeni su kod BG zone trgovanja, gde je histogram simetričan, a opseg grešaka veoma mali za tako veliku oblast.

Svi pomenuti zaključci, koji su izvedeni na osnovu proračunatih vrednosti relativnih grešaka, ali i izgleda histograma grešaka prognoze net pozicija, poslužiće autorima kao smernice za dalje unapređenje algoritma za prognozu net pozicija. Važan napredak u ovom poslu biće uspostavljanje procesa usaglašavanja individualnih prognoza net pozicija sa prognozama čitavog regiona za koje je dati agent za usklađivanje zadužen.

**ZAHVALNICA**

Rad je deo Horizon 2020 projekta *CROSSBOW – CROSS BOrder management of variable renewable energies and storage units enabling a transnational Wholesale market* (Grant No. 773430). Ovaj dokument je izrađen uz finansijsku pomoć Evropske Unije. Sadržaj ovog dokumenta je isključivo odgovornost autora i ni pod kojim okolnostima se ne može smatrati da odražava stav Evropske Unije.

**LITERATURA**

[1] Commission Regulation (EU) 2015/1222 of 24 July 2015 establishing a guideline on capacity allocation and congestion management – "CACM Guideline";
[2] Commission Regulation (EU) 2016/1719 of 26 September 2016 establishing a guideline on forward capacity allocation – "FCA Guideline";
[3] Commission Regulation (EU) 2017/1485 of 02 August 2017 establishing a guideline on electricity transmission system operation – "SO Guideline";
[4] ENTSO-E All TSOs' Common Grid Model Alignment Methodology in accordance with Article 24(3)(c) of the Common Grid Model Methodology, 29 November 2017;
[5] J. D. Hamilton, „Time Series Analysis", Princeton University Press, New Jersey, 1994;
[6] S. N. Sivanandam, S. Sumathi, S. N. Deepa, „Introduction to Neural Networks Using Matlab 6.0", Tata McGraw-Hill Education, Nju Delhi, 2006;
[7] C. Lv, Y. Xing, J. Zhang, X. Na, Y. Li, T. Lui, D. Cao, F. Wang, „Levenberg-Marquardt Backpropagation Training of Multilayer Neural Networks for State Estimation of A Safety Critical Cyber-Physical System", IEEE Transactions on Industrial Informatics, pp. 99, novembar 2017;
[8] M. Lukić, A. Đalović, D. Prešić, P. Orlić, „Proces usklađivanja net pozicija spojenih mrežnih modela", 18. simpozijum CIGRE Srbija, Zrenjanin, oktobar 2018;
[9] G. Dudek, „Pattern-based local linear regression models for short-term load forecasting", Electic Power System Research, 130, pp. 139-147, Jan. 2016.

# FORECAST OF NET POSITINS USING NEURAL NETWORKS

**DUŠAN PREŠIĆ*,**
**ANDREJ TASIĆ**

**SECURITY COORDINATION CENTRE SCC LTD BELGRADE**

**BELGRADE**

**REPUBLIC OF SERBIA**

***Abstract – Common Grid Model Alignment (CGMA) process is a set of procedures by which the initial estimates of net positions are revised such that the resulting set of net positions on the Pan-European level is balanced. The process is applied for those time horizons for which market schedules of net positions are not available – from two days ahead up to one year ahead. Beside the task to control CGMA process, Alignment Agents could be nominated by their TSOs regarding net position forecast. It is rather intuitive that initial estimates of net positions are more accurate if the forecast is performed at the regional level.***

***This paper describes theoretical foundations of neural networks, as well as its application on net position forecast. Also, based on collected set of input data, calculations for testing period of one year are performed, where hourly values of net positions are forecasted for following biding zones – Serbia, Bosnia and Herzegovina, Montenegro and Bulgaria. Forecast was performed for time horizon of two days ahead. At the end, several indicators that describe quality of the forecast on the yearly level are shown.***

***Key words – Net position, Forecast, Neural Network, Regional Security Coordinator, CGMA process.***

* Vojvode Stepe 412, 11000 Belgrade, dusan.presic@scc-rsci.com