

Ivona Sičaja, mag.ing.
Končar – Inženjering za energetiku i transport d.d.
ivona.sicaja@koncar-ket.hr

Matija Zečević, dipl.ing.
Končar – Inženjering za energetiku i transport d.d.
matija.zecevic@koncar-ket.hr

Marko Penzar, dipl. ing.
HEP ODS, Elektra Zagreb
marko.penzar@hep.hr

PROGNOZA OPTEREĆENJA U DISPEČERSKOM CENTRU VOĐENJA ELEKTRA ZAGREB

SAŽETAK

Predviđanje potrošnje električne energije ima važnu ulogu u planiranju rada distribucijskog elektroenergetskog sustava. Pravovremeno predviđanje potrošnje pojedinih dijelova ili cjelovite distribucijske mreže pomaže unapređenju planiranja njezinog vođenja, te tako povećanju razine sigurnosti cijelog distribucijskog sustava.

U sklopu projekta nadogradnje SCADA sustava u DCV (*Dispečerski centar vođenja*) Elektra Zagreb implementiran je podsustav prognoze opterećenja elektroenergetske mreže baziran na umjetnim neuronskim mrežama kao dio DMS (engl. *Distribution Management System*) sustava.

U radu je opisan implementirani podsustav prognoze opterećenja pri čemu je dan naglasak na jednostavnom i sistematičnom korisničkom radu s ulaznim i izlaznim podacima, kao i prognostičkim scenarijima te su prezentirani dobiveni rezultati za određene testne mjerne točke.

Ključne riječi: kratkoročna prognoza opterećenja, prognoza opterećenja, neuronske mreže

LOAD FORECASTING IN DISTRIBUTION SYSTEM OPERATOR ELEKTRA ZAGREB

SUMMARY

Forecasting of the electricity consumption has an important role in the operational planning of the distribution power system. Load forecasting of certain parts or the whole distribution network helps to improve the distribution network planning, operation and control which also increases the safety level of the entire distribution system.

During the revitalization of the Remote Control System of the Distribution System Operator Elektra Zagreb, the electric power system load forecasting subsystem was implemented as integral part of the DMS system.

This article gives a description of the implemented load forecasting subsystem with emphasis on simple and systematic use of input and output data as well as forecasting scenarios where forecasting results of specific measured points are presented.

Key words: short-term load forecasting, load forecast, neural network

1. UVOD

U svakom trenutku rada elektroenergetskog sustava (EES) mijenja se neka od njegovih karakterističnih varijabli, primjerice struktura proizvodnih i potrošačkih objekata, topologija mreže itd. Planiranje pogona EES-a složen je proces koji u obzir uzima niz varijabli tehničkog i društvenog karaktera čiji su temeljni ciljevi proizvodnja električne energije uz minimalne troškove te njena sigurna i kvalitetna isporuka. Potreba za točnim prognoziranjem opterećenja dolazi iz činjenice da se električna energija ne može pohraniti te da se u današnje vrijeme na tržištu njoj pristupa kao i svakom drugom proizvodu.

Pri postupku prognoziranja opterećenja definiraju se tzv. krivulje opterećenja koji prikazuju ovisnost snage o vremenu, odnosno krivulje opterećenja električne energije određenog područja za neko buduće vremensko razdoblje. Opterećenje električne energije predviđa se dugoročno (sezonske, godišnje prognoze) zbog direktnog utjecaja na planiranje razvoja proizvodnih, prijenosnih i distribucijskih kapaciteta te kratkoročno. Kratkoročne su pak prognoze (npr. tjedne) neizostavan dio svakodnevnog vođenja elektroenergetske mreže jer pouzdani rezultati predviđanja direktno utječu na odluke koje se donose u vezi proizvodnje ili nabave električne energije te u procjeni sigurnosti rada elektroenergetskog sustava.

Prognoziranje opterećenja kompleksan je zadatak na koji veliki utjecaj ima odabir matematičkog modela za prognoziranje te kvaliteta podataka koji ulaze u model. Najvažniji ulazni element u model je povijesno opterećenje. Opterećenje u određenom satu ovisi o opterećenju prethodnog sata, opterećenju istog sata prethodnog dana, ali i opterećenju istog sata i dana iz prethodnog tjedna. Također, na potrošnju električne energije veliki utjecaj imaju vremenske prilike (temperatura, padaline, vlažnost zraka) stoga ih je veoma bitno uključiti u model za predviđanje opterećenja.

2. SUSTAV ZA PROGNOZIRANJE OPTEREĆENJA

2.1. Općenito

Tijekom revitalizacije SCADA sustava Operatora distribucijskog sustava Elektra Zagreb implementiran je sustav prognoze opterećenja elektroenergetske mreže kao dio DMS (engl. *Distribution Management System*) sustava.

2.2. Algoritam za izračunavanje prognoze opterećenja

Algoritam za izračunavanje prognoze opterećenja na kojem se bazira spomenuti integrirani sustav za prognoziranje jesu umjetne neuronske mreže (engl. *Artificial Neural Networks - ANN*). Umjetne neuronske mreže koriste sofisticirane matematičke tehnike za prepoznavanje i učenje spojnih veza (linearnih ili nelinearnih) između promatranih varijabli.

Osnovna podjela neuronskih mreža je na:

- a) Biološke (prirodne) neuronske mreže koje čine živčani sustav bioloških organizama, a karakterizira ih visoka složenost i paralelizam. Neuron (živčana stanica) osnovna je jedinica živčanog sustava, a ujedno i najsloženija jedinica ljudskog organizma.
- b) Umjetne neuronske mreže:
 - razvoj im se temelji na uzoru bioloških neuronskih mreža (za sada su njihova relativno primitivna imitacija),
 - slične su mozgu jer koriste međusobne veze između neurona za spremanje znanja, a znanje stječu procesom učenja,
 - implementiraju se na digitalnim računalima opće namjene,
 - glavna im je primjena kod traženja zavisnosti između podataka koji nisu isključivo u linearnoj vezi, ali se mogu ujediniti u jedan složeni ulazni skup.

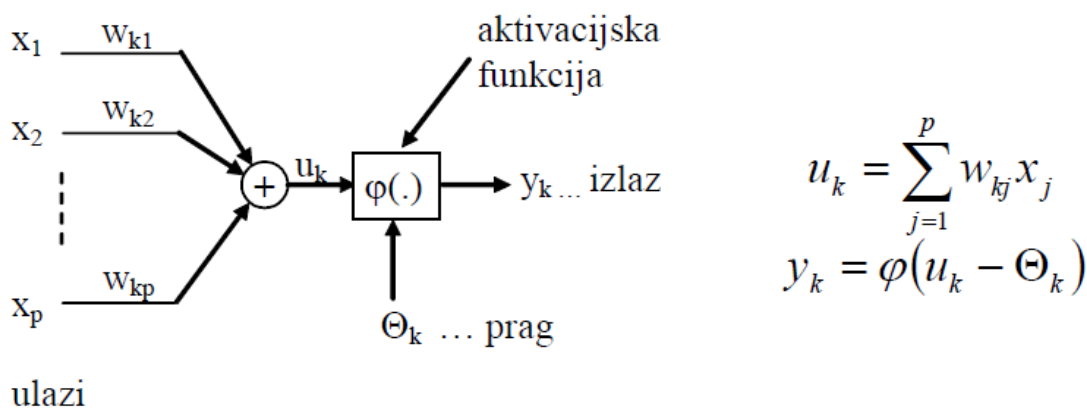
Neuronska mreža obrađuje podatke paralelnim radom svojih čvorova, a informacije spremljene u neuronsku mrežu raspodijeljene su na više jedinica. Neuronska mreža uči složene veze, a znanje se jednostavno proširuje u cilju dobivanja izlaznih varijabli. Pri tome je obradbeno moć pohranjena u snazi veza između pojedinih neurona, tj. težinom do kojih se dolazi postupkom učenja. Osnovne karakteristike neuronske mreže su:

- svi primjeri za učenje sastoje se od ulaznih i izlaznih vrijednosti,
- neuronska mreža uči o okolini kroz iterativni proces podešavanja sinaptičkih težina i pragova (nakon svake iteracije učenja mreža bi trebala imati više znanja o okolini),
- naučiti model okoline i održavati ga dovoljno točnim kako bi se postigli željeni ciljevi danog sustava.

Neuronske mreže karakterizira visok stupanj tolerancije na pogreške što se očituje uspješnom analizom nejasnih i/ili krivih podataka te radom i pri nedostatku dijela podataka (korisna osobina kod predviđanja opterećenja).

Elementi modela neurona prikazani su na *Slici 1* [1]:

- skup sinapsi tj. ulaza od kojih svaki ima svoju jačinu tj. težinu (signal x_i na ulazu j neurona k ima težinu w_{kj})
- sumator za zbrajanje ulaza – ove operacije računaju linearnu kombinaciju ulaza
- prag – kada je iznos dobiven zbrajanjem ulaznih varijabli iznad definiranog praga, neuron daje izlazni signal
- nelinearna aktivacijska funkcija koja ograničava izlaz neurona na interval $[0,1]$



Slika 1. Elementi modela neurona

2.3. Osnovne karakteristike sustava za prognoziranje opterećenja

Sustav prognoze opterećenja omogućuje kvalitetno prognoziranje opterećenja na razini cjelokupnog sustava ili samo na dijelu elektroenergetske mreže. Sustav omogućuje brz unos povijesnih i prognoziranih podataka ručno ili automatski, jednostavno definiranje parametara za prognozu (definiranje modela) te pregledan prikaz izlaznih varijabli koje se mogu međusobno uspoređivati, prikazati u različitim formama (tablični i grafički prikaz) te u drugim aplikacijama. Cjelokupni proces predviđanja moguće je i automatizirati na način da se podaci automatski unose u aplikaciju, nakon čega se izvodi sama prognoza te se prognozirani podaci u obliku datoteke automatski šalju na predefinirano mjesto nakon čega se prebacuju na SCADA poslužitelj.

Dva su glavna procesa pri kreiranju prognostičkog modela:

- Trening - metoda koja se koristi za određivanje veza između ulaznih (nezavisnih) i izlaznih (zavisnih) varijabli na način da se proučavaju povijesni podaci. Tijekom treninga, elementi povijesnih podataka čine ulazni čvor u neuronsku mrežu. Algoritam mijenja težine na internim mrežnim vezama u skladu s razlikom između mrežnih izlaza (predložena rješenja) i znanih rješenja tako da kada mreža primi sličan primjer, njegov izlaz je bliži zahtijevanom uzorku. Ovaj se proces ponavlja dok mreža ne nauči generirati željeni odgovor na svaki ulaz.
- Verifikacija - kvaliteta treninga provjerava se verifikacijom. Trening se može verificirati usporedbom predviđene vrijednosti sa stvarnom vrijednosti ili koristeći verifikacijske podatke.

Verifikacijski podaci su malena količina povijesnih podataka koji namjerno nisu korišteni u treniranju mreže. Koristeći relevantne varijable iz verifikacijskih podataka, prognoza stvarne potrošnje može se napraviti koristeći težinske faktore neuronske mreže kako bi se odredila točnost.


Umjetna neuronska mreža koristi se u prognoziranju zbog ovisnosti budućeg opterećenja o opterećenjima iz prošlosti i vanjskim faktorima (npr. vremenske prilike). Za treniranje mreže stoga je potrebno definirati parametre koje utječu na izlazne vrijednosti. Uobičajeno se koriste povijesni podaci za razdoblje od tri godine kako bi se kreirao pouzdan model. Navedeni su neki od parametara:

- a) Povijesni podaci o opterećenju – podaci o opterećenju mogu biti za cijeli sustav ili za pojedine dijelove sustava.
- b) Povijesni meteorološki podaci - moguće je unijeti razne meteorološke varijable koje imaju utjecaj na opterećenje kao što su temperatura, brzina vjetra, tlak zraka, oblačnost, vlažnost zraka, količina oborina, smjer vjetra. Podaci mogu biti uneseni za jednu ili više lokacija. Aplikacija prepoznaje koje varijable imaju veći utjecaj i uračunava ih na odgovarajući način.
- c) Prognozirani meteorološki podaci – unose se definirani meteorološki podaci kako bi se prema istreniranom modelu napravila prognoza opterećenja.
- d) Nemeteorološki podaci – kao ulazne varijable definiraju se dan u tjednu, praznici i blagdani, dio godine (godišnja doba) itd.
- e) Dodatni parametri prema zahtjevima korisnika:
 - broj prolaza treninga – broj prolaza kroz svaki od 50 ciklusa treninga,
 - broj skrivenih slojeva neurona – neuronska mreža sastoji od tri sloja neurona, prvog, ulaznog (npr. temperatura), drugog, skrivenog sloja, u kojima se nalaze čvorovi koji procesiraju ulazne podatke te trećeg, završnog sloja u kojem je izračunat krajnji rezultat. Povećanje broja čvorova u skrivenom sloju može rezultirati boljim treningom, a time i boljim rezultatima prognoze, ali i povećanjem kompleksnosti neuronske mreže, a time i povećanjem potrebnog vremena treniranja mreže,
 - raspršenost – nezavisna varijabla kroz svoj cjelokupni raspon utječe različito na zavisnu varijablu. Raspon varijable se stoga dijeli na više neurona kako bi mreža bolje naučila vezu među raspršene i zavisne varijable,
 - vremenski pomak – koristi se na način da model u obzir uzima stvarne podatke, a ako ih nema, kombinira postojeće na unaprijed definirani način.

2.4. Osnovne karakteristike sustava za prognoziranje opterećenja

U dispečerskom centru ODS Elektra Zagreb instalirana je sklopovska konfiguracija sustava daljinskog vođenja prikazana na *Slici 2*. Konfiguracija SCADA/DMS sustava zasniva se na poslužitelj/klijent modelu odnosno na distribuiranom modelu sklopovske i programske opreme, uključujući i procesnu bazu podataka. Programske funkcije sustava prognoze opterećenja realizirane su na Oracle bazi podataka poslužitelja za predviđanje opterećenja. Sustav prognoze opterećenja instaliran je na zasebnom *HYPER-V* virtualnom poslužitelju na DE poslužitelju (engl. *Data Engineering*), poslužitelju za održavanje cjelokupnog SCADA sustava. Podaci za prognoziranje uzimaju se iz povijesne baze podataka tzv. UDW (engl. *Utility Data Warehouse*) poslužitelja.

Automatska razmjena podataka između poslužitelja za prognoziranje i SCADA i UDW poslužitelja vrši se pomoću tzv. DCI funkcionalnosti (engl. *Data Communication Interface*) koja se brine da se pravilno strukturirani podaci iz povijesne baze pohranjeni u datoteke prenesu na poslužitelj za prognoziranje koristeći FTP protokol i obrnuto, da se podaci koji su rezultat prognoze prenesu u obliku datoteka na SCADA poslužitelj te upišu u povijesnu bazu.



Slika 2. Konfiguracija SCADA/DMS sustava

Osim unutar same aplikacije za predviđanje opterećenja, sve rezultate prognoze, kao i povijesne podatke moguće je vidjeti i putem trendova i/ili na jednodimenzionalnim krivuljama unutar operatorske aplikacije WS500.

2.5. Primjer prognoze opterećenja u sustavu daljinskog vođenja Elektre Zagreb


Svrha prognoze opterećenja unutar sustava daljinskog vođenja Operatora distribucijskog sustava Elektra Zagreb jest pomoći u pravovremenom prognoziranju potrošnje pojedinih dijelova distribucijske mreže te time i povećanje razine sigurnosti cijelog distribucijskog sustava [4].

Pri vođenju elektroenergetske mreže, dispečeri moraju unaprijed znati planiranu potrošnju neke trafostanice u slučaju prekapčanja kako bi znali odabrati odgovarajuću zamjensku stanicu na koju će se potrošači preusmjeriti. Ciklus opterećenja električne energije promjenjiv je tijekom vremena. Svaki dio EES-a ima svoj karakteristični oblik dnevne krivulje koji ovisi o danu u tjednu, godišnjem dobu, vrsti potrošača itd. Potrošnja trafostanica na koje su spojeni veći industrijski ili trgovački centri ne pokazuje toliku ovisnost o atmosferskim prilikama kao one na koje su spojena kućanstva. Za potrebe testiranja našeg modela odabrali smo stanicu Ksaver 4TS22 iz razloga što ona napaja pretežito kućanstva i poslovne objekte koji zajednički čine karakterističnu krivulju potrošnje. Drugi razlog odabira te stanice je taj što je ona svojim geografskim smještajem izbjegla nedavna prespajanja dijela mreže grada Zagreba, pogotovo centra grada na stanicu 4TS31 Ferenščica. Time je izbjegla promjenu u karakterističnoj krivulji potrošnje te stoga povijesni podaci (koji se koriste za učenje prognostičkog modela) i dalje dobro opisuju njezino vladanje.

U svrhu predviđanja opterećenja definiran je model unutar same aplikacije. Uneseni su povijesni podaci za opterećenje TS Ksaver za period od 1. srpnja 2014. do 11. siječnja 2016. godine. Također, za navedeni su period uneseni i podaci o temperaturi koji su mjereni u samoj stanici. Definiran je period treninga u razdoblju od 1. srpnja 2014. do 1. srpnja 2015. te period verifikacije od 2. srpnja 2015. do 11. siječnja 2016. Model je definiran na način da razlikuje dane u tjednu te doba godine (godišnja doba). Uneseni su službeni hrvatski blagdani i praznici jer kao karakteristični dani odstupaju od tipičnih. Kao dodatni parametar, definiran je broj prolaza treninga (50), broj skrivenih slojeva neurona (20) te je varijabla temperature definirana kao raspršena varijabla koja se dijeli na tri dijela. Nezavisna varijabla (temperatura) kroz cjelokupni raspon različito utječe na zavisnu varijablu pa se raspon nezavisne varijable dijeli na tri neurona kako bi mreža bolje naučila vezu među varijablama.

Točnost modela se u literaturi vrlo često provjerava preko MAPE grafa (engl. *Mean Absolute Percentage Error*) pri čemu se u istoj nailazi na pogreške točnosti modela do 5% [5], [6]. Također, preciznost modela moguće je provjeriti i usporedbom stvarnog i prognoziranog opterećenja u obliku grafa ili u konkretnim brojevima.

Na Slici 3. prikazana je usporedba krivulja stvarnog i prognoziranog opterećenja TS Ksaver za tipičnu zimsku subotu 2. siječnja 2016. godine.




Slika 3. Krivulja stvarnog i prognozirano opterećenja TS Ksaver dana 02.01.2016.

Na *Slici 3.* vidljivo je da prognozirana krivulja opterećenja vrlo dobro prati stvarne vrijednosti. Najveće odstupanje prognozirano opterećenja od stvarnog pojavljuje se u 9 sati te iznosi 1.59 MW.

Budući da je model definiran na način da razlikuje dane u tjednu te mjesece, apsolutnu je pogrešku moguće promatrati i za određene dane odnosno mjesece. Tako je najveća pogreška petkom (MAPE=4.84%), a najmanja nedjeljom (MAPE=3.78%). Na mjesečnoj razini, model je najtočniji za srpanj (MAPE=3.53%). Iz navedenih se podataka može zaključiti da je opisani model za prognoziranje opterećenja stanice Ksaver 4TS22 dobar.

Na *Slici 4.* prikazana je usporedba stvarnog i prognozirano opterećenja TS Ksaver za srpanj 2015. godine.



Slika 4. Krivulja stvarnog i prognozirano opterećenja TS Ksaver u srpnju 2015.

3. ZAKLJUČAK

U radu je opisan princip rada sustava za predviđanje opterećenja implementiran unutar sustava daljinskog vođenja ODS Elektra Zagreb. Na primjeru TS Ksaver prikazano je kako istrenirani prognostički model daje prognozu opterećenja vrlo sličnu stvarnom opterećenju za navedeno područje. Model se može primijeniti i za širi dio mreže prilagodbom potrebnih ulaznih parametara. Također, poboljšavajući kvalitetu ulaznih podataka i optimizirajući kompleksnost definiranog prognostičkog modela mogu se bitno poboljšati i rezultati prognoze opterećenja. Opisani sustav za predviđanje opterećenja može značajno pripomoći u planiranju i vođenju distribucijskog područja Elektre Zagreb.

4. LITERATURA

- [1] Sven Lončarić: *Uvod u neuronske mreže*, Neuronske mreže, FER, Zagreb, 2016.
- [2] *Nostradamus User Guide*, Network Manager, Ventyx an ABB Company, 2014.
- [3] K. Tačković, S. Nikolovski, V. Boras: *Kratkoročno prognoziranje opterećenja primjenom modela umjetne neuronske mreže*, Energija, HEP, listopad 2008.
- [4] M. Zečević, B. Krstulja: *Kratkoročna prognoza opterećenja u distribucijskim elektroenergetskim mrežama*, Hrvatski ogranak međunarodne elektrodistribucijske konferencije HO Cired, svibanj 2010.
- [5] Newfoundland and Labrador Hydro: *Accuracy of Nostradamus Load Forecasting at Newfoundland and Labrador Hydro, Monthly Report: December 2014*, siječanj 2014.
- [6] Newfoundland and Labrador Hydro: *Accuracy of Nostradamus Load Forecasting at Newfoundland and Labrador Hydro, Monthly Report: January 2015*, veljača 2015.