

Prognoza cijene električne energije

Klešić, Ines

Master's thesis / Diplomski rad

2018

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:200:003882>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-11-19**

Repository / Repozitorij:

[Faculty of Electrical Engineering, Computer Science and Information Technology Osijek](#)



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U
OSIJEKU**

**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKIH TEHNOLOGIJA**

Sveučilišni studij

Prognoza cijene električne energije

Diplomski rad

Ines Klešić

Osijek, 2018.

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 26.02.2018.

Odboru za završne i diplomske ispite**Imenovanje Povjerenstva za obranu diplomskog rada**

Ime i prezime studenta:	Ines Klešić
Studij, smjer:	Diplomski sveučilišni studij Elektrotehnika, smjer Elektroenergetika
Mat. br. studenta, godina upisa:	D-730, 06.10.2016.
OIB studenta:	36923448170
Mentor:	Prof.dr.sc. Srete Nikolovski
Sumentor:	Doc.dr.sc. Krešimir Fekete
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	Doc.dr.sc. Goran Knežević
Član Povjerenstva:	Doc.dr.sc. Krešimir Fekete
Naslov diplomskog rada:	Prognoza cijene električne energije
Znanstvena grana rada:	Elektroenergetika (zn. polje elektrotehnika)
Zadatak diplomskog rada:	U radu je potrebno teorijski obraditi prognozu opterećenja EES i proizvodnju el. energije iz vjetroparkova na pučini. U radu je potrebno teorijski obraditi prognozu opterećenja EES i proizvodnju el. energije iz vjetroparkova na pučini. Navesti aktualne metode za prognozu sa posebnim osvrtom na upotrebu neuronskih mreža. Na konkretnom primjeru pučinskih vjetroparkova objasniti prognoziranje proizvodnje električne energije i udjecaj na cijenu el. energije. Pojasniti faktore koji utječu na proizvodnju, provesti prognozu proizvodnje električne energije iz vjetroelektrana s obzirom na dostupne mjerene podatke te analizu pogreške
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 bod/boda Postignuti rezultati u odnosu na složenost zadatka: 2 bod/boda Jasnoća pismenog izražavanja: 3 bod/boda Razina samostalnosti: 3 razina
Datum prijedloga ocjene mentora:	26.02.2018.
Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**IZJAVA O ORIGINALNOSTI RADA**

Osijek, 06.03.2018.

Ime i prezime studenta:	Ines Klešić
Studij:	Diplomski sveučilišni studij Elektrotehnika, smjer Elektroenergetika
Mat. br. studenta, godina upisa:	D-730, 06.10.2016.
Ephorus podudaranje [%]:	8%

Ovom izjavom izjavljujem da je rad pod nazivom: **Prognoza cijene električne energije**

izrađen pod vodstvom mentora Prof.dr.sc. Srete Nikolovski

i sumentora Doc.dr.sc. Krešimir Fekete

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija. Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis studenta:

SADRŽAJ:

1. UVOD.....	1
2. PROGNOZA OPTEREĆENJA ELEKTRIČNE ENERGIJE.....	3
2.1. Faktori koji utječu na obrasce opterećenja	3
2.2. Metode predviđanja	4
2.2.1. Metode srednjoročne i dugoročne prognoze.....	4
2.2.2. Metode kratkoročnog predviđanja.....	5
2.3. Kratkoročno predviđanje opterećenja sa modelom umjetnih neuronskih mreža.....	7
2.3.1. Opis modela i arhitekture umjetne neuronske mreže	8
2.3.2. Kratkoročna prognoza opterećenja pomoću MATLAB-ove ANN „alatne kutije“	11
2.3.4. Aktivacijske funkcije.....	13
2.3.4. Postupak učenja mreže	14
3. PREDVIĐANJE CIJENE ELEKTRIČNE ENERGIJE	16
3.1. Uvod u predviđanje cijene električne energije	16
3.2. Volatilitnost cijene električne energije	17
3.3. Kategorizacija predviđanja cijene	18
3.4. Faktori za predviđanju cijene električne energije.....	19
3.5. Model predviđanja cijene temeljen na ANN	19
3.5.1 Utjecaj zagušenja u prijenosu	21
4. TRŽIŠTE ELEKTRIČNE ENERGIJE U HRVATSKOJ	23
4.1 Hrvatski elektroenergetski sustav	23
4.1.1 Usluge operatora prijenosnog sustava	25
4.1.2 Vođenje EES-a	26
4.1.3 Proizvodni objekti i postrojenja.....	27
4.1.4 Prijenosna i distribucijska mreža.....	31
4.1.5 Potrošači električne energije.....	35
4.2 Općenito o tržištu električne energije u RH	38
4.3 Model tržišta električne energije u Republici Hrvatskoj	39
5. PRIMJER PRIMJENE UMJETNIH NEURONSKIH MREŽA	41
5.1. Odabir ulaznih i izlaznih podataka za model umjetne neuronske mreže.....	41
5.2. Primjena prognoze opterećenja električne energije	46
5.3. Primjena prognoze cijene električne energije.....	53
6. ZAKLJUČAK	58
LITERATURA.....	59
SAŽETAK	61
ABSTRACT.....	61
ŽIVOTOPIS	62

1. UVOD

Predviđanje cijene na tržištu postalo je ciljem brojnih istraživanja na raznim tržištima (kao npr. burzovnim ili poljoprivrednim) te se tako dobivenim prognozama čak i trguje. Međutim, električna energija znatno se razlikuje od ostale robe; ona se ne može isplativo skladištiti budući da zagušenje u prijenosu može uzrokovati dodatne troškove. Stoga njezina cijena može znatno varirati, a metode koje se koriste za predviđanje cijena na drugim tržištima mogu imati jako velike pogreške kada se primjene na energetsom tržištu.

Ovisno o vrsti primjene, predviđanje cijene dijeli se u tri glavne kategorije: kratkoročno (nekoliko dana), srednjoročno (nekoliko mjeseci) te dugoročno (nekoliko godina). U ovome radu, pozornost će se posvetiti kratkoročnoj prognozi opterećenja i cijena (*STPF, en. short term price forecasting*) električne energije u restrukturiranom energetsom tržištu. Postoje različiti modeli prognoze u energetske sustavima. Među modelima su regresija, ekonometrija i metoda prostora stanja. Osim toga, koriste se i algoritmi bazirani na umjetnoj inteligenciji koji se temelje na ekspertnim sustavima, neizrazitoj logici, umjetnim neuronskim mrežama (ANN), te kombinacije ovih algoritama.

Od metoda za predviđanje neke su suviše komplicirane za implementaciju, dok su druge prejednostavne da bi pružile dovoljnu točnost. Metoda umjetnih neuronskih mreža pruža jednostavan i učinkovit alat za predviđanje. Najvažnije je razlučiti koje faktore uzeti u obzir, a koje zanemariti. Kao mjera preciznosti predviđanja koristi se srednja apsolutna postotna pogreška (*MAPE, en. Mean Absolute Percent Error*).

Umjetna neuronska mreža je oblik umjetne inteligencije koja pomoću matematičkih modela nastoji simulirati način učenja mozga. Učenje podrazumijeva predočavanje ulaznog seta podataka te pronalaženje veze između ulaznih i izlaznih varijabli. Možemo ga podijeliti u dvije kategorije: učenje s učiteljem (nadzirano) i učenje bez učitelja (nenadzirano). Ukoliko je poznat izlaz iz mreže pri učenju se koristi svaki ulazni primjer, tj. provodi se nadzirano učenje u obliku para ulaz-izlaz. Kada je točan izlaz nepoznat radi se o nenadziranom učenju te mreža uči bez poznavanja izlaza. Većinom se primjenjuje učenje s učiteljem.

U prvom poglavlju ovog rada detaljnije su opisane metode za prognozu opterećenja električne energije kao i faktori koji utječu na obrasce opterećenja. Također, obuhvaćena je osnovna teorija o modelima neuronskih mreža i njeno učenje pomoću Matlab-a. U drugom poglavlju

pojašnjeno je predviđanje cijene električne energije i predstavljen je model neuronskih mreža za prognozu. U istom poglavlju je definirana volatilitnost cijene električne energije. Treće poglavlje opisuje elektroenergetski sustav i tržište Republike Hrvatske. Četvrto poglavlje obuhvaća analizu primjene modela umjetnih neuronskih mreža za predviđanje opterećenja i cijene električne energije te su prikazani rezultati. Model je implementiran na temelju meteoroloških podataka za mjernu postaju Zagreb Pleso, satnih opterećenja za Republiku Hrvatsku i podataka o cijeni električne energije za razdoblje od 11.2.2016. do 8.10.2017. godine. Raspravlja se o rezultatima iz predloženog modela umjetne neuronske mreže na temelju srednje apsolutne postotne pogreške. Program koji je korišten za predviđanje opterećenja i cijene električne energije je Matlab.

2. PROGNOZA OPTEREĆENJA ELEKTRIČNE ENERGIJE

Glavni cilj prognoze opterećenja jest predvidjeti opterećenje kako bi se mogla planirati proizvodnja. Također, ona služi kako bi se postigao sigurniji rad sustava; za određivanje prikladne količine rezervi; za postizanje što ekonomičnijeg upravljanja sustavom; za pružanje podataka operatoru sustava te za rad tržišta. Prognoza opterećenja od iznimne je važnosti za energetske tržište, kako operatorima sustava, tako i operatorima tržišta, vlasnicima prijenosa i ostalim sudionicima na tržištu da bi mogli planirati energetske transakcije te napraviti prikladne planove rada i strategije ponuda na aukcijama [1].

2.1. Faktori koji utječu na obrasce opterećenja

Prvi korak za pravilno prognoziranje opterećenja jest identificirati faktore koji će utjecati na obrasce opterećenja. Za srednjoročnu i dugoročnu prognozu opterećenja uzimaju se povijesni podaci o opterećenju, vremenu, broju potrošača u raznim sektorima, karakteristikama električnih uređaja, ekonomskoj situaciji i demografskom stanju. Za kratkoročnu prognozu opterećenja važni su vremenski faktor, meteorološki faktor i ekonomski faktor.

Vremenski faktor uključuje utjecaje godišnjih doba, dana u tjednu, praznika i doba dana. Bitna je razlika u opterećenju radnih dana i vikenda jer je industrijsko opterećenje veće preko tjedna. Utjecaj godišnjeg doba može se pojasniti na smanjenju opterećenja ljeti jer se povećava broj sati dnevnog svjetla. Prognozu opterećenja teže je izvršiti za praznike [2].

Ekonomski uvjeti na nekom području mogu utjecati na oblik krivulje opterećenja. Ovi uvjeti mogu obuhvaćati različite tipove kupaca, demografsko stanje, industrijsku aktivnost. Standard građana svakako utječe na potrošnju električne energije. Uglavnom utječu na dugoročno prognoziranje [3].

Meteorološki faktori najvažniji su čimbenici u kratkoročnoj prognozi opterećenja, najutjecajnija među njima svakako je temperatura. Temperaturne promjene mogu utjecati na količinu potrebne energije za zagrijavanje zimi te klimatizaciju ljeti. Drugi meteorološki faktori jesu vlaga, oborine, oluje te dnevni intenzitet vjetera i svjetlosti.

Nasumične smetnje također utječu na krivulju opterećenja. Veliki industrijski potrošači mogu

izazvati nagle promjene opterećenja. Određeni događaji i uvjeti mogu stvoriti nagle promjene opterećenja kao što je npr. iznenadni prestanak rada industrijskih pogona ili popularne TV emisije.

Cijena električne energije ima važan utjecaj na prognozu opterećenja. Na električnom tržištu vrlo je promjenjiva.

Oblik opterećenja može biti različit ovisno o geografskim uvjetima te se razlikuje od urbanih do ruralnih područja. Opterećenje ovisi i o tipu potrošača te se promatra opterećenje u stambenom, komercijalnom i industrijskom sektoru [3].

2.2. Metode predviđanja

Prognoza opterećenja dijeli se na metode kratkoročnog, srednjoročnog i dugoročnog predviđanja. Metoda kratkoročnog predviđanja obuhvaća period do tjedan dana i koristi se za upravljanje elektroenergetskim sustavom, smanjenje gubitaka te regulaciju napona. Srednjoročno predviđanje opterećenja odnosi se na vrijeme od jednog do nekoliko tjedana te se koristi za planiranje kupnje ili prodaje električne energije susjednim mrežama.

2.2.1. Metode srednjoročne i dugoročne prognoze

Najčešće korištene metode pri srednjoročnom i dugoročnom predviđanju jesu metoda krajnje namjene te ekonometrija. Mogu se dobiti u rasponu od jedne do deset godina, a koriste se pri utvrđivanju ekonomske lokacije, tipa i veličine buduće elektrane. Jedini način za utvrditi točnost predviđanja je čekati da godina završi te usporediti stvarnu potrošnju s predviđenom. Točnost predviđanja ovisi o kvaliteti i količini povijesnih podataka, ispravnosti pretpostavke te točnosti predviđene promjene faktora koji utječu na potrošnju električne energije. Budući da se metode temelje na pretpostavkama, nikada ne mogu biti potpuno precizne.

Pristup krajnje namjene govori da potražnja za električnom energijom ovisi o krajnjem korisniku i krajnjoj uporabi za koju se električna energija koristi. Na primjer, proučavaju se povijesni podaci o tome koliko je električne energije utrošeno na električne uređaje u kućanstvu; tada se broj množi s prosječnim brojem električnih uređaja po kućanstvu te se taj broj množi s brojem kuća. Dobiva se procjena koliko će električne energije biti potrebno za sve električne aparate u kućanstvu za određeno geografsko područje tijekom bilo koje iduće godine. Na sličan

način dobivamo koliko je električne energije potrebno u komercijalnom i industrijskom sektoru te se dobiva predviđanje za ukupnu potrošnju električne energije. Prednost modela krajnje namjene jest ta da on prepoznaje gdje se troši koliko električne energije, koliko se koristi za koju svrhu te na taj način ukazuje na mogućnosti kompenzacije energije. Pomoću modela krajnje namjene, možemo pratiti koliko se električne energije uštedi povećanjem energetske učinkovitosti. Također, budući da su potrošači podijeljeni na stambeni, komercijalni i industrijski sektor, možemo predvidjeti promjenu opterećenja uzrokovanu promjenama u jednom od sektora. Nedostatak metode krajnje namjene jest to da zahtjeva opširne podatke o uređajima i korisnicima koji se neprestano mijenjaju te njihov odnos nije konstantan [2].

Ekonometrija povezuje ekonomsku teoriju, matematiku i statistiku kako bi predviđela zahtjeve za električnom energijom. Koristi kompleksne matematičke jednadžbe da bi prikazala prijašnje odnose između potražnje za električnom energijom i faktorima koji utječu na potražnju. Jednadžba može pokazati kako potražnja za električnom energijom ovisi o porastu populacije, promjeni cijena i sličnim faktorima te postotak povećanja ili smanjenja potražnje. Jednadžba se testira kako bismo bili sigurno da ona vjerno prikazuje odnose u prošlosti te se dodaju čimbenici poput broja korisnika, prihodi i cijene kako bi se dobilo predviđanje potrošnje električne energije. Prednost ekonometrije jest to što ona pruža detaljne informacije o budućoj potražnji za električnom energijom, odgovara na pitanja zašto se potražnja povećava ili smanjuje te koji su faktori utjecali na promjenu potražnje. Također, ona pruža uvid u potražnju po stambenom, komercijalnom i industrijskom sektoru. Nedostatak ove metode jest to što njena preciznost ovisi o pretpostavkama da ovisnost potražnje o faktorima ostaje ista kao u prošlom periodu. Ekonometrija se najčešće primjenjuje za predviđanja na regionalnom ili državnom nivou, a za manja geografska područja nije prikladna [4].

2.2.2. Metode kratkoročnog predviđanja

Pri upravljanju elektroenergetskim sustavom, prognoza opterećenja je u rasponu od nekoliko minuta do tjedan dana te se dijeli na jako kratkoročnu i kratkoročnu prognozu opterećenja. Jako kratkoročna prognoza opterećenja je prognoza sljedeće minute i koristi se za automatsko upravljanje proizvodnjom. Kratkoročna prognoza opterećenja je prognoza u rasponu od jednog do 168 sati. Rezultati kratkoročne prognoze većinom se koriste u svrhu planiranja proizvodnje. Općenito, kratkoročna prognoza opterećenja treba biti dostupna svako jutro prije 07:00h za sljedećih 40 sati. Prognoza za petak uključuje vikend i prognozu za nadolazeći ponedjeljak. Kada je prognoza za ponedjeljak od izuzetne važnosti, predviđanje može biti doneseno u

nedjelju [1].

Metode koje se koriste pri kratkoročnoj prognozi opterećenja su: pristup sličnog dana, regresijske metode, vremenski nizovi, umjetne neuronske mreže, ekspertni sustavi, neizrazita logika i metoda potpornih vektora.

Pristup sličnog dana temelji se na traženju povijesnih podataka za dane unutar nekoliko prethodnih godina koje imaju slična obilježja danu kojem se predviđa potrošnja. Karakteristike uključuju slične vremenske prilike, dan u tjednu i datum. Opterećenje sličnog dana uzima se kao predviđanje potrošnje električne energije. Umjesto jednog sličnog dana, predviđanje se dobiva linearnom kombinacijom ili regresijom više sličnih dana [2].

Linearna regresija opisuje odnos zavisne varijable s nezavisnom varijablom. Najprije se razmatraju nezavisne varijable koje su povezane uz vremenske uvjete kao što su temperatura, vlaga ili brzina vjetra. Zavisne su varijable potražnja i cijena električne energije jer ovise o proizvodnji koja ovisi o nezavisnim varijablama. Regresijski koeficijent pokazuje za koliko se u prosjeku mijenja vrijednost zavisne varijable za promjenu vrijednosti nezavisne varijable. Također, može se izmjeriti koliko je svaka nezavisna varijabla bila povijesno važna u odnosu na zavisnu. Postoji nekoliko regresijskih metoda za kratkoročnu prognozu vršnog opterećenja. Modeli sadrže determinističke utjecaje kao što je praznik, slučajne varijable kao što je prosječno opterećenje i vanjske utjecaje kao što su meteorološki uvjeti [4].

Vremenski nizovi pristup su koji se zasniva na ideji da se pouzdano predviđanje može postići pronalaženjem uzorka u vremenu te ekstrapolacijom doći do uzoraka u budućnosti. Model vremenskih nizova može biti točan u određenim situacijama, ali je iznimno kompleksan i zahtjeva veliku količinu povijesnih informacija te se ne primjenjuje često za predviđanje potrošnje električne energije jer ne uzima u obzir ključne faktore kao što je vremenska prognoza [4].

Ekspertni sustavi rezultat su napretka u polju umjetne inteligencije. Ekspertni sustav je računalni program koji ima sposobnost da djeluje kao stručnjak, što znači da može zaključivati, objasniti kako je došao do određenog rješenja te proširiti znanje novim informacijama. Model predviđanja opterećenja rade stručnjaci iz nekog specijalističkog područja. Prema literaturi [2], ekspertni sustavi „koriste činjenice, znanje i zaključivanje kod rješavanja problema. Baza znanja sastoji se od pravila koja kroz duže vrijeme ostaju nepromijenjena, a baza činjenica

mijenja se kroz vrijeme kako se mijenja tok rješavanja zadanog problema. Mehanizam zaključivanja traži rješenje problema tako da ispituje činjenice u bazi činjenica i znanje u bazi znanja te korištenjem činjenica i pravila izvodi niz akcija pomoću kojih će pokušati dokazati neku hipotezu ili pokazati da cilj nije moguće dokazati“.

Neizrazita logika osnovana je na Booleovoj logici gdje ulazne vrijednosti mogu imati vrijednost oblika "0" i "1". U slučaju neizrazite logike, ulazna vrijednost ovisi o usporedbi koja se zasniva na kvalitativnoj vrijednosti. Omogućuje logičko utvrđivanje izlaza od ulaza. Prednost neizrazite logike jest to da nema potrebe za matematičkim modelima za mapiranje između ulaza i izlaza te nema potrebe za preciznim ulaznim podacima. Opterećenje elektroenergetskog sustava ovisi o brojem faktorima kao što su vrijeme, ekonomske i socijalne prilike. Analizom povijesnih podataka nije jednostavno dobiti točnu prognozu opterećenja. Inteligentne metode kao što su neizrazita logika i ekspertni sustavi imaju prednost nad konvencionalnim metodama [2].

Metoda potpornih vektora je algoritam koji se koristi za klasifikacijske i regresijske probleme. Za razliku od ostalih inteligentnih sustava koji pokušavaju definirati složene funkcije ulaznih vrijednosti, potporni vektori koriste nelinearno mapiranje podataka u višedimenzionalne značajke koristeći kernel funkcije. Pomoću jednostavnih linearnih funkcija dobiva se linearna granica odluke u ekspaniranom prostoru. Javlja se problem odabira prikladne kernel funkcije [4].


U sljedećem poglavlju opisana je metoda umjetnih neuronskih mreža.

2.3. Kratkoročno predviđanje opterećenja sa modelom umjetnih neuronskih mreža

Glavni problem u prethodno navedenim modelima jest postavljanje odgovarajućeg nelinearnog matematičkog modela za opterećenje i ostale podatke kao što su temperatura i vlažnost. Druga metoda za predstavljanje nelinearnih funkcija jest korištenje sustava umjetnih neuronskih mreža (*ANN, en. Artificial Neural Network*) koji može predstavljati bilo koje nelinearne funkcije.

2.3.1. Opis modela i arhitekture umjetne neuronske mreže


Umjetna neuronska mreža je sustav za obradu podataka na računalu koji simulira postupak učenja u ljudskom mozgu. Ljudski mozak sastoji se od milijardi međusobno povezanih stanica koje se zovu neuroni. Prema slici 2.1, neuroni se sastoje od četiri dijela: soma ili tijelo stanice, dendrita, aksona i sinapsi.



Slika 2.1. Građa neurona [5]

Dendriti primaju električni potencijal od drugih neurona. Prema literaturi [1], „sinapsa je mjesto komunikacije između dva neurona. To je mjesto na kojem se signal prenosi s jednog neurona na drugi“. Ekscitacijski transmittori povećavaju napon potencijala, a inhibicijski smanjuju napon potencijala. Soma sažima sav potencijal koji su dali dendriti. Ako zbroj potencijala prelazi određenu vrijednost (prag), soma će otpustiti akcijski potencijal kroz akson. Akson će isporučiti ovaj akcijski potencijal drugom neuronu. Nakon otpuštanja akcijskog potencijala, mijenja se električni naboj i neuron je depolariziran. Nakon toga, neuron je neko vrijeme refraktoran – nepodraživ [1].


Matematički model neurona prikazan je na slici 2.2 dendriti su modelirani kao ulazni vektor koji okuplja informacije izvan neurona. Težinski vektor opisuje jakost sinapse. Sumator predstavlja somu koja sažima sve ulazne informacije. Prijenosna funkcija predstavlja određenu vrijednost koji upravlja akcijskim potencijalom neurona, a akson je prikazan kao izlazni vektor.



Slika 2.2. Matematički model neurona [5]

Svaki model umjetne neuronske mreže može se klasificirati po svojoj arhitekturi, učenju i treningu. Arhitektura opisuje neuronske veze. Učenje podrazumijeva postupak pri kojem se želi postići da mreža na temelju predočavanja ulaznih primjera što točnije prognozira buduće rezultate. Treniranje mreže služi za podešavanje težinskih faktora funkcija.

Prema [1] arhitektura umjetne neuronske mreže sastoji se od tri dijela: ulazni sloj, skriveni sloj i izlazni sloj, kao što je prikazano na slici 2.3 ulazni sloj je povezan s vanjskim svijetom, te prima informacije iz vanjskog svijeta. Skriveni sloj nema vezu s vanjskim svijetom; on samo spaja ulazni i izlazni sloj. Izlazni sloj daje ANN izlaz prema vanjskom svijetu nakon što je mreža obradila ulaznu informaciju.




Slika 2.3. Model umjetne neuronske mreže [1]

Postoje četiri vrste arhitekture modela neuronskih mreža koje se najčešće koriste, a to su: jednoslojna, višeslojni perceptron, Hopfieldova i Kohonenova mreža. Jednoslojni mreža nema

skriveni sloj, kao što je prikazano na slici 2.4.. Kako se ulazni sloj ponekad ne računa kao sloj, ova arhitektura smatra se jednoslojnom mrežom. One se još nazivaju i unaprijedne neuronske mreže, budući da protok informacija teče u jednom smjeru, odnosno, prema izlaznom sloju.


Višeslojni perceptron najčešće se primjenjuje. Na slici 2.4 je prikazano kako za razliku od jednoslojnog perceptrona, višeslojni perceptron uvijek ima skriveni sloj.

Najjednostavniji oblik višeslojne perceptrone mreže ima tri sloja: ulazni sloj, skriveni sloj i izlazni sloj. Još uvijek ne postoji najbolja metoda za utvrđivanje broja skrivenih slojeva i neurona za pojedini skriveni sloj. Ovaj broj obično se traži pomoću heuristike.




Slika 2.4. Jednoslojna i višeslojna mreža [1]

Hopfieldova mreža temelji se na principu pamćenja informacija u dinamički stabilnim stanjima, kao što je prikazano na slici 2.5., budući da u toj mreži sloj ne prima samo informacije iz prethodnog sloja, nego i iz prethodnog izlaza i veze. Svaki neuron povezan s drugim neuronom imat će dvije izlazne vrijednosti: -1 (ugašen OFF) ili 1 (upaljen ON). Izlaz svakog neurona ovisi o prethodnoj aktivaciji [1].



Slika 2.5. Hopfieldova mreža [1]

Kohonenova mreža sastoji se od unaprijednih ulaznih jedinica i bočnog sloja, kao što je prikazano na Slici 2.6. Bočni sloj ima više neurona, koji su bočno povezani sa svojim susjedima. Kohonenova se mreža može samoorganizirati te tako uzrokovati da susjedne jedinice učine isto.



Slika 2.6. Kohonenova mreža [1]

2.3.2. Kratkoročna prognoza opterećenja pomoću MATLAB-ove ANN „alatne kutije“

MATLAB je izuzetno učinkovit programski jezik za tehničko proračunavanje. Omogućava računanje, vizualizaciju i programiranje u okolini jednostavnoj za korištenje [7]. Matlabove „alatne kutije“ zbirke su m-datoteka koje proširuju mogućnosti MATLAB-a na brojne tehničke grane kao što su: upravljanje sustavima, obrada signala, optimizacija i umjetne neuronske mreže. U ANN alatnoj kutiji MATLAB posjeduje funkcije za treniranje mreže i primjer modularne mreže, prema kojoj korisnik može dizajnirati svoju mrežu prema potrebama.

S obzirom da MATLAB pruža niz alata, logično je koristiti ANN „alatnu kutiju“ za prognoziranje opterećenja.

Ulazni sloj. Važno je napomenuti da se unutar ulaznog sloja mogu nalaziti svi čimbenici koji utječu na opterećenje direktno ili implicitno, kao što su vrsta dana, opterećenje, temperatura, vlažnost i vjetar.

Skriveni sloj. Mreže su osjetljive na broj neurona u skrivenom sloju koji je potrebno odrediti pomoću heuristike (iskustva) jer ne postoji općenita metoda za određivanje točnog broja

neurona. Ako je broj premal, mreža neće biti u stanju naći složene relacije između ulaznih i izlaznih varijabli te može imati otežano usklađivanje tokom treniranja. Ako je broj neurona prevelik, proces treniranja trajat će predugo te će se na taj način ugroziti sposobnost ANN. Zbog prevelikog broja neurona može doći do prekomjerne specijalizacije modela, tj. do toga da model loše klasificira nove podatke, zbog prenaučivosti na testnim podacima. [6]

Broj neurona u skrivenom sloju varira ovisno o primjeni i često ovisi o veličini seta treniranja i broju ulaznih varijabli. Neka od pravila koja se primjenjuju:

- Broj neurona u skrivenom sloju jednak je dvostrukoj vrijednosti broja neurona na ulaznom sloju plus još jedan neuron, ili je
- Broj neurona u skrivenom sloju jednak sumi broja neurona u ulaznom i izlaznom sloju, ili je
- Broj neurona u skrivenom sloju jednak sumi broja neurona u ulaznom i izlaznom sloju podijeljenom sa 2

U praksi je bolje izvesti nekoliko pokušaja prije nego odredimo točan broj. [1]

Izlazni sloj. Izlazni sloj je vrlo lako postaviti usporedbom sa ulaznim i skrivenim slojem. Potrebno je postaviti ciljane opterećenje za fazu treniranja i stvoriti rezultate prognoza u fazi prognoziranja.

Jedna od ključnih stavki za projektiranje dobre arhitekture umjetnih neuronskih mreža jest odabir odgovarajuće ulazne varijable. U slučaju kratkoročnog predviđanja opterećenja, te ulazne varijable mogu se podijeliti na vrijeme, električno opterećenje i informacije o vremenskim prilikama. Vremenske informacije mogu uključivati vrstu godišnjeg doba, dana u tjednu i sate dana. Informacije o opterećenju mogu uključivati prethodna opterećenja. Vremenske informacije mogu uključivati prošle i buduće temperature, oblake, grmljavinu, vlagu i kišu.

Do sada nije bilo općih propisa o vrstama ulaznih podataka u kreiranju umjetnih neuronskih mreža za kratkoročna predviđanja opterećenja. Međutim, po principu, povijesno opterećenje i temperatura predstavljaju najvažnije ulaze. Za normalno klimatsko područje, ta dva ulazna podatka i drugi srodni ulazi (npr. vrijeme) bit će dovoljni da bi se napravilo dobro kratkoročno predviđanje opterećenja. Za ekstremne vremenske uvjeti u vlažnim područjima ili za područja s puno oluja, za predviđanje opterećenja trebalo bi uključiti dodatne vremenske faktore.

2.3.4. Aktivacijske funkcije


Prema ugrađenoj prijenosnoj funkciji razlikuju se vrste matematičkog modela umjetnog neurona koji je prikazan na slici 2.2. Prema [5] najjednostavnija aktivacijska funkcija je

$$f(\text{net}) = \text{net} \quad (2-1)$$

Izlaz neurona opisujemo kao težinsku sumu njegovih ulaza..

Moguće je koristiti funkciju skoka ili praga (*en. Threshold function, gard-limiter*) koja daje Booleov izlaz. Prema literaturi [9], „neuron s ovakvim tipom aktivacije naziva se McCulloch-Pitts model. Svojstvo modela je sve ili ništa“.


$$f(\text{net}) = \begin{cases} 0, & \text{net} \leq 0 \\ 1, & \text{net} > 0 \end{cases} \quad (2-2)$$



Slika 2.7. Funkcija skoka [5]

Prijenosna funkcija može biti definirana linearno po odsječcima te slijedi:


$$f(\text{net}) = \begin{cases} 0, & \text{net} \leq a \\ \text{net}, & a < \text{net} < b \\ 1, & \text{net} \geq b \end{cases} \quad (2-3)$$



Slika 2.7 Djelomično linearna prijenosna funkcija [5]

Najčešći oblik aktivacijske funkcije jest sigmoidalna funkcija. Najvažnije svojstvo ove funkcije je da je diferencijabilna što olakšava učenje neuronske mreže. Naziva se i logističkom funkcijom.

$$f(\text{net}) = \frac{1}{1+e^{-a \text{net}}} \quad (2-4)$$



Slika 2.7. Sigmoidalna prijenosna funkcija [5]

Parametar a određuje nagib funkcije. U slučaju kada $a \rightarrow \infty$ sigmoidalna funkcija postaje funkcija praga [9].

2.3.4. Postupak učenja mreže

Faze rada umjetnih neuronskih mreža mogu se podijeliti na: fazu učenja ili treniranja, fazu selekcije, fazu testiranja te na operativnu fazu ili fazu opoziva.

Učenje neuronske mreže je postupak kroz koji se težine postupno prilagođavaju sve dok izlaz iz mreže nije zadovoljavajući. Podaci u izlaznom sloju predstavljaju željene vrijednosti izlaznih varijabli.

Ovisno o tome je li nam poznat izlaz iz mreže ili je točan izlaz nepoznat, razlikujemo učenje s učiteljem i učenje bez učitelja. Učenje s učiteljem provodi se primjerima u obliku para (ulaz, izlaz), dok kod učenja bez učitelja mreža uči bez poznavanja izlaza.

Skup primjera za učenje dijeli se na skup za učenje, skup za testiranje i skup za provjeru. Preporuča se najveći dio podataka ostaviti za treniranje mreže. Skup za učenje služi za podešavanje težinskih faktora. Pomoću skupa za testiranje, za vrijeme učenja vrši se provjera rada mreže s trenutnim težinskim faktorima kako bi se postupak učenja zaustavio u trenutku degradacije performanse mreže. Umjetnu neuronsku mrežu moguće je pretrenirati. Nakon određenog broja iteracija, mreža gubi svojstvo generalizacije te postaje stručnjak za obradu podatka iz skupa primjera za učenje dok preostale podatke obrađuje loše. Stalnim praćenjem izlaza iz mreže dobivenog pomoću primjera iz skupa za testiranje moguće je otkriti iteraciju u kojoj dobiveni izlaz najmanje odstupa od željenog. Skup za provjeru služi za provjeru točnosti i preciznosti obrade podataka [5]. Nisu definirana strogo određena pravila za dužinu treniranja.

Na osnovu dobivene pogreške umjetne neuronske mreže određuje se kriterij zaustavljanja procesa treniranja. Pogrešku određujemo apsolutnom postotnom pogreškom (*en. APE - Absolute Percent Error*) i srednjom apsolutnom postotnom pogreškom (*MAPE en. Mean Absolute Percent Error*) čija je definicija:

$$|APE| = \frac{|L_f - L_a|}{L_a} \times 100\% \quad (2-5)$$

$$MAPE = \frac{1}{N_h} \sum_{N_h} APE \quad (2-6)$$

gdje N_h označuje broj sati za period prognoziranja [1].

Određuje se tačnost prema kojoj se svaki model trenira po vlastitom podešavanju treniranja. Nakon što model dosegne maksimalan broj epoha završava se treniranje i dobivaju se rezultati treniranja. Zatim slijedi testiranje pomoću seta podataka realnih mjerenih vrijednosti i kao rezultat se dobivaju simulirane vrijednosti mreže.

Usporedbom simuliranih vrijednosti nakon testiranja i stvarno izmjerenih vrijednosti mjerenja moguće je izračunati APE i MAPE. Ako je izračunata MAPE viša od 3%, trening se mora ponoviti. Taj proces nastavlja se sve dok sve MAPE iz testnih rezultata ne budu ispod 3%.


Vrijeme potrebno za dostizanje srednje apsolutne postotne pogreške razlikuje se ovisno o modelu. Jedan od razloga jest veličina vektora treniranja. Nadalje, razlozi mogu biti razlika temperatura. Velika razlika temperatura u svakom modelu otežava raspoznavanje strukture umjetne neuronske mreže.

3. PREDVIĐANJE CIJENE ELEKTRIČNE ENERGIJE

3.1. Uvod u predviđanje cijene električne energije

Cijena električne energije na energetsom tržištu najvažniji je faktor svim njegovim sudionicima, a najosnovniji koncept jest određivanje tržišne cijene poravnavanja (en. *MCP - market-clearing price*), što znači da ponuda mora biti jednaka potražnji. ANN analiza ostvaruje vezu između cijene električne energije i uzročnika promjene cijene. Ako nema nikakvih zagušenja na mreži, određena tržišna cijena će vrijediti za cijelo tržište, ali u slučaju zagušenja formira se cijena poravnavanja za određene zone (en. *ZMCP – Zonal Market Clearing Price*) ili lokacije (en. *LMP - Locational Marginal Price*) [1].

Izračunavanje tržišne cijene poravnavanja vrši se tako da nakon zaprimljenih ponuda, nezavisni operateri izračunavaju krivulju ponude (S) i krivulju potražnje (D). Na njihovom sjecištu nalazi se vrijednost cijene određena MCP metodom.




Slika 3.1. Izračun tržišne cijene [1]

Pomoću tržišne cijene poravnavanja određene zone računa se razina zagušenja ili naknada korištenja prijenosnog voda za svaki zagušeni vod. Ako u bilo kojem periodu nezavisni operater primijeti zagušenje na bilo kojem prijenosnom putu, vrši se prilagodba rasporeda zona kako bi se gušenje eliminiralo.


Tržišna cijena poravnavanja određene lokacije (LMP) prikazuje trošak isporuke idućeg MW snage za određenu lokaciju, uzimajući u obzir graničnu cijenu generiranja energije, trošak gušenja u prijenosu i gubitaka, iako se trošak uzrokovan gubicima uglavnom zanemaruje. Ako nema gušenja, LMP jednak je MCP-u.

3.2. Volatilnost cijene električne energije

Najizraženije svojstvo električne energije jest njezina volatilnost. To je mjera promjene cijene električne energije kroz određeni period. Najčešće se izražava u postotnom obliku, a računa se na godišnjoj razini kao standardna devijacija promjene dnevnih cijena (u nekim slučajevima se uzimaju tjedne ili mjesečne cijene). U usporedbi s opterećenjem mreže, cijena električne energije u restrukturiranoj energetske mreži je znatno nestabilnija. Potrebno je odrediti pravila koja se pojavljuju na tržištu, npr. promatranjem cijena koje su se ponavljale u istim periodima u prethodnim razdobljima. Slike 3.2 i 3.3 prikazuju usporedbu cijene električne energije u Republici Hrvatskoj za prvi tjedan u srpnju 2016. i 2017. godine prema podacima preuzetim sa internetske stranice Hrvatske burze električne energije CROPEX [18].



Slika 3.3 Cijena električne energije za prvi tjedan u srpnju 2016. godine



Slika 3.3 Cijena električne energije za prvi tjedan u srpnju 2017. godine

Glavni razlog za promjenjivost jest uvjet da ponuda i potražnja u svakom trenutku moraju biti iste. Osim toga, postoje i sljedeći razlozi:

- Promjenjivost cijena goriva
- Nepouzdanost opterećenja
- Oscilacije u hidroelektričnoj proizvodnji
- Nepouzdanost generiranja energija (prekidi u radu)
- Zagušenja u prijenosu
- Ponašanje sudionika tržišta (ovisno o očekivanim cijenama)
- Tržišno manipuliranje

Zbog svih ovih svojstava, promjenjivost struje ima znatno više razine nego druge vrste robe u energetske segmentima te je teško napraviti točno predviđanje cijena struje.

3.3. Kategorizacija predviđanja cijene

Kategorizacija se vrši ovisno o promatranom periodu, točki predviđanja te vrsti korisnika.

Ovisno o vremenskom periodu postoje dvije glavne vrste vremenskog predviđanja - kratkoročno i dugoročno. Kratkoročne metode koriste se pri odlučivanju o strategijama za slanje ponuda tržištu ili pri bilateralnim transakcijama. Dugoročno predviđanje važno je za planiranje novih lokacija generatora i time ostvarivanje uspješnih poslova u izuzetno promjenljivoj okolini.

Prema točki predviđanja postoje predviđanja za cijeli sustav (MCP), specifičnu zonu (ZMCP) ili specifični vod (LMP).

Kategorizacija prema vrsti korisnika dijeli se na:

- Predviđanje cijene nezavisnih operatora u biti je određivanje tržišne cijene. Ova vrste predviđanja nije predviđanje u pravom smislu riječi jer se ono može napraviti tek nakon što se dobiju ponude od potrošača.
- Proizvođači električne energije rade predviđanje MCP, ZMCP i LMP-a prije nego dobiju ponude. Svaki proizvođač električne energije ima jako malo informacija o

drugim proizvođačima; najčešće samo one koje su javno dostupne, kao što je predviđeno opterećenje te povijesni podaci o opterećenju ili MCP cijenama. Zbog ograničenih informacija, točnost ovog predviđanja ne može biti velika. Što predviđanje bude bliže tržišnoj cijeni, proizvođači električne energije imat će veću dobit [1].

3.4. Faktori za predviđanju cijene električne energije

Faktori koji se koriste za predviđanje cijene električne energije mogu se grupirati na sljedeći način:

- Vrijeme: sat u danu, dan u tjednu, mjesecu, godini i posebni dani
- Pričuva: povijesna ili predviđena
- Cijena: povijesna cijena
- Opterećenje: povijesno ili predviđeno. Promjene opterećenje mogu utjecati na cijenu, ali i promjena cijena na opterećenje. Zbog toga se predviđanje cijene i opterećenja promatra u istom modelu
- Cijena goriva

3.5. Model predviđanja cijene temeljen na ANN

Simuliranjem cijene električne energije pokušavamo proučiti utjecaje fizičkih karakteristika sistema, strategija potraživanja tržišta i raspodjele opterećenja na cijene. Sama simulacija oponaša stvarni prijenosni sustav sa svojim ograničenjima i zahtjevima. Rezultati mogu ukazati na više mogućih razvoja situacije na tržištu. Svaka simulacija mora sadržavati detaljni model energetskeg sustava i procedure procjenjivanja električne energije. Energetski sustav se sastoji od tri dijela: generiranja, prijenosa i distribucije, stoga se svaki od njih mora uzeti u obzir pri simulaciji. Glavni čimbenici koji utječu na cijenu generiranja su dostupnost generatora i strategija kupovanja generatora. Najčešće se ovi podaci mogu pronaći u podacima iz prethodnih razdoblja. Trebalo bi se obratiti i pozornost na: model prijenosne mreže, ograničenost prijenosa te sigurnost prijenosa. Također, bitan faktor u prognozi cijene su nestanci struje i prekidi u radu generatora.

Klasične metode predviđanja uključuju regresiju i metodu prostora stanja. Moderne metode uključuju ekspertne sustave, evolucijsko programiranje, neizrazite (fuzzy) sustave, umjetne neuronske mreže i razne kombinacije svega navedenog. ANN dobiva najviše pažnje zbog svoje jednostavnosti, lake primjene i dobrih rezultata. U predviđanju metodom umjetnih neuronskih mreža, uzimaju se parametri koji odgovaraju povijesnim podacima te mogu pomoću stvarnih ulaznih vrijednosti predvidjeti cijene u budućnosti. Problem kod ANN-a jest to što nije moguće prikupiti trenutne vrijednosti faktora, kao što su zagušenje i druge nepredviđene situacije. Ulazni sloj sadrži vremenski faktor (dana u tjednu ili sat u danu), faktor opterećenja (opterećenje sustava i sabirnice), i podatke o vodu (stanje i ograničenja voda); izlazni sloj predstavlja pojedinačne cijene sabirnica; broj neurona u skrivenom sloju najčešće je jednak prosječnom broju neurona u ulaznim i izlaznim slojevima.

Prema literaturi [10], „zagušenjem u prijenosnoj mreži nazivamo stanje prijenosnog sustava u kojem proizvođači ili potrošači električne energije žele proizvesti i potrošiti električnu energiju na način koji bi uzrokovao pogon prijenosnog sustava na granici jednog ili više ograničenja. Ograničenja podrazumijevaju prekoračenje termičkih granica, nezadovoljavanje naponskih prilika i nestabilnost rada sustava“.

U velikim sustavima teško je uključiti informacije o svim sabirnicama jer bi sama ANN znatno porasla, što bi povećalo i vrijeme učenja mreže. Stoga je potrebno smanjiti veličinu ANN-a, a istovremeno zadržati određenu razinu točnosti smanjivanjem broja ulaznih neurona ili smanjivanjem broja ulaznih vektora ili oboje. Kako bi se smanjio broj neurona, umjesto za svaku sabirnicu pojedinačno, koriste se zonska opterećenja. Također se može zanemariti vremenski faktor jer je ta informacija sadržana u faktoru ulaznog opterećenja. Broj ulaznih vektora se smanjuje tako da ih se podijeli u grupe. Ako su rezultati druge grupe nakon učenja kroz MATLAB jednaki rezultatima prve grupe, drugu možemo zanemariti [1].

Za učenje ANN-a potreban je pokazatelj prema kojem se stvara uzorak ponuda. Jedno od rješenja je uzeti vremenski period promatranja, npr. dan u tjednu koji će biti novi ulazni podatak. Ako želimo staviti da se promatra sat u danu stavljamo drugi novi ulazni podatak, ako želim promatrati i dane i sate posebno, potrebno je unijeti dvije posebne varijable.

Što je sustav veći, to je manji utjecaj prestanka rada generatora na tržišnu cijenu. Za promatranje prekida rada generatora koristi se prekid cijele zone, međutim, zbog osjetljivosti analize, jako su bitne i same lokacije generatora.


3.5.1 Utjecaj zagušenja u prijenosu

Zagušenje može uzrokovati različite cijene sabirnica (zona), stoga je predviđanje stupnja zagušenosti bitan faktor u predviđanju cijene. Do zagušenja dolazi kada ukupan tok snage na vodu prelazi granice ograničenja samog voda. Pomoću informacija o tokovima snaga i ograničenjima voda može se predočiti zagušenje i njegova razina. Zbog toga se računaju utjecaji zagušenja i ograničenja vodova na cijenu, kako bi pronašli vezu između cijene i zagušenja.


Vežu možemo prikazati u ANN-u na dva načina. Prvi je da ograničenje voda i tok snaga unesemo kao ulazne varijable kao što je prikazano na slici 3.5, ali u slučaju velikog broja vodova dolazi do problema. Zbog toga se najčešće promatraju samo glavni vodovi (međuzonske). Postoji još jedna opcija da se ograničenje voda i tok unesu kao dio pokazatelja zagušenja koji je sposoban prikazati fizičko ponašanje sustava. Jedan primjer takvog slučaja:

$$I_c = \sum_i f(L_i - F_i) \quad (3-1)$$


Gdje je I_c pokazatelj zagušenja, L_i je ograničenje voda, a F_i je tok voda i .



Slika 3.4. ANN model za eksplicitno promatranje zagušenja [1]



Slika 3.5 Pokazatelj zagušenja [1]



Slika 3.6 ANN model za pokazatelj zagušenja [1]

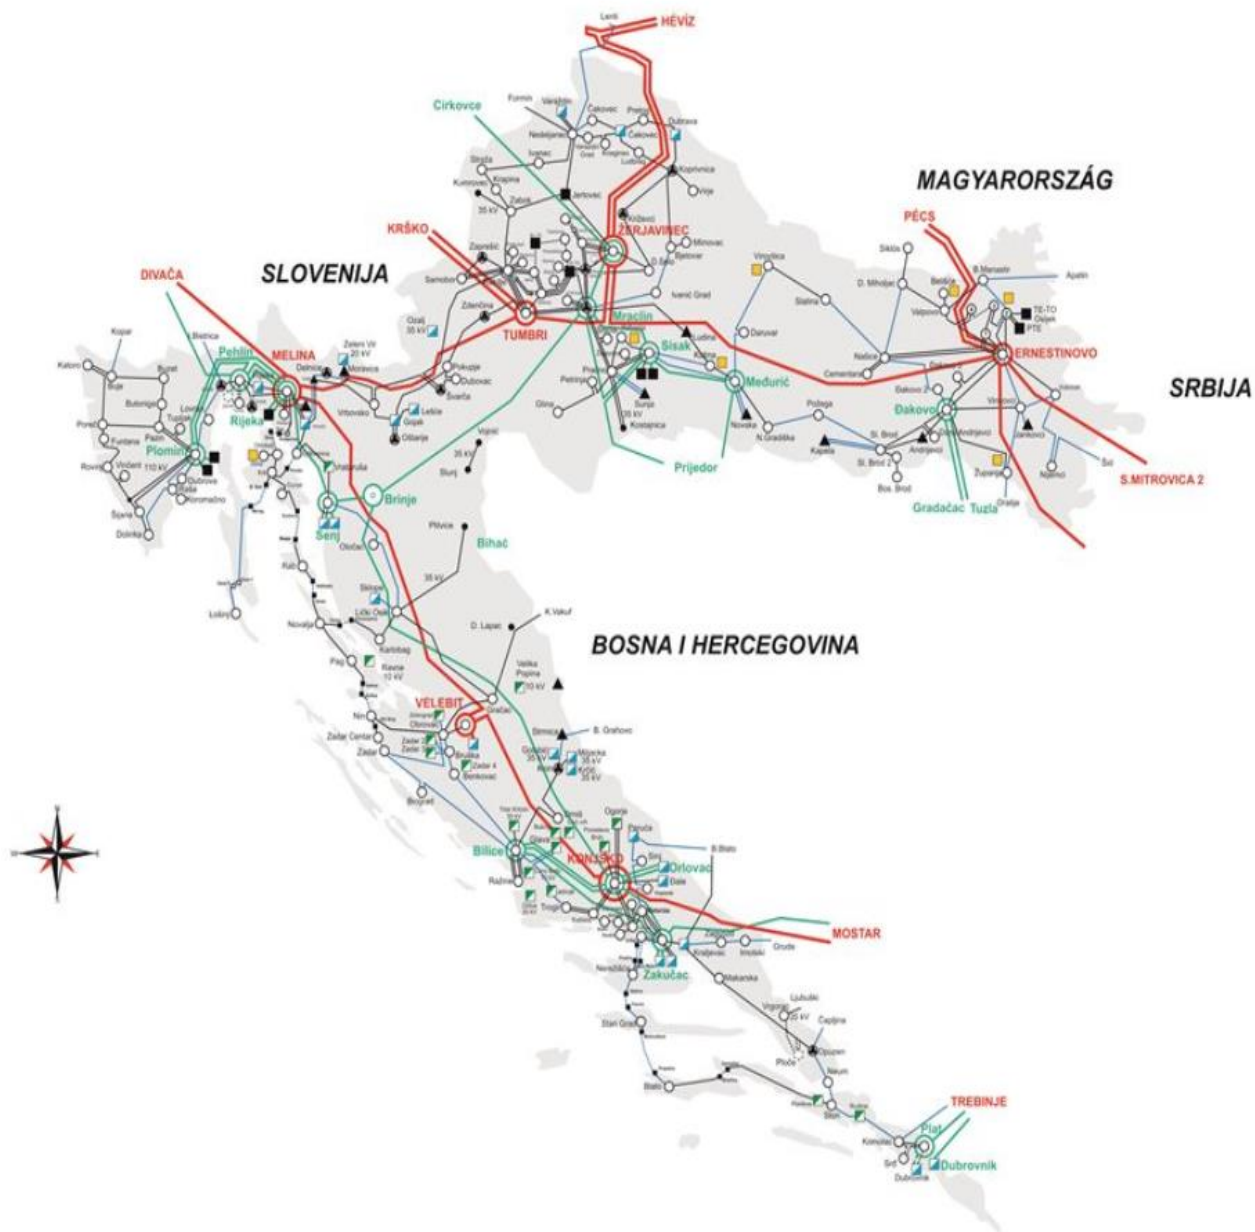
Slika 3.5 pokazuje da je mogućnost zagušenja sve veća kako se stvarni tok snage približava granici. Kada je opterećenje voda puno manje od limita, onda je i sama mogućnost zagušenja manja. Ovaj faktor se može koristiti kao ulazna varijabla u ANN-u što je prikazano na slici 3.6. Razlika između slučaja na slici 3.4 i 3.6 je što potonji ima samo jednu ulaznu varijablu koja se odnosi na zagušenje.

4. TRŽIŠTE ELEKTRIČNE ENERGIJE U HRVATSKOJ

4.1 Hrvatski elektroenergetski sustav

Elektroenergetski sustav (EES) je složeni sustav koji čine proizvođači električne energije, prijenosna i distribucijska mreža te potrošači električne energije. Čini sastavni dio upravljačkog bloka SLO – HR – BIH unutar ENTSO-E (*en. the European Network of Transmission System Operators*) zajedno sa slovenskim EES-om i EES-om Bosne i Hercegovine te je povezan s ostalim sustavima članica ENTSO-E koji zajedno tvore sinkronu mrežu kontinentalne Europe. Električna energija se zbog geografskog položaja i rasporeda elektrana uglavnom prenosi s juga na sjever i obratno, te sa sjevera ka istoku. Prema veličini hrvatski EES je jedan od manjih sustava u Europi [11]. Ukupna instalirana snaga nešto je veća od 4453 MW, što uključuje i hrvatski dio NE Krško [12].

Hrvatski EES je regulacijsko područje koje vodi HOPS (Hrvatski operator prijenosnog sustava d.o.o.). Prema [11], „HOPS obavlja energetske djelatnosti prijenosa električne energije, proizvedene u Hrvatskoj ili uvezene iz inozemstva, hrvatskim kupcima ili kupcima u drugim zemljama te tranzit električne energije preko prijenosne mreže hrvatskog elektroenergetskog sustava (EES)“. Također, zadaća mu je vođenje EES Republike Hrvatske, brine o održavanju, razvijanju i izgradnji prijenosnih mreža zbog pouzdanosti opskrbljivanja korisnika uz što manje troškove i očuvanje okoliša. HOPS d.o.o. posluje kao neovisni operator prijenosa od 2.7.2013. godine, odnosno djeluje izvan Hrvatske elektroprivrede d.d. Jedini upravlja elektroenergetskim prijenosnim sustavom Republike Hrvatske te je kao vlasnik cjelokupne hrvatske prijenosne mreže mjerodavan i odgovoran za uklopna stanja jedinica prijenosne mreže 400 i 220 kV i 110kV. Nezavisan je od djelatnosti proizvodnje i opskrbe električnom energijom [11].



Slika 4.1. Shema hrvatskog elektroenergetskog sustava [11]

Slika 4.1 prikazuje trenutno stanje prijenosne mreže hrvatskog EES-a. Crvenom bojom označeni su 400kV prijenosni vodovi, zelenom bojom 220kV, a crnom bojom je označena 110kV prijenosna mreža. Republika Hrvatska ima posebice dobre veze sa Slovenijom (dvostruki 400 kV vod) i Mađarskom (2 dvostruka 400 kV voda). Vezu sa Slovenijom, Mađarskom, Srbijom i Bosnom i Hercegovinom čine jednostruki vodovi na sve 3 naponske razine.

4.1.1 Usluge operatora prijenosnog sustava

Vođenje sustava je usluga kojom se vrši koordinacija planiranja potrošnje i proizvodnje električne energije; nadziru se svi oblici razmjene električne energije, analizira i upravlja hrvatski elektroenergetski sustav. Naplaćuje se kroz naknadu za korištenje prijenosne mreže kao nepridjeljiva usluga. Prema [11], „kad se opterećenja jedinica mreže približe njihovoj nazivnoj snazi nastaju zagušenja u mreži. HOPS u takvim okolnostima mora primijeniti posebne mjere smanjenja opterećenja jedinica mreže kako bi se očuvala sigurnost sustava: promjenom proizvodnje elektrana, promjenom stanja regulacijskih transformatora i uklopnog stanja mreže ili izmjenom ugovornih rasporeda tržišnih sudionika. Usluga se naplaćuje kroz naknadu za korištenje prijenosne mreže“.

Održavanje napona i frekvencije – parametri koji iskazuju kvalitetu električne energije su napon, frekvencija i valni oblik električne energije. Odgovornost operatora prijenosnog sustava je da osigura kvalitetu električne energije. Naplaćuje se kroz naknadu za korištenje mreže.

Ponovna uspostava EES-a nakon poremećaja ili isključenja. Ukoliko dođe do poremećaja parametara kvalitete električne energije, isključenja jedinica mreže ili raspada elektroenergetskog sustava operator postupa sukladno određenom slučaju poremećaja kako bi ponovno uspostavio sustav. Usluga se naplaćuje kroz naknadu za korištenje prijenosne mreže [11].

Prema [11], „pomoćne usluge daje korisnik mreže (npr.proizvođač) ili operator distribucijskog sustava na zahtjev operatora prijenosnog sustava i za čiju dobavu (tehničko rješenje, pogonski troškovi) operator prijenosnog sustava računa s primjerenom naknadom troškova. Te usluge koristi operator prijenosnog sustava za ostvarenje usluga sustava“.

Održavanje frekvencije u EES-u vrši se primarnom, sekundarnom i tercijarnom regulacijom proizvođača električne energije. Za reguliranje frekvencije služi primarna regulacija, a sekundarna i tercijarna regulacija služe za reguliranje frekvencije i snage razmjene.

Regulacija napona i proizvodnje jalove energije je pomoćna usluga kojoj je zadaća održati napon u propisanim granicama i smanji tokove jalove energije u mreži. Vršiti se podešavanjem prijenosnih odnosa transformatora, kompenzacijskim uređajima i proizvodnjom jalove energije u proizvodnim objektima.

Neke proizvodne jedinice imaju mogućnost samostalnog pokretanja agregata bez vanjskog napajanja električnom energijom. Navedenu pomoćnu uslugu operator plaća proizvodnim jedinicama.

Otočni rad, u slučaju prekida ili radova na održavanju EES-a, osigurava rad pojedinih dijelova EES-a. Zadaća mu je prekida opskrbe kupaca električne energije svesti na što kraće vrijeme [11].

4.1.2 Vođenje EES-a

Kako bi prijenos električne energije bio što učinkovitiji ključno je uspješno vođenje elektroenergetskog sustava Republike Hrvatske kao cjeline te uskladiti rad hrvatskog EES-a sa sustavima susjednih država i sinkronim područjem ENTSO-E regije kontinentalna Europa. Centar za provođenje vođenja hrvatskog elektroenergetskog sustava je Nacionalni dispečerski centar (NDC) u Zagrebu [11].

Model vođenja hrvatskog elektroenergetskog sustava ima strukturu "1+4", tj. jedan glavni i četiri centra na drugoj razine vođenja.

Hijerarhijski je podijeljen na tri razine:

1. Nacionalni dispečerski centar (NDC) koji se nalazi u Zagrebu
2. Mrežni centri (MC). Ima ih četiri, a nalaze se u Zagrebu, Rijeci, Splitu i Osijeku
3. Centri daljinskog upravljanja (CDU), elektroenergetski objekti i postrojenja (transformatorske stanice, elektrane), centri u kojima se provodi vođenje elektrana

Prema literaturi [11], „NDC je glavni centar vođenja elektroenergetskog sustava kao cjeline i hrvatskog upravljačkog područja. Zadaća mu je planiranje i analiza rada EES-a i vođenje EES-a u stvarnom vremenu. Ovlašten je za koordinaciju aktivnosti s operatorima sustava susjednih upravljačkih područja, koordinatorima upravljačkih blokova i koordinacijskim centrima UCTE-a“.

Zadaća MC-a za određeno prijenosno područje nadziranje i upravljanje mrežom od 400kV, 220kV i 110kV prema uputama Nacionalnog dispečerskog centra u vlastitom prijenosnom području, samostalno upravljanje mrežom od 110kV ako nije sistemskog značaja te druge poslove koje im zada Nacionalni dispečerski centar[11].

Prema vremenskom opsegu razlikujemo kratkoročno, srednjoročno i dugoročno planiranje rada EES-a.

Kratkoročno planiranje obuhvaća: pripremu tehničkih podloga vođenja elektroenergetskog sustava za sljedeći dan, suglašava se o izvodljivosti Tržišnog plana i sklopnih operacija u mreži te izrađivanje Plana rada sustava.

Prema literaturi [11], „srednjoročno planiranje obuhvaća: koordinaciju izrade plana za održavanje prijenosnih postrojenja i daje suglasnost na plan održavanja proizvodnih postrojenja, izradu plana podfrekvencijskog rasterećenja EES-a, izradu plana ograničenja potrošnje električne energije kod velikih poremećaja u EES-u ili nedostatne dobave električne energije, izradu plana ponovne uspostave EES-a“.

Dugoročno planiranje obuhvaća: izradu dugoročne prognoze potrošnje električne energije kako bi se planirao razvoj prijenosne mreže, prepoznaje i istražuje moguće slabe točke u elektroenergetskom sustavu i odabire tehnička rješenja kako bi se otklonile [11].

Prema [11], „poslovi vođenja EES-a provode se sukladno zakonskim i podzakonskim aktima Republike Hrvatske te Pravilima pogona ENTSO-E regionalne grupe za kontinentalnu Europu“.

4.1.3 Proizvodni objekti i postrojenja

Priključna snaga svih proizvodnih objekata i postrojenja Republike Hrvatske za 2016. godinu iznosi 4452MW. Nastavljajući trend stalnog rasta u odnosu na 2015. godinu priključna snaga je porasla za 228 MW. Glavni razlog rasta su nova postrojenja koja su izgrađena pomoću poticaja za proizvodnju električne energije iz obnovljivih izvora i kogeneracije.

Prema literaturi [13], „instalirani kapaciteti za proizvodnju električne energije u Republici Hrvatskoj obuhvaćaju hidro i termoelektrane u sastavu HEP grupe, sve veći broj vjetroelektrana i drugih elektrana na obnovljive izvore energije u privatnom vlasništvu te određeni broj industrijskih termoelektrana“.

Hidroelektrane čine najveći dio instalirane snage sa 45,37%, slijede termoelektrane sa 42,10%, vjetroelektrane sa 10,05%, elektrane na biomasu sa 1,32% te solarne elektrane sa 1,16%. Omjer instalirane snage elektrana u RH i vršnog opterećenja hrvatskog EES-a u 2016. godini iznosio

je 1,67 što je što ukazuje da je mogućnost domaće proizvodnje da pokrije opterećenje zadovoljavajuća [12].

Prema literaturi [13], „kapaciteti za proizvodnju električne energije u sastavu HEP grupe obuhvaćaju 17 pogona velikih hidroelektrana, sedam pogona termoelektrana i polovinu instaliranih kapaciteta u nuklearnoj elektrani Krško (na teritoriju Slovenije). Termoelektrane koriste ugljen, plin i loživo ulje. Većinski vlasnik nad proizvodnim kapacitetima Republike Hrvatske je HEP d.d. Ukupna raspoloživa snaga elektrana u sastavu HEP grupe na teritoriju Republike Hrvatske je 4 105 MW (uračunata TE Plomin d.o.o, bez NE Krško d.o.o.)“.

U potpunom vlasništvu HEP-a se ne nalaze:

- NE Krško d.o.o. –HEP d.d. ima udio od 50% te slovenski partner ELES GEN d.o.o. posjeduje udio od 50%
- TE Plomin d.o.o. –HEP d.d. ima od udio 50%, ugovor o vođenju i održavanju, a njemački partner RWE Power posjeduje udio od 50%

Prikaz ukupnih proizvodnih kapaciteta Republike Hrvatske u sastavu HEP grupe nalazi se u tablici 4.1.

Kapaciteti za proizvodnju električne energije Electricity generation capacity	Raspoloživa snaga Available power (MW)	Udio Share (%)	Proizvedena električna energija u 2016. Electricity produced in 2016 (GWh)
Hidroelektrane (HE) Hydro power plants (HPP)	2 198,7	49,4	6 128,3
Termoelektrane (TE) Thermal power plants (TPP)	1 714,0	38,5	1 876,6
TE Plomin d.o.o. (B) TE Plomin Ltd.	192,0	4,3	1 531,3
Ukupno u Republici Hrvatskoj Total in the Republic of Croatia	4 104,7	92,2	9 536,2
Nuklearna elektrana Krško (NE Krško) – 50% Nuclear power plant Krško (NPP Krško) – 50%	348,0	7,8	2 715,4
UKUPNO TOTAL	4 452,7	100,0	12 251,6

Tablica 4.1. Kapaciteti za proizvodnju električne energije RH u sastavu HEP grupe [13]

Popis hidroelektrana i termoelektrana u RH nalazi se u tablicama 4.2. i 4.3. Ukoliko isključimo proizvodnju električne energije TE Plomin, blok B od 1.531TWh tada je ostvarena proizvodnja elektrana u nadležnosti HEP-a iznosi 8.249 TWh. Najveći udio u ukupnoj proizvodnji čine

hidroelektrane sa 6.138 TWh ili 74.4%, dok su termoelektrane i termoelektrane-toplane (TE i TE-TO) proizvele 2.111 TWh ili 25.6%.

Ukupna raspoloživost proizvodnih postrojenja u vlasništvu HEP Proizvodnje za 2016. godinu (TE Plomin uključeno) iznosi 89.2%, što je za 5.4% manje od ostvarenog stupnja raspoloživosti u 2015. godini [14].

Hidroelektrane Hydro power plants			
	Raspoloživa snaga Available power (MW)		Raspoloživa snaga Available power (MW)
Akumulacijske hidroelektrane Storage plants		Protočne hidroelektrane Run-of-river plants	
HE Zakučac	535	HE Varaždin	92,5
RHE Velebit	276/(-240)	HE Čakovec	77,4
HE Orlovac	237	HE Dubrava	79,8
HE Senj	216	HE Gojak	55,5
HE Dubrovnik	228	HE Rijeka	36,8
HE Vinodol	90	HE Miljacka	20
HE Kraljevac	46,4	HE Lešće	41,2
HE Peruća	60	Male protočne hidroelektrane Small run-of-river plants	
HE Đale	40,8	HE Jaruga	7,2
HE Sklope	22,5	HE Lešće ABM	1,1
RHE Buško Blato	11,7/(-15)	HE Golubić	6,5
Male akumulacijske hidroelektrane Small storage plants		HE Ozalj	5,5
		HE Krčić	0,3
RHE Fužina	4,6/(-5,7)	Ukupno protočne Total run-of-river	423,8
HE Zavrle	2	Ukupno male HE Total small HPP	31,2
RHE* Lepenica	0,8/(-1,2)		
HE Zeleni Vir	1,7		
Ukupno akumulacijske HE Total storage HPP	1 774,9	Ukupno HE Total HPP	2 198,7
*RHE – reverzibilna HE reversible HPP			

Tablica 4.2. Hidroelektrane u RH u vlasništvu HEP grupe [13]

Termoelektrane Thermal power plants	Raspoloživa snaga na pragu Available net capacity (MW)	Proizvedena električna energija tijekom 2016. Electricity produced during 2016 GWh	Gorivo Fuel
TE Sisak	631	277,7	loživo ulje / prirodni plin fuel oil / natural gas
TE-TO Zagreb	422	710,9	prirodni plin / loživo ulje natural gas / fuel oil
TE Rijeka	303	0	loživo ulje fuel oil
TE Plomin (A)	105	819,3	ugljen coal
EL-TO Zagreb	89	215,6	prirodni plin / loživo ulje natural gas / fuel oil
KTE Jertovec	74	0,6	prirodni plin / ekstralako ulje natural gas / extra light oil
TE-TO Osijek	90	86,6	loživo ulje / prirodni plin / ekstralako ulje fuel oil / natural gas / extra light oil
TE Plomin d.o.o. (B)	192	1 531,3	ugljen coal
UKUPNO TOTAL	1 906	3 407,9	

Tablica 4.3. Termoelektrane u RH u vlasništvu HEP grupe [13]

Prema tablici 4.4. u RH postoji oko 520 MW instaliranih kapaciteta za proizvodnju električne energije iz obnovljivih izvora energije koje nisu u vlasništvu HEP grupe.

Instalirana snaga Installed capacity (MW)	Proizvodnja u 2016. Produced in a 2016 (GWh)
Elektrane na biomasu Thermal Power Plants (biomass)	
26,0	194,1
Elektrane na bioplin Thermal Power Plants (biogas)	
35,9	237,3
Male hidroelektrane* Small hydro power plants*	
6,6	22,2
Sunčane elektrane Solar power plants	
55,8	65,5
Vjetroelektrane (VE) Wind power plants (WPP)	
483,1	1014,2
Ukupno OIE Total RES	610,6
	1533,3
* nisu uključene male HE (< 10 MW) u sastavu HEP grupe (Tablica 5.1.2.)	
* does not include Small HPPs (< 10 MW) in HEP Group ownership (Table 5.1.2)	

Tablica 4.4. Elektrane na obnovljive izvore u Republici Hrvatskoj koje nisu u vlasništvu HEP grupe [13]


Elektrana Plant name	Instalirana snaga Installed capacity (MW)	Proizvodnja u 2016. Production in 2016 (GWh)	Gorivo Fuel
Termoelektrane (plin, tekuća goriva, ugljen, drvo) Thermal power plants (gas, liquid fuels, coal, wood)			
Belišće d.d., Belišće	31,0	3,2	prirodni plin / drveni otpad natural gas / wood
Viro d.o.o., Virovitica	8,0	18,5	prirodni plin / natural gas
INA Rafinerija nafte, Rijeka	40,5	94,9	prirodni plin / loživo ulje natural gas / fuel oil
Tvornica Šećera Osijek d.o.o.	18,5	19,5	ugljen / coal
INA d.d. Naftaplin CPS Molve, Đurđevac	11,1	62,3	prirodni plin / natural gas
INA d.d. Pogon Etan, Ivanić Grad	8,0	20,0	prirodni plin / natural gas
Petrokemija d.d., Kutina	35,0	84,6	prirodni plin / loživo ulje natural gas / fuel oil
Sladorana d.d., Županja	10,0	11,7	prirodni plin / natural gas
Termoplin d.d. Varaždin	0,03	0,1	prirodni plin / natural gas
Energo d.o.o. Rijeka	0,5	1,3	prirodni plin / natural gas
Kogeneracija Tomašanci Osatina Grupa d.o.o.	1,8	5,8	prirodni plin / natural gas
„Staklenik ...“ Osatina Grupa d.o.o.	1,0	4,1	prirodni plin / natural gas
UKUPNO TOTAL	165,4	326,0	

Tablica 4.5. Ostale kogeneracijske elektrane u Republici Hrvatskoj [13]

4.1.4 Prijenosna i distribucijska mreža


Zadaća elektroenergetske mreže je povezati proizvodna postrojenja i potrošače te omogućiti što sigurniju i kvalitetniju opskrbu potrošača električnom energijom. Razlikuje se prijenosna i distribucijska mreža. Prema literaturi [12], „prijenosna mreža dio je hrvatskog elektroenergetskog sustava koju čine transformatorske stanice, rasklopna prijenosna postrojenja te zračni vodovi i kabeli. Prijenos i distribucija električne energije su regulirane energetske djelatnosti koje se obavljaju kao javne usluge“.

Podaci o broju transformatorskih stanica i snazi instaliranih transformatora, duljini vodova, snazi priključenih elektrana te broju obračunskih mjernih mjesta u prijenosnom sustavu prikazani su na slici 4.2.



Slika 4.2. Podaci o prijenosnom sustavu za 31.12.2016. [12]

Prema literaturi [12], „HEP-ODS izvršava javnu uslugu distribucije električne energije i odgovoran je za pogon i vođenje, održavanje, razvoj i izgradnju distribucijske mreže te za osiguravanje dugoročne sposobnosti mreže da zadovolji razumne zahtjeve za distribucijom električne energije. Slika 4.3 prikazuje osnovne podatke o broju transformatorskih stanica (TS) i snagama instaliranih transformatora (TR), duljini vodova, snazi priključenih elektrana te broja obračunskih mjernih mjesta (OMM) u distribucijskom sustavu“.



Slika 4.3. Osnovni podaci o distribucijskom sustavu dana 31.12.2016. godine [12]

U tablicama 4.6. i 4.7. su redom prikazani kapaciteti prijenosne mreže Hrvatskog operatora prijenosnog sustava te kapaciteti distribucijske mreže HEP-Operatora distribucijskog sustava.


Naponska razina Voltage level	400 kV	220 kV	110 kV	Srednji napon Medium voltage
Duljina vodova Lines length (km)*	1 247	1 213	5 200	11
Broj TS Number of substations	6	14	154	

Tablica 4.6. Kapaciteti prijenosne mreže HOPS-a [13]

Naponska razina Voltage level	110 kV	35 (30) kV	20 kV, 10 kV	0.4 kV	Priključci Connections
Duljina vodova Lines length (km)*	10	4 479	8 516 28 258	61 790	38 302
Broj TS Number of substations	139	307 (35(30)/10(20) kV)	25 550 (10(20)/0,4 kV)		

Tablica 4.7. Kapaciteti distribucijske mreže HEP ODS-a [13]

Gubici električne energije u prijenosnoj mreži 2016. godine iznose 510 GWh ili 2.2% ukupno prenesene električne energije. Na slici 4.4 je prikaz ukupnog godišnjeg gubitka u prijenosnoj mreži i postotka.



Slika 4.4. Ukupni godišnji gubici električne energije u prijenosnoj mreži [12]

Prema literaturi [12], „gubici električne energije u distribucijskoj mreži iznosili su 1.235 GWh odnosno 7,6% nabave električne energije, što je po apsolutnom i relativnom iznosu niže u odnosu na 2015. godinu.

Razina sigurnosti opskrbe električnom energijom u hrvatskom elektroenergetskom sustavu je zadovoljavajuća.“

Hrvatski operator prijenosnog sustava je u listopadu 2016. godine donio „Desetogodišnji plan razvoja prijenosne mreže 2017. - 2026. godine, s detaljnom razradom za početno trogodišnje i jednogodišnje razdoblje“ koji je po usvajanju funkcionalno usuglašen s desetogodišnjim planom razvoja prijenosne mreže Europske unije iz 2016. godine. Tablica 4.8 je prikazana procjena budućih investicijskih ulaganja za razvoj prijenosne mreže u razdoblju od 2017. godine do 2026. godine, a tablica 4.9. prikazuje izvršene investicije u mrežu za razdoblje od 2012. do 2016. godine.

Investicije	Iznos [tisuće kn]
Vlastite investicije u prijenosnu mrežu	5.944.490
Investicije za priključenje građevina krajnjih kupaca	154.477
Investicije za priključenje novih konvencionalnih elektrana	416.191
Investicije za priključenje vjetroelektrana	105.000
Investicije u projekte od zajedničkog interesa Europske unije ²	99.825
Ukupno	6.719.983

Tablica 4.8. Procjena ulaganja u razvoj prijenosne mreže prema desetogodišnjem planu od 2017. do 2026. godine [12]


Vrsta investicije	2012.	2013.	2014.	2015.	2016.
Priprema investicija	6,1	6,6	7,9	8,4	12,6
Zamjene i rekonstrukcije	147,9	125,4	201,2	189,2	166,2
Revitalizacije	30,8	30,8	49,9	61,5	59,0
Novi objekti	218,4	130,7	85,8	90,3	71,1
Ostale investicije	8,5	46,2	35,1	37,9	34,9
Elektroenergetski uvjeti i priključenja	78,1	76,6	43,8	64,2	33,7
Ukupno	489,8	416,3	423,7	451,5	377,5

Tablica 4.9. Godišnje investicije u prijenosnu mrežu izražene u milijunima kuna [12]

4.1.5 Potrošači električne energije


Ukupna potrošnja električne energije u RH 2016. godine iznosi 18349.5 GWh što je za 0.9% veće u naspram 2015. godine [13]. Prema literaturi [12], „najveći dio ukupne potrošnje električne energije pokriven je proizvodnjom na teritoriju Republike Hrvatske (64.1%), dok je ostatak pokriven fizičkim neto uvozom (35.9%). Pritom je 2.7 TWh podmireno uvozom električne energije iz Nuklearne elektrane Krško u Sloveniji, koja je u 50% vlasništvu HEP-a. Smanjena je potrošnja uvozne električne energije za 18.5%“.

Bruto potrošnja električne energije po stanovniku se smanjila za 30.7% u odnosu na prosječnu potrošnju u Europskoj Uniji kao što se vidi na slici 4.5.




Slika 4.5. Bruto potrošnja električne energije po stanovniku [13]

Raspoloživa električna energija u Republici Hrvatskoj i struktura potrošnje električne energije u Republici Hrvatskoj su prikazane na slikama 4.6 i 4.7.



Slika 4.6. Raspoloživa električna energija u Republici Hrvatskoj [13]



Slika 4.7. Struktura potrošnje električne energije u Republici Hrvatskoj [13]

Ukupan prikaz kupaca i potrošnje električne energije prikazan je u tablicama 4.10 i 4.11.

	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.
VN HV	34* + 4	34* + 4	35* + 4	35* + 4	35** + 4	62	65	48
SN MV	2 081	2 112	2 124	2 135	2 114	2 127	2 167	2 165
NN Poduzetništvo LV Business	188 775	190 711	191 182	189 926	189 559	190 204	192 927	193 718
NN Javna rasvjeta LV Public lighting	20 818	21 126	21 351	21 537	21 817	23 934	21 454	21 650
NN Kućanstva LV Households	2 099 133	2 330 332	2 120 247	2 137 283	2 148 375	2 157 442	2 171 110	2 169 826
UKUPNO TOTAL	2 310 845	2 330 366	2 344 908	2 350 885	2 361 869	2 373 711	2 387 662	2 387 407

Tablica 4.10. Broj mjernih mjesta prema naponskim razinama [13]

Za 2016. godinu ukupna potrošnja električne energije iznosi 15570 GWh, uključujući 645 GWh potrošnje kupaca koji priključeni direktno na prijenosnu mrežu. Pojedinačna i ukupna potrošnja električne energije kupaca nalazi se u tablici 4.11.

	Poduzetništvo (visoki i srednji napon) Business (high and medium voltage)	Niski napon Poduzetništvo Low Voltage Business	Niski napon Javna rasvjeta Low Voltage Public lighting	Niski napon Kućanstva Low Voltage Households	Ukupno niski napon Total Low Voltage	UKUPNO TOTAL
2009.	3 542 471 318	4 240 355 944	446 329 284	6 471 768 469	11 158 453 696	14 700 925 014
2010.	3 547 311 967	4 210 544 743	440 314 330	6 664 706 848	11 315 565 921	14 862 877 888
2011.	3 640 932 611	4 236 654 246	432 871 805	6 540 376 066	11 209 902 117	14 850 834 729
2012.	3 593 538 474	4 240 897 171	432 203 477	6 486 494 762	11 159 595 410	14 753 133 885
2013.	3 657 261 855	4 139 576 795	432 259 748	6 236 983 433	10 808 819 977	14 466 081 832
2014.	3 654 341 710	4 067 253 211	428 832 559	6 032 926 244	10 529 012 014	14 183 353 724
2015.	3 905 767 255	4 247 706 385	424 682 904	6 202 453 678	10 874 842 967	14 780 610 222
2016.	4 086 610 529	4 284 198 691	426 207 781	6 128 042 889	10 838 449 361	14 925 059 890

Tablica 4.11. *Pojedinačna i ukupna potrošnja električne energije kupaca u Hrvatskoj od 2009. do 2016. godine [kWh] [13]*

4.2 Općenito o tržištu električne energije u RH

Liberalizacija tržišta električne energije ima za cilj odvajanje prijenosa i distribucije električne energije od proizvodnje, prijenosa i distribucije električne energije. Cijena i kvaliteta električne energije ovise o međusobnom natjecanju između konkurentnih sudionika na tržištu. U Hrvatskoj imamo jedno tržište koje je potpuno otvoreno od 1. srpnja 2008. godine kada se koristi model bilateralnog tržišta. Trgovanje fizičkim isporukama električne energije ili financijskim izvedenicama se provodi temeljem bilateralnih ugovora između sudionika na tržištu. [11].


Prema literaturi [12], „zakon o tržištu električne energije uređuje pravila i mjere za sigurnu i pouzdanu proizvodnju, prijenos, distribuciju i opskrbu električnom energijom te za trgovinu električnom energijom i organizaciju tržišta električne energije kao dijela budućeg jedinstvenog elektroenergetskog tržišta EU-a“.

4.3 Model tržišta električne energije u Republici Hrvatskoj

Model tržišta električne u Republici Hrvatskoj naziva se model bilančnih grupa te se primjenjuje od 1. siječnja 2016.godine.

Model bilančnih grupa se sastoji od:

- EKO bilančna grupa (HROTE)
- Tržišne bilančne grupe (proizvođači, trgovci, opskrbljivači)
- Bilančna grupa operatora prijenosnog sustava (HOPS)
- Bilančna grupa operatora distribucijskog sustava (HEP-ODS)
- Bilančna grupa burze električne energije (CROPEX)




Slika 4.8. Model bilančnih grupa [15]

Operator tržišta je voditelj EKO bilančne grupe. Njegov zadatak je kupovina električne energije od povlaštenih proizvođača u sustavu poticanja. Operator može prodati/kupiti električnu energiju od tržišnih sudionika ili je uvesti/izvesti preko granica Republike Hrvatske ili na burzi. Tržišnu bilančnu grupu čine proizvođači, trgovci i opskrbljivači. Može imati jednog ili više tržišnih sudionika od kojih je jedan voditelj. Broj i vrsta članova unutar jedne tržišne bilančne grupe nije ograničen. Svaki tržišni sudionik je dužan biti član tržišne bilančne grupe, a istovremeno se ne može nalaziti u više grupa. U Bilančnoj grupi operatora prijenosnog sustava i grupi distribucijskog sustava jedini član je pripadajući operator, koji je ujedno i voditelj u svojoj grupi. Operatori sustava reguliraju odnose sa Operatorom tržišta putem ugovora. Bilančnu grupu burze električne energije čini burza koja je istovremeno i voditelj. Obvezan je sklopiti ugovor s Operatorom tržišta kojim se reguliraju međusobni odnosi, a odnose se na način

dostave ugovornih rasporeda i podataka vezanih uz vođenje evidencija, trajanje i raskid ugovora i ostale međusobne odnose.

Prema literaturi [15], „zakonima su uspostavljeni okviri za obavljanje energetskih djelatnosti u tržišnim uvjetima, a podzakonskim aktima su detaljnije razrađene zakonske postavke“.



Slika 4.9. Bilateralno trgovanje [15]

Prema [15], „tradicionalan način trgovanja je bilateralnim ugovorima ili OTC tržište (Over thecounter). Bilateralni ugovori se sklapaju između opskrbljivača, trgovca ili proizvođača te u slučaju uvoza ili izvoza električne energije preko granica regulacijskog područja RH.

Ugovorne strane u bilateralnom ugovoru su: član bilančne grupe – voditelj bilančne grupe, voditelj bilančne grupe – voditelj bilančne grupe i član bilančne grupe – član bilančne grupe.“

5. PRIMJER PRIMJENE UMJETNIH NEURONSKIH MREŽA

Slijedi implementacija modela neuronskih mreža za hrvatsko elektroenergetsko tržište. Program koji je korišten za predviđanje opterećenja i cijene električne energije je Matlab.

5.1. Odabir ulaznih i izlaznih podataka za model umjetne neuronske mreže


Za ovaj primjer koriste se podaci za razdoblje od 11.2.2016. do 8.10.2017. godine. Ulazni meteorološki podaci potrebni za učenje neuronske mreže preuzeti su od Weather Underground [16] za mjernu postaju Zagreb Pleso. Satni podaci o opterećenju su preuzeti iz ENTSO-E [17], a povijesni podaci o cijeni električne energije su preuzeti od CROPEX-a (*en. Croatian Power Exchange Ltd.*) [18]. Podaci koji nedostaju su dobiveni interpolacijom u Matlab-u. Također, iz Excel tablice su učitani i praznici u Hrvatskoj.

Umjetna neuronska mreža je osmišljena na temelju prethodnog opterećenja, vrste godišnjeg doba, tipa dana, sata dana, temperature, rosišta, relativne vlage, tlaka i brzine vjetra.


Mjesec	Opterećenje	
	[MWh]	Cijena [€/MWh]
ožu-16	1441551	26.1939
tra-16	1259850	28.7421
svi-16	1283609	29.1092
lip-16	1296410	33.7979
srp-16	1526501	35.5124
kol-16	1422400	32.7648
ruj-16	1367898	36.1124
lis-16	1404080	44.7574
stu-16	1449262	40.1258
pro-16	1628189	48.1370
sij-17	1744731	84.9671
vlj-17	1422892	56.3596
ožu-17	1431745	38.6741
tra-17	1333488	39.9805
svi-17	1360452	46.0490
lip-17	1429442	47.1290
srp-17	1600029	53.3399
kol-17	1627206	59.3658
ruj-17	1376861	42.1641

Tablica 5.1. Ukupno mjesečno opterećenje i mjesečni prosjek cijene električne energije prema podacima preuzetim sa internetske stranice Hrvatske burze električne energije CROPEX [18]


U tablici 5.1. vidimo da je najveće opterećenje bilo u siječnju 2017. godine, a drugo najveće u prosincu 2016. godine. Prema povijesnim podacima sa [16], najveće opterećenje se događa tijekom zime, a drugo najveće u ljeto. Opterećenja u proljeće i jesen imaju male razlike i sličan obrazac, a zimski i ljetni imaju svoje vlastite obrasce. Temperatura se također razlikuje ovisno o godišnjem dobu, to jest, zima ima najnižu temperaturu, a ljeto najvišu temperaturu. Mjesečni prosjek temperature, ukupno mjesečno opterećenje i prosječna cijena električne energije prikazani su na slikama 5.1, 5.2 i 5.3 prema podacima preuzetim sa internetske stranice Hrvatske burze električne energije CROPEX [18].



Slika 5.1. Prosječna mjesečna temperatura za mjernu stanicu Zagrebu Pleso




Slika 5.2. Ukupno mjesečno opterećenje, izvor podataka [18]



Slika 5.3. Prosječna cijena električne energije, izvor podataka [18]

Podaci dnevnog opterećenja se sastoje od satnih opterećenja, pratimo podatke opterećenja za tjedne, dnevne i satne vršne postotke. Prema slici 5.4. najniže opterećenje javlja se nedjeljom, a najviše petkom. U utvrđivanju satnih opterećenja, razlikujemo radni dan i vikend.




Slika 5.4. Prikaz dnevnog opterećenja, izvor podataka [18]

Ova satna opterećenja također se razlikuju za svako godišnje doba. Zimi se vršna opterećenja javljaju u večernjim satima, a ljeti u poslijepodnevnom satima kada temperatura raste. Uspoređujući godišnja doba, doznajemo da je zimi najveće opterećenje zbog hladnog vremena i korištenja električnih grijača.


Mjesec	Max opterećenje (MW)		Min opterećenje (MW)	
	Opterećenje (MW)	Sat	Opterećenje (MW)	Sat
ožu-16	2572	20	1192	5
tra-16	2374	21	1162	4
svi-16	2272	21	1098	6
lip-16	2474	13	1132	6
srp-16	2776	14	1263	6
kol-16	2543	21	1245	5
ruj-16	2542	21	1231	4
lis-16	2540	20	1253	4
stu-16	2714	18	1269	4
pro-16	2818	18	1437	4
sij-17	3067	20	1476	4
vlj-17	2736	18	1393	4
ožu-17	2594	19	1273	4
tra-17	2515	20	1193	3
svi-17	2289	12	1247	5
lip-17	2718	12	1271	5
srp-17	2930	13	1333	5
kol-17	3082	13	1394	3
ruj-17	2477	20	1128	3

Tablica 5.2. Maksimalna i minimalna opterećenja, izvor podataka [18]

U tablici 5.2 maksimalno opterećenje se javlja u siječnju 2017. godine u podne. Prema tablici 5.1 u siječnju 2017. godine je i najviše ukupno opterećenje. Drugo najviše opterećenje je u prosincu 2016. godine te slijedi kolovoz 2017. godine kada su zabilježene najviše temperature. Minimalna opterećenja se javljaju u proljeće, odnosno travanj, svibanj i lipanj 2016. godine. Veza između opterećenja i temperature je prikazana na slikama 5.5 i 5.6.




Slika 5.5. Prosječno opterećenje po satu u mjesecu, izvor podataka [18]




Slika 5.6. Prosječna temperatura po satu, izvor podataka [18]

Na slici 5.7 je uspoređeno ukupno mjesečno opterećenje za 2016. i 2017. godinu, a na slici 5.8 je prikazana usporedba prosječne cijene električne energije.



Slika 5.7. Usporedba opterećenja izražena u [MWh] za 2016. i 2017. godinu, izvor podataka [18]



Slika 5.8. Usporedba cijena izražena u [€/MWh] za 2016. i 2017. godinu, izvor podataka [18]

U Matlabu su napravljene dvije umjetne neuronske mreže, jedna za prognozu opterećenja, a druga za prognozu cijene električne energije.

5.2. Primjena prognoze opterećenja električne energije

Odabrana je mreža sa dva skrivena sloja i 90 neurona. Podaci su podijeljeni u dvije skupine; trening i testni podaci. Podaci od od 11.2.2016. do 1.5.2017. godine su odabrani za set za treniranje, a testiranje je izvršeno sa podacima od 1.5.2017. do 8.10.2017. godine. Testni podaci se neće koristiti za obuku; njihova svrha je samo ispitati pogreške koje proizvodi umjetna neuronska mreža nakon treninga.

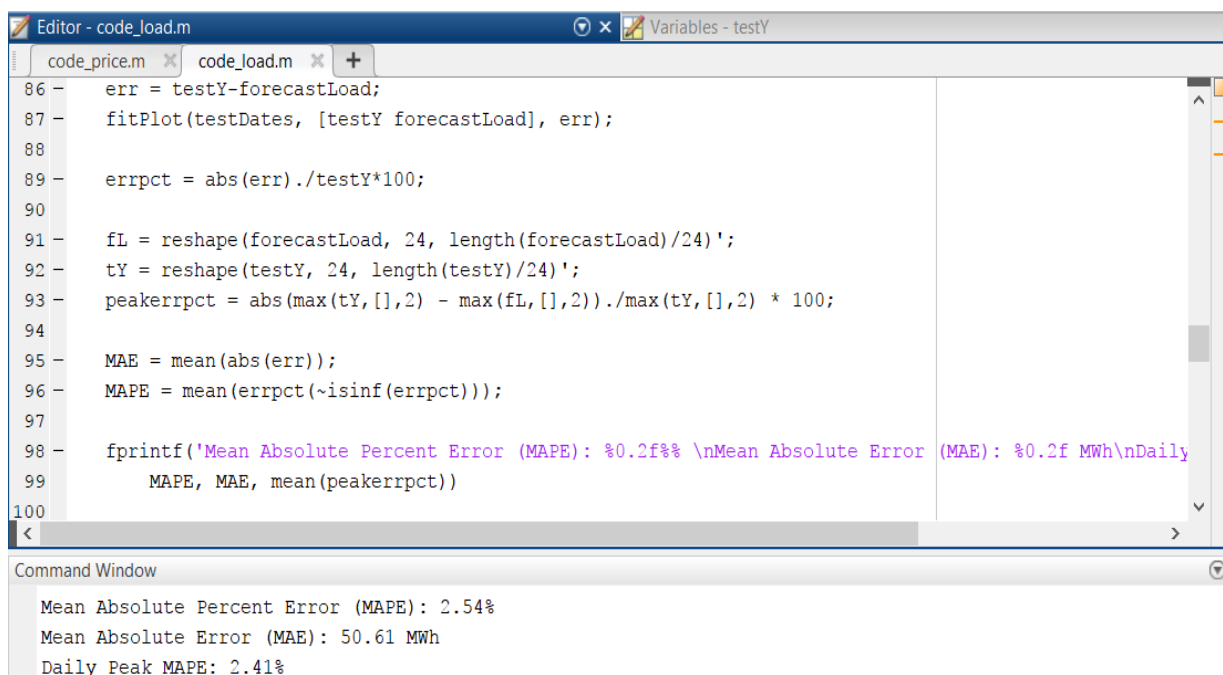
```

37 % Create training set
38 - trainInd = data.NumDate < datenum('2017-05-01');
39 - trainX = X(trainInd, :);
40 - trainY = data.SYSLoad(trainInd);
41
42 % Create test set and save for later
43 - testInd = data.NumDate >= datenum('2017-05-01');
44 - testX = X(testInd, :);
45 - testY = data.SYSLoad(testInd);
46 - testDates = dates(testInd);
47
48 - save Data_load\testSet testDates testX testY
49 - clear X data trainInd testInd term holidays dates ans num text raw my_num my_text
50

```

Slika 5.9. Podjela podataka na set za treniranje i set za testiranje za prognozu opterećenja

Nakon što je proces treniranja završen, umjetna neuronska mreža je potvrđena pomoću testnih podataka. Izračunata je MAPE predviđanje svakog dana. Osim toga, MAE (srednja apsolutna pogreška) za svakodnevno vršno opterećenje je također izračunata. Srednja apsolutna postotna pogreška (MAPE) je 2.54% što je unutar prihvatljive točnosti.



```
86 - err = testY-forecastLoad;
87 - fitPlot(testDates, [testY forecastLoad], err);
88
89 - errpct = abs(err)./testY*100;
90
91 - fL = reshape(forecastLoad, 24, length(forecastLoad)/24)';
92 - tY = reshape(testY, 24, length(testY)/24)';
93 - peakerrpct = abs(max(tY, [],2) - max(fL, [],2))./max(tY, [],2) * 100;
94
95 - MAE = mean(abs(err));
96 - MAPE = mean(errpct(~isinf(errpct)));
97
98 - fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error (MAE): %0.2f MWh\nDaily
99 - MAPE, MAE, mean(peakerrpct))
100
```

Command Window

```
Mean Absolute Percent Error (MAPE): 2.54%
Mean Absolute Error (MAE): 50.61 MWh
Daily Peak MAPE: 2.41%
```

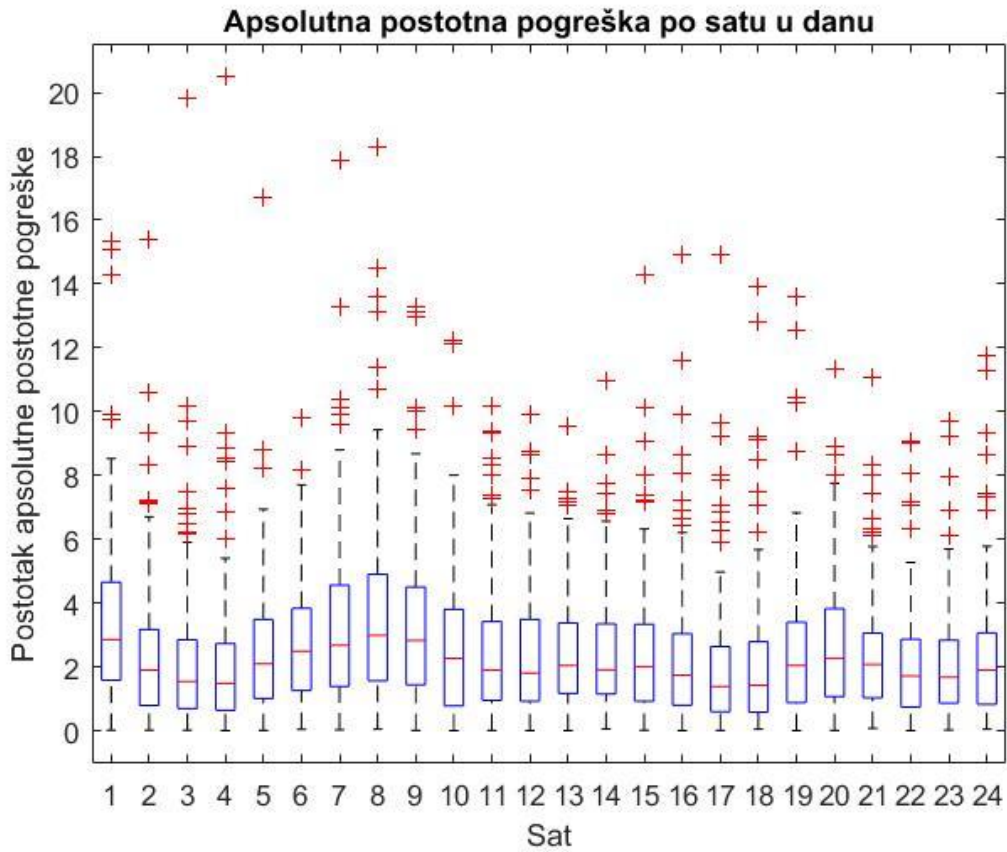
Slika 5.10. Izračun srednje apsolutne postotne pogreške

Nakon završetka procesa treniranja ma slici 5.11 prikazana je usporedba stvarnih vrijednosti opterećena sa prognoziranima za razdoblje od 1.5.2017. do 8.10.2017. godine.




Slika 5.11. Usporedba stvarnog opterećenja sa prognoziranim

Za bolji uvid u točnost prognoze opterećenja, na slikama 5.12 i 5.13 prikazana je grupna analiza srednje apsolutne postotne pogreške po satu u danu i danu u tjednu. Prema slici 5.13, MAPE je najmanja četvrtkom za koji je utvrđeno da ima najniže opterećenje u usporedbi sa ostalim danima u tjednu.




Slika 5.12. Analiza srednje apsolutne postotne pogreške po satu u danu



Slika 5.13. Analiza srednje apsolutne postotne pogreške po danu u tjednu

Na slici 5.14 prikazana je usporedba stvarnog opterećenja sa prognoziranim za razdoblje od 18.9.2017. do 1.10.2017. godine. U promatranom setu podataka prikazanom u tablici 5.3, prognoza se može smatrati pouzdanom za sve dane osim za petak 22.9.2017. i utorak 26.9.2017. jer se MAPE nalazi u rasponu od 1.53% do 2.93%. Dana 22.9.2017. MAPE iznosi 4.33%, a u utorak 26.9.2017., kada je najviša temperatura, MAPE iznosi 7.89%. Što je veća varijacija čimbenika, veći je MAPE. Prethodna opterećenja i temperatura imaju najveći utjecaj na prognoziranje opterećenja.

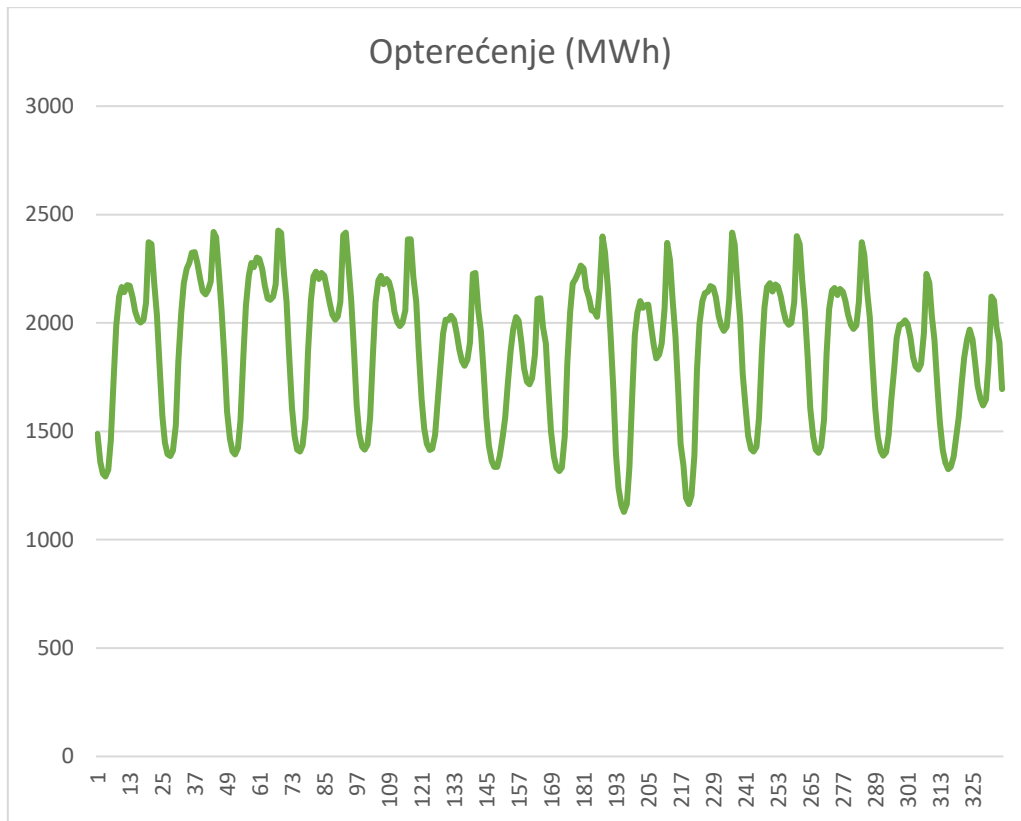


Slika 5.14. Usporedba stvarnog opterećenja sa prognoziranim za razdoblje od 18.9.2017. do 1.10.2017. i prikaz srednje apsolutne postotne pogreške


Datum	Predviđeno opterećenje [MWh]	Stvarno opterećenje [MWh]	MAPE %	MAE
18/09/2017	1906.2341	1908.6250	2.5561	2.3909
19/09/2017	1960.4706	2000.0417	2.4637	39.5711
20/09/2017	1974.7362	2003.0417	2.2045	28.3055
21/09/2017	1961.0055	1976.7500	1.5510	15.7445
22/09/2017	1894.6752	1961.7083	4.3305	67.0331
23/09/2017	1834.3363	1826.1667	2.0410	-8.1696
24/09/2017	1725.2932	1733.0417	2.5944	7.7485
25/09/2017	1910.0646	1934.2500	2.9310	24.1854
26/09/2017	1930.6490	1806.8333	7.8984	-123.8156
27/09/2017	1883.6987	1880.6250	2.6563	-3.0737
28/09/2017	1913.2449	1950.9167	2.9251	37.6718
29/09/2017	1938.5459	1933.7083	1.5333	-4.8376
30/09/2017	1796.5646	1804.7083	2.1218	8.1437
42745.0000	1668.6976	1701.5417	2.4584	32.8441

Tablica 5.3. Usporedba stvarnog opterećenja sa prognoziranim [MWh] za razdoblje od 18.9.2017. do 1.10.2017. i prikaz srednje apsolutne postotne pogreške

Slike 5.15 i 5.16 prikazuju krivulje opterećenja i cijena za hrvatsko energetska tržište u periodu od 18.9.2017. do 1.10.2017. godine. Iz krivulja vidimo da je krivulja opterećenja homogena i varijacije se ciklički ponavljaju dok to ne vrijedi za krivulju cijena. Iako je cijena promjenjiva, ne smatra se nasumičnom jer je moguće odrediti određene uzorke i pravila koja se pojavljuju na tržištu. Moguće je promatrati i cijene koje su se ponavljale u istim periodima u prethodnim razdobljima, npr. u istom mjesecu prošle godine.




Slika 5.15. Krivulja opterećenja za energetska tržište u periodu od 18.9.2017. do 1.10.2017., izvor podataka [18]



Slika 5.16. Krivulja cijena za hrvatsko energetska tržište u periodu od 18.9.2017. do 1.10.2017., izvor podataka [18]

5.3. Primjena prognoze cijene električne energije

Ponovno odabiremo mrežu sa dva skrivena sloja i 90 neurona. Set za treniranje se sastoji od ulaznih i izlaznih podataka od 11.2.2016. do 1.5.2017. godine, a testni podaci su za razdoblje od 1.5.2017. do 8.10.2017. godine. Rezultat je prikazan na slici 5.17.



Slika 4.17. Usporedba stvarne cijene sa prognoziranom

Na slici 5.18 je izračunato da MAPE iznosi 22.7% što se ne smatra prihvatljivim. Do velike srednje apsolutne postotne greške dolazi jer su korišteni meteorološki podaci samo za mjernu postaju Zagreb Pleso. Kako bi prognoza cijene električne energije bila što točnija potrebno je provesti opsežnija istraživanja za više različitih lokacija.

```

Editor - code_price.m
code_load.m code_price.m
89 - err = testY-forecastPrice;
90 - fitPlot(testDates, [testY forecastPrice], err);
91
92 - errpct = abs(err) ./testY*100;
93
94 - fL = reshape(forecastPrice, 24, length(forecastPrice)/24)';
95 - tY = reshape(testY, 24, length(testY)/24)';
96 - peakerrpct = abs(max(tY, [],2) - max(fL, [],2)) ./max(tY, [],2) * 100;
97
98 - MAE = mean(abs(err));
99 - MAPE = mean(errpct(~isinf(errpct)));
100
101 - fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error (MAE): %0.2f MWh\nDaily
102 - MAPE, MAE, mean(peakerrpct))

```

Command Window


```

Mean Absolute Percent Error (MAPE): 22.71%
Mean Absolute Error (MAE): 6.94 MWh
Daily Peak MAPE: 12.44%


```

Slika 5.18 Izračun srednje apsolutne postotne pogreške za prognozu cijene električne energije


Na slikama 5.19 i 5.20 prikazana je grupna analiza srednje apsolutne postotne pogreške za prognozu cijene električne energije po satu u danu i danu u tjednu.



Slika 5.19 Analiza srednje apsolutne postotne pogreške po satu u danu



Slika 5.20 Analiza srednje apsolutne postotne pogreške po danu u tjednu



Slika 5.21 Usporedba stvarne cijene sa prognoziranom za razdoblje od 18.9.2017. do 1.10.2017. i prikaz srednje apsolutne postotne pogreške

Datum	Predviđena cijena [€/MWh]	Stvarna cijena [€/MWh]	MAPE %	MAE
18/09/2017	49.2257	51.8025	7.7792	2.5768
19/09/2017	46.9203	44.4846	8.7477	-2.4357
20/09/2017	45.5527	44.1133	6.6463	-1.4393
21/09/2017	41.8956	44.5354	6.9440	2.6399
22/09/2017	42.6097	39.0646	13.3963	-3.5451
23/09/2017	38.3063	38.6450	10.0374	0.3387
24/09/2017	35.5226	37.5579	7.2635	2.0353
25/09/2017	44.6079	40.8721	10.6306	-3.7358
26/09/2017	36.5684	40.7346	14.7438	4.1661
27/09/2017	40.3779	41.3975	7.8527	1.0196
28/09/2017	41.4073	39.5196	6.5899	-1.8878
29/09/2017	39.7889	38.0313	8.1461	-1.7576
30/09/2017	35.2339	34.4075	5.4974	-0.8264
1/10/2017	31.6235	32.1796	12.7495	0.5561

Tablica 5.4 Usporedba stvarne cijene sa prognoziranom [€/MWh] za razdoblje od 18.9.2017. do 1.10.2017. i prikaz srednje apsolutne postotne pogreške

MAPE ima široku primjenu pri ocjenjivanju izvedbe predviđanja opterećenja. Međutim, u predviđanju cijene MAPE nije dobar kriterij jer može voditi do krivih zaključaka. Ako uzmemo da je V_a stvarna vrijednost, a V_f predviđena vrijednost, tada se postotna greška (PE) računa izrazom:


$$PE = \frac{(V_f - V_a)}{V_a} \times 100\% \quad (5-1)$$

A apsolutna postotna greška (APE) je jednaka apsolutnoj vrijednosti od PE [1].

Tada je srednja apsolutna postotna greška (MAPE) izražena kao:

$$MAPE = \frac{1}{N} \sum_{i=1}^N APE_i \quad (5-2)$$

Ako je stvarna vrijednost velika, a predviđana vrijednost mala, APE će biti blizu 100%. Ako je stvarna vrijednost mala, APE može biti velika iako je razlika između stvarne i predviđene vrijednosti jako mala. Na primjer, ako je stvarna vrijednost nula, APE će postići beskonačnu vrijednost za svaku prognozu veću od nule. Zbog toga dolazi do problema pri korištenju APE pri predviđanju cijene. Treba napomenuti da se ovaj problem ne pojavljuje kod predviđanja opterećenja jer su vrijednosti otpora jako velike, za razliku od vrijednosti cijene. Usporedba je prikazana na slici 5.11. [1].



Slika 5.22. Usporedba rezultata MAPE za prognozu opterećenja i prognozu cijene električne energije za razdoblje od 18.9.2017. do 1.10.2017.

Prema slici 5.22 najveća odstupanja MAPE i za opterećenje i za cijenu električne energije su se dogodila za iste datume zbog neočekivanih vremenskih prilika.

6. ZAKLJUČAK

Uvođenjem restrukturiranja u industriju električne energije, sama cijena postala je glavni fokus svih aktivnosti na energetsom tržištu. U radu je opisan princip izrade modela umjetnih neuronskih mreža za kratkoročnu prognozu opterećenja i cijene električne energije, kao i njegova šira primjena i implementacija. Arhitektura umjetne neuronske mreže sastoji se od tri dijela: ulazni sloj, skriveni sloj i izlazni sloj. Za pouzdanu prognozu, potrebno je pronaći optimalan broj vektora za učenje ANN mreže kako ne bi došlo do kontra-efekta, odnosno pretreniranja.

Razvijen je model za prognozu opterećenja i cijene električne energije na temelju podataka o prethodnom opterećenju, cijeni električne energije, vrsti godišnjeg doba, tipa dana, sata dana, temperature, rosišta, relativne vlage, tlaka i brzine vjetra za razdoblje od 11.2.2016. do 8.10.2017. godine. Podaci su podijeljeni na set za treniranje i testne podatke. Generirane su dvije umjetne neuronske mreže sa po dva skrivena sloja i 90 neurona. Prva se koristi za prognozu opterećenja električne energije u RH. Srednja apsolutna postotna pogreška (MAPE) za prognozu opterećenja je 2.54% što je unutar prihvatljive točnosti. Najveći utjecaj na prognoziranje opterećenja imaju prethodna opterećenja i temperatura. Zaključeno je kako je najviše opterećenje zimi, zatim u ljeto, a proljeće i jesen imaju slične obrasce i male razlike. Dnevno vršno opterećenje se javlja nedjeljom, a najniže četvrtkom.

Drugu neuronsku mrežu koristimo za prognozu cijene električne energije na hrvatskom tržištu, MAPE iznosi 22.7% što se ne smatra prihvatljivim. Srednja apsolutna postotna pogreška se koristi kao mjera preciznosti, ali može imati prevelike vrijednosti zbog naglih promjena u cijeni električne energije koja se povremeno može povećati nekoliko stotina puta, pasti na nulu ili čak poprimiti negativne vrijednosti. Nagle pojave vršnih vrijednosti cijena električne energije uzrokovane preopterećenjem mreže jedna su od glavnih zapreka točnom predviđanju. Zbog velike volatilnosti teško je napraviti točno predviđanje cijena struje, za razliku od predviđanja opterećenja. Kod krivulje opterećenja varijacije se ciklički ponavljaju dok to ne vrijedi za krivulju cijena. Međutim, predviđanje cijene ima veću toleranciju na pogrešku nego predviđanje opterećenja. Predstavljeni model se može nadopunjavati, te je moguće povećati točnost s aktualnim podacima o meteorološkim prilikama. U radu su korišteni meteorološki podaci za mjernu postaju Zagreb Pleso, te bi bilo poželjno da se prikupe podaci za ostale gradove kroz duži vremenski period.

LITERATURA

- [1] M. Shahidehpour, H. Yamin, Z. Li, Market Operations in Electric Power Systems: Forecasting, Scheduling, and Risk Management, John Wiley & Sons, New York, 2002.
- [2] E. A. Feinberg, D. Genethliou, Applied Mathematics for Restructured Electric Power Systems Optimization, Control, and Computational Intelligence, Springer US, 2005.
- [3] S. Nikolovski, K. Fekete, G. Knežević, Z. Stanić: Uvod u tržište električne energije; Grafika d.o.o., Osijek, 2010.
- [4] B. U. Islam: Comparison of Conventional and Modern Load Forecasting Techniques Based on Artificial Intelligence and Expert Systems, IJCSI International Journal of Computer Science; No. 5; Vol. 8; str. 504 - 513; rujan 2011.
- [5] B. D. Bašić, M. Čupić, J.Šnajder: Umjetne neuronske mreže; Fakultet elektrotehnike i računarstva; Zagreb, 2008.
- [6] K. Tačković, S. Nikolovski: Kratkoročno prognoziranje opterećenja primjenom modela neuronske mreže, Energija, No. 5, Vol. 57, str. 560 - 579, Zagreb, svibanj 2008.
- [7] M.H. Beale, M. T. Hagan, H. B. Demuth, Neural Network Toolbox User's Guide R2017b, 2017. Dostupno na: https://se.mathworks.com/help/pdf_doc/nnet/nnet Ug.pdf, pristup ostvaren: 20.12.2017.
- [8] M. T. Hagan, H. B. Demuth, M. H. Beale, O. De Jesús: Neural Network Design (2nd Edition); Martin Hagan, Tulsa Oklahoma, 2014.
- [9] O. Bilan, Obrada zvučnih signala, Stručni studiji elektrotehnike Sveučilišta u Splitu 2010/2011. Dostupno na: http://www.audiologs.com/ozrenbilan/05_DSP.pdf, pristup ostvaren 28.12.2017.
- [10] G. Majstorović, D. Bajs, N. Dizdarević, Upravljanje zagušenjem u prijenosnoj mreži, Energija br. 2, pp 121-136, Zagreb, travanj 2005.
- [11] Hrvatski operator prijenosnog sustava d.o.o., podaci o hrvatskom prijenosnom sustavu i tržištu električne energije. Dostupno na <https://www.hops.hr/wps/portal/hr/web>, pristup ostvaren 3.1.2018.

[12] Hrvatska energetska regulatorna agencija, Godišnje izvješće za 2016. godinu, Zagreb, 2017. Dostupno na: https://www.hera.hr/hr/docs/HERA_izvjesce_2016.pdf, pristup ostvaren 6.1.2018.

[13] B. Vuk, R. Fabek, D. Golja, M. Maričević, T. Baričević, S. Antešević, J. Maras, N. Karadža, T. Borković, V. Krstulović, B. Židov, Ž. Jurić, M. Karan, P. Ramljak, Energija u Hrvatskoj godišnji energetske pregled 2016, Ministarstvo zaštite okoliša i energetike Republike Hrvatske, Zagreb, 2017. Dostupno na: <http://www.eihp.hr/wp-content/uploads/2018/02/EUH2016.pdf>, pristup ostvaren 6.1.2018.

[14] HEP Godišnje izvješće 2016. Dostupno na: http://www.hep.hr/UserDocsImages//dokumenti/Godisnje_izvjesce//2016godisnje.pdf, pristup ostvaren 3.1.2018.

[15] Hrvatski operator tržišta energije, podaci o tržištu električne energije u Republici Hrvatskoj- Dostupno na: <http://www.hrote.hr/>, pristup ostvaren: 15.1.2018.

[16] Weather Underground, povijesni podaci o meteorološkim uvjetima za mjernu postaju Zagreb Pleso. Dostupno na: <https://www.wunderground.com/history/airport/LDZA/2011/02/10/DailyHistory.html>, pristup ostvaren: 20.12.2017.

[17] European Network of Transmission System Operators, povijesni podaci o opterećenju elektroenergetskog sustava Republike Hrvatske. Dostupno na: <https://transparency.entsoe.eu/load-domain/r2/totalLoadR2/show>, pristup ostvaren: 20.12.2017.

[18] Hrvatska burza električne energije, podaci za dan unaprijed cijene električne energije. Dostupno na: <https://www.cropex.hr/hr/>, pristup ostvaren: 20.12.2017.

SAŽETAK

Diplomski rad podijeljen je na teorijski i praktični dio. Ovisno o vrsti primjene, predviđanje opterećenja i cijena dijeli se u tri glavne kategorije: kratkoročno, srednjoročno i dugoročno. Faktori koji utječu na obrasce opterećenja i cijene su opisani. ANN metoda se koristi jer pruža jednostavan i učinkovit način za prognozu u praktičnoj primjeni te također predstavlja i nelinearne funkcije. Načini učenja i metode treniranja su pojašnjeni. Praktični dio najprije opisuje podatke za trening i testiranje koji su korišteni za predloženi model za kratkoročnu prognozu opterećenja i cijene. Opterećenje, cijena i temperatura su prikazani. Rezultati su razmotreni na temelju srednje apsolutne postotne pogreške.

Ključne riječi: umjetne neuronske mreže, kratkoročna prognoza opterećenja, kratkoročna prognoza cijene, srednja apsolutna postotna pogreška, volatilnost

ABSTRACT

The final thesis has theoretical and the practical part. Based on its specific application, load and price forecasting can be categorized into short-term, mid-term and longterm. Factors affecting load and price patterns are described. ANN method is used because it provides a simple and powerful tool for forecasting in practical systems and it also represents non-linear functions. Learning strategies and training methods are explained. Practical section first described training and test data used to test the proposed ANN model for short-term load and price forecasting. Load, price and temperature data are presented. Then results are discussed based on the mean absolute percentage error.

Key words: artificial neural networks, short-term load forecast, short-term price forecast, mean absolute percentage error, volatility

ŽIVOTOPIS

Ines Klešić rođena je u Osijeku, 28.1.1991. godine. 2005. godine završava Osnovnu školu Višnjevac u Višnjevcu te upisuje III. Gimnaziju Osijek. Po završetku gimnazije, upisuje Elektrotehnički fakultet Osijek, studij elektrotehnike, smjer energetika. U travnju 2017. godine odlazi na stručnu praksu u Veliku Britaniju nakon koje obavlja stručnu praksu u Švedskoj. Trenutno je zaposlena u tvrtki Opcon Energy System AB. U slobodno vrijeme bavi se crtanjem i volontiranjem.