

PREDVIĐANJE POTROŠNJE
PRIRODNOG PLINA

ZAHTJEVI I ISKUSTVA
U PRIMJENI
NEURONSKIH MREŽA

PTMG

Dupli**co**

PREDVIĐANJE POTROŠNJE PRIRODNOG PLINA – ZAHTJEVI I ISKUSTVA U PRIMJENI NEURONSKIH MREŽA

SAŽETAK

Pravilnikom o organizaciji tržišta prirodnog plina predviđeno je da opskrbljivači na distributivnom sustavu svakodnevno opskrbljivaču (dobavljaču) dostavljaju potrebne dnevne količine prirodnog plina u TJ/dan, odnosno u m³/dan, razrađene za svaki sat. Krajnji kupci priključeni na distribucijski sustav, a koji godišnje troše više od 35 MJ ili imaju priključnu snagu veću od 10 MW, dužni su svakodnevno opskrbljivaču na distributivnom sustavu dostavljati planiranu potrošnju plina. Opiskrbljivač je dužan svakodnevno nominirati potrošnju operatoru transportnog sustava. Nominacije se moraju početi dostavljati počevši od 01. siječnja 2010.

Da bi predviđanje planirane potrošnje plina odnosno nominacije bile što točnije razvijeni su razni sustavi kojima se izračunava potrošnja plina za naredni dan.

Suvremeni sustavi za izračun potrošnje plina koriste neuronske mreže. Kod primjene neuronskih mreža potrebno je odrediti što bolju strukturu neuronske mreže te odrediti elemente koji će se uzimati u obzir. Također treba pravilno odabrati način učenja neuronske mreže kao i način arhiviranja svih izmjerenih podataka.

Sustav mora omogućiti pravovremenu reakciju opskrbljivača na distributivnom sustavu u slučaju prekoračenja planiranih vrijednosti potrošnje plina. U tu svrhu opskrbljivaču mora biti omogućen podatak o trenutnoj potrošnji plina na distributivnom sustavu. Za to se treba koristiti stabilna komunikacijska veza, te odgovarajući oprema za arhiviranje podataka. Ujedno sustav za očitanje satne potrošnje plina mora biti prilagođen za prijenos podataka sa različitih korektora plina.

PREDVIĐANJE POTROŠNJE PRIRODNOG PLINA – ZAHTJEVI I ISKUSTVA U PRIMJENI NEURONSKIH MREŽA

1. UVOD

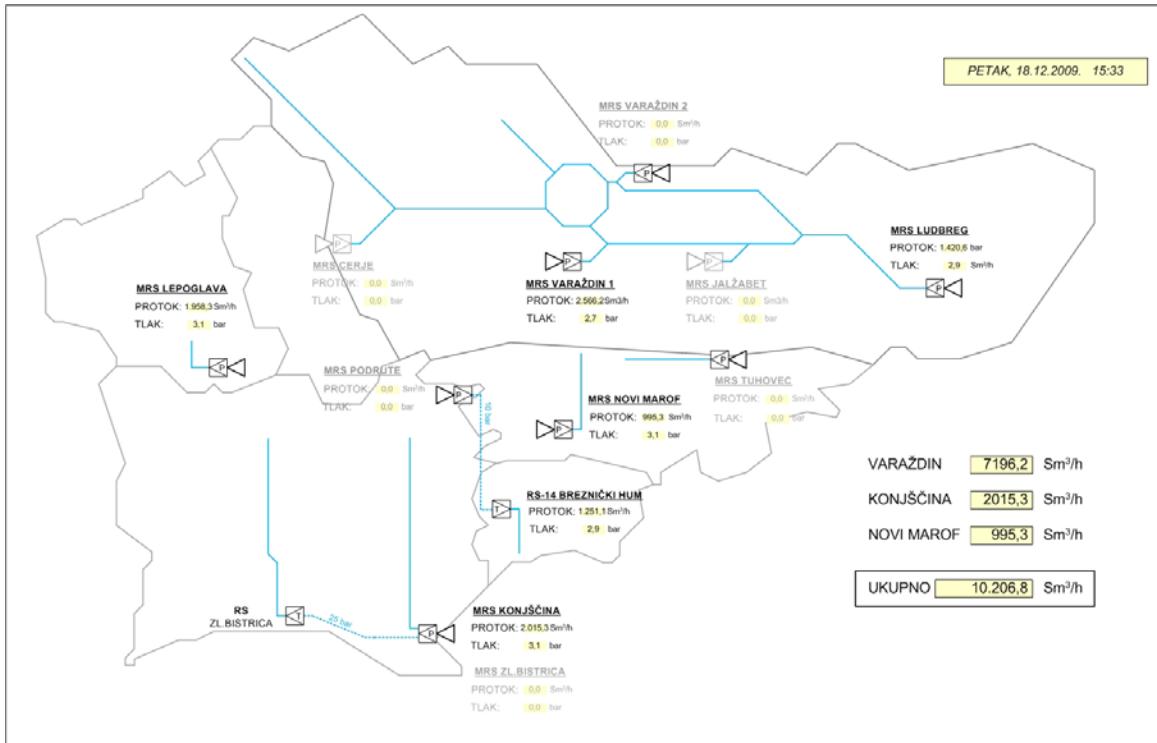
Pravilnikom o organizaciji tržišta prirodnog plina predviđeno je da opskrbljivači na distributivnom sustavu svakodnevno opskrbljivaču (dobavljaču) dostavljaju potrebne dnevne količine prirodnog plina u MJ/dan, odnosno u m³/dan, za sutrašnji plinski dan, razrađene za svaki sat. Krajnji kupci priključeni na distribucijski sustav, a koji godišnje troše više od 35 TJ ili imaju priključnu snagu veću od 10 MW, dužni su također svakodnevno opskrbljivaču na distributivnom sustavu dostavljati svoju planiranu potrošnju plina za sutrašnji plinski dan. Opiskrbljivač je dužan svakodnevno nominirati potrošnju operatoru transportnog sustava. Nominacije se moraju početi dostavljati počevši od 01. siječnja 2010.

2. BAZA PODATAKA

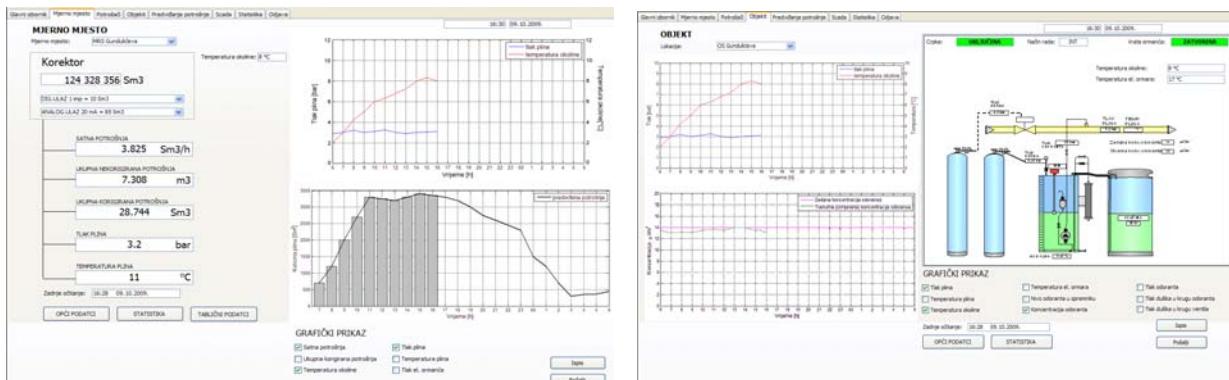
Za predviđanje što preciznije prognoze za potrošnju prirodnog plina potrebno je imati što veću bazu sa višegodišnjim podacima o dnevnom profilu potrošnje plina prema određenim uvjetima kao što su dnevna temperatura, tip dana, brzina vjetra, nivo svjetlosti dana itd.

Kako su za stvaranje baze podataka odnosno za izradu standardnih i relativnih dijagrama opterećenja zaduženi operateri distribucijskog sustava to je nužna dobra povezanost između opskrbljivača na distributivnom sustav i operatera distribucijskog sustava. Zbog toga operater distribucijsko sustava treba imati odgovarajući nadzorno upravljački centar (NUC) sa instaliranom odgovarajućom SCADA aplikacijom. SCADA (engl. supervisory control and data acquisition) aplikacija predstavlja računalni sustav za prikupljanje i obradu podataka u stvarnom vremenu.

Preko SCADA-e (sl. 1) iz NUC-a operater je povezan sa objektima na plinskom distribucijskom sustavu i pomoću odgovarajućih aplikacija prima podatke sa plinskih objekata te daljinski nadzire i upravlja opremom instaliranom u plinskim objektima. Plinski objekti sa kojih se prenose podaci mogu biti MRS –e tvrtke PLINACRO (sl. 2), odorizacijske stanice (sl. 3), MRS-e operatera distribucijskog sustava (sl. 4), regulacijska okna (sl. 5) te mjerna mjesta krajnjih korisnika sa potrošnjom većom od 35 TJ/god. i priključenih na distribucijski sustav.

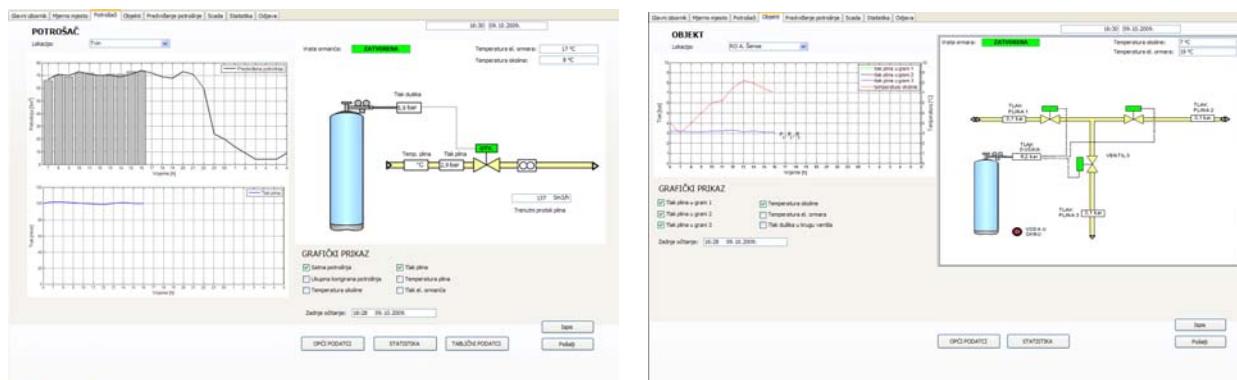


SI. 1 – SCADA – prikaz naslovne stranice



SI. 2 – SCADA – prikaz MRS PLINACRO

SI. 3 – SCADA – prikaz odorizacijske stanice



SI. 4 – SCADA – prikaz MRS distributera

SI. 5 – SCADA – prikaz regulacijskog okna

Podaci koje operater može dobiti sa plinskih objekata između ostalog mogu biti:

- datum očitanja
- vrijeme očitanja
- trenutni protok plina
- satna potrošnja plina [Sm^3/h]
- ukupni protok plina [Sm^3]
- tlak plina [bar]
- temperaturna plina [$^\circ\text{C}$]
- temperaturna okoline [$^\circ\text{C}$]
- temperaturna upravljačkog ormarića [$^\circ\text{C}$]
- zadana koncentracija odoranta [$\mu\text{l}/\text{Sm}^3$]
- stvarna koncentracija odoranta [$\mu\text{l}/\text{Sm}^3$]
- količina odoranta u spremniku - izračunata vrijednost [l]
- rezervna razina odoranta

Prijenos podataka sa opreme instaliranih u objektima smještenim na plinskom distributivnom sustavu do centralne jedinice – SCADA-e i njihovo povezivanje u jedinstven sustav ostvaruje se uz pomoć GPRS veze unutar zatvorene VPN mreže sa statičkim IP adresama objekata. Za funkcioniranje GPRS veze nije potrebna posebna infrastruktura već se koriste postojeće komunikacije, a sam prijenos podataka je siguran, brz i točan. Važno je naglasiti da je korisnik iz NUC-a 24 sata povezan sa svojim distributivnim sustavom te da podatke sa sustava prima u razmaku od po 15 minuta. Takvim načinom prijenosa podataka korisniku je omogućeno da praktički kontinuirano prati potrošnju plina na svom cjelokupnom distribucijskom sustavu, te potrošnju plina krajnjih korisnika na distribucijskom sustavu koji su u obvezi nominirati potrošnju plina. To mu omogućuje da u slučaju značajnijeg odstupanja potrošnje plina od nominirane vrijednosti pokuša određenim aktivnostima vratiti potrošnju u nominirane okvire i time izbjegne plaćanje nepotrebne kazne.

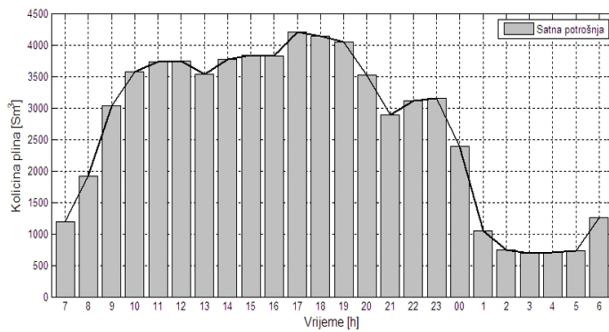
Sa hidrometeorološke stanice koja je smještene na području operatera distribucijskog sustava operater dobiva podatke o:

- datumu očitanja
- vremenu očitanja
- temperaturi zraka
- relativnoj vlažnosti
- tlaku zraka
- smjeru vjetra
- brzini vjetra
- naoblaci
- oborinama

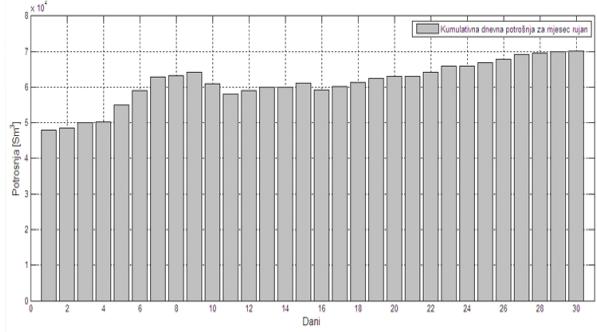
Podaci o potrošnji plina dobiveni sa korektora smještenih u MRS-a tvrtke PLINACRO u korelaciji sa navedenim podacima sa hidrometeorološke stanice i podacima o tipu dana (radni dan, neradni dan, školski dan,) spremaju se u bazu podataka.

Podaci iz baze služe operateru distribucijskog sustava da može izrađivati određene statističke obrade i analize i prikaze kao:

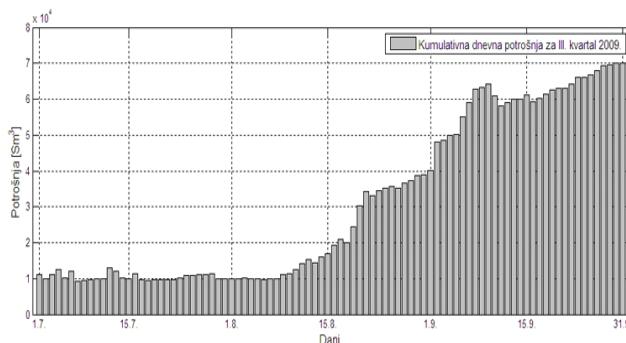
- prikaz potrošnje plina za plinski dan po satima
- prikaz ponašanja tlaka plina u sustavu
- prikaz satne potrošnje plina krajnjih korisnika na sustavu
- prikaz mjesečne potrošnje plina dane po plinskim danima
- prikaz kvartalne potrošnje plina dane po plinskim danima
- prikaz godišnje potrošnje plina dane po mjesecima
- analize potrošnje plina po godinama
- ostale analize po zahtjevu korisnika



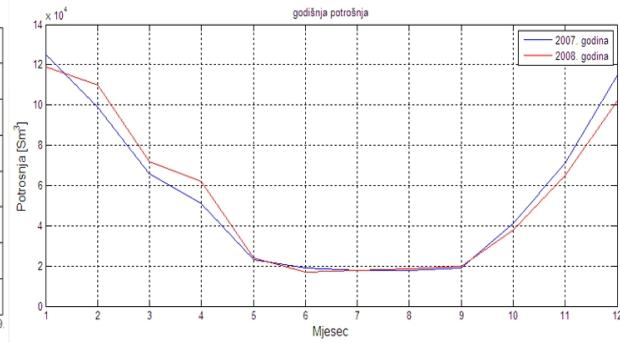
Sl. 6 – prikaz potrošnje plina za plinski dan



Sl. 7 – prikaz mjesečne kumulativne potrošnje plina

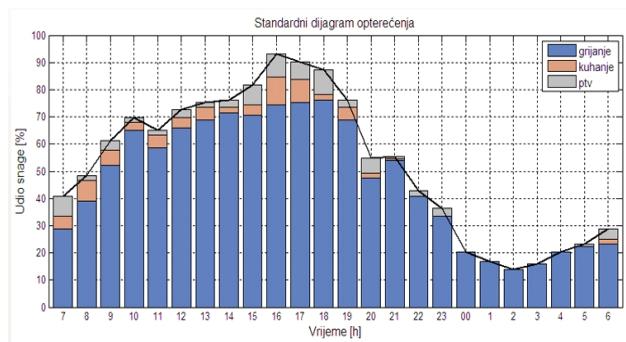


Sl. 8 – prikaz kvartalne kumulativne potrošnje plina

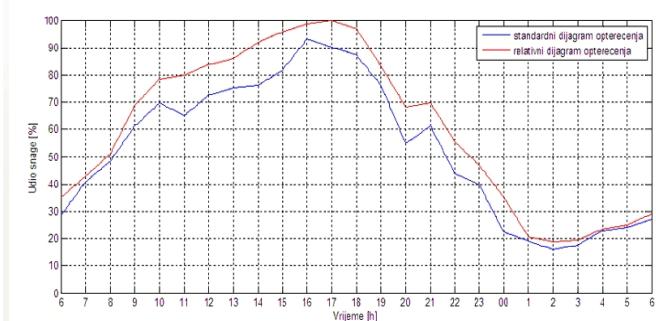


Sl. 9 – analiza potrošnje plina po godinama

Ujedno se iz potrošnje plina za plinski dan koja se umanjuje za potrošnju plina krajnjih korisnika na distributivnom sustavu koji troše više od 35 TJ/god plina godišnje izrađuje standardni dijagram opterećenja te relativni dijagram opterećenja.



Sl. 10 – standardni dijagram opterećenja



Sl. 11- relativni dijagram opterećenja

3. NAJAVA POTROŠNJE PLINA ZA IDUĆI PLINSKI DAN

Opskrbljivač na distributivnom sustavu dužan je najaviti svoju potrošnju plina za idući plinski dan opskrbljivaču (dobavljaču) plina na transportu, te očekivani satni maksimum na svakom mjestu preuzimanja plina.

Prognoza potrošnje može se vršiti korištenjem:

- statističkih metoda
- umjetnih neuronskih mreža

Kako je količina raspoloživih povijesnih podataka o potrošnji plina kod naših distributera vrlo skromna za izradu prognoze potrošnje plina za naredni plinski dan razvili sustav koji je baziran na umjetnim neuronskim mrežama. Takav način izrade nominacija izabran je zbog nelinearnog ponašanja sustava potrošnje plina, a upravo je to bitna karakteristika neuronskih mreža. Njezina prednost nad statističkim metodama je i mali broj povijesnih podataka potrebnih za izradu nominacija zadovoljavajućih točnosti.

Sustav potrošnje plina je kompleksan i sa velikim brojem ulaznih parametara. Iz tog razloga potrebno je točno prikupiti povijesne podatke na kojima će biti moguće učenje neuronskih mreža te odrediti koji od njih su bitni, a koji negativno utječu na naš sustav izrade prognoze.

Kako bi se osigurali podaci za učenje neuronskih mreža potrebno je kontinuirano mjerjenje i arhiviranje podataka. To podrazumijeva i osiguravanje stabilne komunikacijske veze te prepoznavanje i pravovremeno reagiranje na ispad komunikacije. Na taj način osiguravamo potpunu autonomnost i automatiziranost sustava izrade prognoze te njegovu točnost i ažuriranost.

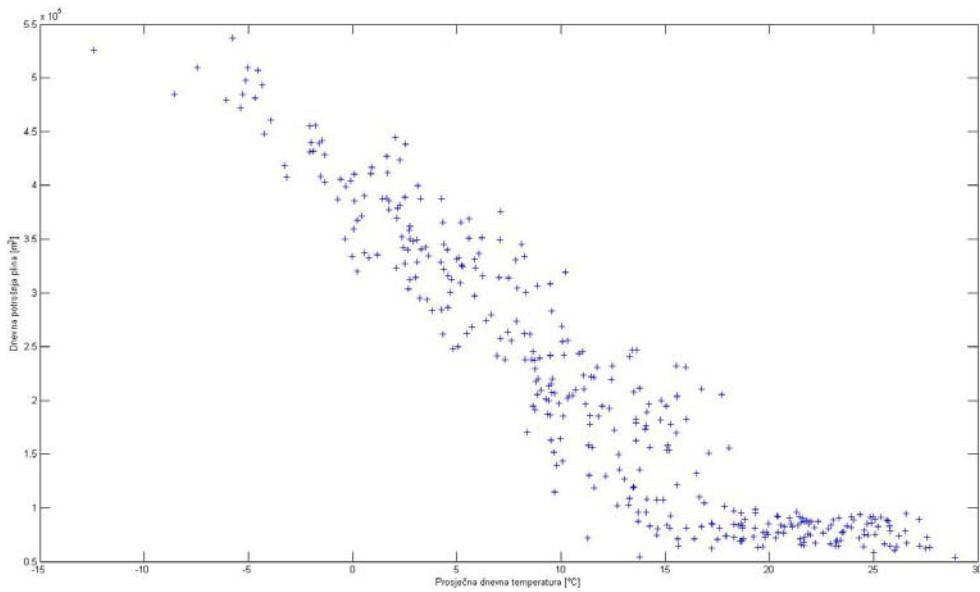
4. PRIKUPLJANJE I ODABIR ULAZNIH PODATAKA ZA NEURONSKE MREŽE

Iskustveno se može zaključiti da će potrošnja prirodnog plina uglavnom ovisiti o godišnjem dobu, vanjskim temperaturama, prijašnjoj potrošnji i tipu dana u tjednu (sl. 12). Količinu ulaznih podataka treba pomno odabrati jer prevelika količina ulaznih podataka u sustav mogla bi se loše odraziti na preciznost izrađenih prognoza zbog moguće pojave šuma tj. prenaučenosti neuronske mreže.

Najveći problem sa stajališta ulaznih podataka je nepostojanje povijesnih podataka za mjerna mjesta praktički svih operatera distribucijskih sustava u Hrvatskoj. To se naročito odnosi na nepostojanje ili netočnost te nedovoljnu preciznost meteoroloških podataka.

Za osiguranje meteoroloških podataka nužnih za kvalitetnu izradu prognoze potrošnje plina predviđeno je da svaki operater distribucijskog sustava instalira vlastitu automatiziranu meteorološku stanicu sa koje bi se dobivali svi relevantni podaci o vremenu. Podaci o dobivenim satnim vremenskim parametrima povezivat će se sa očitanom potrošnjom plina za određeni sat i kao takvi pohranjivat u bazu podataka. Zbog toga sustav mora imati i opremu za očitanje i prikupljanje podatak o satnim potrošnjama plina. Kako bi tako očitani iznosi za potrošnju plina odgovarali iznosima koje očitava operater transportnog sustava nužna je sinhronizacija sata našeg sustava sa satom operatera transportnog sustava.

Osim toga operater transportnog sustava dužan je svakodnevno za prethodni plinski dan opskrbljivaču na distributivnom sustavu dostaviti stvarne podatke o potrošnji plina za prethodni plinski dan. Na taj način smo u mogućnosti kontrolirati točnost naših očitanih podataka o potrošnji plina te taj podatak iskoristiti za daljnje učenje neuronskih mreža u svrhu što točnije izrade prognoze potrošnje plina.



Sl. 12 - ovisnost dnevne potrošnje plina o prosječnoj dnevnoj temperaturi

5. ODABIR NEURONSKE MREŽE

Umetne neuronske mreže su sustav koji matematičkim formulacijama pokušava opisati biološke neuronske mreže. One se kao i biološke sastoje od neurona te njihovih dendrita (ulaza u neuron), aksona (izlaza iz neurona) i some (jezgre). Neuroni su posloženi u slojeve te tako razlikujemo ulazni, skriveni i izlazni sloj. Ovisno o tipu mreže može postojati jedan ili više skrivenih slojeva. Organizacijom slojeva i raspodjelom neurona postiže se željena struktura neuronske mreže.

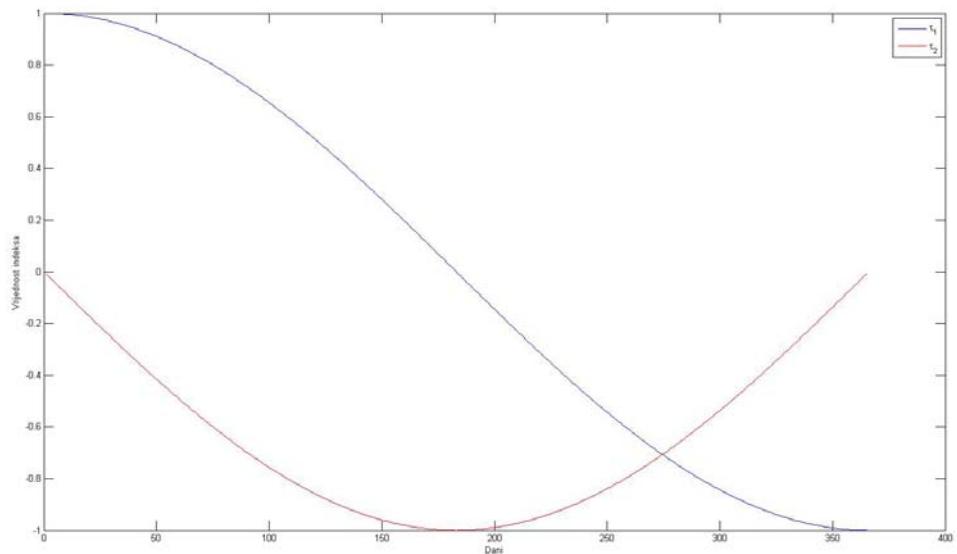
Postoji više vrsti neuronskih mreža od kojih naš sustav koristi dva tipa - MLP (multi layer perceptron) i RBF (radial bias function) mreže. Ove dvije mreže se razlikuju po svojoj strukturi, broju neurona, matematičkim funkcijama u neuronima te mogućnosti lokalizacije RBF mreže koja nije prisutna u MLP mreži.

Najveći problem pri izradi sustava temeljenog na neuronskim mrežama je optimalan odabir broja neurona, slojeva te ulaza u neuronske mreže. Povećavanjem broja ulaza neminovno se povećava i broj neurona, kako bi se dobio dovoljan broj parametara koji će omogućiti mreži da na temelju ulaznih podataka nauči ponašanje sustava potrošnje prirodnog plina. Ukoliko je broj parametara mreže sumjerljiv sa količinom povijesnih podataka mreža neće moći dobro naučiti. Naime izgubit će svoj svojstvo poopćavanja te će naučiti šum koji je neminovno prisutan u svim podacima što će se odraziti na preciznost predviđanja potrošnje. Da bi se to izbjeglo potrebno je imati što veću količinu povijesnih podataka odnosno morali bi posjedovati povijesne podatke od minimalno zadnjih godinu dana. Na taj način mreža učenjem prolazi kroz sva stanja sustava potrošnje plina te zadržava svojstvo poopćavanja.

Veliki problem prilikom izrade prognoze potrošnje je pogreška u prognoziranim meteorološkim podacima. Potrošnja plina najviše ovisi o vanjskoj temperaturi, a netočnost koja je prisutna u prognozi značajno se prenosi i na sustav za izradu prognoze potrošnje plina.

Ulazi koji su u potpunosti točni su povijesne izmjerenе potrošnje plina, tipovi dana te vremenski indeksi kojima opisuјemo godišnja doba, odnosno dan u godini.

Kao tip dana razlikujemo praznik (nosi oznaku 0), dan vikenda (nosi oznaku 1), petak (nosi oznaku 0,5) te radni dan izuzev petak (nosi oznaku -1). Ova četiri tipa dana pokazala su se kao optimalnim izborom s obzirom na količinu povijesnih podataka i rezultate nominacija.



Sl. 13 - Prikaz vremenskih indeksa korištenih za opis godišnja doba

Iz slike 13 je vidljivo da vremenski indeksi imaju vrijednosti od -1 do +1. Razlog tome je normiranje ulaza za neuronski mrežu. Zbog svojih matematičkih funkcija u neuronima na ulaz se mogu dovesti samo vrijednosti od -1 do +1.

Pomoću ovih vremenskih indeksa može se precizno odrediti dan u godini, odnosno godišnje doba. Razlog uvođenja ovih indeksa je velika ovisnost potrošnje o godišnjim dobima, tj. potrošnja nije jednaka pri 12°C u svibnju i pri 12°C u ožujku.

U normiraju leži još jedan problem koji do izražaja dolazi ako postoji mali broj povijesnih podataka. Standardni način normiranja se provodi tako da se svaki ulazni podatak podjeli sa najvećim ulaznim podatkom istog tipa uvećanim za 20%. Ukoliko imamo samo povijesne podatke za zimu jasno je da niti najveća zimska temperatura uvećana za 20% neće biti blizu ljetne temperature. U tom slučaju normirana temperatura će iznositi više od jedan i kao takva dovest će neuron u zasićenje. Neuron u zasićenju nije u mogućnosti učiti, a ukoliko se kod tih uvjeta provodi nominacija izlazi iz mreže će biti vrlo netočni. Ukoliko bi se vršilo renormiranje onda bi nakon svakog novoprikljenog podatka bilo potrebno ponovno generirati mrežu i učiti je ispočetka. Ako se ne bi tako postupilo, novo normiranje ne bi odgovaralo starom što znači da bi se isti podaci različito prezentirali te tako unosili grešku.

Danas nažalost distributeri u Hrvatskoj ne posjeduju povijesne podatke o potrošnji plina koji bi bili povezani sa vanjskim temperaturama zraka i tipom dana. Zbog toga su prisiljeni prikupljati spomenute podatke praktički iz početka. Takva situacija bila i u Virovitici na odorizacijskoj stanici Đolta sa koje smo vršili prikupljanje podataka i testiranja sustava.

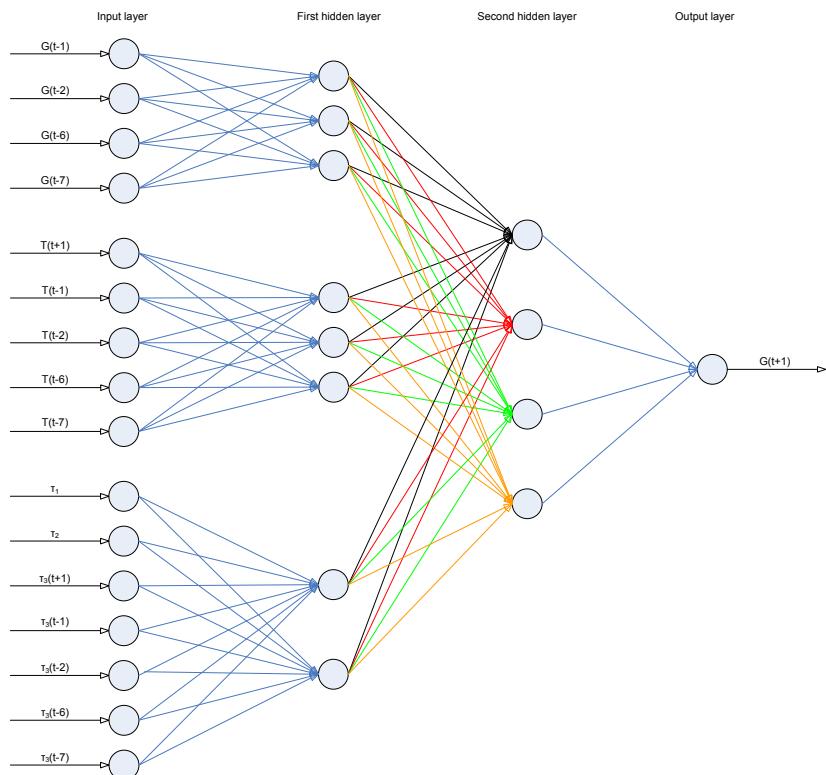
Nakon dvomjesečnog prikupljanja podataka pristupilo se izradi nominacija. Sustav za nominiranje se sastojao od više različitih struktura i tipova mreža te načina izrade nominacija. Naime, pokazalo se kako određeni tip mreže i način određivanja nominacija daje bolje rezultate kod jednih uvjeta a drugi tip mreže kod drugih uvjeta (temperatura, tip dana, dio dana). Kombiniranjem navedenih sustava neuronskih mreža dobiveni su bolji rezultati nego što su to bili rezultati svakog pojedinog sustava.

6. PRIKAZ DOBIVENIH REZULTATA

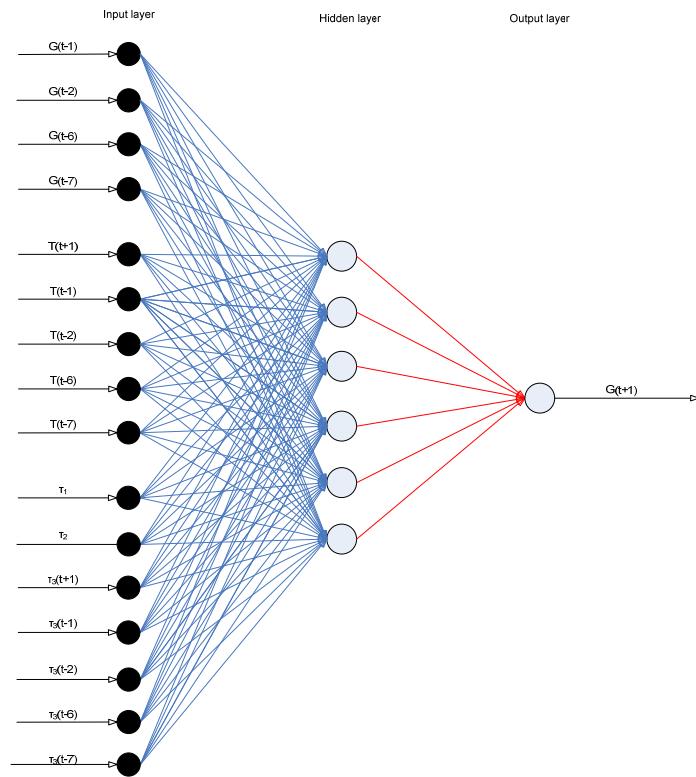
6.1. Izrada satnih nominacija temeljena na 24 neuronske mreže

Prvi dio sustava čine dvadeset i četiri MLP i dvadeset i četiri RBF mreže od kojih je svaka mreža zadužena za izradu nominacija za svaki pojedini sat. Svaka od tih mreža ima sljedeće ulaze:

$G(t-1)$	- satna potrošnja plina na jučerašnji dan
$G(t-2)$	- satna potrošnja plina na prekjučerašnji dan
$G(t-6)$	- satna potrošnja plina prije šest dana
$G(t-7)$	- satna potrošnja plina prije sedam dana
$T(t+1)$	- satna temperatura na sutrašnji dan
$T(t-1)$	- satna temperatura na jučerašnji dan
$T(t-2)$	- satna temperatura na prekjučerašnji dan
$T(t-6)$	- satna temperatura prije šest dana
$T(t-7)$	- satna temperatura prije sedam dana
τ_1	- vremenski indeks 1
τ_2	- vremenski indeks 2
$\tau_3(t+1)$	- tip sutrašnjeg dana
$\tau_3(t-1)$	- tip jučerašnjeg dana
$\tau_3(t-2)$	- tip prekjučerašnjeg dana
$\tau_3(t-6)$	- tip dana prije šest dana
$\tau_3(t-7)$	- tip dana prije sedam dana

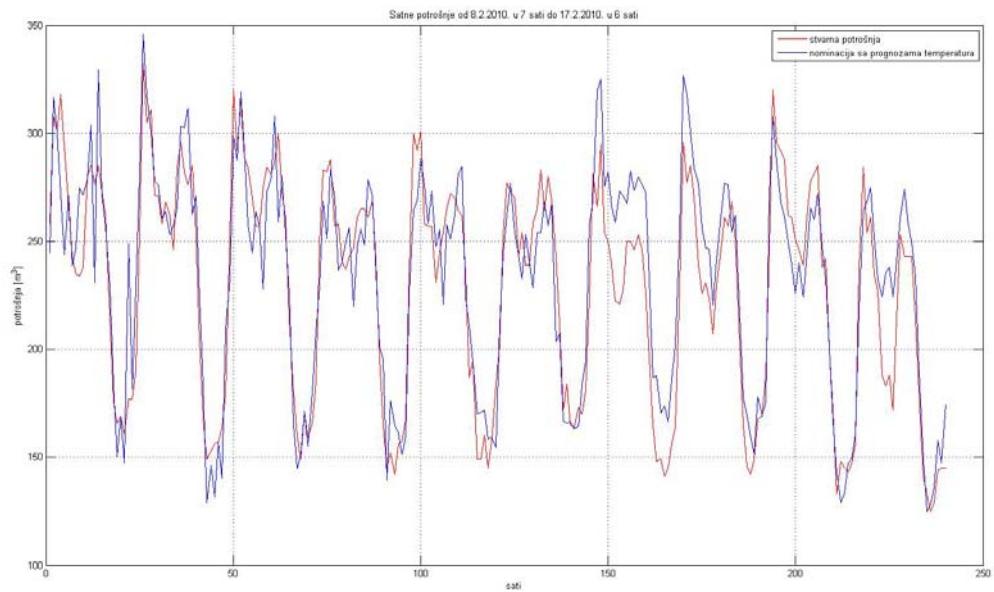


Sl. 14 – Struktura MLP mreža korištenih za satne nominacije

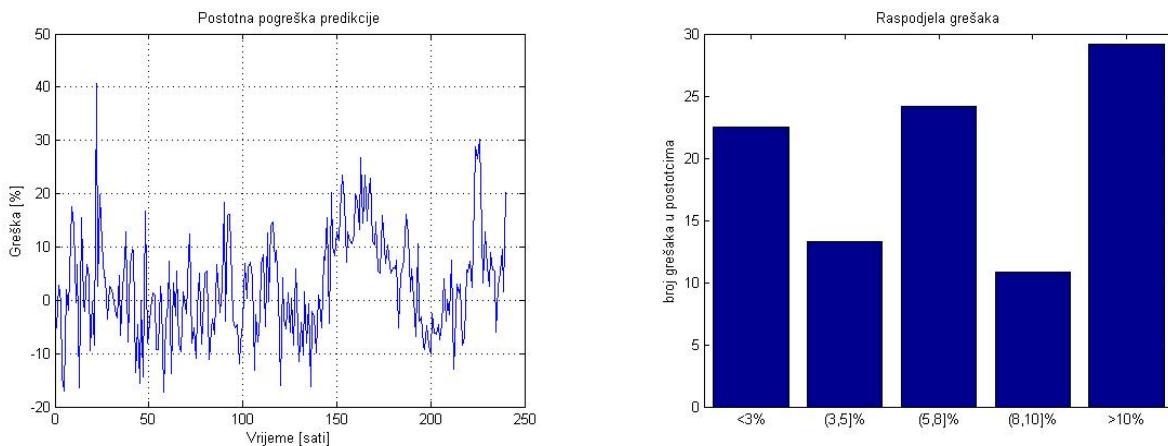


Sl. 15 – Struktura RBF mreža korištenih za satne nominacije

Rezultati dobiveni korištenjem 24 MLP neuronske mreže



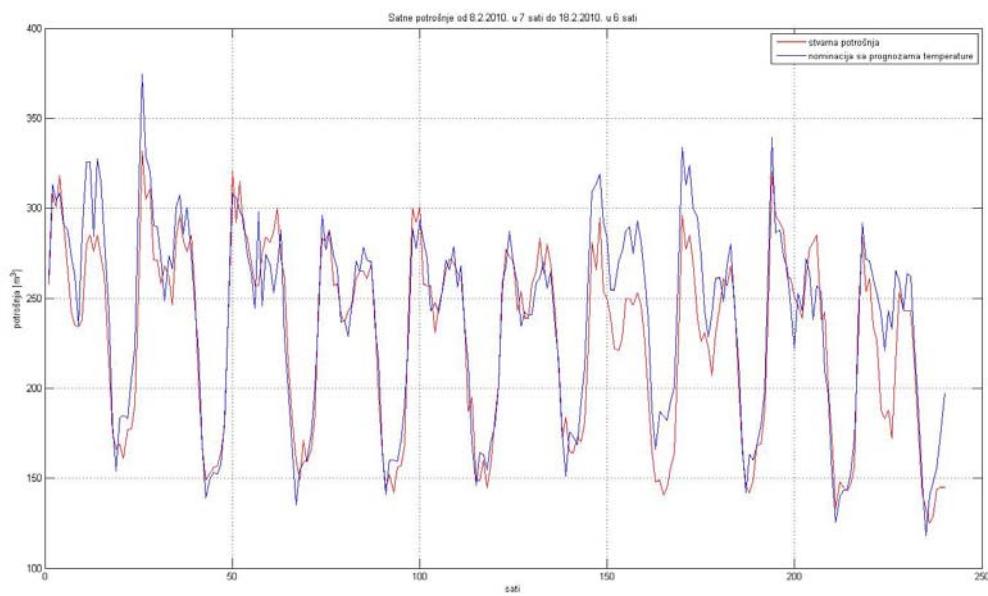
Sl. 16 – Nominirana satna potrošnja korištenjem MLP mreža



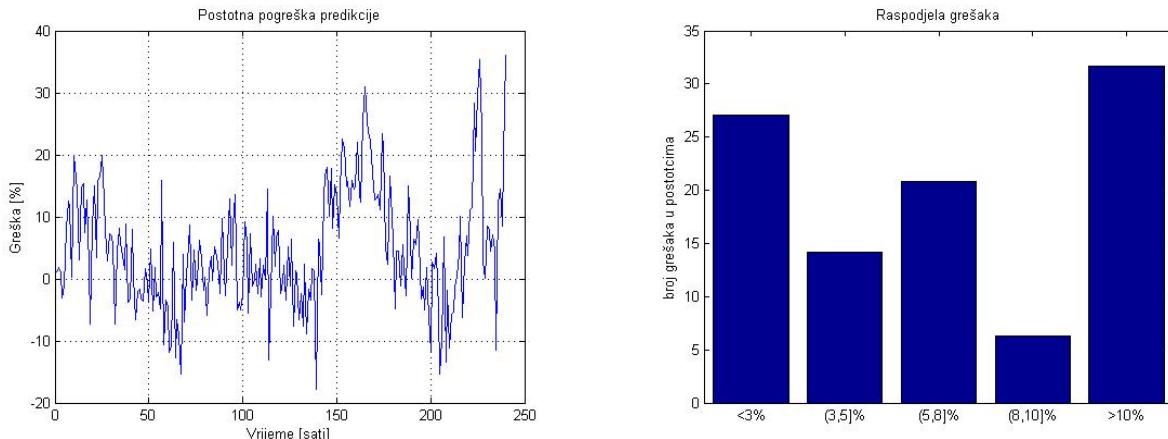
Sl. 17 - Pogreške nominacija satne potrošnje korišnjem 24 MLP mreže i njihova raspodjela

Prosječna pogreška ovako izrađenih nominacija za deset dana iznosila je 7,98%.

Rezultati dobiveni korištenjem 24 RBF neuronske mreže



Sl. 18 - Nominirana satna potrošnja korištenjem RBF mreža



Sl. 19 - Pogreške nominacija satne potrošnje korištenjem 24 RBF mreže i njihova raspodjela

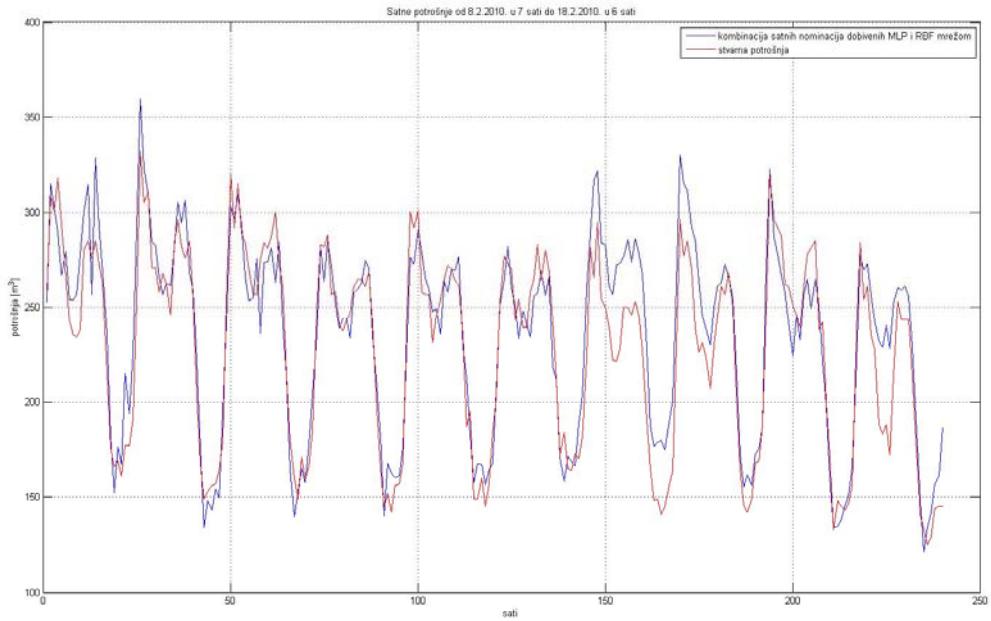
Prosječna pogreška ovako izrađenih nominacija za deset dana iznosila je 8,09%.

6.2. Izrada satnih nominacija temeljenih na kombinaciji RBF i MLP neuronskih mreža

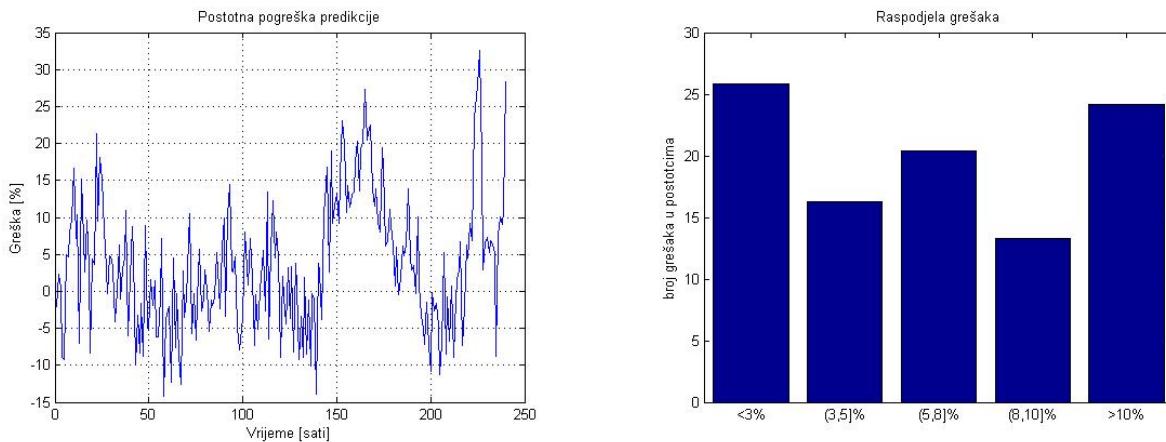
Analizom dobivenih rezultata uočena je ovisnost pogreške mreža o dobu dana. Stoga je dan raspodjeljen na četiri razdoblja prema kojima su raspodjeljeni i izlazi mreža. Ta razdoblja čine intervali:

1. od 7 do 12 sati
2. od 13 do 17 sati
3. od 18 do 24 sata
4. od 1 sat do 6 sati

Za svako razdoblje izračunata je varijanca (kvadrat pogreške) te je preko nje dobiven koeficijent po kojem je proračunat udio pojedinog izlaza u ukupnom izlazu.



Sl. 20 – Nominirane satne potrošnje dobivene kombinacijom izlaza 24 RBF i 24 MLP mreže



Sl. 21 – Pogreške nominacija satne potrošnje dobivenih kombinacijom izlaza 24 RBF i 24 MLP mreže te njihova raspodjela

Prosječna pogreška ovako izrađenih nominacija za deset dana iznosila je 7,4%.

6.3. Izrada satnih nominacija temeljenih na dnevnim nominacijama i udjelu satnih potrošnji u dnevnoj potrošnji

Ovaj dio sustava za izradu nominacija čine RBF mreža koja je korištena za izradu dnevnih nominacija te MLP i RBF mreže pomoću kojih se izrađuje oblik satne potrošnje.

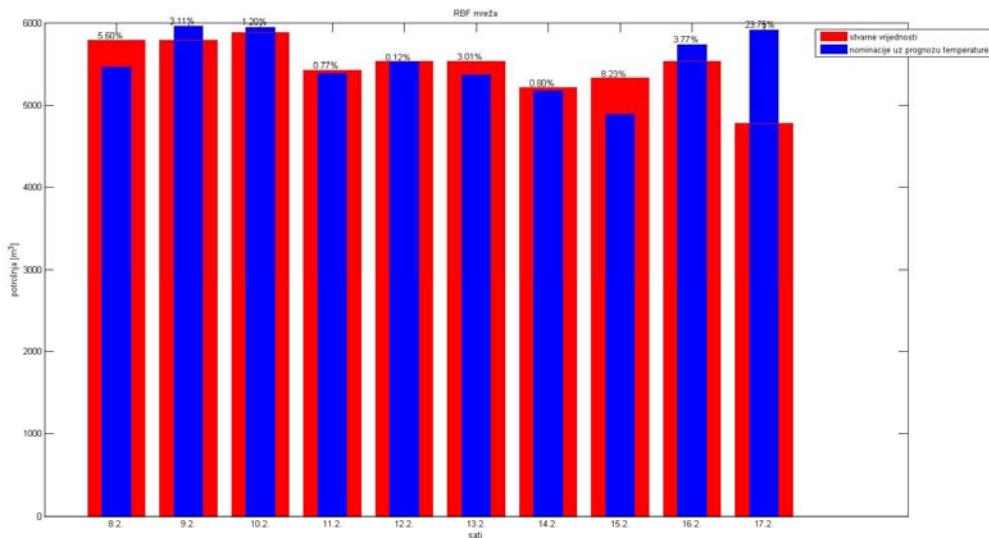
Izrada dnevnih nominacija

RBF neuronska mreža za izradu dnevnih nominacija ima ulaze slične onima kod neuronskih mreža za izradu satnih nominacija s razlikom što su ulazi promatrani na dnevnoj razini dok se za temperature uzimaju minimalne i maksimalne dnevne razine.

RBF mreže za izradu dnevnih nominacija ima sljedeće ulaze:

$G(t-1)$	- dnevna potrošnja plina na jučerašnji dan
$G(t-2)$	- dnevna potrošnja plina na prekjučerašnji dan
$G(t-6)$	- dnevna potrošnja plina prije šest dana
$G(t-7)$	- dnevna potrošnja plina prije sedam dana
$T_{min}(t+1)$	- minimalna dnevna temperatura na sutrašnji dan
$T_{min}(t-1)$	- minimalna dnevna temperatura na jučerašnji dan
$T_{min}(t-2)$	- minimalna dnevna temperatura na prekjučerašnji dan
$T_{min}(t-6)$	- minimalna dnevna temperatura prije šest dana
$T_{min}(t-7)$	- minimalna dnevna temperatura prije sedam dana
$T_{max}(t+1)$	- maksimalna dnevna temperatura na sutrašnji dan
$T_{max}(t-1)$	- maksimalna dnevna temperatura na jučerašnji dan
$T_{max}(t-2)$	- maksimalna dnevna temperatura na prekjučerašnji dan
$T_{max}(t-6)$	- maksimalna dnevna temperatura prije šest dana
$T_{max}(t-7)$	- maksimalna dnevna temperatura prije sedam dana
τ_1	- vremenski indeks 1
τ_2	- vremenski indeks 2
$\tau_3(t+1)$	- tip sutrašnjeg dana
$\tau_3(t-1)$	- tip jučerašnjeg dana
$\tau_3(t-2)$	- tip prekjučerašnjeg dana
$\tau_3(t-6)$	- tip dana prije šest dana
$\tau_3(t-7)$	- tip dana prije sedam dana

Rezultati dobiveni pomoću RBF mreže za izradu dnevnih nominacija:



Sl. 22 - Nominirane dnevne potrošnje

Prosječna pogreška nominiranih vrijednosti na dnevnoj razini za deset dana iznosila je 5,07%.

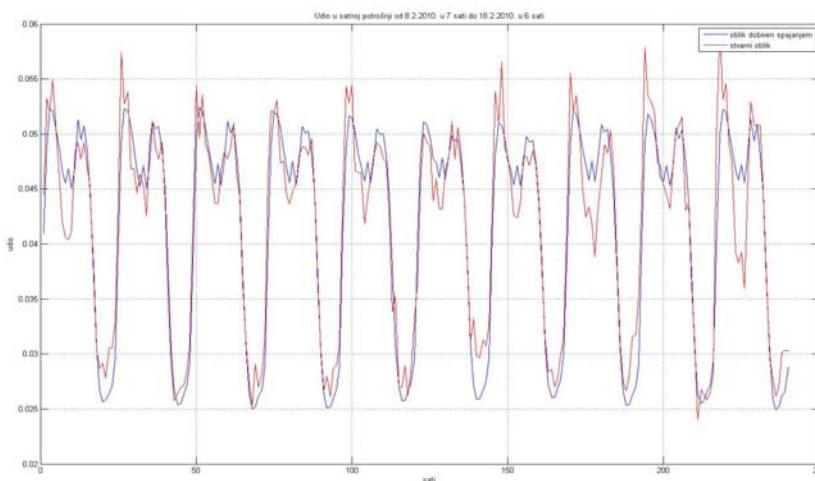
Za izradu dnevne nominacije nije korištena MLP neuronska mreža jer je kod prethodnih analiza dala nezadovoljavajuće rezultate.

Proračun udjela satne potrošnje u ukupnoj dnevnoj potrošnji

Vrlo dobre rezultate koje smo dobili kod dnevnih nominacija u izradi satnih nominacija odlučili smo primijeniti kod neuronske mreže u proračunu udjela satne potrošnje u dnevnoj potrošnji. Na taj način dobiven je oblik dnevne potrošnje, a ukupno dobivenu dnevnu nominaciju smo raspodjelili po satima prema dobivenim udjelima.

Za proračun oblika dnevne potrošnje korištene su dvije mreže, jedna RBF i jedna MLP koje kao ulaze primaju udio jučerašnje dnevne potrošnje u svakom satu, temperaturu svakoga jučerašnjeg sata, predviđenu temperaturu svakoga sutrašnjeg sata te tip dana jučer i sutra.

Procedura koja je korištena za spajanje izlaza sustava za izradu satnih nominacija temeljenog na dvadeset i četiri MLP i RBF mreže upotrebljena je i ovdje za spajanje izlaza MLP i RBF mreža za proračun oblika dnevne potrošnje. Tako dobiveni izlazi su za razdoblje od deset dana imali odstupanje od stvarnog oblika dana u iznosu od 5,56%.

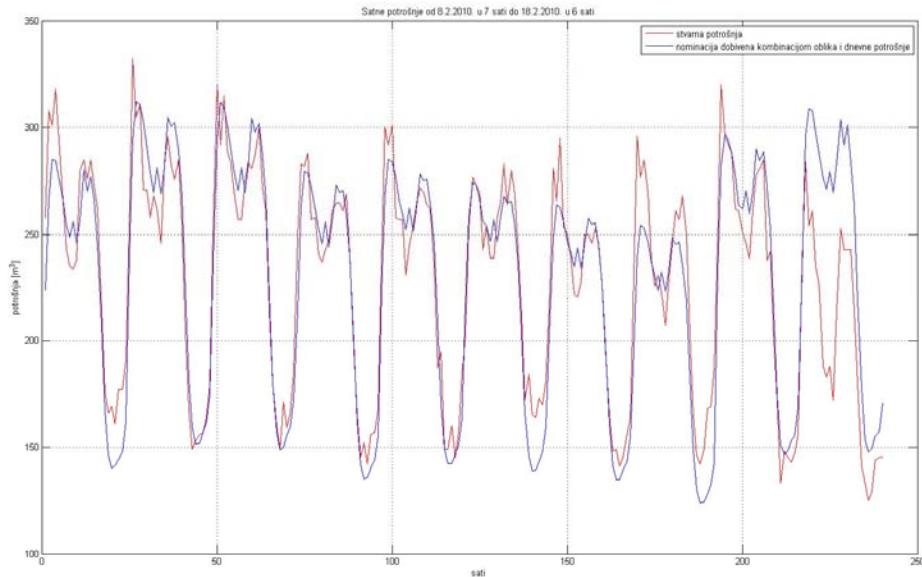


Sl. 23 – Prikaz proračuna udjela satne potrošnje u dnevnoj dobivenog spajanjem izlaza MLP i RBF mreža

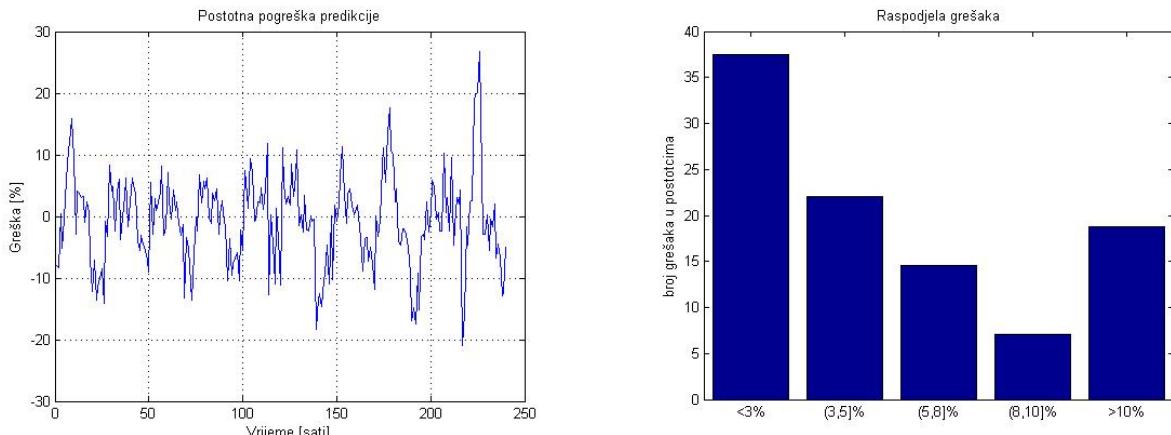
Podjela dnevnih nominacija na satne prema obliku dnevne potrošnje

Dnevnu nominaciju koja je izrađena jednom RBF mrežom raspodjeli smo po satima prema dobivenom obliku dnevne potrošnje. Na taj način smo indirektno generirali satne nominacije.

Tako dobiveni grafovi satnih potrošnji imaju glatkiji oblik, bez velikih oscilacija što je njihova prednost naspram direktnog proračuna satnih nominacija objašnjenog u točki 6.2. To je vidljivo usporedimo li sliku 24 s grafovima potrošnje prikazanim na slikama 16 i 18.



Sl. 24 – Prikaz satnih nominacija proračunatih pomoću udjela satne potrošnje u dnevnoj i dnevnih nominacija



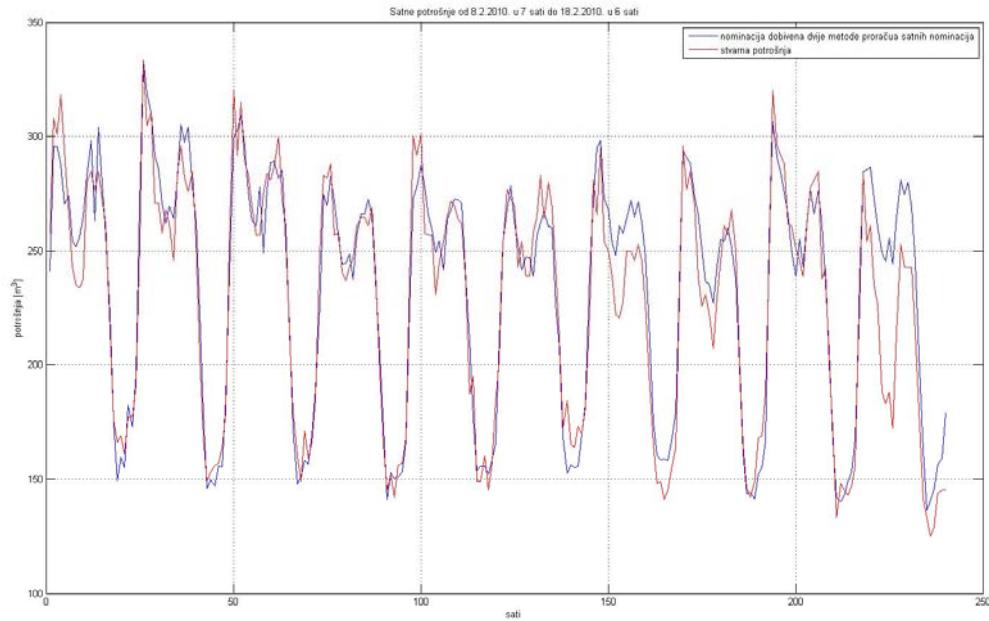
Sl. 25 – Pogreške izrade satnih nominacija pomoću dnevnih nominacija i udjela satne potrošnje u dnevnoj te njihova raspodjela

Prosječna pogreška ovako izrađenih satnih nominacija za deset dana iznosila je 7,72%.

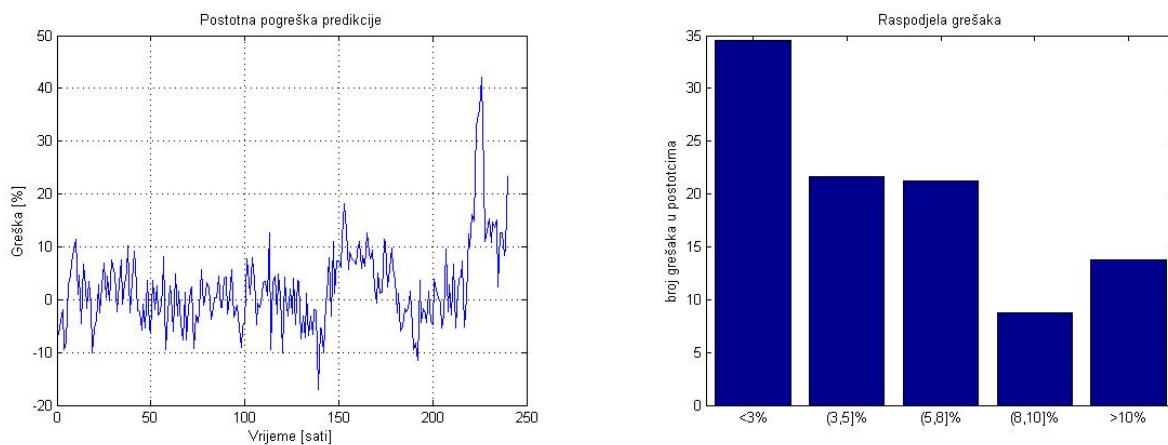
Konačni proračun satnih nominacija

Satne nominacije dobivene pomoću dvadeset i četiri MLP i RBF neuronske mreže te satne nominacije dobivene pomoću udjela satne potrošnje u dnevnoj potrošnji i dnevnih nominacija iskorištene su za proračun konačnih satnih nominacija. Proces njihova spajanje jednak je spajanju kao u prethodna dva slučaja, dan je podjeljen na četiri razdoblja, a koeficijenti udjela pojedine nominacije u konačnosti proračunati su preko varijanci.

Rezultati konačnog produkta spajanja vidljivi su na sljedećim slikama.



Sl. 26 – Prikaz satnih nominacija dobivenih kombinacijom obje metode izrade satnih nominacija



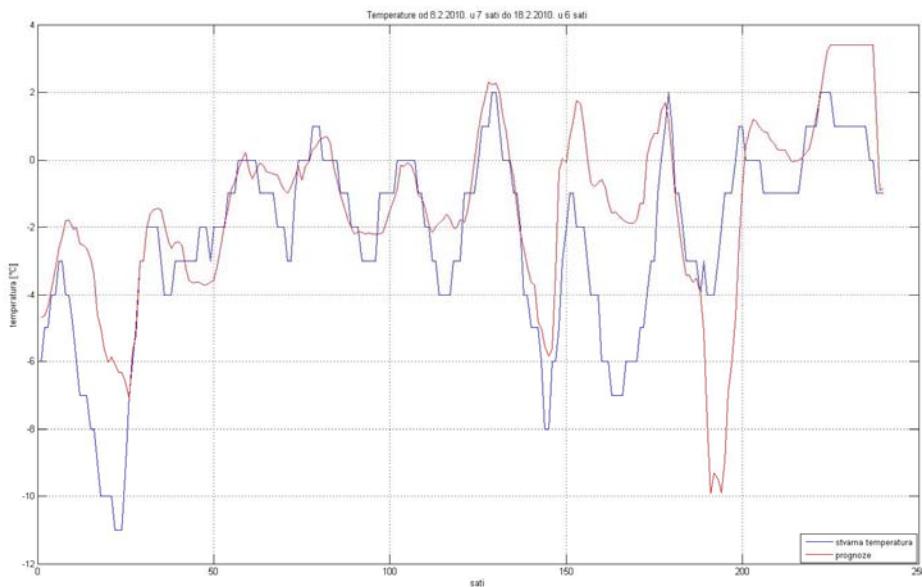
Sl. 27. Pogreške izrade satnih nominacija dobivenih kombinacijom obje metode izrade satnih nominacija i raspodjela grešaka

Prosječna postotna pogreška konačnih satnih nominacija za deset dana iznosila je 5,84%.

7. ZAKLJUČAK

Nominacije potrošnje plina koje se rade za naredni dan uvelike se oslanjaju na vremensku prognozu i to prvenstveno na prognozu temperature za naredni dan. Analiza dobivenih rezultata u promatranom razdoblju ukazala je na značajan utjecaj temperature na točnost nominiranih vrijednosti. Netočnost prognoziranih podataka za temperature zraka po satima za naredni dan neminovno se prenose i u naš sustav te smanjuju njegovu točnost. Osjetljivost na takvo ponašanje naročito je vidljiva pri nekim kritičnim temperaturama kod kojih dolazi do značajnog odstupanja od prognoziranih vrijednosti.

Na slici 28 vidljivo je da je u promatranom razdoblju bilo odstupanja i do 6°C u odnosu na prognoziranu temperaturu. Analiza je pokazala da istovjetna razlika između stvarne i prognozirane temperature ima veći utjecaj na točnost nominacija kod viših temperatura (primjerice kod temperature oko 0°C) nego kod nižih temperatura (primjerice kod -8°C).



Sl. 28 – Izmjerene temperature i njihove prognozirane vrijednosti u promatranom razdoblju

Isto tako analiza je pokazala da osim temperature određen utjecaj na točnost nominacija imaju padaline i količina naoblake.

Padaline u obliku snijega i kiše imaju utjecaj na potrošnju plina naročito u današnjem vikendu.

Količina naoblake (svjetlosti) također ima značajan utjecaj na potrošnju plina. Kod iste vanjske temperature manja je potrošnja plina kod sunčanijeg dana nego kod oblačnijeg a naročito u gradovima – utjecaj velikih staklenih ploha na novoizgrađenim poslovnim i stambenim objektima.

Zbog toga smo trenutno u fazi uvođenje vrijednosti za padaline i naoblake kao novih ulaza u neuronske mreže našeg sustava.

Kako Pravilnik o tržištu prirodnog plina dozvoljava izradu naknadnih renominacija naš sustav sadrži i tu mogućnost. Naime sustav dobiva podatke o očitanim vrijednostima sa korektora u razmacima od po 10 minuta a stvarne podatke o temperaturi zraka svaku minutu. Ujedno svakih 6 sati dobivaju se nove prognoze za temperature zraka koje su mnogo točnije od prognoziranih prethodni dan. Na osnovu novodobivenih podataka softver izračunava novu prognozu potrošnje plina i omogućava nam da izvršimo renominiranje dostavljenih nominiranih vrijednosti.

Autor: **Milan Fistonić**, dipl.inž.,PTMG d.o.o.
Gornjostupnička 18, 10255 STUPNIK
tel. 01 6588 772
fax. 01 6588 544
e-mail: milan.fistonic@ptmg.hr

Koautori: **Matija Bilandžija**, dipl.inž.,DUPLICO d.o.o.
Gornjostupnička 27b, 10255 STUPNIK
tel. 01 6589 222
fax. 01 6589 231
e-mail: matija@duplico.hr

Bojana Vukadinović, dipl.inž.,DUPLICO d.o.o.
Gornjostupnička 27b, 10255 STUPNIK
tel. 01 6589 222
fax. 01 6589 231
e-mail: bojana@duplico.hr