

# Pregled primjenjivih matematičkih/statističkih metoda za predviđanje te izgradnja modela za predviđanje potrošnje prirodnog plina

---

Cerovečki, Marta

Master's thesis / Diplomski rad

2019

*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://urn.nsk.hr/urn:nbn:hr:200:952168>

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

*Download date / Datum preuzimanja:* **2025-02-20**

*Repository / Repozitorij:*

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



**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEK  
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I  
INFORMACIJSKIH TEHNOLOGIJA**

**Diplomski studij**

**PREGLED PRIMJENJIVIH MATEMATIČKIH/STATISTIČKIH  
MODELA ZA PREDVIĐANJE TE IZGRADNJA MODELA ZA  
PREDVIĐANJE POTROŠNJE PRIRODNOG PLINA**

**Diplomski rad**

**Marta Cerovečki**

**Osijek, 2019.**

# SADRŽAJ

1. UVOD .....	1
Zadatak diplomskog rada.....	3
2. SUDIONICI NA TRŽIŠTU PLINA U REPUBLICI HRVATSKOJ .....	4
2.1. Trgovanje plinom .....	7
2.1.1. Obračun odstupanja od nominacija .....	8
2.1.2. Obračun troškova uravnoteženja.....	9
3. PRIMJENJIVI MODELI PREDVIĐANJA POTROŠNJE PLINA.....	11
3.1. Model linearne regresije (eng. Linear regression).....	14
3.2 ARX metoda za modeliranje procesa (eng. Auto-regressive model with exogenous inputs) .....	14
3.3 ARMAX metoda za modeliranje procesa (eng. Auto-Regressive Moving-Average model with eXogenous inputs) .....	15
3.4. Box-Jenkins metoda za modeliranje procesa (engl. Box-Jenkins).....	15
3.5. Umjetne neuronske mreže (eng. Artificial Neural Network) .....	16
4. BAZA PODATAKA.....	19
4.1. Ulazne varijable modela ili utjecajne veličine.....	19
4.1.1. Povijesni pregled potrošnje plina .....	20
4.1.2. Meteorološki podaci.....	21
4.1.3. Potrošnja plina u ovisnosti o tipu dana .....	22
4.2. Statistička obrada ulaznih podataka .....	22
5. IMPLEMENTACIJA I REZULTATI ODABRANIH MODELA NA REALNOM SETU PODATAKA.....	26
5.1. Izgradnja, treniranje i testiranje odabranih modela .....	26
5.2. Pregled rezultata predviđanja .....	36
6. ZAKLJUČAK .....	40
LITERATURA.....	42
SAŽETAK .....	45
ABSTRACT .....	46
ŽIVOTOPIS .....	47

# 1. UVOD

Uspostavljanjem jedinstvenog tržišta električne energije i prirodnog plina, povećana je sigurnost i pouzdanost opskrbe energijom. Niža cijena energije, provedba vlasničkog razdvajanja za djelatnost prijenosa (transporta) od djelatnosti proizvodnje i opskrbe te slobodan izbor opskrbljivača neke su od glavnih stavki Trećeg energetskeg paketa [1].

Energetski paketi sadrže skup mjera koje imaju za cilj unaprijediti i poboljšati energetske tržište Europske unije (EU) kao cjeline, ali i energetska tržišta svih njezinih članica. Koncept Trećeg energetskeg paketa razrađen je u dvije direktive i tri uredbe. Direktive se implementiraju u nacionalna zakonodavstva država članica, a uredbe se izravno primjenjuju u svim državama članicama EU [1]. Europska unija namjerava stvoriti jedinstveno europsko energetske tržište pa želi jednake uvjete i dostupnost svim zainteresiranim tvrtkama na tržištu za prijenos i distribuciju struje i plina. Europska komisija liberalizira tržište plina Direktivom 2009/73/EZ o zajedničkim pravilima za unutarnje tržišta plina, koja naglašava kako nacionalni regulatori tržišta plina mogu donositi odluke o svim regulatornim pitanjima kako bi unutarnje tržište prirodnog plina ispravno funkcioniralo [2]. Prema [3] ovlasti se dodjeljuju regulatoru čija je funkcija osiguravanje pravilnog funkcioniranja tržišta. Kako bi se to ostvarilo, regulatorna tijela moraju nadzirati pravila za upravljanje i raspodjelu kapaciteta interakcije. Također nadziru operatore transportnog i distribucijskog sustava i njihovo vrijeme potrebno za izvođenje, spajanje ili popravke u cilju izbjegavanja nelikvidnosti i netransparentnosti. Kao i druge države, tako i Republika Hrvatska procesom pridruživanja EU postupno liberalizira tržište plinom. Direktiva 2009/73/EC uvedena je u hrvatsko zakonodavstvo Zakonom o tržištu plina objavljeno u (4, NN 28/13., 14/14.) i sadrži skup pravila vezanih za transport, distribuciju, skladištenje i opskrbu prirodnim plinom kojima se želi postići daljnji napredak tržišta plina i njegova potpuna liberalizacija. Liberalizacijom tržišta stvoreni su uvjeti za povećanje konkurencije, odnosno ukidanje državnih monopola, smanjenje nabavne cijene plina i snižavanje transportnih troškova [2].

Razvoj i liberalizacija tržišta prirodnog plina pred sudionike tržišta stavlja nove izazove. Model tržišta koji se danas primjenjuje u Republici Hrvatskoj, a isto tako i u ostatku EU, podrazumijeva princip balansa u sustav isporuke plina. Voditelji bilančnih skupina imaju obavezu osigurati balans između količina koje predaju u sustav (primjerice uvozom plina) i količina koje izuzmu iz sustava (primjerice prodajom kupcima). Pregled stanja bilančnih skupina se radi na dnevnoj razini te konačno utvrđuje na mjesečnoj razini. Ukoliko dođe do disbalansa u sustavu (bilo da se radi o višku ili manjku plina), potrebno je izvršiti uravnoteženje koje se naplaćuje voditeljima bilančnih skupina koji su odgovorni za uzrok disbalansa, što

znači da disbalans ima izravan financijski utjecaj na sudionike tržišta koji su doveli do takvog stanja. Kako bi se izbjegle takve situacije, koriste se prednominacija i nominacija potrebne količine plina. Stvarna potrošnja plina na dnevnoj bazi mora biti unutar propisanih tolerancija odstupanja od nominacije kako bi transportni sustav prirodnog plina bio u ravnoteži. Opskrbljivači za potrošnju plina koja nije unutar propisane tolerancije moraju plaćati penale. U svrhu održavanja ekonomičnosti ili povećanja dobiti opskrbljivača plinom nužno je što točnije nominirati korištenje transportnog sustava na dnevnoj bazi. Ovakav koncept temelji se na najavi potrebne količine plina za nadolazeći dan. Lanac dojave kreće od krajnjih potrošača, preko opskrbljivača, zatim preko voditelja bilančanih skupina pa sve do operatera transportnog sustava i na kraju do vanjskih dobavljača plina.

Uvođenjem financijske odgovornosti za neodgovorno i neplanirano ponašanje na tržištu, svim sudionicima postaje izrazito bitna mogućnost što točnijeg predviđanja očekivane potrošnje. Predviđanje potrošnje prirodnog plina predstavlja problem predviđanja vrijednosti neke varijable u ovisnosti o raznim faktorima koji na njeno ponašanje utječu svaki u određenom omjeru. Stoga je prije odabira metode rješavanja problema i izrade modela predviđanja potrebno utvrditi koji su utjecajni faktori te kolika je njihova relevantnost. Dosadašnja istraživanja su pokazala da je temperatura najbitniji faktor koji ima utjecaj na potrošnju plina, iako postoje i mnogi drugi (period godine, radni/neradni dan, jačina vjetera i slično). Za rješavanje ovakvih problema uglavnom se koriste metode matematičke regresije ili neuronske mreže. Primjena jedne ili druge skupine metoda uglavnom ovisi o količini i kvaliteti raspoloživih povijesnih podataka temeljem kojih se model uči.

U uvodu se upoznajemo s problematikom nominacije plina te upoznajemo sudionike na tržištu plina u Republici Hrvatskoj. U trećem ulomku dan je pregled mogućih rješenja i opisana su četiri linearna modela, postupna regresija, ARX metoda modeliranja procesa, ARMAX metoda modeliranja procesa, Box-Jenkins metoda modeliranja procesa te jedan model neuronske mreže kao moguće rješenje navedenog problema. Prikupljene podatke o dosadašnjoj potrošnji plina za svaki dan, u vremenskom razdoblju od 2009. godine do 2017. godine kao i meteorološke podatke za navedeno razdoblje potrebno je sjediniti u zajedničku bazu podataka, statistički obraditi te odrediti utjecajne veličine za izradu samih modela što je i učinjeno u četvrtom ulomku. Izgradnja i implementacija spomenutih modela, kao i njihovo treniranje i testiranje prikazano je u petom ulomku. Spomenuti modeli trenirani su na realnom setu podataka te su nakon toga testirani, a na temelju dobivenih podataka doneseni su zaključci.


## **1.1. Zadatak diplomskog rada**

Zadatak rada je istražiti matematičke modele predviđanja koji bi bili primjenjivi za izgradnju sustava predviđanja potrošnje prirodnog plina. Potrebno je izvršiti demonstraciju rada odabranih modela na realnom setu podataka te stvoriti zaključke o uspješnosti pojedinog modela uspoređujući predviđene sa stvarno evidentiranim potrošnjama prirodnog plina.

## 2. SUDIONICI NA TRŽIŠTU PLINA U REPUBLICI HRVATSKOJ

Sve djelatnosti na tržištu plina (od proizvodnje do prodaje) moraju se obavljati na transparentan i pravedan način. Postojeći zakonski propisi nastali na temelju Trećeg energetskeg paketa nalažu organizaciju tržišta plina na način koji će ići u korist cjelokupnom gospodarstvu i svim građanima. U interesu države i svih njenih građana jest opskrba koja će osigurati dovoljnu količinu plina za normalno funkcioniranje gospodarstva. Djelatnosti na tržištu plina podijeljene su na regulirane (djelatnosti koje se obavljaju kao javne usluge) i tržišne djelatnosti. U regulirane djelatnosti ubrajamo: transport plina, distribuciju plina, organiziranje tržišta plina, opskrbu plinom u javnoj usluzi i zajamčenu opskrbu te skladištenje plina. Dok tržišne djelatnosti obuhvaćaju: proizvodnju plina, trgovinu plinom i opskrbu plinom krajnjih kupaca na tržištu plina. Energetski subjekti koji provode navedene djelatnosti su: proizvođač plina, operator transportnog sustava, operator sustava skladišta plina, operator distribucijskog sustava, operator tržišta plina, trgovac plinom, opskrbljivač i krajnji kupac. Djelatnost operatora tržišta plina u Republici Hrvatskoj obavlja Hrvatski operator tržišta energije (HROTE). Njegova osnovna uloga jest organiziranje tržišta energije u Republici Hrvatskoj, ali i postupno integriranje hrvatskog u europsko tržište. Za uspješno provođenje svih djelatnosti na tržištu plina zadužena je Hrvatske energetska regulatorna agencija (HERA) koja je direktno podređena Vladi Republike Hrvatske. U svrhu nesmetanog obavljanja kupoprodajnih transakcija na tržištu plina te osiguranja podudarnosti količina plina predanih i preuzetih iz transportnog sustava uspostavio se model bilančnih skupina [1].

Prirodni plin u hrvatski transportni sustav ulazi preko interkonektora. Na transportnom sustavu djeluje operator transportnog sustava (OTS). Transportni sustav, kojim upravlja operator transportnog sustava Plinacro d.o.o., sastoji se od međunarodnih, magistralnih, regionalnih i odvojnih plinovoda i objekata na plinovodu, mjernih redukcijskih stanica (MRS) različitih kapaciteta te ostalim objektima i sustavima koji omogućavaju pouzdan i siguran rad transportnog sustava [5]. Distribuirani plin mora biti zadovoljavajuće kvalitete, a distribucija obavljena na siguran i kvalitetan način. Radi osiguranja visoke razine kvalitete usluge transporta plina te visoke pouzdanosti i sigurnosti rada transportnog sustava, sustavno se obavlja operativni nadzor plinovoda i pripadajućih objekata na terenu, kao i kontinuirani nadzor te upravljanje iz Nacionalnog dispečerskog centra u Zagrebu.




**Slika 2.1.**Transportni sustav RH, [5]

Transportni sustav se grana na distribucijske sustave. PRMS (primo-predajne mjerno-regulacijske stanice) je dio transportnog sustava na kojemu operator transportnog sustava predaje plin i na kojemu se mjeri količina prirodnog plina, a pod nadzorom je operatora transportnog sustava koji je ujedno i vlasnik PRMS-a. Operator distribucijskog sustava (ODS) primarno obavlja djelatnost transporta i distribucije plina. Također je odgovoran za održavanje, rad i razvoj distribucijskog sustava. Na distribucijskom sustavu također se nalaze PMRS, a u ovom slučaju njihov vlasnik je ODS. Na njima se, također, mjeri količina plina i preko njih ODS predaje plin. Opskrbljivači su vlasnici plina u transportnom i distribucijskom sustavu dok OTS i ODS samo vrše uslugu transporta i distribucije i ne mogu biti vlasnici plina, osim u slučaju plina za pogonsku potrošnju i pokrivanje gubitaka.

Opskrbljivač plinom definira se kao fizička ili pravna osoba koja obavlja energetske djelatnosti opskrbe plinom te prodaju plina krajnjim kupcima (kućanstva ili poslovni korisnici).





**Slika 2.2.** Pregled plinskog sustava

Bilančna skupina je skupina s jednim ili više sudionika na tržištu plina koju organizira i vodi energetski subjekt za plin, tzv. voditelj bilančane skupine (VBS), a unutar nje se uravnotežuje količina plina koja se predaje i preuzima iz transportnog sustava. Članom bilančne skupine dužan je biti svaki sudionik na tržištu plina (krajnji kupci, trgovci, distributeri, opskrbljivači, operatori), osim operatora tržišta plina. VBS je odgovoran za nominiranje količine plina, usklađivanje preuzete i predane količine plina te obračun troškova vezanih uz energiju uravnoteženja i odstupanja. Naravno, svaki voditelj bilančne skupine odgovoran je samo za svoje interesno udruženje, odnosno, svoju bilančnu skupinu. VBS je trgovac i opskrbljivač plinom. On kupuje plin od opskrbljivača, trgovaca ili proizvođača plina i/ ili kupuje plin izvan Republike Hrvatske radi prodaje unutar države. Plinski sustav funkcionira tako da krajnji kupac treba dostaviti prednominaciju za naredni dan svom opskrbljivaču. Pod pojmom prednominacija smatra se najava količine plina za naredni plinski dan koju član bilančne skupine namjerava preuzeti iz plinskog sustava. Plinski dan je razdoblje od 24 sata koje počinje u 6:00 i završava u 6:00 sati narednog kalendarskog dana. Bilo bi dobro da na temelju planirane potrošnje svojih krajnjih kupaca opskrbljivač izradi prednominaciju koju će dostaviti VBS-u. VBS skuplja prednominacije iz kojih kreira nominaciju<sup>1</sup> koju šalje OTS-u. VBS zakonski mora dostaviti nominaciju za sutrašnju potrošnju OTS-u. VBS mora danas dostaviti

<sup>1</sup> Nominacija je najava količine plina za bilančnu skupinu za naredni plinski dan koju članovi bilančne skupine namjeravaju preuzeti iz plinskog sustava, tj. ona predstavlja količinu plina koja će izaći iz sustava.

nominaciju za sutra i to mora raditi svaki dan. Kupac može za vrijeme plinskog dana izmijeniti prihvaćenu nominaciju ili renominaciju za taj plinski dan, ovisno o ugovoru kojeg ima sa svojim opskrbljivačem, tj. VBS-om. Renominacija podrazumijeva izmijenjenu nominaciju. VBS mora predati još jednu nominaciju OTS-u, a to je količina plina koja će ući u sustav. Ta količina plina ne mora biti jednaka količini koja će izaći iz sustava, ona ovisi o parametrima balansiranja bilančne skupine. Te dvije nominacije VBS-a prema OTS-u su obavezne i zakonski regulirane. Postoji i treća nominacija koju VBS predaje. S tom nominacijom VBS naručuje količine plina od svojih opskrbljivača ili proizvođača u zemlji, odnosno od vanjskih dobavljača u slučaju uvoza plina.

## **2.1. Trgovanje plinom**

Pravilnik o organizaciji tržišta plina donosi i određuje propise o organizaciji tržišta plina, pravila za određivanje i evidentiranje bilančnih skupina njihovih voditelja, ugovorni odnos između operatora tržišta plina i voditelja bilančnih skupina i način obračuna energije uravnoteženja. Prilikom trgovanja plinom važno je osigurati podudarnost količina plina predanih i preuzetih iz transportnog sustava. VBS ima zadatak da svaki dan uravnotežuje količinu plina koju njegova bilančna skupina predaje u transportni sustav s količinom plina koju ista bilančna skupina preuzima iz transportnog sustava. Kako bi postigao uravnoteženje, voditelj bilančne skupine služi se ugovorenim kapacitetima transportnog sustava, svojim pravom na renominaciju transporta, sustavom skladišta i trgovinom na virtualnoj točki trgovanja. Na virtualnoj točki trgovanja može se trgovati plinom nakon njegovog ulaska u transportni sustav i prije njegovog izlaska iz transportnog sustava. Transakcije mogu obavljati voditelji bilančnih skupina koji su korisnici transportnog sustava. Trgovanje nadgleda operator tržišta plina koji mora omogućiti voditeljima bilančnih skupina davanje ponuda za kupnju ili prodaju plina.

Voditelji bilančnih skupina koji usuglase sve uvjete i dogovore trgovačku transakciju dužni su operatoru transportnog sustava dostaviti najavu trgovačke transakcije za naredni plinski dan. Nakon zaprimanja najave trgovačke transakcije, operator transportnog sustava provjerava njenu valjanost, provjerava usklađenost trgovačke transakcije o kupnji te provjerava trgovačke transakcije o prodaji. Operator transportnog sustava mora izvijestiti voditelje bilančne skupine o prihvaćanju ili odbijanju. Operator tržišta plina mora evidentirati svaku obavljenju trgovačku transakciju i na kraju mjeseca dostaviti popis svih provedenih transakcija Hrvatskoj energetske regulatornoj agenciji[4].

### 2.1.1. Obračun odstupanja od nominacija

Prema [6] ukoliko dođe do disbalansa u sustavu (bilo da se radi o višku ili manjku plina), potrebno je izvršiti uravnoteženje koje se naplaćuje voditeljima bilančanih skupina koji su odgovorni za uzrok disbalansa, što znači da disbalans ima izravan financijski utjecaj na sudionike tržišta koji su doveli do takvog stanja. Kako bi se izbjegle takve situacije, koriste se prednominacija i nominacija potrebne količine plina. Stvarna potrošnja plina na dnevnoj bazi mora biti unutar propisanih tolerancija odstupanja od nominacije kako bi transportni sustav prirodnog plina bio u ravnoteži. Opskrbljivači za potrošnju plina koja nije unutar propisane tolerancije moraju plaćati penale. Odstupanje od nominacije utvrđuje se u apsolutnom iznosu za svaku bilančnu skupinu, za svaki plinski dan, prema formuli:

$$\Delta N_{bs} = |N_{iz,bs} - V_{iz,bs}| [kWh] \quad (2-1)$$

gdje  $\Delta N_{bs}$  predstavlja odstupanje od nominacije. Pri tome je  $N_{iz,bs}$  nominirana količina plina na izlazima iz transportnog sustava u plinskom danu.  $N_{iz,bs}$  se utvrđuje za svaku bilančnu skupinu, ne uključujući energiju uravnoteženja od ponuditelja na godišnjoj i dnevnoj razini i operativnu zalihu iskorištenu za uravnoteženje u plinskom danu te je zaokružena na višekratnik broja 10 [kWh].  $V_{iz,bs}$  je količina plina preuzeta iz transportnog sustava u plinskom danu, utvrđena za svaku bilančnu skupinu, ne uključujući energiju uravnoteženja od ponuditelja na godišnjoj i dnevnoj razini i operativnu zalihu iskorištenu za uravnoteženje u plinskom danu, zaokružena na višekratnik broja 10 [kWh]. Ukoliko je za pojedinu bilančnu skupinu odstupanje od nominacije ( $\Delta N_{bs}$ ) na kraju plinskog dana veće od dozvoljenog odstupanja od nominacije ( $\Delta N_{doz,bs}$ ) operator tržišta plina dužan je toj bilančnoj skupini obračunati iznos za odstupanje od nominacija. Kako bi znali je li odstupanje od nominacije veće od dozvoljenog, potrebno je izračunati dozvoljeno odstupanje od nominacije. Ono se također utvrđuje za svaku bilančnu skupinu, za svaki plinski dan, prema sljedećoj formuli:

$$\Delta N_{doz,bs} = 0,30 \cdot V_{iz,bs} [kWh] \quad (2-2)$$

pri čemu je  $V_{iz,bs}$  količina plina preuzeta iz transportnog sustava u plinskom danu kako je ranije objašnjeno [7]. Iznos koji se obračunava za odstupanje od nominacija jednak je umnošku 1% cijene energije uravnoteženja koja se predaje u transportni sustav i razlike odstupanja od nominacije i dozvoljenog odstupanje od nominacije. Operator tržišta plina dužan je izraditi i ispostaviti račun voditelju bilančne skupine do 15. dana u mjesecu za sve plinske dane u prethodnom mjesecu te prikupljena sredstva sukladno tom računu uplatiti operatoru transportnog sustava. Operator tržišta plina i operator transportnog sustava dužni su sklopiti ugovor kojim se uređuju međusobni odnosi vezani uz plaćanje obračuna nedovoljne točnosti nominacija. Stoga je vrlo važno za voditelja bilančne skupine da što bolje prognozira potrošnju plina za nadolazeći plinski dan kako bi izbjegao nepotrebne dodatne troškove [5].

### 2.1.2. Obračun troškova uravnoteženja

Energija uravnoteženja na plinskom tržištu predstavlja plin preuzet ili predan u transportni sustav radi njegovog uravnoteženja. Vrlo je teško precizno odrediti potrebe krajnjih kupaca, odnosno teško je predvidjeti njihovu buduću potrošnju pa se mora angažirati dodatna energija koja će zadovoljiti potrebe cjelokupnog sustava. Operator tržišta plina zadužen je za prikupljanje ponuda energije uravnoteženja od strane ponuditelja. „Ponuditelj“ energije uravnoteženja je obavezan dostaviti svoju ponudu za naredni plinski dan, najkasnije do 15 sati tekućeg plinskog dana. Nakon primitka ponuda, operator tržišta plina sastavlja rang liste za pozitivnu energiju uravnoteženja (energija koja se predaje u transportni sustav) i isto tako za negativnu energiju uravnoteženja (energija koja se preuzima iz transportnog sustava). Pri sastavljanju rang lista operator tržišta plina mora dati prednost povoljnijim ponudama. Povoljniji ponuditelji su oni ponuditelji koji nude pozitivnu energiju uravnoteženja za nižu cijenu, odnosno ponuditelji koji primaju negativnu energiju uravnoteženja za višu cijenu [7]. Ponuđenu energiju uravnoteženja prema potrebi aktivira operator transportnog sustava, pri čemu šalje naloge za aktiviranje svim sudionicima transakcije (operatoru sustava skladišta plina, kupcu, proizvođaču prirodnog plina i ponuditelju energije uravnoteženja).

Operator transportnog sustava računa dnevno odstupanje bilančne skupine kao razliku količine energije predane u transportni sustav  $q_{ul,bs}$  i količine energije preuzete iz sustava  $q_{iz,bs}$ , pri čemu su sve veličine izražene u kWh.

$$q_{bs} = q_{ul,bs} - q_{iz,bs} \quad (2-3)$$

Nakon primitka svih dnevnih odstupanja za protekli mjesec, operator tržišta plina izračunava ukupno pozitivno i negativno odstupanje bilančne skupine za prethodni mjesec koje je jednako zbroju pozitivnih, odnosno negativnih dnevnih odstupanja u svim plinskim danima prethodnoga mjeseca. Izračunavanje raspodjele aktivirane energije uravnoteženja po bilančnim skupinama računa se prema danoj formuli:

$$AE_{poz,i} = U_{neg,i} \cdot AE_{poz,n} \quad , \quad (2-4)$$


gdje je  $AE_{poz,i}$  ukupno aktivirana pozitivna energija uravnoteženja prouzročena neravnotežom pojedine bilančne skupine izražena u kWh.  $U_{neg,i}$  je udio ukupnog negativnog odstupanja određene bilančne skupine u ukupnom negativnom odstupanju svih bilančnih skupina u pojedinom mjesecu izražen u postotku.  $AE_{poz,n}$  je ukupno aktivirana pozitivna energija uravnoteženja u pojedinom mjesecu izražena u kWh. Udio ukupnog negativnog odstupanja određene bilančne skupine  $U_{neg,i}$  računamo kao:

$$U_{neg,i} = \frac{U_{neg,bs}}{U_{neg,n}} \quad , \quad (2-5)$$

gdje je  $U_{neg,bs}$  suma dnevnih negativnih odstupanja određene bilančne skupine u pojedinom mjesecu, a  $U_{neg,n}$  suma dnevnih negativnih odstupanja svih bilančnih skupina u pojedinom mjesecu. Analogno ovom postupku provodi se i izračun raspodjele aktivirane negativne energije uravnoteženja. Iz ovoga je vidljivo da se ukupna iskorištena energija uravnoteženja nastoji raspodijeliti na bilančne skupine proporcionalno njihovom udjelu u sumi izračunatih dnevnih odstupanja [1].

### 3. PRIMJENJIVI MODELI PREDVIĐANJA POTROŠNJE PLINA

Pod modelom prognoziranja potrošnje plina podrazumijeva se skup matematičkih jednadžbi kojima se opisuje sustav opskrbe plinom i prvenstveno sa stajališta ponašanja potrošnje plina u ovisnosti od različitih utjecajnih veličina (meteorološke varijable, tipovi dana i sl.) [8]. Izlaz iz modela je niz podataka koji pokazuje očekivano kretanje dnevne potrošnje za sve dane u periodu predviđanja potrošnje. Kako bi se prognoziranje potrošnje moglo uvesti u primjenu, potrebno je odabrati metode prognoziranja te razviti i provjeriti odabrane modele prognoziranja. Koji će se model koristiti u nekoj konkretnoj situaciji ovisi o nizu faktora kao što su jednostavnost primjene, raspoloživost ulaznih podataka, zahtijevana točnost prognoze i slično. Proces razvoja i provjere modela prognoziranja sastoji se od nekoliko koraka. Bez obzira na odabrani model prognoziranja potrošnje plina moguće je generalizirati postupak prognoziranja. Prije svega važno je prikupiti povijesne podatke o kretanju potrošnje prirodnog plina te stvoriti bazu podataka. Isto tako treba prikupiti podatke o meteorološkim parametrima i kreirati odgovarajuću povijesnu bazu meteoroloških podataka. Nakon toga potrebno je statistički obraditi prikupljene podatke i prikazati odnose između prikupljenih podataka, npr. ovisnost potrošnje plina o dnevnoj temperaturi i ovisnost potrošnje plina o karakterističnom razdoblju (ljetu, zima). Kako bi se odabrao odgovarajući model, potrebno je formulirati ovisnosti izlazne veličine o ulaznim veličinama te time definirati ključne utjecajne veličine na prognozu potrošnje plina. Kada su definirane utjecajne veličine slijedi izbor metode i modela predviđanja te provjera signifikantnosti odabrane metode i modela. Da bi se model prognoziranja mogao praktično koristiti potrebno je odrediti konkretne numeričke vrijednosti svih parametara modela. Nakon toga na skupu povijesnih podataka obavljaju se učenja i statistička testiranja razvijenog modela prema unaprijed određenim kriterijima. Najvažniji kriteriji su točnost i granice točnosti prognoziranih vrijednosti. Kasnije estimacije parametara modela (na temelju novih podataka) nazivaju se ažuriranje ili adaptacija modela. Nakon što su parametri modela poznati, na poznatom skupu povijesnih podataka provodi se validacija, odnosno provjerava se kvaliteta prognoze. Moguće je s više metoda provjeriti kvalitetu prognoze, a neki od načina su standardna devijacija prognoze, srednja kvadratna pogreška, srednja vrijednost apsolutnog odstupanja, prosječni apsolutni postotak pogreške. Slikom 3.1. prikazan je dijagram tijeka postupka prognoziranja potrošnje plina.



Slika 3.1. Dijagram tijeka postupka prognoziranja potrošnje plina

Prema [9] u prethodnim istraživanjima, prognoziranje potrošnje plina ispitano je u nekoliko različitih vremenskih horizonata. Veliki broj istraživača predviđao je potrošnju plina na godišnjoj ili mjesečnoj razini, kao što je to radio J. Hubbert, koji je analizirao mjesečnu prodaju prirodnog plina stanovništvu u Sjedinjenim Američkim Državama pomoću regresijskog odnosa za procjenu mjesečne i godišnje isporuke prirodnog plina [10]. Dnevne modele za prognoziranje potrošnje plina istražio je R. H. Brown, koji je razvio model neuronske mreže [11], a on i Iftekhar predvidjeli su dnevnu potrošnju za dvije regije u Wisconsinu na temelju tih neuronskih mreža [12], dok je H. Elragal koristio kombinaciju umjetnih neuronskih mreža i predvidio prognozu plina za dan unaprijed [13]. Općenito, kada se govori o modelima predviđanja, možemo ih podijeliti na linearne i nelinearne modele. Linearni modeli uključuju regresijske metode. Prema [9] regresijski model prognoziranja potrošnje temelji se na primjeni pojma linearne regresije u prognoziranju potrošnje. Linearna regresija podrazumijeva metode modeliranja ovisnosti zavisne stohastičke varijable o skupu nezavisnih varijabli na način da su te ovisnosti linearne. Svi regresijski koeficijenti modela prognoziranja, ovisno o vrsti regresijske metode, određuju se na temelju statističke analize povijesnih podataka o kretanju potrošnje i odgovarajućih meteoroloških podataka (primjerice o temperaturi zraka). Moderne neuronske mreže predstavljaju alat za nelinearno statističko modeliranje podataka. Obično se koriste za modeliranje kompleksnih odnosa između ulaza i izlaza ili za pronalaženje uzoraka ponašanja procesnih veličina. Najčešće se koriste za prognoziranje potrošnje prvenstveno tamo gdje dominantan utjecaj na ukupnu potrošnju ima široka potrošnja i gdje je značajan utjecaj meteoroloških veličina [9]. Dakle, da bi se postigao zadani cilj rada, ispituju se sljedeći modeli predviđanja:

- linearni modeli: Linearna regresija (eng. Linear regression), ARX (engl. Auto-regressive model with exogenous inputs), ARMX (eng. Auto-Regressive Moving-Average model with exogenous inputs), Box-Jenkins metoda za modeliranje procesa (engl. Box-Jenkins)
- nelinearni modeli: Model umjetne neuronske mreže (engl. Artificial neuron network model)



### 3.1. Model linearne regresije (eng. Linear regression)

Linearna regresija provodi se na temelju n parova vrijednosti varijabli X i Y :  $(x_1, y_1)$ ,  $(x_2, y_2)$ , ...,  $((x_n, y_n)$ , pa se model predočuje sustavom od n jednadžbi:

$$y_i = bx_i + a + e_i \quad i=1,2,\dots,n \quad (3-1)$$

gdje su a i b parametri te se najčešće određuju metodom najmanjih kvadrata koja minimizira vrijednosti kvadrata udaljenosti između opaženih podataka i regresijske krivulje (pravca), a  $e_1, \dots, e_n$  nezavisne slučajne varijable tako da je  $E[e_i] = 0$  i  $\text{Var}(e_i) = \sigma^2$ .

Veličina b je regresijski koeficijent koji pokazuje za koliko se u prosjeku mijenja vrijednost zavisne varijable Y za jediničnu promjenu vrijednosti nezavisne varijable X [8].

### 3.2. ARX metoda za modeliranje procesa (eng. Auto-regressive model with exogenous inputs)

Autoregresivni model s egzogenim ulaznim podacima (u daljnjem tekstu ARX) je linearna parametarska metoda za modeliranje procesa. Ova metoda se koristi uglavnom za procese sa zanemarivom smetnjom. Metoda se temelji na modeliranju nula ulaza procesa te modeliranje polova izlaza. Polinomska jednadžba ARX modela predstavljena je formulom:

$$y(t) + \sum_{i=1}^{n_a} a_i y(t-i) = \sum_{j=1}^{n_b} b_j u(t-n_k-j+1) + e(t) \quad (3-2)$$

Gdje je:

- $n_a$  – broj polova
- $n_b$  – broj nula +1
- $n_k$  – mrtvo vrijeme (transportno kašnjenje)
- $a_i$  – koeficijent i-tog člana polinoma izlaza
- $b_j$  – koeficijent j-tog člana polinoma ulaza
- $y(t-i)$  – izlazna vrijednost koja kasni i koraka
- $u(t-j)$  – ulazna vrijednost koja kasni j koraka
- $e(t)$  – ulazni šum

### 3.3. ARMAX metoda za modeliranje procesa (eng. Auto-Regressive Moving-Average model with eXogenous inputs)

ARMAX (eng. Auto-Regressive Moving-Average model with eXogenous inputs) je linearna parametarska metoda za modeliranje procesa. Ova metoda se koristi kada znam da u procesu imamo velike smetnje na ulazu. Metoda je vrlo slična ARX metodi samo što se kod ARMAX metode modelira i ulazni šum. Polinomska jednačba ARMAX modela predstavljena je formulom:

$$y(t) + \sum_{i=1}^{n_a} a_i y(t-i) = \sum_{j=1}^{n_b} b_j u(t-n_k-j+1) + \sum_{k=1}^{n_c} c_k e(t-k) + e(t) \quad (3-3)$$

Gdje je:

- $n_a$  – broj polova
- $n_b$  – broj nula +1
- $n_c$  – red polinoma koji modelira šum
- $n_k$  – mrtvo vrijeme (transportno kašnjenje)
- $a_i$  – koeficijent i-tog člana polinoma izlaza
- $b_j$  – koeficijent j-tog člana polinoma ulaza
- $y(t-i)$  – izlazna vrijednost koja kasni i koraka
- $u(t-j)$  – ulazna vrijednost koja kasni j koraka
- $e(t-k)$  – ulazni šum koji kasni k koraka

### 3.4. Box-Jenkins metoda za modeliranje procesa (engl. Box-Jenkins)

Box-Jenkins je linearna parametarska metoda za modeliranje procesa. Ova metoda se koristi kada znamo da imamo smetnje na izlazu iz procesa. Polinomska jednačba modela predstavljena je formulom:

$$y(t) = \sum_{i=1}^{n_u} \frac{B_i(q)}{F_i(q)} u_i(t - nk_i) + \frac{C(q)}{D(q)} e(t) \quad (3-4)$$

$$B(q) = \sum_{i=1}^{n_b} b_i q^{-i+1} \quad (3-5)$$

$$C(q) = 1 + \sum_{i=1}^{n_c} c_i q^{-i} \quad (3-6)$$

$$D(q) = 1 + \sum_{i=1}^{n_d} d_i q^{-i} \quad (3-7)$$

$$F(q) = 1 + \sum_{i=1}^{n_f} f_i q^{-i} \quad (3-8)$$

Gdje je:


- $n_u$  – broj ulaza
- $B(q)$  – nule ulaza
- $F(q)$  – polovi ulaza
- $C(q)$  – nule ulaznog šuma
- $D(q)$  – polovi ulaznog šuma
- $n_b$  – red polinoma  $B(q) + 1$
- $n_c$  – red polinoma  $C(q) + 1$
- $n_d$  – red polinoma  $D(q) + 1$
- $n_f$  – red polinoma  $F(q) + 1$
- $n_k$  – mrtvo vrijeme (transportno kašnjenje)

### 3.5. Umjetne neuronske mreže (eng. Artificial Neural Network)

Umjetna neuronska mreža (ANN) je skup umjetnih neurona koji su međusobno povezani i interaktivni kroz operacije obrade signala [4]. Općenito, ANN mreža sastoji se od nekoliko slojeva. Slojevi u mreži, u kojima su raspodijeljeni neuroni, tako mogu biti ulazni, skriveni i izlazni. Ulazni sloj ima funkciju primanja podataka te slanja istih u skrivene slojeve. Informacije se obrađuju u skrivenim slojevima te se po realizaciji navedenog šalju u neurone izlaznog sloja. Umjetni neuron unutar neuronske mreže predstavlja memoriju. Svaki neuron nekog skrivenog sloja je povezan vezom sa svakim neuronom prijašnjeg skrivenog sloja i svakoj vezi dodijeljena je težina koja određuje utjecaj nekog neurona prijašnjeg sloja na rezultat neurona u trenutnom sloju. Svaki neuron ima aktivacijsku funkciju koja aktivira neuron i utječe na rezultat neurona. Neuron može imati prag osjetljivosti (engl. „threshold“, „bias“) koji utječe na vrijednost koja će aktivirati neuron. Kako bi kreirana mreža mogla predviđati izlazne vrijednosti na temelju ulaza potrebno je namjestiti težine veza na temelju već poznatih podataka postupkom treniranja mreže. Aktivacijska funkcija neurona bira se

ovisno o željenim svojstvima. Neka od svojstva idealne funkcije su: nelinearnost, diferencijabilna u svakoj točki, ograničena, glatka, i monotona.

Slika 3.2 prikazuje shemu umjetne neuronske mreže koja se koristi za prognoziranje.



**Slika 3.2.** Principijelna shema umjetne neuronske mreže koja se koristi za prognoziranje potrošnje [16]

Izlaz (engl. output) neuronske mreže je predstavljen općim izrazom ulaznih podataka  $u$ , na primjer, za mrežu s  $K$  veličinom ulaznog podatka  $u = \{u_1, u_2, \dots, u_K\}$ ,  $L$  neuroni u skrivenom sloju, i pojedini izlaz su opisani matematičkom formulacijom:

$$y(t + 1) = F_0\left(\sum_{j=0}^L w_j F_h\left(\sum_{i=0}^K w_{ji} u_i\right)\right) \quad (3-9)$$

Uspjeh ANN modela ovisi o pravilno odabranim parametrima kao što su broj neurona i slojevi, nelinearna funkcija koja se koristi u neuronima, algoritam učenja, početne težine ulaza i broj epoha za koje se model ponavlja. Neuroni su povezani prema težinama, koje su prikazane kao linije na Slici 3.2. U metodologiji ANN uzorci podataka često su podijeljeni u 2 glavna poduzorka. Oni se nazivaju uzorak za treniranje i uzorak za testiranje mreže. Tijekom procesa treniranja, neuronska mreža uči odnos između izlaza i kriterij unosa, dok se u procesu testiranja skup testova koristi za procjenu izvedbe modela. Tijekom procesa treniranja, neuronska mreža

uči odnos između izlaznih i ulaznih neurona. Model je potrebno što više trenirati kako bi rezultat bio što bolji, odnosno kako bi pogreška bila što manja. Ulazni neuroni su prethodna opažanja, dok izlaz daje predviđanja za buduću vrijednost. Za obradu podataka koriste se skriveni neuroni s odgovarajućim nelinearnim prijenosnim funkcijama koje primaju ulazni neuroni. [16].

## 4. BAZA PODATAKA

Za predviđanje što preciznije prognoze za potrošnju prirodnog plina potrebno je imati što veću bazu s višegodišnjim podatcima o dnevnom profilu potrošnje plina prema određenim uvjetima kao što su dnevna temperatura, tip dana, brzina vjetra i mnogi drugi. Do danas provedena istraživanja pokazala su da potrošnja prirodnog plina uglavnom ovisi o godišnjem dobu, vanjskim temperaturama, količini oborina, jakosti vjetra, prijašnjoj potrošnji plina i tipu dana u tjednu.

Dobiveni su podatci o potrošnji prirodnog plina na vukovarskoj distribuciji za razdoblje od 1.10.2009. do 30.9.2017.

Osim podataka o potrošnji plina u navedenom razdoblju, u bazu podataka uneseni su i neprekidni podatci o minimalnoj temperaturi, maksimalnoj temperaturi i prosječnoj temperaturi. Isto tako dobivena je količina oborina, jakost vjetra mjerena u 7h, jakost vjetra mjerena u 14h i jakost vjetra mjerena u 21h. Osim toga, baza sadrži i kategorijalne podatke koji su definirani na sljedeći način: tip dana (radni=0 ili neradni=1), dan u tjednu (ponedjeljak=1, utorak=2, srijeda=3, četvrtak=4, petak=5, subota=6, nedjelja=7), smjer vjetra u 7h, smjer vjetra u 14h, smjer vjetra u 21h (N=1, NNW=2, NW=3, WNW=4, W=5, WSW=6, SW=7, SSW=8, S=9, SSE=10, SE=11, ESE=12, E=13, ENE=14, NE=15, NNE=16).

### 4.1. Ulazne varijable modela ili utjecajne veličine

Model za prognoziranje potrošnje [17] je matematička obrada koja na svojim ulazima ima određeni skup ulaznih veličina, a na izlazu daje očekivano kretanje potrošnje u definiranom budućem intervalu vremena. Ulazne veličine nazivaju se utjecajne veličine.

Definirani modeli prognoziranja potrošnje mogu koristiti sljedeće utjecajne veličine:

- povijest kretanja potrošnje,
- povijest kretanja temperature zraka (srednja dnevna ili minimalna i maksimalna dnevna temperatura),
- tip dana (ponedjeljak, utorak, srijeda, četvrtak, petak, subota, nedjelja ili neradni dan, specijalni dan),
- ostale meteorološke veličine.


#### 4.1.1. Povijesni pregled potrošnje plina

Operator 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 i testiranje potrebnih modela u svrhu što točnije izrade prognoze potrošnje plina.

Potrošnja plina dobivena je na ulaznim postajama gdje Distribucija preuzima plin iz transportnog sustava RH. Plin se preuzima na mjerno - regulacijskim stanicama (MRS), a u slučaju ovog Distributera postoje dvije lokacije. Unutar MRS-a se nalazi plinomjer koji mjeri količinu plina koju preuzima cijela distribucija i te podatke mjeri na razini jedne minute, ali uobičajeno se promatraju podatci na satnoj razini. Bitno je primijetiti da je to ukupna potrošnja svih potrošača na distribucijskom sustavu.

Raspodjelu po pojedinim kategorijama potrošača (npr. kućanstvo i poduzetništvo) moguće je napraviti tek na mjesečnoj razini jer se jednom mjesečno vrši očitavanje potrošnje samih potrošača na distribuciji. Početkom mjeseca vrši se postupak fizičkog očitavanja potrošnje na terenu na mjestima priključka krajnjeg korisnika - potrošača na distributivni sustav (OMM – obračunsko mjerno mjesto) te se dobivaju podatci o potrošnji za prethodni mjesec. Dakle, za razliku od MRS-a, očitavanje potrošača je manualna procedura koja uključuje ljude - očitavače koji fizički očitavaju stanje svakog brojila jednom mjesečno.

Dobiveni su podatci o potrošnji prirodnog plina na vukovarskoj distribuciji za razdoblje od 1.10.2009. do 30.9.2017. Ukupna potrošnja plina za navedeno razdoblje prikazana je slikom 4.1.



**Slika 4.1.** Pregled potrošnje plina za područje vukovarske distribucije

#### 4.1.2. Meteorološki podaci

Pod meteorološkim podacima koji se koriste u procesu prognoziranja potrošnje podrazumijeva se skup meteoroloških varijabli, kao što su temperatura zraka, globalno zračenje, stupanj naoblake, brzina i smjer vjetra, relativna vlažnost i drugo. Meteorološki podaci dobiveni su od DHMZ-a (Državni hidrometeorološki zavod). Osnovni proizvod DHMZ-a su informacije temeljene na rezultatima meteoroloških i hidroloških motrenja (mjerenja i opažanja), mjerenja elemenata kvalitete zraka i daljinskih mjerenja s postaja DHMZ-a. Na osnovu motrenja, prikupljanja, obrade i kontrole podataka, stvara se baza meteoroloških, hidroloških i njima srodnih podataka. Podatke iz baze podataka koriste za daljnju upotrebu zaposlenici DHMZ-a i vanjski korisnici. Podatci, proizvodi i usluge koji se objavljuju na mrežnim stranicama DHMZ-a su besplatni. Podatci koji se na zahtjev vade iz baze podataka, kao i iz njih izvedeni parametri, proizvodi i usluge korisnicima se naplaćuju [18].



### 4.1.3. Potrošnja plina u ovisnosti o tipu dana

Potrošnja plina se različito ponaša u različitim tipovima dana. Ta različitost se reflektira u različitim iznosima ukupne dnevne potrošnje za iste meteorološke uvjete. Tipovi dana prikazani su na sljedeći način:

**Tablica 4.1.** Prikaz tipova dana s pridruženim adekvatnim oznakama

<b>Dan:</b>	Ponedjeljak	Utorak	Srijeda	Četvrtak	Petak	Subota	Nedjelja
<b>Oznaka:</b>	1	2	3	4	5	6	7

Osim toga, vidljiva je razlika u potrošnji s obzirom na to radi li se o radnom ili neradnom danu pa je i taj podatak uveden u bazu podataka. U bazu je unesen tako što je radni dan označen nulom, a neradni dan ili vikend jedinicom. U slučaju prognoziranja potrošnje važno je definirati i vrijeme u kojem se mijenja tip dana. Tako se kod prognoziranja dnevne potrošnje plina tip dana mijenja u trenutku promjene plinskog dana (6:00), što bi značilo da tip dana 1, odnosno u ovom slučaju ponedjeljak, traje od 06:00 u ponedjeljak do 06:00 u utorak. Analogno vrijedi i za ostale tipove dana.

## 4.2. Statistička obrada ulaznih podataka

Cilj analize podataka je pripremiti prikupljene podatke za modeliranje i izgradnju vlastitog modela predviđanja. Podatci su statistički obrađeni u Matlabu (programski jezik i okruženje za numeričke proračune). Baza podataka napravljena je u Excel tablici koja je konvertirana u CSV datoteku (eng. Comma Separated Values) radi poboljšavanja brzine učitavanja u Matlab. Za svaku navedenu varijablu iz baze podataka (Tmin, Tmax, Tsrednja, Tip dana i sl.) izračunata je korelacija s potrošnjom. Korelacija predstavlja međusobnu povezanost između različitih pojava predstavljenih vrijednostima dviju varijabli. Povezanost znači da je vrijednost jedne varijable moguće s određenom vjerojatnošću predvidjeti na osnovi saznanja o vrijednosti druge varijable. Od svih meteoroloških parametara, vanjska temperatura zraka ima najveći utjecaj na potrošnju prirodnog plina. Očito je da je vanjska temperatura obrnuto proporcionalna potrošnji prirodnog plina. Iz tablice je vidljivo kako temperatura, bez obzira radi li se o minimalnoj, maksimalnoj ili srednjoj temperaturi, ima koeficijent korelacije u rasponu od -0.88 do -0.95, što znači da postoji korelacija između varijable temperature i potrošnje.

Negativni koeficijent korelacije dobiva se kada mala vrijednost jedne varijable odgovara velikoj vrijednosti druge varijable i obrnuto. Odnosno, mala potrošnja plina posljedica je visoke temperature, a niska temperatura odgovara većoj potražnji i samim time i većoj potrošnji prirodnog plina. Kada mala vrijednost jedne varijable odgovara maloj vrijednosti druge varijable, kao i kada velika vrijednost jedne varijable odgovara velikoj vrijednosti druge varijable, radi se o pozitivnoj korelaciji.

Navedeni koeficijenti korelacije za promatrane varijable prikazane su u tablici (Tablica 4.2.).

**Tablica 4.2. Koeficijenti korelacije**


VARIJABLA\POTROŠNJA	2009-2010	2010-2011	2011-2012	2012-2013	2013-2014	2014-2015	2015-2016	2016-2017	2017
<b>Tmax</b>	-0.93	-0.91	-0.94	-0.93	-0.91	-0.91	-0.9	-0.93	-0.92
<b>Tmin</b>	-0.94	-0.94	-0.93	-0.92	-0.88	-0.91	-0.9	-0.93	-0.88
<b>Tsrednja</b>	-0.93	-0.95	-0.94	-0.93	-0.84	-0.88	-0.91	-0.94	-0.92
<b>Tip dana</b>	-0.03	-0.04	-0.04	-0.02	-0.04	-0.04	-0.03	-0.04	-0.04
<b>Dan u tjednu</b>	-0.03	-0.02	-0.03	-0.01	-0.06	-0.04	-0.03	-0.01	-0.03
<b>Oborine</b>	-0.01	0.05	0.07	0.02	-0.09	-0.01	-0.03	-0.06	0.12
<b>Jakost vjetra u 7h</b>	0.17	0.08	0.2	0.24	0.09	0.15	0.16	-0.12	0.25
<b>Jakost vjetra u 14h</b>	0.12	-0.02	0.06	0.06	-0.07	-0.04	0.06	-0.13	0.09
<b>Jakost vjetra u 21h</b>	0.25	0.21	0.3	0.29	0.15	0.12	0.22	0.16	0.25
<b>Smjer vjetra u 7h</b>	0.13	0.08	0.08	0.1	0.16	0.11	0.15	0.13	-0.09
<b>Smjer vjetra u 14h</b>	0.1	-0.02	0.13	0.11	0.12	0.06	0.04	0.18	-0.11
<b>Smjer vjetra u 21h</b>	0.13	0.05	0	0.04	0.09	-0.05	0.03	0.02	-0.19

Koeficijenti korelacije izračunati su kako bi se mogle odrediti utjecajne veličine prije samog modeliranja. Utjecaje veličine određene su prema Chadockovoj ljestvici (Tablica 4.3.) koja pojašnjava ovisnost koeficijenta korelacije i same korelacije. Kao utjecajna veličina bila je promatrana temperatura jer jedina ima značajnu korelaciju prema dobivenim rezultatima.

**Tablica 4.3. Chadockova ljestvica**

R <sup>2</sup>	Značenje
<b>0.00</b>	Odsutnost veze
<b>0.00-0.25</b>	Slaba veza
<b>0.25-0.64</b>	Veza srednje jakosti
<b>0,64-1.00</b>	Čvrsta veza
<b>1.00</b>	Potpuna veza


Uz dobivenu tablicu korelacija (4.2.) prikazani su i dijagrami ovisnosti potrošnje plina o svakom od navedenih parametara u tablici. Na prikazanom primjeru (Slika 4.2.) vidljiva je ovisnost ukupne dnevne potrošnje na području grada Vukovara o srednjoj dnevnoj temperaturi na navedenoj lokaciji te se može uočiti rasipanje mjernih rezultata oko regresijskog pravca. U prikazanom slučaju uzeti su u obzir podaci o potrošnji za svaki plinski dan za plinsku godinu 2009/2010. te je vidljivo da je funkcija po dijelovima linearna.



**Slika 4.2.** Dijagram korelacije za plinsku godinu 2009/2010.

Iz dijagrama je vidljivo da su najveće potrošnje plina kada je vanjska temperatura najniža, jer je primarna svrha potrošnje prirodnog plina kao energent za potrebe grijanja. Može se primjetiti kako je odnos potrošnje prirodnog plina i temperature ispod 18 stupnjeva Celzija linearan i potrošnja prirodnog plina reagira na promjenu temperature. Nakon povećanja temperature zraka gubi se potreba za grijanjem prostora te se potrošnja plina uvelike smanjuje što je vidljivo i na dijagramu.

S obzirom da je funkcija po dijelovima linearna, tj. jedna linearna funkcija za zimski period i jedna za ljetni period, biti će izgrađena dva modela, jedan za zimski period (Slučaj 1) i jedan za ljetni period (Slučaj 2). Slučaj 1 obuhvaća mjerne uzorke od 1.10. do 10.4. dok preostali uzorci, od 11.4 do 30.9. pripadaju drugom slučaju.



Slika 4.3. Dijagram korelacije za plinsku godinu 2009/2010.

## **5. IMPLEMENTACIJA I REZULTATI ODABRANIH MODELA NA REALNOM SETU PODATAKA**

U radu su konstruirana četiri linearna modela (model linearne regresije, ARX, ARMAX i Box-Jenkins model) te jedan model umjetne neuronske mreže iz skupine nelinearnih modela. Svaki od navedenih modela kreiran je u programskom paketu Matlab na način koji je objašnjen u daljnjem tekstu.


### **5.1. Izgradnja, treniranje i testiranje odabranih modela**

Dvije temeljne faze u radu s navedenim modelima su faza učenja i faza testiranja. Nakon izrade modela potrebno je odrediti ulazne i izlazne varijable te pripremiti podatke na kojima će se primijeniti odabran model. Podatke je potrebno prije svega podijeliti u dva poduzorka: uzorak za treniranje odnosno učenje i uzorak za testiranje. Za podjelu podataka u uzorke za treniranje i testiranje ne postoji točno određeno pravilo, ali je preporučljivo najveći dio podataka ostaviti za treniranje. U ovom slučaju, podatci za treniranje su vremensko razdoblje od 1.10.2009. do 30.9.2015. Vremensko razdoblje od 1.10.2015. do 30.9.2017. koristi se za testiranje dobivenog modela. Što znači da u bazi imamo ukupno 2922 mjerna uzorka od čega se 80% uzoraka odnosno 2338 uzoraka raspoloživo je za treniranje i preostalih 20%, preciznije 585 mjernih uzoraka raspoloživih za testiranje modela.

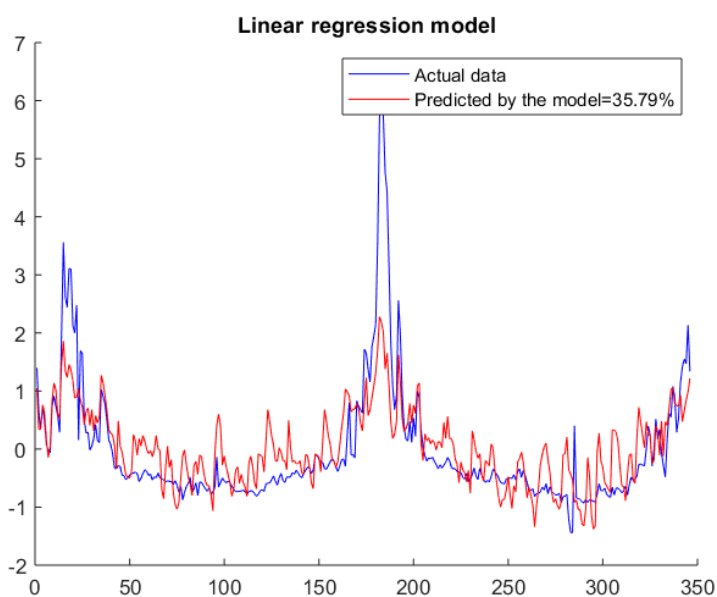
Nakon podjele podataka provodi se faza treniranja u svrhu prepoznavanja veze među podacima i predviđanja izlaznih vrijednosti na temelju ulaznih. Ne postoji egzaktno pravilo za dužinu treniranja. Druga faza rada je testiranje danih modela. Možemo ju opisati kao odlučujuću fazu za ocjenjivanje samog postupka i modela. U ovoj fazi modeli su istrenirani, a vrijednosti težina su fiksirane na vrijednostima dobivenim u fazi učenja. Sada se modelima predstavljaju nove ulazne vrijednosti koje nisu sudjelovale u procesu učenja, a od modela se očekuje da za predstavljenu novu ulaznu vrijednost proizvede pripadajuću izlaznu vrijednost. Ocjenjivanje modela vrši se izračunavanjem greške tako da se izlazna vrijednost modela uspoređuje sa stvarnim izlaznim vrijednostima. U nastavku su opisani postupci izgradnje svakog modela.

Model linearne regresije je najjednostavniji regresijski model prognoziranja potrošnje. Temelji se na korištenju srednje dnevne temperature zraka. Kreirana su dva modela, jedan model za zimski period (Slučaj 1) i jedan za ljetni period (slučaj 2). Modeli su kreirani razdoblje 2009/2010 do 2014/2015. Potom se svaki model testira na testnom skupu koji je predstavljen

zadnje dvije plinske godine, 2015/2016 i 2016/2017. Rezultati predikcije za zimski period prikazan je slikom 5.1. dok je testiranje modela za zimski period prikazana slikom 5.2.



**Slika 5.1.** Dijagram predikcije potrošnje plina dobiven modelom linearne regresije (Slučaj 1)

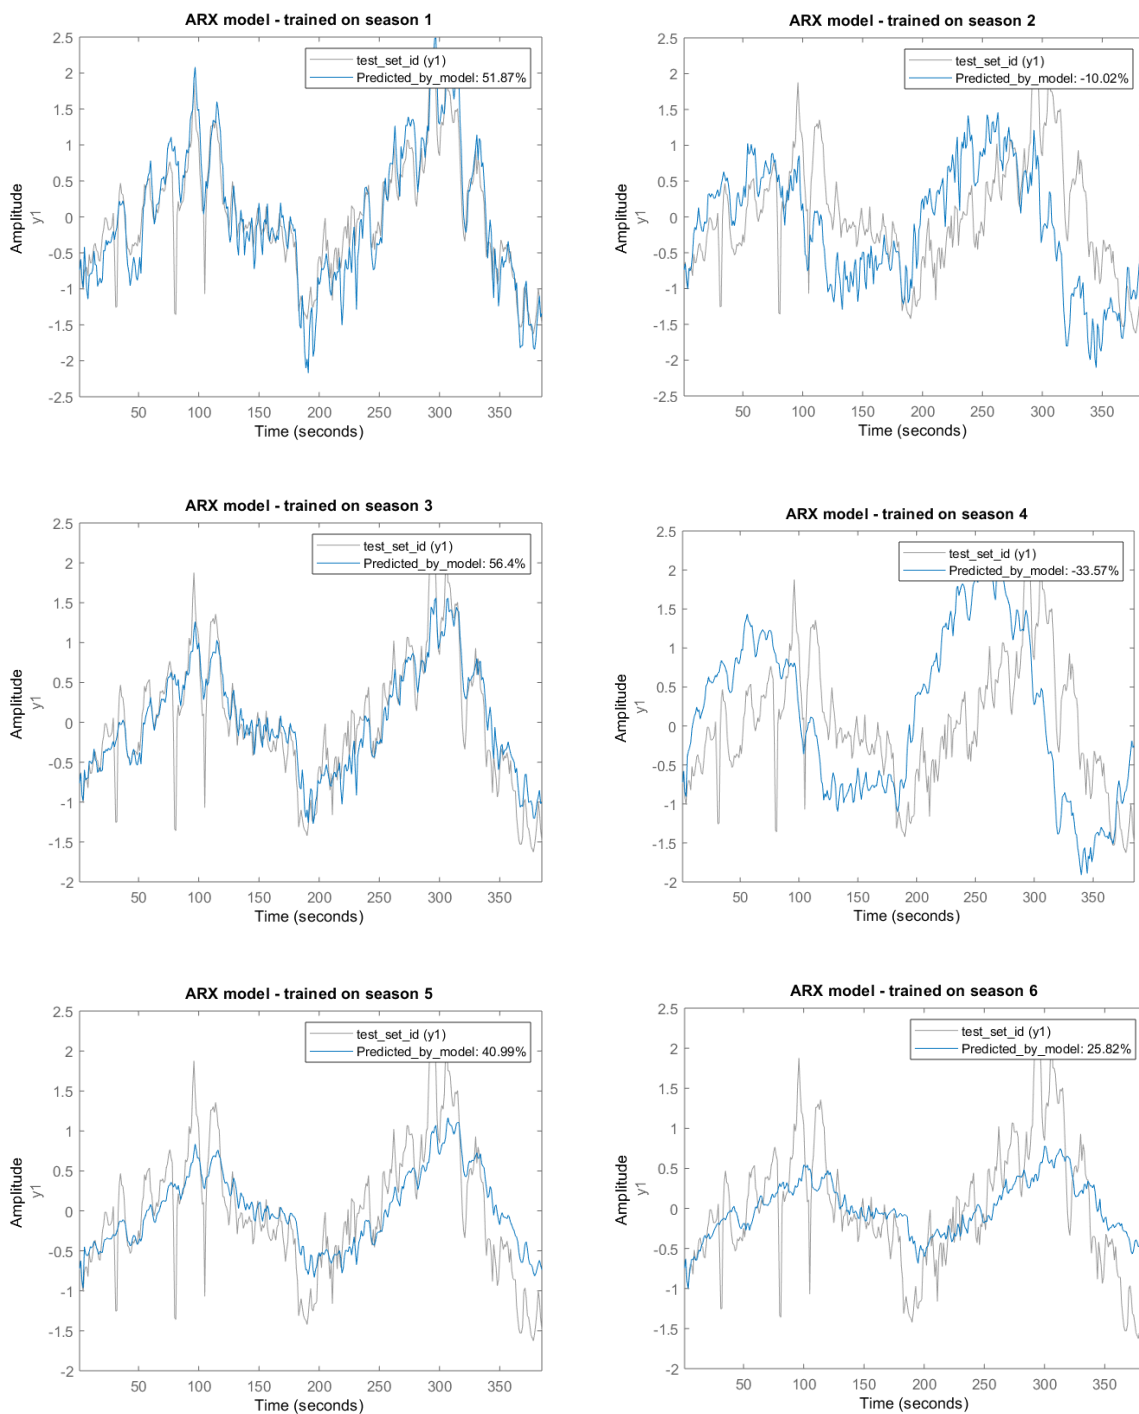


**Slika 5.2.** Dijagram predikcije potrošnje plina dobiven modelom linearne regresije (Slučaj 2)

Kod ARX modela potrebno je kreirati dva modela za svaku godinu zasebno, tj. jedan model za zimski period (Slučaj 1) i jedan za ljetni period (Slučaj 2). Za određeni period unutar godine podatci se dijele na skup za učenje i na skup za validaciju. Parametri modela se određuju

pomoću skupa za treniranje, dok se kvaliteta modela određuje na temelju validacijskog skupa. Na taj se način određuje najbolja struktura (i parametri) modela za određeni period unutar određene godine. Modeli se određuju za razdoblje 2009/2010 do 2014/2015. Svaki tako određeni model se onda testira na istom testnom skupu koji je predstavljen zadnje dvije plinske godine, 2015/2016 i 2016/2017.


U nastavku su prikazani grafovi testiranja svakog pojedinog modela.



**Slika 5. 3.** Set grafova ARX modela za Slučaj 1

**Tablica 5.1.** Rezultati testiranja ARX modela za Slučaj 1

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
ARX	51.87%	-10.02%	56.40%	-33.57%	40.99%	25.82%



**Slika 5. 4.** Set grafova ARX modela za Slučaj 2



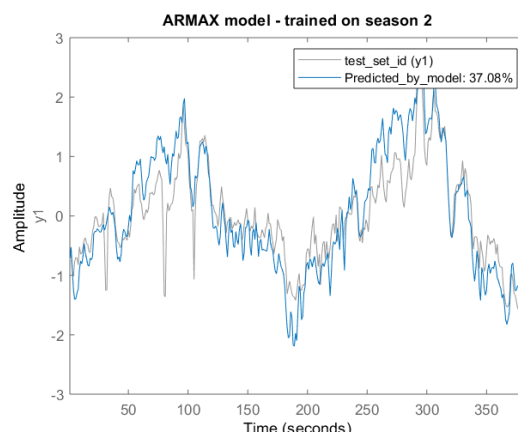





**Tablica 5.2.** Rezultati testiranja ARX modela za Slučaj 2

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
ARX	32.73%	25.82%	14.44%	21.55%	17.09%	27.59%

Kao i kod ARX modela, ARMAX model potrebno je kreirati dva modela za svaku godinu zasebno, tj. jedan model za zimski period (Slučaj 1) i jedan za ljetni period (Slučaj 2). Za određeni period unutar godine podatci se dijele na skup za učenje i na skup za validaciju. Parametri modela se određuju pomoću skupa za treniranje, dok se kvaliteta modela određuje na temelju validacijskog skupa. Na taj se način određuje najbolja struktura (i parametri) modela za određeni period unutar određene godine. Modeli se određuju za razdoblje 2009/2010 do 2014/2015. Svaki tako određeni model se onda testira na istom testnom skupu koji je predstavljen zadnje dvije plinske godine, 2015/2016 i 2016/2017.

U nastavku su prikazani grafovi testiranja svakog pojedinog modela.










Slika 5. 5. Set grafova ARMAX modela za Slučaj 1

Tablica 5.3. Rezultati testiranja ARMAX modela za Slučaj 1

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
ARMAX	60.61%	37.8%	-	-	6.51%	18.00%



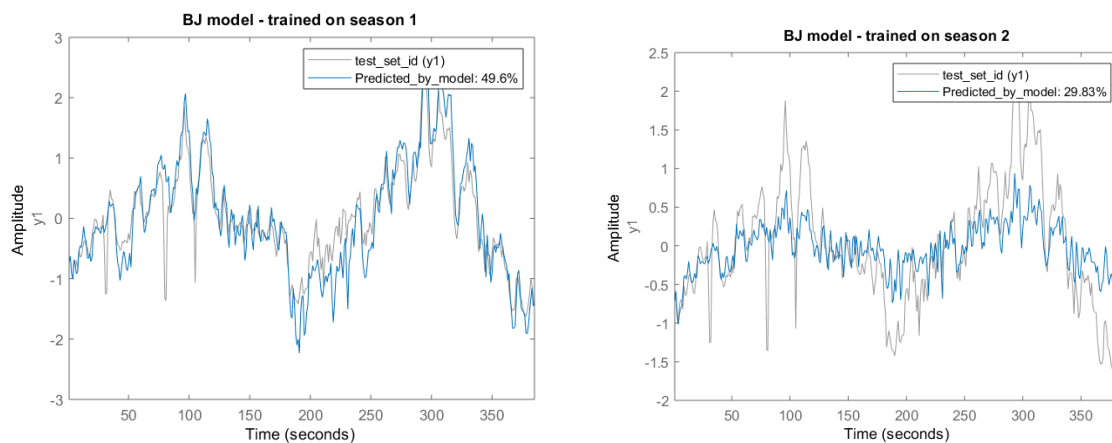



Slika 5. 6. Set grafova ARMAX modela za Slučaj 2

Tablica 5.4. Rezultati testiranja ARMAX modela za Slučaj 2

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
ARMAX	35.82%	12.47%	2.34%	23.12%	14.9%	29.81%

Kao što je već opisano za ARX i ARMAX model, na isti način kreiran je i testiran i Box-Jenkins model. Rezultati su prikazani sljedećim setom slika i tablicama 5.7 i 5.8.

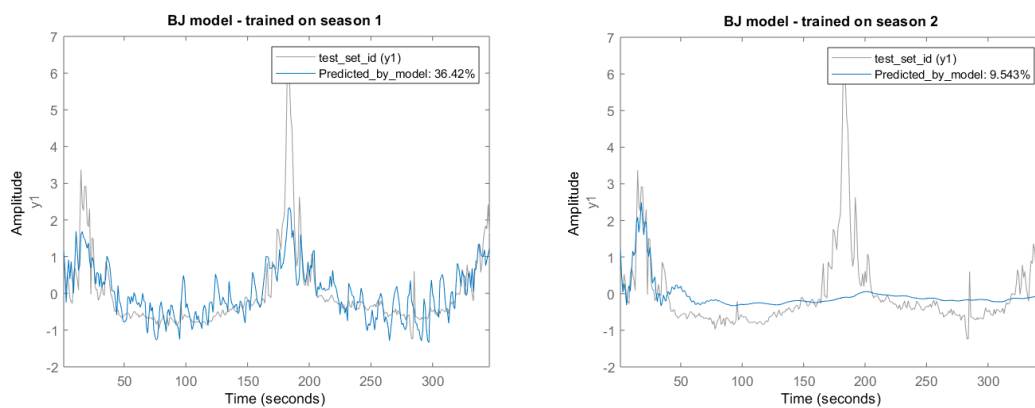


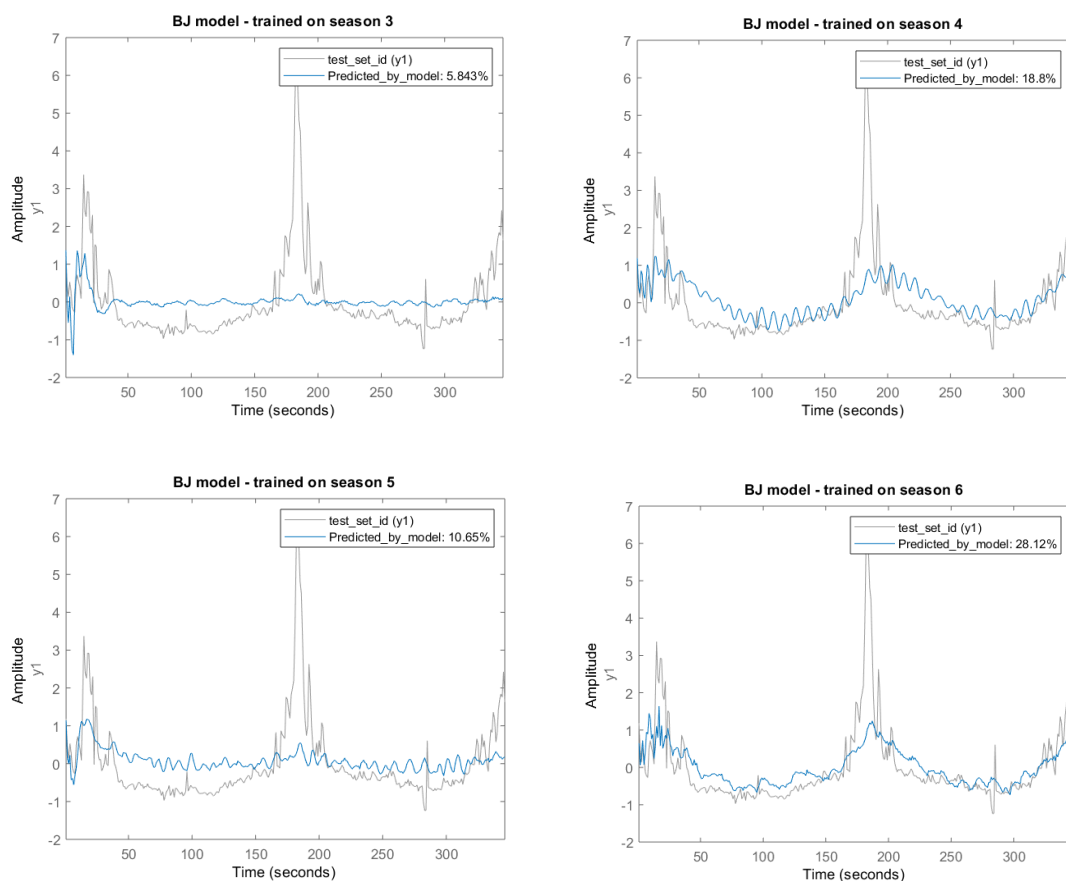


Slika 5. 7. Set grafova Box-Jenkins modela za Slučaj 1

Tablica 5.5. Rezultati testiranja Box-Jenkins modela za Slučaj 1

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
BXJ	49.6%	29.83%	59.24%	59.50%	38.93%	27.00%





**Slika 5. 8.** Set grafova Box-Jenkins modela za Slučaj 2

**Tablica 5.6.** Rezultati testiranja Box-Jenkins modela za Slučaj 2

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6
<b>BXJ</b>	36.42%	9.54%	18.8%	18.8%	10.65%	28.12%

Umjetna neuronska mreže (ANN) je mreža međusobno povezanih umjetnih neurona koji su organizirani u slojevima te može imati samo jedan ulazni i izlazni sloj. U ovom slučaju kreiran je ANN model koji sadrži samo jedan skriveni sloj. Svaki neuron ima aktivacijsku funkciju koja aktivira neuron i utječe na rezultat neurona. Ukoliko ne bi imali aktivacijsku funkciju, neuronska mreža ne bi mogla predviđati nelinearne ovisnosti. ANN model napravljen je tako da se mijenja aktivacijska funkcija i broj neurona dok broj skrivenih slojeva ostaje uvijek isti.

```

actList = {'purelin','softmax','tansig','logsig'};
ann_result=zeros(3,noNeurons*length(actList));
ann_models=cell(1,noNeurons*length(actList));
step=1;

for i=1:noNeurons
    for j=1:length(actList)
        ann = feedforwardnet(i,'trainlm');
        ann.trainParam.showWindow=false;
        ann.layers{1}.transferFcn=actList{j};
        net=train(ann,train_set(:,1)',train_set(:,end)');
        y_ann=net(test_set(:,1)');
        ann_result(:,step)=[goodnessOfFit(y_ann,test_set(:,end),'NRMSE') i j];
        ann_models{step}=net;
        step=step+1;
    end
end

```

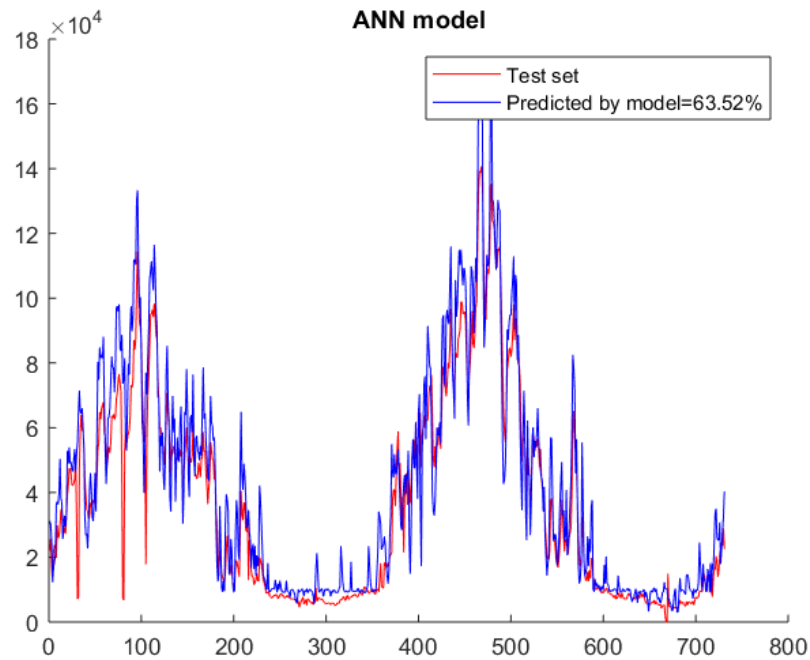
**Slika 5.9.** Dio koda za izradu ANN modela za predviđanje potrošnje

Korištena je feedforwardnet neuronska mreža koja se sastoji od jednog skrivenog sloja. Prvi sloj ima vezu s mrežnim ulazom. Svaki sljedeći sloj ima vezu iz prethodnog sloja. Završni sloj proizvodi izlaz mreže. Prilikom izrade modela kombinirane su različite funkcije kao što su: logsig, purelin, softmax i tansig. Broj neurona u srednjem tj. skrivenim sloju zadanog modela je određen iterativnom metodom. Prilikom treniranja modela primijenjena je standardna gradijentna metoda za učenje neuronske mreže – Levenberg-Marquardt -ova metoda. Svaki puta kada je mreža istrenirana, pamte se parametri i goodness of fit te se provjere parametri najboljeg i taj graf se crta. U ovom slučaju kao najbolje rezultate dala je mreža s 3 neurona u srednjem sloju s aktivacijskom funkcijom logsig. Na slici 5.10. su prikazani rezultati. Prvi redak označava vrijednost goodness of fit, drugi redak prikazuje broj neurona u skrivenom sloju te treći redak označava aktivacijsku funkciju.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
1	0.5433	-0.0237	0.6016	0.6057	0.5566	0.6114	0.6070	0.6144	0.5439	0.6041	0.5970	0.6352	0.5047	0.6007
2	1	1	1	1	2	2	2	2	3	3	3	3	4	4
3	1	2	3	4	1	2	3	4	1	2	3	4	1	2

**Slika 5.10.** Prikaz rezultata

Za potrebe učenja i testiranja modela raspoloživi podaci podijeljeni su u dvije skupine. Prva skupina predstavlja podatke za određivanje strukture i treniranje mreže dok druga skupina predstavlja podatke za testiranje modela. Usporedba izmjerene potrošnje i predikcije dobivene modelom za testni skup prikazana je na slici 5.11.



**Slika 5.11.** Dijagram predikcije potrošnje plina dobiven ANN modelom

## 5.2. Pregled rezultata predviđanja

Da bi se analizirala odnosno izmjerila kvaliteta modela u procjenjivanju potrošnje pline potrebno je sagledati i usporediti srednje-kvadratno odstupanje (RMSD, eng. root-mean-square deviation). RMSD je mjera točnosti za usporedbu pogrešaka predviđanja različitih modela za određeni skup podataka, a ne između skupova podataka, budući da ovisi o skali. RMSD je uvijek ne-negativan, a vrijednost 0 (gotovo nikad postignuta u praksi) ukazuje na savršeno uklapanje u podatke. Općenito govoreći, ako se predviđena i stvarna vrijednost bitno razlikuju, RMSD će biti veći. Odnosno ako se ove dvije vrijednosti vrlo bliske tada je RMSD manji. RMSD se računa preko sljedeće formule:

$$RMSD = \sqrt{\frac{\sum_{t=1}^T (\hat{y}_t - y_t)^2}{T}} \quad , \quad (5-1)$$

gdje  $t = 1, 2, \dots, N$  označava vremenski period,  $\hat{y}_t$  predstavlja modelsku prognozu za uzorak testiranja, dok predstavlja  $y_t$  stvarnu potražnja za prirodnim plinom.

U radu je korišten normaliziran RMSD, jer olakšava usporedbu između modela različitih razina. Ova vrijednost naziva se normalizirano odstupanje ili pogreška srednje vrijednosti (NRMSD ili NRMSE) i najčešće se izražava kao postotak gdje niža vrijednost ukazuje na manju rezidualnu varijancu [19].

U programskom paketu Matlab postoji gotova funkcija koja je korištena za izračunavanje NRMSD-a. Sintaksa fitness funkcije:

$$\text{fit}=\text{goodnessOFFit}(x,xref,\text{cost\_func}) \quad (5-1)$$

Dobiveni rezultati fitness funkcije prikazani su u sljedećim tablicama.

**Tablica 5.7.** Tablični prikaz reprezentativnosti konstruiranih modela za Slučaj 1

Matematički model:	model 1	model 2	model 3	model 4	model 5	model 6
<b>ARX</b>	51.87%	-10.02%	56.40%	-33.57%	40.99%	25.82%
<b>ARMAX</b>	60.61%	37.8%	-	-	6.51%	18.00%
<b>BXJ</b>	49.6%	29.83%	59.24%	59.50%	38.93%	27.00%

**Tablica 5.8.** Tablični prikaz reprezentativnosti konstruiranih modela za Slučaj 2

Matematički model:	model 1	model 2	model 3	model 4	model 5	model 6
<b>ARX</b>	32.73%	25.82%	14.44%	21.55%	17.09%	27.59%
<b>ARMAX</b>	35.82%	12.47%	2.34%	23.12%	14.9%	29.81%
<b>BXJ</b>	36.42%	9.54%	18.8%	18.8%	10.65%	28.12%

Kod ARX, ARMAX i Box-Jenkins metoda potrebno je kreirati dva modela za svaku godinu. Jedan model se radi za zimski period (Slučaj 1) i jedan za ljetni period (Slučaj 2). Za određeni period unutar godine podatci se dijele na skup za učenje i na skup za validaciju. Pomoću seta



za učenje i validacijskog seta određuje se najbolja struktura modela za određeni period unutar godine. Prvi slučaj se odnosi za zimski period u godini za koji se uzimaju mjerni uzorci iz baze podataka od 1.10 do 10.4. Dobiveni rezultati prikazani su u tablici 5.7. Drugi slučaj odnosi se na ljetni period godine od 11.4. do 30.9. Generalno gledajući rezultati možemo zaključiti da niti jedan model nije dao zadovoljavajuće rezultate Razlog tome može biti fiksirana vrijednost granica za ljetni i zimski period. Teško je odrediti točnu granicu za Slučaj 1 i Slučaj 2 zbog prijelaznih razdoblja i oscilacija u temperaturama u tim razdobljima. Još jedan 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.

Kod modela linearne regresije bilo je potrebno je kreirati dva modela, jedan za zimski period (Slučaj 1) i jedan za ljetni period (Slučaj 2). Modeli su trenirani na skupu podataka od 2009/2010 do 2014/2015. Potom se svaki model testira na testnom skupu koji je predstavljen zadnje dvije plinske godine, 2015/2016 i 2016/2017.

**Tablica 5.9.** Tablični prikaz reprezentativnosti konstruiranih modela za Linearnu regresiju

Matematički model:	Slučaj 1	Slučaj 2
<b>Model linearne regresije</b>	40.10%	35.79%

Model umjetne neuronske mreže kreiran i treniran na skupu podataka od 2009/2010 do 2014/2015., te je testiran na testnom skupu koji je predstavljen zadnje dvije plinske godine, 2015/2016 i 2016/2017.

**Tablica 5.10.** Tablični prikaz reprezentativnosti konstruiranig modela umjetne neuronske mreže

Matematički model:	Fittestest
<b>ANN</b>	63.20%

Nelinearni model umjetne neuronske mreže može donijeti bolje rezultate treninga, a time i bolje uklapanje podataka o treningu, ali rezultati otkrivaju da generalizacija izvedbe ovog modela ne nadmašuje u velikoj mjeri performanse testiranja jednostavnijih linearnih modela. 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.

## 6. ZAKLJUČAK

Republika Hrvatska kao i druge članice EU postupno je počela primjenjivati smjernice EU u svrhu liberalizacije tržišta. Razvoj i liberalizacija tržišta prirodnog plina pred sudionike tržišta stavlja nove izazove. Model tržišta koji se danas primjenjuje u Republici Hrvatskoj, a isto tako i u ostatku EU, podrazumijeva princip balansa u sustav isporuke plina. Ukoliko dođe do disbalansa u sustavu potrebno je izvršiti uravnoteženje koje se naplaćuje voditeljima bilančanih skupina koji su odgovorni za uzrok disbalansa, što znači da disbalans ima izravan financijski utjecaj na sudionike tržišta koji su doveli do takvog stanja. Uvođenjem financijske odgovornosti za neodgovorno i neplanirano ponašanje na tržištu, svim sudionicima postaje izrazito bitna mogućnost što točnijeg predviđanja očekivane potrošnje. Stoga je bitno što bolje predvidjeti potrošnju plina za idući plinski dan kako bi šteta bila što manja.

Cilj diplomskog rada bio je istražiti postojeće metode predviđanja potrošnje plina te na temelju saznanja samostalno konstruirati neke od odabranih modela u programskom paketu Matlab. Pod modelom prognoziranja potrošnje plina podrazumijeva se skup matematičkih modela kojima se opisuje sustav opskrbe plinom i prvenstveno sa stajališta ponašanja potrošnje plina u ovisnosti od različitih utjecajnih veličina. Da bi se odredile utjecajne veličine potrebno je izračunati koeficijente korelacije između potrošnje plina kao jedne vrijednosti i meteoroloških podataka kao druge vrijednosti. 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 faktor temperature na točnost nominiranih vrijednosti. Na temelju toga dan je pregled mogućih modela te su izgrađena 4 regresijska modela i jedan model umjetne neuronske mreže. Baza podataka napunjena je podacima o potrošnji plina za svaki plinski dan u razdoblju od 1.10.2009. do 30.9.2017. Izgrađene modele bilo je potrebno trenirati na određenom skupu podataka iz baze te ih kasnije testirati na novim podacima koji modelu nisu bili dani za učenje. Stoga su podaci iz baze podjeljeni na dva dijela, u uzorke za treniranje i te uzorak za testiranje. Ne postoji točno određeno pravilo po kojem se vrši podjela, ali je preporučljivo najveći dio podataka ostaviti za treniranje mreže. U ovom slučaju, podatci za treniranje su vremensko razdoblje od 1.10.2009. do 30.9.2015. Vremensko razdoblje od 1.10.2015. do 30.9.2017. koristi se za testiranje dobivenog modela. Konačno su dobiveni i rezultati izgrađenih modela. Općenito, nelinearni model umjetne neuronske mreže može donijeti bolje rezultate treniranja, a time i bolje uklapanje podataka o treningu, ali rezultati otkrivaju da generalizacija izvedbe ovog modela ne nadmašuje u velikoj mjeri performanse testiranja jednostavnijih linearnih modela. Korištenje samo jednog ulaza (temperature) i mala količina podataka mogući su uzroci

ovakvih rezultata. Neki od nedostataka umjetne neuronske mreže je to da za uspješno učenje neuronske mreže potreban izrazito velik broj podataka, neuronske mreže nisu u mogućnosti dati zadovoljavajuće rješenje izvan raspona vrijednosti iz kojih uče, te generalizacija naučenih primjera uspješna je kod „neprekidnih“ pojava. S obzirom da ne postoji standardiziran pristup kojim bi se problem mogao riješiti pomoću neuronskih mreža, prilikom ispitivanja svakog problema potrebno je isprobati veći broj neuronskih mreža, u svrhu dobivanja najkvalitetnije mreže, tj. mreže s najvećom pouzdanošću.

Glavne prednosti jednostavnijih linearnih modela su njihova robusnost, njihova manja razina i lakše razumijevanje arhitekture te brze i optimalne procedure obuke koje se mogu primijeniti na njih.

U praksi, modeli za predviđanje potrošnje plina moraju imati iznimnu preciznost stoga koriste veći broj ulaznih podataka i su daleko složeniji. Vremenski faktori, osim temperature (sunčeva svjetlost, vjetar), mogu utjecati na stvarnu potrošnju plina osobito zimi, ali nisu bili uključeni u modele zbog nemogućnost njihove ispravne procjene za cijelo područje distribucije.

Pokazalo se kako prognoziranje potrošnje plina oslanjajući se samo na vanjsku temperaturu nije pouzdano već je potrebno kombinirati veći broj vanjskih faktora te ispitati veći broj metoda, u svrhu dobivanja kvalitetnijih rezultata.

## LITERATURA

- [1] J. Rožman, „Analiza razvitka tržišta plina u Republici Hrvatskoj nakon donošenja Trećeg energetskeg paketa EU“, 2015. Dostupno na: <https://repozitorij.unizg.hr/islandora/object/rgn%3A20/datastream/PDF/view>[Ožujak, 2018.]
- [2] A Bajo, M. Primorac, D. Jurinec, „Tržište plina u Republici Hrvatskoj – liberalizacija i financijsko poslovanje“, Br. 3 listopad 2016. Dostupno na: <http://www.ijf.hr/upload/files/31.pdf> [ožujak, 2018]
- [3] „DIREKTIVA 2009/73/EZ EUROPSKOG PARLAMENTA I VIJEĆA“ - o zajedničkim pravilima za unutarnje tržište prirodnog plina i stavljanju izvan snage Direktive 2003/55/EZ, 13.srpanj 2009. [online]. Dostupno na:<https://www.derk.ba/DocumentsPDFs/EU-DIR-2009-73-HR.pdf>[Ožujak, 2018.]
- [4] „Zakon o energiji“, 2010. [online] Dostupno na:[https://narodne-novine.nn.hr/clanci/sluzbeni/2012\\_10\\_120\\_2583.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2012_10_120_2583.html)[ožujak, 2018]
- [5] „Opis transportnog sustava“, [online]. Dostupno na: <http://www.plinacro.hr/default.aspx?id=162>[ožujak, 2018]
- [6] „Pravilnik o organizaciji tržišta prirodnog plina“, 2013 [online]. Dostupno na: <http://www.propisi.hr/print.php?id=9202>[ožujak, 2018]
- [7] „PRAVILNIK O IZMJENAMA I DOPUNAMA PRAVILNIKA O ORGANIZACIJI TRŽIŠTA PRIRODNOG PLINA“, NN 29/2013 [online]. Dostupno na: [https://narodne-novine.nn.hr/clanci/sluzbeni/2013\\_03\\_29\\_508.html](https://narodne-novine.nn.hr/clanci/sluzbeni/2013_03_29_508.html)[ožujak, 2018]
- [8] „Modeli prognoziranja“, [online]. Dostupno na: <http://zelplin.hr/wp-content/uploads/2018/03/Modeli-prognoziranja.pdf>[ožujak, 2018]

- [9] B. Soldo, „Forecasting natural gas consumption“, Applied Energy 92 (2012)26-37, 2011 Dostupno na: [https://www.researchgate.net/publication/257156711\\_Forecasting\\_natural\\_gas\\_consumption](https://www.researchgate.net/publication/257156711_Forecasting_natural_gas_consumption) [travanj, 2018]
- [10] J. Herbert, „An analysis of monthly sales of natural gas to residential customers in the United States. Energy Syst Policy 1987“[travanj, 2018]
- [11] R. H. Brown , P. Kharouf , X Feng, L. P Piessens , „Nestor Dick. Development of feed-forward network models to predict gas consumption“, IEEE international conference on neural networks – conference proceedings, vol. 2; 1994. p. 802–5 Dostupno na: <https://ieeexplore.ieee.org/abstract/document/374281/>[travanj, 2018]
- [12] R. H. Brown, I Matin, „Development of artificial neural network models to predict daily gas consumption“, In: IECON proceedings (industrial electronics conference) Dostupno na: <https://ieeexplore.ieee.org/abstract/document/484153/>[travanj, 2018]
- [13] A. Khotanzad, H. Elragal, „Natural gas load forecasting with combination of adaptive neural networks“, In: Proceedings of the international joint conference on neural networks Dostupno na: <https://ieeexplore.ieee.org/document/830812/>[travanj, 2018]
- [14] „Heating Degree Days“, EGEE 102 Energy Conservation and Environmental Protection, [online]. Dostupno na: <https://www.education.psu.edu/egee102/node/2055> [ožujak, 2018]
- [15] P. Potočnika, B. Soldob, G. Šimunović, T. Šarić, A. Jeromena, E. Govekara, „Comparison of static and adaptive models for short-term residential natural gas forecasting in Croatia“, In: Applied Energy, vol. 129, 15 September 2014, Pages 94-103 Dostupno na: <https://www.sciencedirect.com/science/article/pii/S0306261914004656> [ožujak, 2018]

- [16] S. Dumančić, „Neuronske mreže“, Osijek, 2014. Dostupno na: <http://www.mathos.unios.hr/~mdjumic/uploads/diplomski/DUM05.pdf> [travanj, 2018.]
- [17] „Standardni-profil-potrosnje-na-ODS-Zelinaplin“, [online]. Dostupno na: <http://zelplin.hr/wp-content/uploads/2018/03/Standardni-profil-potrosnje-na-ODS-Zelinaplin.pdf> [svibanj, 2018.]
- [18] „Katalog i cjenik podataka, proizvoda i usluga“, 2017, [online] Dostupno na: [http://klima.hr/razno/katalog\\_i\\_cjenikDHMZ.pdf](http://klima.hr/razno/katalog_i_cjenikDHMZ.pdf) [travanj, 2018]
- [19] „Root-mean-square deviation“, [online]. Dostupno na: [https://en.wikipedia.org/wiki/Root-mean-square\\_deviation](https://en.wikipedia.org/wiki/Root-mean-square_deviation) [svibanj, 2019]

## SAŽETAK

Pridruživanjem Republike Hrvatske Europskoj Uniji započeta je liberalizacija tržišta plina. Liberalizacijom tržišta stvaraju se uvjeti za povećanje konkurencije i ukidanje državnih monopola, ali isto tako ostvaruje se smanjivanje nabave cijene plina kao i snižavanje transportnih troškova. Uvođenjem financijske odgovornosti za neodgovorno i neplanirano ponašanje na tržištu, svim sudionicima postaje izrazito bitna mogućnost što točnijeg predviđanja očekivane potrošnje. Predviđanje potrošnje prirodnog plina predstavlja problem predviđanja vrijednosti neke varijable u ovisnosti o raznim faktorima koji na njeno ponašanje utječu svaki u određenom omjeru.

Zadatak diplomskog rada bio je istražiti matematičke modele predviđanja koji bi bili primjenjivi za izgradnju sustava predviđanja potrošnje prirodnog plina te izvršiti demonstraciju rada odabranih modela na realnom setu podataka. Kreirana su četiri linearna modela predviđanja i jedan nelinearan model. Modeli su trenirani i testirani na stvarnim podacima, potom su uspoređeni. Doneseni su zaključci o prednostima i nedostacima svakog pojedinog modela.

Ključne riječi: prirodni plin, liberalizacija tržišta, potrošnja, model linearne regresije, ARX, ARMAX, Box-Jenkins model, ANN



## ABSTRACT

Croatia's accession to the European Union initiated the liberalization of the gas market. Market liberalization makes conditions for increased competition and the abolition of state monopolies, but also reduces purchase prices and reduces transport costs. By introducing financial responsibility for irresponsible and unplanned behavior on the market, the possibility of accurate forecasting of consumption becomes extremely important to all participants. Prediction of natural gas consumption indicates the problem of predicting the value of a variable depending on the various factors affecting its behavior in each particular proportion. The task of this graduate thesis was to investigate the mathematical forecasting models that were applied for the construction of a system that predicts natural gas consumption and to demonstrate the work of selected models on a real data set. Three regression model predictions and one nonlinear model were created. The models were trained and tested on the actual data that was up and the conclusions about the advantages and disadvantages of each particular model.

Key words: natural gas, market liberalization, consumption, linear regression , ARX, ARMAX, Box-Jenkins model, ANN

## **ŽIVOTOPIS**

Marta Cerovečki rođena je 15.11.1994. u Osijeku. Živi u Viljevu, gdje je završila Osnovnu školu Ante Starčevića. Nakon završetka osnovne škole upisuje Opću gimnaziju u Srednjoj školi Donji Miholjac u Donjem Miholjcu. Poslije srednje škole upisuje Fakultet elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. Upisuje preddiplomski studij elektrotehnike te stječe titulu sveučilišnog prvostupnika inženjera elektrotehnike. Nakon završenog prediplomskog studija, upisuje diplomski studij, izborni blok Komunikacijske tehnologije.