

Neuralna mreža za predikciju temperature kao deo servisno-orijentisane mreže pametnih pretvarača

Goran Ferenc

Robotika i simulacija leta
Lola institut
Beograd, Srbija
goran.ferenc@li.rs

Ivan Popović

Katedra za elektroniku
Elektrotehnički fakultet
Univerzitet u Beogradu
Beograd, Srbija
popovici@el.etf.rs

Nikola Bežanić

Elektrotehnički fakultet
Univerzitet u Beogradu
Beograd, Srbija
nbezanic@gmail.com

Sadržaj—U ovom radu je predstavljena *feedforward* neuralna mreža za predikciju temperature vazduha za naredni sat. Predikcija se vrši na osnovu istorije merenja temperature i relativne vlažnosti vazduha za prethodnih šest sati. Realizovana neuralna mreža je implementirana kao virtuelni pretvarač u okviru servisno-orijentisane arhitekture u mreži pametnih pretvarača. Neuralna mreža je obučena na obučavajućem skupu, koji je deo baze podataka formirane snimanjem vrednosti temperature i relativne vlažnosti vazduha na svakih deset sekundi za period od 3 dana i 6 sati u Beogradu. Tokom obučavanja, neuralna mreža je nakon svake iteracije u kojoj joj je predstavljen celokupan obučavajući skup, verifikovana na izdvojenom skupu podataka iz baze, označenom kao skup za verifikaciju. Kada je zadovoljena tačnost predikcije na obučavajućem i skupu za verifikaciju, tačnost neuralne mreže je proverena na izdvojenom skupu za testiranje.

Ključne reči - neuralne mreže; predikcija temperature; pametni pretvarači; web service; STWS;

I. UVOD

Veštačke neuralne mreže su se pokazale kao vrlo efikasan metod u rešavanju mnogih problema gde su karakteristike procesa stohastičke i teške za opisivanje pomoću matematičkih modela. One su relativno nov koncept u analizi podataka i imaju potpuno drugačiji pristup od onog koji je zastupljen kod multivarijacionih tehnika. Iako počeci razvoja neuralnih mreža ne sežu daleko u prošlost, one danas nalaze široku primenu, kako u tehničkim, tako i u društvenim naukama. Sa jedne strane, neuralne mreže se uspešno koriste u oblastima kao što su: upravljanje sistemima, robotika, obrada zvuka i slike, optimizacija funkcija, telekomunikacije, energetske sistemi, biomedicina i slično, ali i u ekonomiji na primer, za predviđanje ekonomskih obima prodaje u zavisnosti od aktivnosti koje se razmatraju, za predviđanje cena akcija na određeni dan i tako dalje, sa druge strane.

Neuralne mreže su pronašle svoju primenu i u meteorologiji. To nije slučajno, s obzirom da su iznenadne promene vremenskih uslova od izuzetnog značaja u mnogim sferama. Tačnom predikcijom vremenskih prilika se mogu preduzeti odgovarajuće mere za zaštitu poljoprivrednih kultura, u ekstremnim situacijama se može evakuisati stanovništvo u slučaju prirodnih katastrofa, kao što su poplave

ili snažni olujni vetrovi. Ova tematika je vrlo aktuelna i u mnogim radovima su se autori bavili predikcijom meteoroloških prilika [1], [2]. Predikcija temperatura je tema u ovom radu.

U radu je predstavljena realizacija jednog tipa *feedforward* neuralne mreže za predikciju temperature vazduha za naredni sat na osnovu prethodnih šest sati merenja temperature i relativne vlažnosti vazduha. Neuralna mreža je implementirana kao virtuelni pretvarač u servisno-orijentisanoj arhitekturi u mreži pametnih pretvarača.

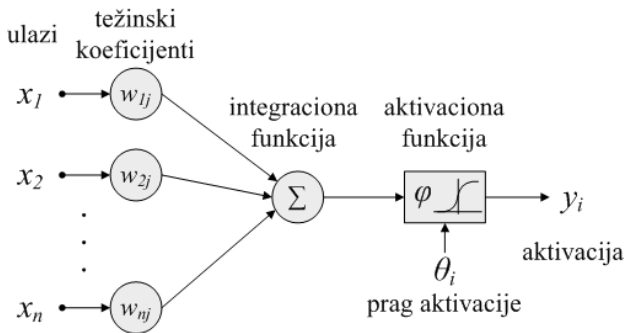
Rad je podeljen u šest poglavlja. Nakon uvoda, u drugom poglavlju je dat teorijski uvod kako bi se razumeo koncept neuralnih mreža. U trećem poglavlju je predstavljena korišćena baza podataka, dok je u četvrtom poglavlju predstavljena realizacija neuralne mreže sa osvrtom na model, metod obučavanja i dobijene rezultate. U petom poglavlju je pokazana integracija neuralne mreže u vidu virtuelnog pretvarača u distribuiranoj, servisno-orijentisanoj mreži pametnih pretvarača. Na kraju je izveden zaključak.

II. NEURALNE MREŽE

Neuralne mreže predstavljaju jednu od metoda veštačke inteligencije. Umesto što konceptualizuju problem u matematičkoj formi, neuralne mreže koriste principe ljudskog mozga i njegove strukture, kako bi razvile strategiju procesiranja podataka. Veštačke neuralne mreže podsećaju na ljudski mozak, jer se sastoje iz određenog broja procesorskih elemenata (veštačkih neurona), primaju znanje kroz proces obučavanja, dok težine međuneuralnih veza (jačina sinaptičkih veza) služe za memorisanje znanja. Masivni paralelizam, sposobnost obučavanja i generalizacija čine osnovnu snagu neuralnih mreža. Generalizacija predstavlja sposobnost produkovanja zadovoljavajućeg izlaza neuralne mreže i za ulaze koji nisu bili prisutni u toku obučavanja.

Na sl. 1 je prikazan matematički model veštačkog neurona. Model neurona čine tri osnovna elementa:

- skup težinskih koeficijenata: $\{w_{ij}\}$
- integraciona funkcija: Σ
- aktivaciona funkcija: ϕ



Slika 1. Matematički model neurona

Skup težinskih koeficijenata predstavlja snagu sinaptičkih veza između neurona i (izvora) i neurona j (destinacije), pri čemu pozitivne težine odgovaraju ekscitirajućim sinaptičkim vezama, a negativne inhibitornim. Integraciona funkcija formira težinsku sumu izlaza, dok aktivaciona funkcija predstavlja vezu ulaznog i izlaznog signala neurona.

Ulazni signal predstavlja linearnu kombinaciju izlaznih signala prethodnih neurona, odnosno ulaza neuralne mreže koji su povezani na taj neuron, pri čemu je svaki od tih signala pomnožen odgovarajućim težinskim koeficijentom. Izlaz neurona u zavisnosti od ulaza se može predstaviti sledećom relacijom:

$$y_i(t+1) = \varphi \left(\sum_{j=1}^n w_{ij} x_j(t) - \theta_i \right) \quad (1)$$

U prethodnoj relaciji, integraciona funkcija je linearna. Postoje i složeniji oblici integracionih funkcija, kao što su kvadratna ili sferična funkcija:

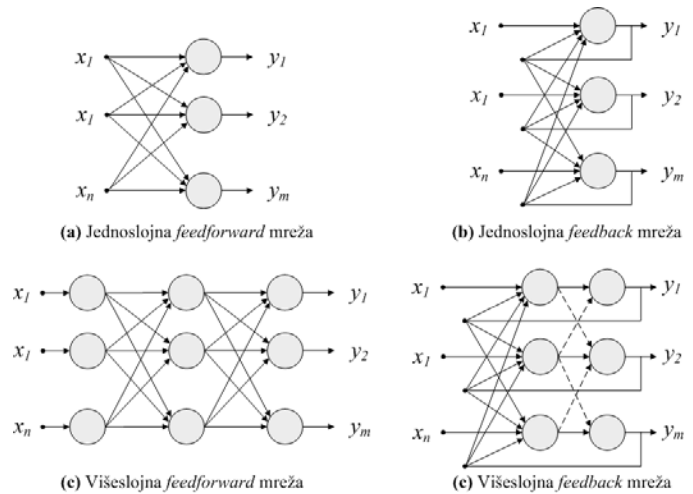
$$f = \sum_{j=1}^n w_{ij} x_j^2 - \theta_i \quad (2)$$

$$f = \rho^{-2} \sum_{j=1}^n (x_j - w_{ij})^2 - \theta_i \quad (3)$$

Kako bi se postigle željene performanse, neuralnoj mreži se na sistematičan način menjaju težine međuneuralnih veza. Težinski koeficijenti ne moraju da budu adaptivni, ali snaga neuralnih mreža leži upravo u mogućnosti adaptacije težinskih koeficijenata. Adaptacija težinskih koeficijenata neuralne mreže naziva se obučavanje i postoje brojni algoritmi, kao i nekoliko podela načina obučavanja. Postoje tri osnovna načina obučavanja, koji se razlikuju po informacijama koje mreža dobija iz spoljnog sveta. To su obučavanje sa supervizorom, sa kritikom, i bez supervizora. Obučavanje sa supervizorom podrazumeva da neuralna mreža dobije informaciju o željenoj vrednosti izlaza, koju zatim poredi sa vrednošću koju je sama izračunala i na osnovu njihove razlike podešava težinske koeficijente sa ciljem da tu razliku minimizira. Obučavanje sa kritikom je slično, ali se raspoloživo samo delimičnim informacijama o željenom izlazu, pri čemu se neki relevantan signal ipak može proslediti neuralnoj mreži. Kod obučavanja bez supervizora, mreža ne dobija nikakvu informaciju o tome

da li njen izlaz zadovoljava određeni kriterijum, već je u potpunosti prepuštena sama sebi. Na taj način se ne može postići mnogo, ali postoje slučajevi, kao što je klasifikacija objekata u prostoru, gde ovaj način obučavanja može uspešno da se primeni.

Arhitektura neuralne mreže predstavlja specifično povezivanje neurona u jednu celinu. Struktura neuralne mreže se razlikuje po broju slojeva. Na sl. 2 su prikazane osnovne strukture neuralnih mreža. Može se videti da se neuroni organizuju po slojevima pri čemu u svaki od neurona ulazi više ulaznih signala kao i da iz svakog sloja postoji više izlaznih signala, po jedan za svaki neuron. Mreža može sadržati jedan ili više slojeva pa se u zavisnosti od toga dele na jednoslojne i višeslojne. Kod višeslojnih mreža prvi sloj se naziva ulazni, a poslednji izlazni, dok se slojevi između nazivaju skriveni slojevi. Skriveni slojevi mogu, ali i ne moraju da postoje. Po pravilu, slojevi komuniciraju tako što se izlaz svakog neurona iz prethodnog sloja povezuje sa ulazima svih neurona narednog sloja. Ako je struktura mreže takva, kaže se da je neuralna mreža potpuno povezana.



Slika 2. Različite strukture neuralnih mreža

Ulazni sloj je jedini sloj koji prima podatke iz spoljašnje sredine i on nema nikakvu funkciju već da ulazni signal distribuira na onoliki broj neurona kolike su potrebe sledećeg sloja. To može biti jedan od skrivenih slojeva ili izlazni sloj, ukoliko nema skrivenog sloja. Ukoliko postoje, skriveni slojevi prosleđuju relevantne podatke do izlaznog sloja, na čijem se izlazu dobija rezultat.

Neuralne mreže mogu da budu bez povratne grane (*feedforward*) ili sa povratnom granom (*feedback*). Pri tom je moguće i kašnjenje u propagaciji signala kroz neurone. Mreže u kojima ne postoje vremenska kašnjenja nazivaju se statičke, dok se mreže u kojima ta kašnjenja postoje nazivaju dinamičke.

Osnovna prednost neuralnih mreža nad klasičnim kompjuterskim algoritmima leži u činjenici da se mreže obučavaju, dok je za ostale algoritme potrebno da se unapred zna koje korake treba preduzeti da bi se došlo do rešenja. Naravno, ta prednost ponekad može biti i nedostatak, jer

nepoznavanje načina na koji se dolazi do rešenja često onemogućava ispravljanje grešaka.


Kako bi se rešio zadati problem, kao što je modeliranje nekog fizičkog procesa na klasičan način, potrebno je do detalja proučiti fiziku tog procesa, precizno mereći fizičke dimenzije, vodeći računa o nelinearnostima i transportnim kašnjenjima. S druge strane, ako se za modeliranje koristi neuralna mreža, sve što je potrebno jeste dovoljno reprezentativan skup podataka za obučavanje i najčešće su to sami ulazi i izlazi datog sistema. Pored toga, da bi proces obučavanja bio što kvalitetniji, neophodno je pokriti što širi opseg radnih režima.

Najčešće korišćeni algoritam za obučavanje višeslojnih neuralnih mreža sa supervizorom je propagacija greške unazad (*backpropagation*) i primenjiva je samo na *feedforward* mreže. Naime, kod obučavanja jednoslojnih *feedforward* mreža težinski koeficijenti mreže se podešavaju tako da se za svaki neuron minimizira razlika izlaza i željenog izlaza tog neurona. Problem je u tome što se kod višeslojnih *feedforward* mreža ne poznaju željene vrednosti izlaza neurona koji se nalaze u skivenim slojevima, već samo izlaznog sloja. Metod propagacije greške unazad rešava taj problem i on je korišćen u ovom radu. Osnovna ideja je da ulazni signal propagira unapred, od ulaznog do izlaznog sloja dok signal greške propagira unazad, od izlaznog do ulaznog sloja, menjajući težinske koeficijente mreže tim redom. Ovaj metod obuhvata dve faze:

- ulazni vektor $x^{(k)}$ propagira od ulaznog ka izlaznom sloju, produkujući izlaz $y^{(k)}$
- signal greške zatim u drugoj fazi propagira unazad od izlaznog ka ulaznom sloju u cilju korigovanja težina w_{ij}

III. FORMIRANJE BAZE PODATAKA


Baza podataka korišćena u ovom radu je formirana snimanjem vrednosti temperature i relativne vlažnosti vazduha na svakih deset sekundi za period od 3 dana i 6 sati. Format baze se tako sastoji iz tri kolone podataka: temperatura vazduha, relativna vlažnost vazduha i vreme kada je izvršeno merenje, respektivno. Podaci su snimani od 3. do 6. oktobra 2012. godine u Beogradu na lokaciji prikazanoj na sl. 3. Koordinate lokacije su 44° 48' 38" severne geografske širine i 20° 28' 53" istočne geografske dužine.




Slika 3. Lokacija postavljene senzora

Za merenje temperature je korišćen senzor iz KTY81 serije KTY81-110 [3] sa maksimalnom greškom u mernom opsegu od interesa od 2.5°C i mernim opsegom [-55°C, 150°C]. Relativna vlažnost vazduha je merena pomoću digitalnog senzora SHT11 [4], čija je tačnost 4.5%, a merni opseg [0%, 100%]. Oba senzora su povezana sa *mbed* platformom [5], o kojoj će biti reči u petom poglavlju. Očitavanja se vrše na svake dve sekunde, a po pozivu servisa na svakih 10 sekundi, vrednosti temperature i relativne vlažnosti se šalju preko interneta klijentskoj aplikaciji.

Zbog privremenih gubitaka u komunikaciji sa senzorima, neke vrednosti su interpolirane u bazi podataka. Zbog toga, podaci u bazi nisu relevantni u celom opsegu, naročito u poslednjih 15% vrednosti za temperaturu, gde je interpolacija vršena u najvećoj meri. Vrednosti temperature vazduha su u opsegu od 16.98°C do 31.85°C, nakon ukljanjanja najizraženijih vršnih vrednosti. Vrednosti relativne vlažnosti vazduha su u opsegu od 19% do 59%. Nakon analize snimljenih podataka, s obzirom da je na nekim mestima vršena interpolacija i da podaci poseduju određenu količinu šuma, odlučeno je da se izvrši usrednjavanje sa pokretnim prozorom širine 30 odbiraka, odnosno u vremenskom trajanju od 5 minuta, i pomerajem od jednog odbirka, odnosno 10 sekundi. Ovako obrađeni podaci za temperaturu i relativnu vlažnost vazduha su prikazani na sl. 4 i sl. 5.



Slika 4. Temperatura vazduha nakon usrednjavanja



Slika 5. Relativna vlažnost vazduha nakon usrednjavanja

Nakon usrednjavanja podataka za temperaturu i relativnu vlažnost vazduha, izvršena je normalizacija temperature u intervalu [0, 1], prema sledećem obrascu:


$$T_i^{norm} = \frac{T_i - T_{min}}{T_{max} - T_{min}} \quad (4)$$

gde je T_i^{norm} normalizovana vrednost temperature vazduha, T_i vrednost temperature vazduha pre normalizacije, a $T_{max} = 35^\circ C$ i $T_{min} = 0^\circ C$. Vrednosti relativne vlažnosti vazduha nisu normalizovane, jer se one već nalaze u intervalu [0, 1].

IV. IMPLEMENTACIJA NEURALNE MREŽA ZA PREDIKCIJU TEMPERATURE

A. Realizacija neuralne mreže

Za implementaciju neuralne mreže korišćen je višeslojni perceptron (*Multi Layer Perceptron*), koji po definiciji predstavlja potpuno povezanu *feedforward* neuralnu mrežu sa jednim ulaznim, jednim izlaznim i jednim ili više skrivenih slojeva. U realizaciji neuralne mreže u ovom radu, korišćen je višeslojni perceptron sa 14 ulaza, jednim izlazom i jednim skrivenim slojem sa 7 neurona (sl. 6). Kao aktivaciona funkcija korišćena je sigmoidalna funkcija i u skrivenom i u izlaznom sloju.



Slika 6. Relativna vlažnost vazduha nakon usrednjavanja

Izlaz y_1 predstavlja predikciju temperature za naredni sat. Ulazi su podeljeni u tri grupe, pri čemu je t trenutno vreme, a x_i i -ti ulaz:

- 1) Prva grupa se odnosi na prethodne vrednosti temperature vazduha:
 - (a) x_1 : prosečna temperatura na intervalu $[t-6h, t-5h]$
 - (b) x_2 : prosečna temperatura na intervalu $[t-5h, t-4h]$
 - (c) x_3 : prosečna temperatura na intervalu $[t-4h, t-3h]$
 - (d) x_4 : prosečna temperatura na intervalu $[t-3h, t-2h]$
 - (e) x_5 : prosečna temperatura na intervalu $[t-2h, t-1h]$
 - (f) x_6 : prosečna temperatura na intervalu $[t-1h, t]$
- 2) Druga grupa se odnosi na prethodne vrednosti relativne vlažnosti vazduha:
 - (a) x_7 : prosečna vlažnost na intervalu $[t-6h, t-5h]$
 - (b) x_8 : prosečna vlažnost na intervalu $[t-5h, t-4h]$
 - (c) x_9 : prosečna vlažnost na intervalu $[t-4h, t-3h]$
 - (d) x_{10} : prosečna vlažnost na intervalu $[t-3h, t-2h]$
 - (e) x_{11} : prosečna vlažnost na intervalu $[t-2h, t-1h]$
 - (f) x_{12} : prosečna vlažnost na intervalu $[t-1h, t]$
- 3) Treća grupa se odnosi na period dana kada se vrši predikcija. Dan je podeljen na tri jednaka vremenska intervala [00:00, 08:00], [08:00, 16:00], [16:00, 24:00] i prema vremenu za koje se vrši predikcija, koduju se poslednja dva ulaza kao 00, 01 i 11, respektivno:
 - (a) x_{13} : prvi bit kodiranja
 - (b) x_{14} : drugi bit kodiranja

B. Obučavanje neuralne mreže

Nakon obrade originalne baze podataka, koja uključuje odstranjivanje vršnih vrednosti, normalizaciju vrednosti temperature vazduha, usrednjavanje vrednosti temperature i relativne vlažnosti vazduha i odbacivanje poslednjih 15% podataka zbog vršene interpolacije, novoformirana baza podataka je podeljena na tri skupa: obučavajući skup, validacijski i skup za testiranje i to u odnosu na originalnu bazu u proporciji 60%, 15% i 3% za ulazne podatke i preostalih 7% je deo u koji ulazi deo ciljanih podataka (*targets*).

Obučavanje je vršeno primenom algoritma propagacije greške unazad (*backpropagation algorithm*) sa dodatim koracima pri obučavanju, kako bi se izbegao *overfitting* [6], odnosno postigla generalizacija. Na taj način se neuralna mreža obučava da produkuje zadovoljavajuću prognozu temperature za naredni sat i onda kada se implementira u realni system. U takvoj situaciji će se javljati nove ulazne vrednosti, koje naravno nisu bile prisutne u toku obučavanja. U tu svrhu je predložen sledeći algoritam pri obučavanju, koji se pokazao uspešnim.

Prilikom svake iteracije, na podatke iz obučavajućeg skupa se dodaje niska vrednost veštačkog šuma, pomoću koga se

simuliraju moguće vrednosti koje bi se mogle javiti nakon obučavanja, čime se neuralna mreža podstiče na generalizaciju.

U jednoj iteraciji, neuralnoj mreži se predstavlja celokupan obučavajući skup, tako što se jedan po jedan 14-dimanzionalni ulazni vektor propusti kroz neuralnu mrežu, koja na izlazu izračuna predikcionu vrednost temperature za naredni sat. Dobijena vrednost se zatim uporedi sa ciljanom vrednošću iz baze, izračuna se greška i primenom propagacije greške unazad se promene težinski koeficijenti i računaju greške za prethodni sloj. Ukoliko su svi uzorci iz obučavajućeg skupa prošli proceduru, iteracija je završena. Testiranjem su dobijeni mnogo bolji rezultati ukoliko se vrednosti iz obučavajućeg skupa predstavljaju neuralnoj mreži slučajnim rasporedom.

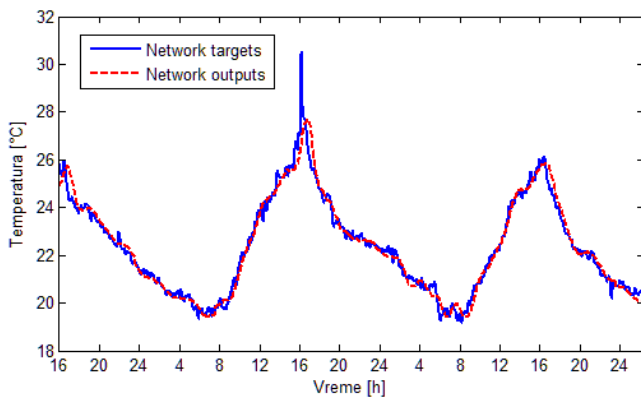
Nakon svake iteracije se računa srednja kvadratna greška predikcije RMSE (*Root Mean Square Error*) za obučavajući i za validacijski skup. Dok se greške za obučavajući i validacijski skup smanjuju, obučavanje se nastavlja.

Obučavanje se može prekinuti iz dva razloga: ukoliko je postignuta zadovoljavajuća tačnost predviđanja za oba skupa, što se definiše na početku, ili posle unapred definisanog broja iteracija, ako greška za validacijski skup krene da se povećava. U tom slučaju se pamte težinski koeficijenti pre početka povećavanja greške.

Nakon završetka obučavanja, neuralna mreža se testira na skupu podataka za testiranje i ako je zadovoljena tačnost predviđanja, mreža se smatra konačno obučenom.

C. Dobijeni rezultati

Za konkretnu implementaciju neuralne mreže za predikciju temperature za naredni sat, dobijeni rezultati su prikazani na sl. 7. Greška predikcije izražena kroz srednju kvadratnu grešku iznosi $RMSE = 0.361$.



Slika 7. Rezultati predikcije i *target* vrednosti

V. NEURALNA MREŽA KAO VIRTUELNI PRETVARAČ

A. Distribuirana mreža pametnih pretvarača

Pametni pretvarači su neizostavni deo u mnogim sistemima, imajući u vidu njihovu široku primenu u raznim granama industrije. Pri tome, njihovo povezivanje u sistem se može realizovati na različite načine. Uvođenjem raznih protokola za digitalnu komunikaciju, olakšano je očitavanje

pametnih pretvarača. Na taj način je moguće efikasno ostvariti vezu putem bežičnih predajnika/prijemnika ili nekim od standardnih žičanih serijskih interfejsa [7].

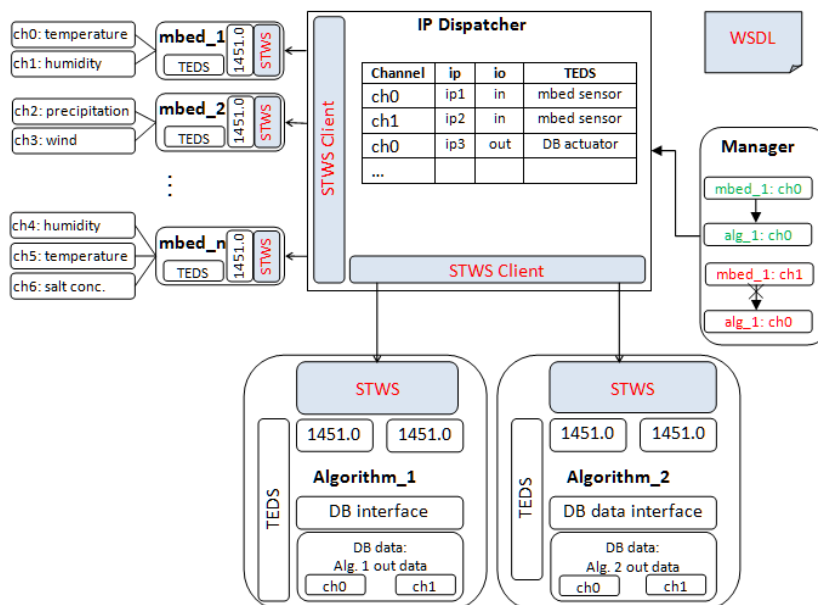
Kako bi se olakšala proizvodnja pametnih pretvarača u još većoj meri, definisana je familija IEEE 1451 standarda sa ciljem da pojednostavi razvoj i primenu pretvarača i obezbedi set standardnih interfejsa za povezivanje pretvarača u sisteme, mreže i povezivanje sa instrumentima, integrišući na taj način senzorske i mrežne tehnologije [8]. Da bi se omogućio lakši protok podataka, predloženo je pristupanje pretvaračima putem *web service* tehnologije [9]. *Web service* obezbeđuje izvršavanje operacija na zahtev klijenata, pri čemu je implementiran u okviru internet mreže kao deo distribuiranog sistema. Za slučaj pametnih prevarača operacije dostupne od strane mrežne aplikacije podrazumevaju pristup funkcijama i servisima pametnih pretvarača. Detalji komunikacije sa pretvaračima se na taj način apstrakuju. Poruke dobijene od strane uređaja konvertuju u SOAP/XML poruke, pogodno za dalju obradu u okviru distribuiranog sistema. Internet servis je implementiran pomoću *web service* tehnologije sa zadatkom da vrši ovu konverziju i šalje poruke krajnjem klijentu ili distribuiranoj senzorskoj aplikaciji višeg nivoa.

Dakle, *web service* tehnologija na efikasan način omogućava implementaciju servisno-orijentisane arhitekture u mreži pametnih pretvarača. Model implementacije *web service* koncepta, poznat pod nazivom *Smart Transducer Web Services* (STWS) [10], je baziran na IEEE 1451.0 standardu. Ovaj koncept se uklapa u različite arhitekture distribuirane senzorske aplikacije i obezbeđuje jedinstven interfejs za pristup funkcijama i servisima pametnih pretvarača.

B. Implementacija neuralne mreže u distribuirani sistem

U radu je uveden pojam virtuelnih pretvarača. Jedan tip virtuelnog pretvarača bi bila realizovana neuralna mreža, koja pristupa bazi podataka sa izmerenim vrednostima temperature i relativne vlažnosti vazduha, čita ih i na taj način vrši funkciju virtuelnog senzora. Predikcijom temperature za naredni sat i upisom u bazu podataka neuralna mreža vrši funkciju virtuelnog aktuatora. Predloženi sistem, u kojem je neuralna mreža integrisana kao virtuelni pretvarač, ima izgled kao na sl. 8. Čvor koji se povezuje na centralni server, može da se tretira kao senzor i/ili aktuator, pravi ili virtuelni. Uređaji *mbed_i*, $i = [1, n]$, imaju funkcije senzora, dok su moduli *Algorithm₁* i *Algorithm₂* istovremeno i virtuelni senzori i virtuelni aktuatori. Neuralna mreža je integrisana u okviru modula *Algoritam₁*.

Prilikom povezivanja na mrežu, virtuelnog ili pravog, senzora/aktuatora, potrebno je da se isti prijavi putem HTTP protokola centralnom server. Centralni server prihvata adresu senzora, upisuje je u tabelu i dodelje ID svakom prijavljenom kanalu. U odgovarajućem trenutku, tabela u centralnom serveru se dopunjava dodatnim opisom putem čitanja TEDS fajlova registrovanih uređaja. Ova tabela je dostupna menadžerskoj aplikaciji *Manager*, koja povezuje odgovarajuće ulazne kanale sa izlaznim kanalima i na taj način konfigurise mrežu. Izlazni kanali dobijaju podatke senzora sa unapred određenim periodom koji zavisi od vrednosti periode osvežavanja iz TEDS fajlova i načina rada servera.



Slika 8. Servisno-orijentisana mreža pametnih pretvarača

VI. ZAKLJUČAK

U ovom radu je predstavljena implementacija jednog tipa neuralne mreže za predikciju temperature. Predikcija temperature vazduha se vrši za naredni sat na osnovu istorije merenja temperature i relativne vlažnosti vazduha za prethodnih šest sati. Neuralna mreža je realizovana kao višeslojni perceptron sa 14 ulaza, jednim izlazom i jednim skrivenim slojem sa 7 neurona. Mreža je obučena, verifikovana i testirana na 85% originalne baze, koja sadrži izmerene vrednosti temperature i relativne vlažnosti vazduha za 3 dana i 6 sati. U radu su prikazani dobijeni rezultati kroz uporedni dijagram rezultata predikcije i ciljanih vrednosti, kao i ukupna greška predikcije izražena kroz srednju kvadratnu grešku koja iznosi $RMSE = 0.361$. Na kraju je predstavljena distribuirana servisno-orijentisana mreža pametnih pretvarača u kojoj je neuralna mreža implementirana kao virtuelni pretvarač.

U realizaciji neuralne mreže i servisno-orijentisanog sistema korišćeno je razvojno okruženje *NetBeans* i *Java* programski jezik.

LITERATURA

- [1] A. Ruano, E. Crispim, E. Conceicao, M. Lucio, "Prediction of building's temperature using neural networks models," *Energy and Buildings* 38, 2006, pp. 682-694.
- [2] B. Smith, R. McClendon, G. Hoogenboom, "Improving air temperature prediction with artificial neural networks," *International Journal of Computational Intelligence* 3(3), 2006, pp. 179-186.
- [3] KTY81-1 series, Silicon temperature sensors, Product datasheet, Philips, March 1998.
- [4] Datasheet SHT1x (SHT10, SHT11, SHT15), Humidity and Temperature Sensor, Product datasheet, Sensirion, September 2008.
- [5] N. Bežanić, I. Popović, "Servisno-orijentisana senzorska mreža za praćenje parametara okoline," *Zbornik radova Telfor 2012*, Beograd, novembar 2012, DOI:10.1109/TELFOR.2012.6419515, pp. 1544-1547.

- [6] B. Stallard, J. Taylor, "Quantifying Multivariate Classification Performance – The Problem Of Overfitting," *CD Proceedings, SPIE Annual Conference*, Denver, 1999.
- [7] N. Bežanić, I. Popović, I. Radovanović, "Implementacija servisno orijentisane arhitekture u reži pametnih pretvarača," *YU INFO 2012*, Kopaonik, mart 2012, pp. 544-548.
- [8] I. Popović, N. Rajović, "Design of IEEE 1451 Smart Transducer Communication module for Embedded Application," *5th ECCSC*, ISBN 978-1-61284-400-8, Belgrade, November 2010, pp. 236 – 239.
- [9] E. Batista, L. Gonda, A. da Silva, S. Rossi, M. Pereira, A. de Carvalho, C. Cugnasca, "HW/SW for an intelligent transducer network based on IEEE 1451 standard," *Computer Standards & Interfaces*, Januar 2012, vol. 34-1, pp. 1-13.
- [10] E. Song, K. Lee, "Smart Transducer Web Services Based on the IEEE 1451.0 Standard," *IEEE Instrumentation and Measurement Technology Conference (I2MTC)*, 2007.

ABSTRACT

In this paper a feedforward neural network for one-hour ahead air temperature prediction has been presented. The prediction is based on the temperature and the relative humidity measurements for the previous six hours. The neural network has been implemented as a virtual transducer in the service-oriented architecture in the smart transducers network. It is trained on the part of the database marked as a training set. The database consists of temperature and relative humidity measurements which have been carried out for a period of 3 days and 6 hours in Belgrade. After each iteration during training where the entire training set was presented to the neural network, the network accuracy is verified on a separate verification set. When the desired accuracy on both the training and the verification sets was met, the neural network is tested on a separate testing set.

NEURAL NETWORK FOR AIR TEMPERATURE PREDICTION AS A PART OF SERVICE-ORIENTED NETWORK OF SMART TRANSDUCER
Goran Ferenc, Ivan Popović, Nikola Bežanić