

# PREDVIĐANJE POTROŠNJE TOPLOTE U UNIVERZITETSKOM KAMPUSU KORIŠĆENJEM NEURONSKE MREŽE

## PREDICTION OF HEATING ENERGY CONSUMPTION IN UNIVERSITY BUILDINGS BASED ON ARTIFICIAL NEURAL NETWORKS

Radiša JOVANOVIĆ,  
rjovanovic@mas.bg.ac.rs,  
Aleksandra SRETENOVIĆ,  
asretenovic@mas.bg.ac.rs,  
Branislav ŽIVKOVIĆ,  
Univerzitet u Beogradu, Mašinski fakultet,  
bzivkovic@mas.bg.ac.rs

*Tema ovog rada je predviđanje potrošnje toplote korišćenjem pojednostavljenih neuronskih mreža. Za obučavanje i testiranje mreže korišćene su dnevne potrošnje toplote u univerzitetskom kampusu NTNU Gløshaugen, kao i srednje dnevne spoljne temperature. Za obučavanje mreže korišćen je Levenberg–Marquardt (LM) feedforward backpropagation algoritam (algoritam sa povratnim prostiranjem greške). Različiti pokazatelji kvaliteta predviđanja su izračunati i prikazani za obučavanje i testiranje mreže. Pokazuje se da pojednostavljen model može da predviđa potrošnju toplote sa zadovoljavajuće visokom tačnošću. Kreiranje ovakvih modela je korisno s aspekta energetskog planiranja izgradnje; pruža informacije o verovatnoj potrošnji toplote za slične zgrade, ili predviđa potrošnju pri različitim vremenskim uslovima.*

**Ključne reči:** predviđanje potrošnje toplote; neuronske mreže;

*In this paper, the main objective is to predict heating energy consumption using a simple artificial neural network. For training and testing the network daily consumption for NTNU University campus Gløshaugen and mean outside temperatures were used. Training of the network was performed by using Levenberg–Marquardt (LM) feedforward backpropagation algorithm. Different indices of the prediction accuracy were calculated for training and testing. Simplified model showed that it can predict heating consumption with adequate accuracy. Creating a model of energy use helps in future building planning; it can provide useful information about most probable energy consumption for similar buildings, or predict energy use in different conditions.*

**Keywords:** heating energy consumption, prediction; artificial neural network;

### I. Uvod

Analiziranje potrošnje energije zgrada je tema od izuzetnog značaja, uzimajući u obzir veliki porast interesovanja za održivost energije i energetsku efikasnost, o kojoj se sve više govori nakon usvajanja evropske direktive EPBD [1]. U Evropi, na zgrade odlazi oko 40% ukupne potrošnje energije, kao i 36% ukupne emisije CO<sub>2</sub> [2]. Univerzitetski kampusi predstavljaju specifičnu grupu raznorodnih zgrada, sa značajnom potrošnjom energije. Oni se sastoje iz mnogo različitih zgrada, i na neki način predstavljaju mali grad za sebe. Upravo zbog toga su izabrani kao odličan primer, na kom se može analizirati i bolje razumeti potrošnja energije grupe zgrada različitih namena. Naučnici i inženjeri se u poslednje vreme sve više okreću ka analizi stvarne potrošnje energije u zgradama. Jedan od razloga za to je da nekalibrirani modeli ne mogu dovoljno dobro da predvide potrošnje energije, pa se javlja potreba za stvarnom slikom potrošnje (korišćenjem merenih i analiziranih vrednosti).

U ovom radu prikazano je predviđanje potrošnje toplote u univerzitetskom kampusu. Mereni ulazni i izlazni podaci koji utiču na potrošnju toplote su korišćeni za obučavanje, validaciju i testiranje mreže.

## II. Statističke metode za predviđanje potrošnje energije

Klasičan pristup proceni potrošnje energije u zgradi se zasniva na korišćenju modela poznate strukture i osobina, kao i sa poznatim promenjivim veličinama („unapred“, „forward“). Takav pristup zahteva detaljno poznavanje karakteristika sistema i elemenata zgrade [2].

Drugačiji pristup analizi potrošnje u zgrada je inverzno modeliranje („unazad“, „inverse“, „data-driven“) zasnovano na merenim vrednostima [2]. Inverznim modeliranjem analizira se merena potrošnja energije i traže se odnosi sa jednom ili više promenljivih. Kako bi se napravio inverzan model, neophodno je matematički opisati objekat, a zatim odrediti parametre od važnosti koristeći statističku analizu. Ulazne i izlazne veličine su poznate i merene, a cilj je odrediti matematičke relacije između nezavisno i zavisno promenljivih. Nasuprot pristupu „unapred“, pristup „unazad“ („data-driven“) je koristan kada je zgrada (ili sistem) već izgrađen, (tj. zgrada je već u upotrebi) i stvarni podaci su mereni i dostupni za izradu modela. Jedan od najznačajnih postulata energetske efikasnosti je racionalno upravljanje energijom i njeno praćenje. Praćenje potrošnje energije je tehnika koja se zasniva na aksiomu da „nije moguće unaprediti nešto što se ne meri“, čime se ističe značaj merenja. Isto tako, veoma je važno odgovoriti na pitanja koje parametre treba posmatrati, izabrati odgovarajuću učestanost merenja (na godišnjem, mesečnom, dnevnom, časovnom ili petominutnom nivou). Ključno je odrediti glavne uticajne faktore, kako bi se smanjio broj parametara koji se prati. Kako bi se sprovela adekvatna analiza potrošnje energije u zgradi, neophodno je formirati odgovarajući bazu podataka.

## III. Veštačke neuronske mreže

Veštačke neuronske mreže (Artificial neural networks, ANN) se primenjuju u raznim oblastima inženjerstva, kao što su industrijski procesi, obrada digitalnih signala, elektronika, robotika, prepoznavanje govora, proizvodnja, automatsko upravljanje, medicinsko inženjerstvo, kao i modeliranje potrošnje energije [4]. Neke od primena neuronskih mreža su u klasifikaciji [5], aproksimaciji funkcija, optimizaciji, predviđanju i automatskom upravljanju [6]. Glavna prednost modela sa neuronskom mrežom je sposobnost „učenja“, kao i mogućnost aproksimacije nelinearnih veza između ulaznih i izlaznih parametara u veoma složenim sistemima. U većem broju studija se pokazalo modeli za predviđanje potrošnje energije zasnovani na neuronskim mrežama mogu biti veoma precizni [7,8]. Neuronske mreže predstavljaju računarsku strukturu inspirisanu biološkim neuronskim sistemom, koji se sastoji iz velikog broja veoma jednostavnih i međusobno povezanih procesora koji se zovu neuroni. Uglavnom se sastoje iz ulaznog sloja, izlaznog sloja i jednog ili više skrivenih slojeva. Izlaz iz određenog neurona je funkcija ulaznih parametara, težinskih koeficijenata, praga osetljivosti neurona i aktivacione funkcije. Na Slici 1 prikazan je osnovni model veštačkog neurona. U svom najjednostavnijem obliku svaki pojedinačni neuron je povezan sa neuronima iz prethodnog sloja pomoću adaptibilnih sinaptičkih težina. Izlaz svakog neurona je određen sa:

$$y_i = f(v_i), \quad v_i = \sum_{j=1}^n w_{ij}x_j + b_i \quad (1)$$

gde su  $x_1, x_2, \dots, x_n$  ulazni signali,  $w_{i1}, w_{i2}, \dots, w_{in}$  su sinaptičke težine  $i$ -tog neurona,  $b_i$  je prag osetljivosti (bias),  $v_i$  je aktivaciona vrednost  $i$ -tog neurona,  $f$  je aktivaciona funkcija i  $y_i$  je izlazni signal neurona.

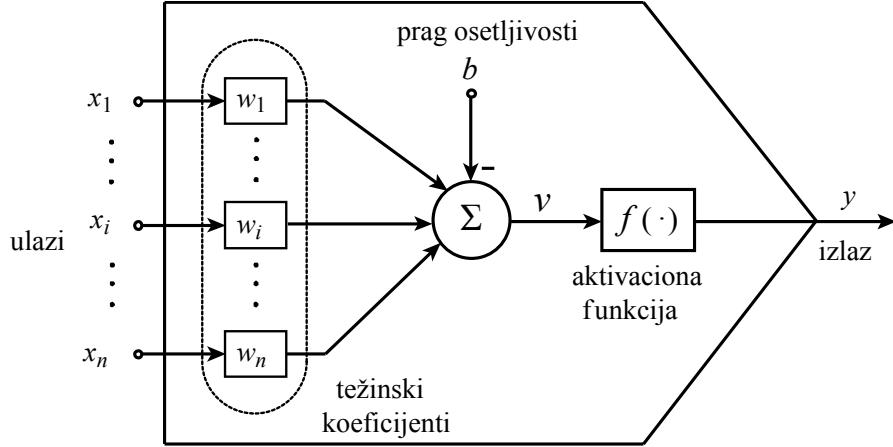
Svaki neuron prima ulazne signale od drugih neurona ili iz spoljašnjeg okruženja, lokalno ih obrađuje koristeći aktivacionu funkciju i generiše transformisani izlazni signal koji se vodi na druge neurone ili pak u spoljašnju okolinu. Nelinearna aktivaciona funkcija u skrivenom sloju neurona omogućava da neuronska mreža bude univerzalni aproksimator. Iako svaki pojedinačni neuron ostvaruje svoju funkciju relativno sporo i ne potpuno tačno, zajednički, mreža može da izvrši iznenađujuće veliki broj zadataka sa zadovoljavajućom efikasnošću. Ovaj način obrade podataka čini neuronsku mrežu moćnom alatkom, koja može da uči na osnovu uzorka, a zatim uopštava zaključke na nove, pre toga nepoznate uzorke.

Proces obučavanja neuronske mreže se sastoji u modifikaciji težinskih koeficijenata sve dok vrednost izlaza mreže ne postane dovoljno blizak stvarnoj, željenoj vrednosti. Definisane veze između ulaznog, skrivenog i izlaznog sloja određuju tip modela neuronske mreže. U praktičnim primenama najviše se koriste mreže bez povratnih veza, kompetitivne mreže i rekurentne asocijativne memorije. U ovom radu razmatra se višeslojna mreža bez povratnih veza (feedforward mreža), sa metodom obučavanja sa povratnim prostiranjem greške (backpropagation algoritam). Kod višeslojne neuronske mreže neuroni su organizovani u slojevima bez povratnih ili lateralnih veza. Backpropagation algoritam predstavlja iterativnu metodu obučavanja sa nadzorom namenjenu za višeslojne feedforward mreže sa diferencijalnom nelinearnom

aktivacionom funkcijom, a koja minimizira kvadrat greške izlaza mreže, to jest, kvadrat razlike između željenih i stvarnih izlaza mreže. Funkcija greške koju backpropagation algoritam minimizira može se izraziti kao:

$$E = \frac{1}{2} \sum_j \sum_k (y_{jk} - \hat{y}_{jk})^2, \quad (2)$$

gde je  $j$  index uzorka,  $k$  je indeks elemenata u vektoru izlaza mreže,  $y_k$  je  $k$ -ti element  $j$ -tog željenog vektora uzorka,  $\hat{y}_k$  je  $k$ -ti element vektora izlaza koji se dobija kada se uzorak  $j$  dovede na ulaz mreže.



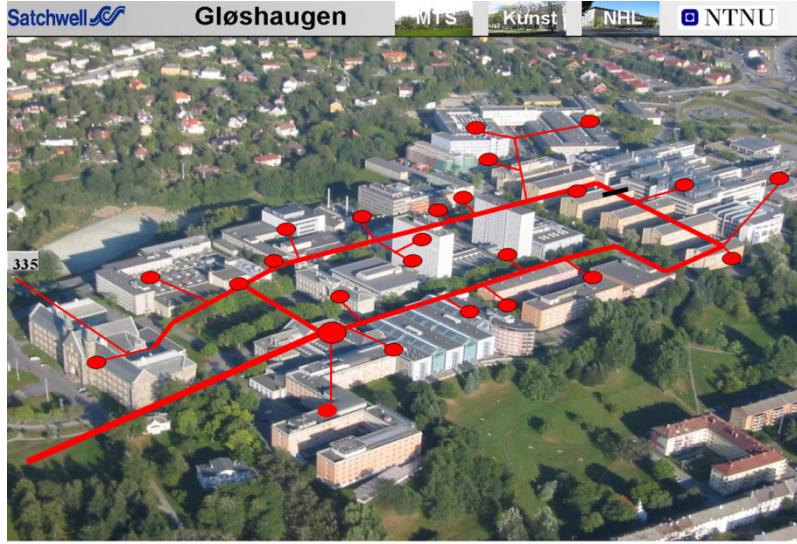
Slika 1: Model neurona

Jedinstvena prednost primene neuronskih mreža je to što nije potrebno definisati jasnu vezu između ulaznih i izlaznih parametara pre korišćenja modela za proces predviđanja, pošto se veze između parametara određuju tokom procesa učenja. Zbog ove značajne osobine neuronskih mreža, vreme i trud uobičajeno neophodni za kreiranje odgovarajućeg matematičkog modela primenom konvencionalnih metoda, mogu biti značajno smanjeni, [9].

#### IV. Primer primene neuronskih mreža u predviđanju potrošnje

U ovom radu analizirana je potrošnja toplote u univerzitetском kampusu Gløshaugen Norveškog Univerziteta za Nauku i Tehnologiju (Norwegian University of Science and Technology (NTNU)). Kampus, koji je prikazan na slici 2, se sastoji iz 35 zgrada, ukupne površine oko  $300.000 \text{ m}^2$ . U zavisnosti od namene, tipovi zgrada su: kancelarije, učionice, laboratorije, radne prostorije i sportske zgrade. Ukupna potrošnja toplote za 2012 godinu iznosila je 27.853 MWh, dok je potrošnja električne energije bila 62.405 MWh. Sistem za kontrolu i praćenje sistema (Building and Energy Management System (BEMS)), kao i sistem za praćenje potrošnje energije (Energy Monitoring System (Energy Remote Monitoring – ERM)) su dostupni na NTNU [10]. U kampusu su instalirana 46 merača toplote i 79 merača električne energije. Časovne vrednosti potrošnje električne energije i toplote su dostupne i mogu se naći na sajtu, koji je povezan sa ERM. Sistem daljinskog grejanja u kampusu je organizovan u obliku prstena, dok se glavni merač nalazi u Staroj zgradi elektrotehnike. (Slika 2). Glavni merač je instaliran od strane snabdevača daljinskog grejanja, pa je on uzet kao relevantan merač potrošnje toplote.

Ulagani parametri za neuronsku mrežu su: srednja dnevna temperatura, parametar koji pokazuje dan u nedelji (za radni dan 1, za vikend i praznike 2), i mesec u godini. Model predstavljen u ovom radu je pojednostavljen, pri čemu ne uzima u obzir druge meteorološke parametre (brzinu vetra, sunčevu zračenje, i dr.). Glavni parametar potrošnje je svakako spoljašnja temperatura, ali u daljim radovima se može analizirati i uticaj ostalih meteoroloških karakteristika. Ulagani parametri za tip dana i mesec u godini su kodirani, pri čemu se koriste vrednosti 1 ili 2, i brojevi 1 do 12, respektivno. Topologija mreže je prikazana na Slici 3, a broj neurona u skrivenom sloju će biti variran tokom obučavanja mreže. U radu [11] slična analiza je urađena, koristeći za kodiranje dana brojeve 1 do 7 (ponedeljak do nedelje). Rezultati pokazuju da pojednostavljenje koje je uvedeno u ovom radu, ne utiče u značajnoj meri na kvalitet predviđanja.

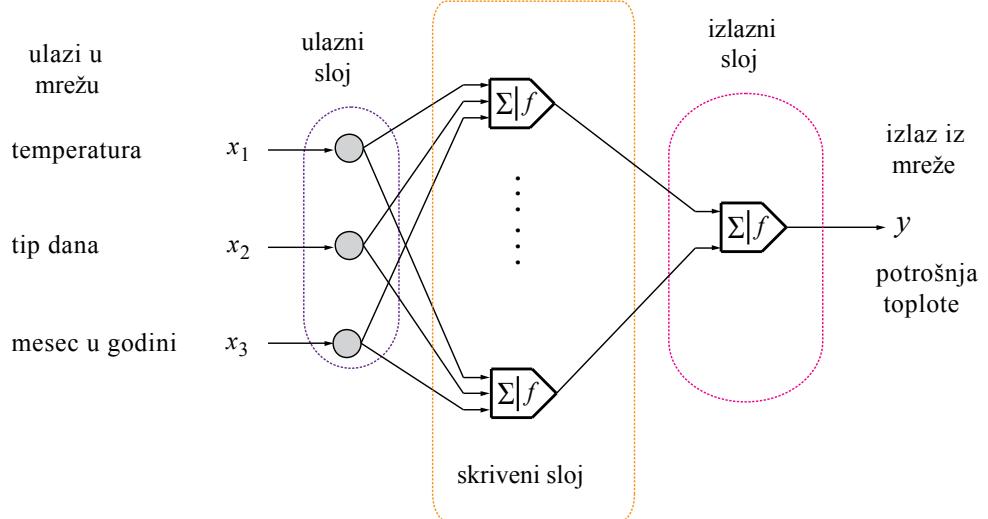


Slika 2: Mreža daljinskog grejanja u univerzitetskom kampusu NTNU Gløshaugen

Kako bi se elimisala mogućnost da zbog reda veličine neki faktor bude značajno dominantniji u odnosu na drugi, svi ulazni i izlazni parametri su normalizovani u intervalu (0,1), primenom linearne funkcije za skaliranje:

$$x'_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}, \quad i = 1, \dots, N \quad (3)$$

gde su  $x_{\max}$  i  $x_{\min}$  očekivani minimum i maksimum posmatrane promenljive, a  $N$  broj prikupljenih uzoraka za posmatranu promenljivu. Kreirana su dva seta podataka: podaci o dnevnoj potrošnji topline za godine 2008 i 2009 su korišćeni za obučavanje neuronske mreže, a podaci za 2010. godinu za testiranje.



Slika 3: Topologija mreže

## V. Rezultati i diskusija

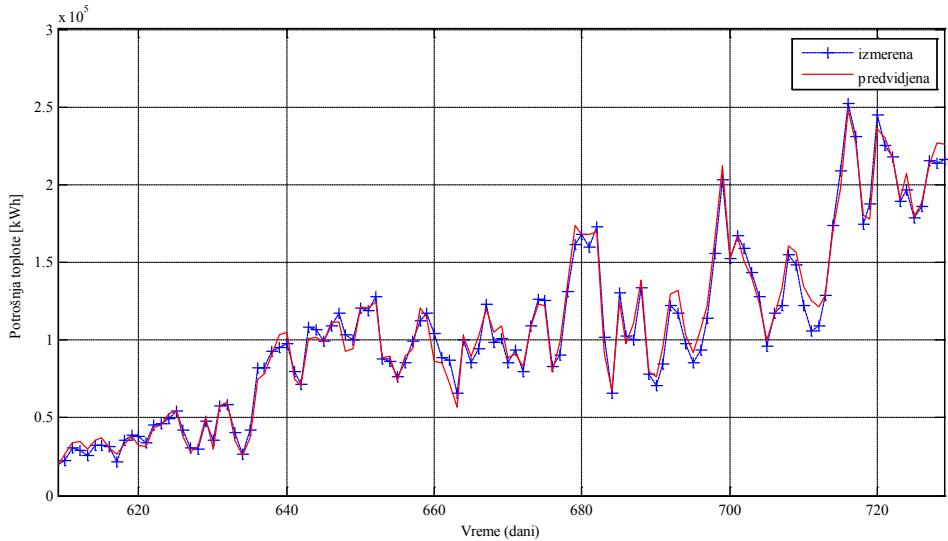
Model korišćen u ovom radu je troslojna mreža sa povratnim prostiranjem greške, koja se sastoji iz jednog ulaznog, jednog izlaznog i jednog skrivenog sloja. Ova mreža je izabrana jer se pokazalo da takva struktura mreže može aproksimirati gotovo svaku potrebnu funkciju [12]. Ulazni sloj se sastoji iz 3 neurona koji predstavljaju 3 različita ulaza u mrežu. Izlazni sloj se sastoji iz jednog neurona, čiji je izlaz predviđena potrošnja topline. U ovom modelu korišćen je Levenberg–Marquardt (LM) algoritam učenja, koji predstavlja varijantu algoritma sa povratnim prostiranjem greške. U izlaznom i skrivenom sloju korišćene su sigmoidalna (logsig) i linearna (purelin) aktivaciona funkcija, respektivno. Matlab/Neural Network Toolbox se koristi za kreiranje, konfigurisanje i obučavanje neronske mreže za predviđanje potrošnje topline. Tokom obučavanja mreže variran je broj neurona u skrivenom sloju, a najbolji rezultati su dobijeni sa 7 neurona.

Za određivanje tačnosti predviđanja koriste se koeficijent determinacije ( $R^2$ ), koren srednje vrednosti kvadratne greške (RMSE), kao i koeficijent varijacije (CV) i srednja apsolutna procentualna greška (MAPE) korišćeni u ASHRAE kontekstu [13], i definisani sa:

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2}, \quad CV = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - \hat{y}_k)^2} / \bar{y} \quad (4)$$

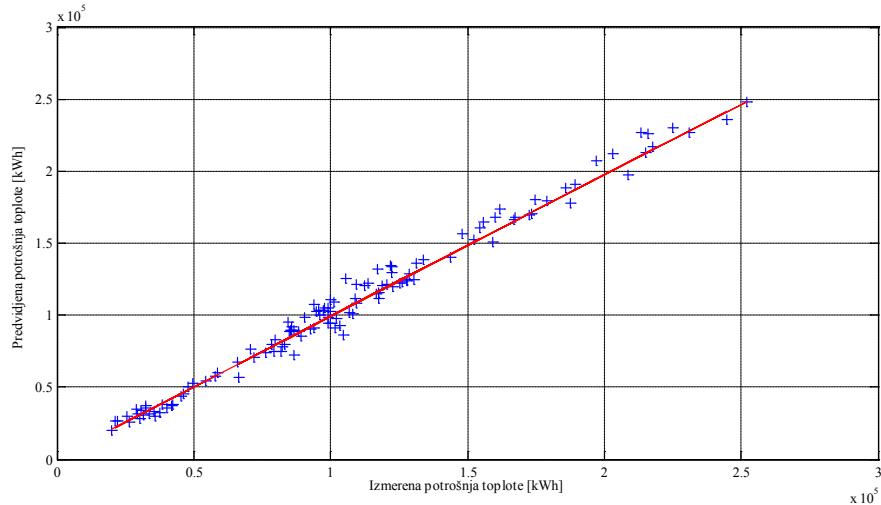
$$MAPE = \frac{1}{N} \sqrt{\sum_{k=1}^N \frac{|y_k - \hat{y}_k|}{y_k}} \cdot 100, \quad (5)$$

gde su  $y_k$  i  $\hat{y}_k$  željena i stvarna vrednost izlaza za  $k$ -ti uzorak,  $\bar{y}$  je srednja vrednost od  $y$  i  $N$  je ukupan broj uzoraka.

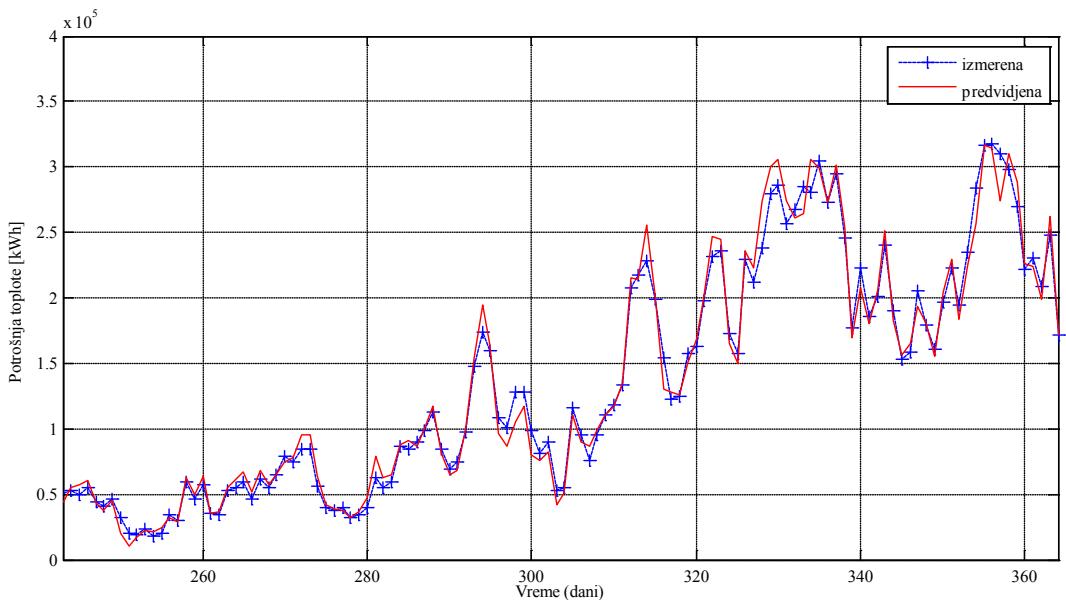


Slika 3. Merene i predviđene vrednosti za period septembar-decembar 2009: rezultati obučavanja

Na Slici 3 su prikazane vrednosti za stvarnu potrošnju topline (izmerenu na glavnom meraču) i predviđenu potrošnju, za period od septembra do decembra 2009. godine. Prikazan je deo podataka koji su korišćeni za obučavanje mreže. Na Slici 4 su prikazani rezultati obučavanja neuronske mreže (crvena linija predstavlja idealno poklapanje).

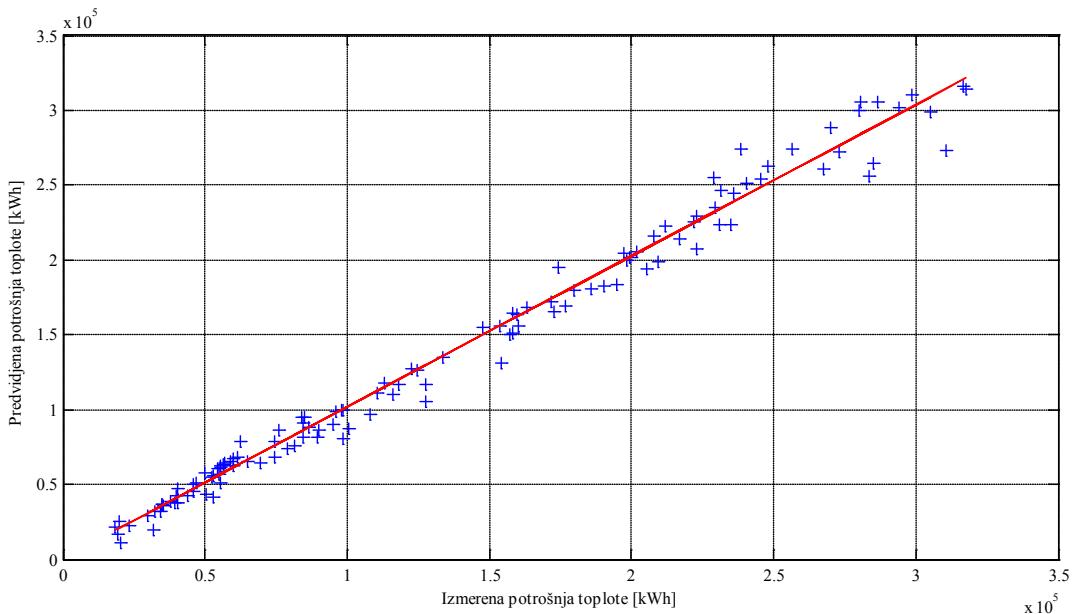


Slika 4: Rezultati obučavanja neuronske mreže



Slika 5: Merene i predviđene vrednosti za period septembar-decembar 2010: rezultati testiranja

Na Slici 5 su prikazane vrednosti za stvarnu potrošnju toplove (izmerenu na glavnom meraču) i predviđenu potrošnju, za period od septembra do decembra 2010. godine (deo podataka koji su korišćeni za testiranje mreže. Na Slici 6 su prikazani rezultati testiranja neuronske mreže (crvena linija predstavlja idealno poklapanje).



Slika 6: Rezultati testiranja neuronske mreže

Rezultati pokazuju da je neuronska mreža u stanju da predviđa potrošnju toplove sa velikom tačnošću, iako je raspon potrošnje izuzetno velik (dnevna potrošnja toplove varira između 100 kWh i 320.000 kWh). Pokazateli tačnosti predviđanja, određeni jednačinama (4) i (5) prikazani su u Tabeli 1.

Tabela 1. Poređenje pokazatelja kvaliteta predviđanja za obučavanje i testiranje mreže

Godina/period	R <sup>2</sup> [-]	RMSE [kWh]	CV [-]	MAPE [-]
2008-2009; obučavanje	0,9840	7,908	0,0886	10,92
2010; testiranje	0,9864	10,154	0,0926	11,17

## VI. Zaključak

U ovom radu primenjena je pojednostavljena neuronska mreža za predviđanje potrošnje toplote univerzitetskog kampusa NTNU Gløshaugen. Mreža je obučavana sa dnevnim podacima iz 2008 i 2009 godine, a testirana na podacima iz 2010. Na osnovu pokazatelja kvaliteta predviđanja, može se zaključiti da je primena neuronskih mreža veoma efikasan metod za ovakva predviđanja. Jednom napravljen dovoljno tačan model dalje može koristiti inženjerima za predviđanje i određivanje potrošnje toplote, a da pri tome oni ne moraju detaljno da poznaju neuronske mreže, pri čemu im je neophodan minimum ulaznih podataka (srednja dnevna temperatura). Dobijeni rezultati pokazuju da se metoda predviđanja pomoću neuronskih mreža može posmatrati kao alternativna i praktična tehnika za predviđanje potrošnje. Dalje analize se mogu odnositi na uticaj različitog broja skrivenih slojeva, kao i uvođenje dodatnih meteoroloških parametara i drugih ulaznih veličina.

### NAPOMENA

Podaci korišćeni u ovom radu su sakupljeni tokom studijskog boravka na NTNU, kao deo kolaborativnog projekta “Sustainable Energy and Environment in Western Balkans”. Projekat je finansiran od strane Norwegian Programme in Higher Education, Research and Development in the Western Balkans, Programme 3: Energy Sector (HERD Energy) za period 2011-2013.

## VII. Literatura

- [1] \*\*\*, *Commission, E., Directive 2002/91/EC of the European Parliament and of the Council of 16 December 2002 on the energy performance of buildings*. Official Journal of the European Communities, 2002. 4(2003): p. L1.
- [2] **Zhao H.-X., F. Magoules**, A review on the prediction of building energy consumption, *Renewable and Sustainable Energy Reviews* 16, pp. 3586-3592, 2012.
- [3] **Eskin N.**, Analysis of annual energy requirements of nonresidential buildings, *14<sup>th</sup> International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology"*, TMT 2010, Mediterranean Cruise, 2010.
- [4] **Karatasou S., M. Santamouris, V. Geros**, Modeling and predicting building's energy use with artificial neural networks: Methods and results, *Energy and Buildings* 38, pp. 949-958, 2006.
- [5] **Bishop C. M.**, *Neural Networks for Pattern Recognition*, Oxford University Press, 1996.
- [6] **Pham D.T., Liu X.**, *Neural Networks for Identification, Prediction and Control*, Springer-Verlag, London, 1995.
- [7] **Anstett M., J. F. Kreider**, Application of neural networking models to predict energy use, *ASHRAE Transactions* 99 (1), pp. 505–517, 1993.
- [8] **Dombayci, Ö. A.**, The prediction of heating energy consumption in a model house by using artificial neural networks in Denizli-Turkey. *Advances in Engineering Software*, 41(2), pp. 141-147, 2010.
- [9] **Yang, J., H. Rivard, R. Zmeureanu**, On-line building energy prediction using adaptive artificial neural networks. *Energy and buildings*, 37(12), pp. 1250-1259, 2005.
- [10] **Sretenovic A.**, *Analysis of energy use at University*, M. Sc. thesis, NTNU, Norway, 2013.
- [11] **Jovanović R., A. Sretenović, B. Živković**, Prediction Of Heating Energy Consumption In University Buildings Based On Simplified Artificial Neural Networks, *Proceedings: 18th International Research/Expert Conference "Trends in the Development of Machinery and Associated Technology"* TMT 2014, Budapest, Hungary, 10-12 September, 2014.
- [12] **Irie B., S. Miyaki**, Capabilities of three layer perceptrons, *Proceedings of the IEEE , Second International Conference on Neural Networks*, San Diego, CA, 1988.
- [13] **Kreider J.F., J. S. Haberl**, Predicting hourly building energy use: the great energy predictor shootout - overview and discussion of results, *ASHRAE Transactions* 100 (2), pp. 1104–1118, 1994.