

KRATKOROČNO PROGNOZIRANJE OPTEREĆENJA PRIMJENOM MODELA UMJETNE NEURONSKE MREŽE SHORT-TERM LOAD FORECASTING BY USING THE ARTIFICIAL NEURAL NETWORK MODEL


Krešimir Tačković – Srete Nikolovski, Osijek, Hrvatska
Vedran Boras, Split, Hrvatska

U članku je opisan model za kratkoročnu prognozu opterećenja primjenom umjetne neuronske mreže i njegova primjena na predviđanje opterećenja jednog konkretnog distribucijskog područja. Umjetne neuronske mreže koriste se najčešće za rješavanje problema klasifikacije i predviđanja kada su odnosi između ulaznih i izlaznih varijabli vrlo složeni i egzaktno teško opisivi. S obzirom na stohastičku prirodu i veliki utjecaj vremenskih prilika (temperatura, vlažnost, vjetar i dr.) na potrošnju električne energije, primjena umjetnih neuronskih mreža prikladna je za kratkoročno predviđanje opterećenja elektroenergetskog sustava. U članku su opisani korišteni modeli umjetnih neuronskih mreža za sezonsku i višestruku dnevnu prognozu opterećenja, te su prikazani rezultati predviđanja opterećenja jednog distribucijskog područja napajano preko sabirnica transformatorske stanice 110/x u HEP Operator distribucijskog sustava Elektroslavonija (HEP ODS).

The article describes a model for short-term load forecasting by using the artificial neural network, and its application to load forecasting for a concrete distribution area. The artificial neural networks are mostly used in solving the problems of classification and prediction when the relations between input and output variables are highly complex and hard to describe exactly. Considering the stochastic nature and the major impact of weather conditions (temperature, humidity, wind, etc.) on electricity consumption, the application of artificial neural networks is suitable for short-term forecasting the load of an electric power system (EPS). Furthermore, the article describes the used models of artificial neural networks for seasonal and multiple daily load forecasts and presents the load forecast results for a distribution area supplied over the busbars of the 110/x substation at the HEP Elektroslavonija Distribution System Operator (HEP ODS).

ključne riječi: kratkoročna prognozira opterećenja; modeli prognoziranja; umjetne neuronske mreže

Keywords: artificial neural networks; forecast models; short-term load forecast



1 UVOD

Prognoziranje opterećenja u elektroenergetskom sustavu jedna je od vrlo značajnih i bitnih aktivnosti. Potreba za točnim prognoziranjem opterećenja dolazi iz prirode električne energije koja se ne može pohraniti, a koja se u novije vrijeme na tržištu počinje trenirati kao i svaki drugi proizvod. Za predviđanje opterećenja potrebna je procjena buduće potrošnje, kako prilikom planiranja proizvodnje, tako i prilikom kupovine uz uvažavanje ekonomskih i drugih kriterija.

Početna aktivnost u prognoziranju opterećenja je planiranje razvoja potrošnje električne energije. To je potrebno učiniti radi planiranja razvoja proizvodnih i prijenosnih kapaciteta. Poznavanjem tih podataka može se ići i korak dalje, sve do planiranja i razvoja svih ostalih dijelova elektroenergetskog sustava.

Osnovne veličine s kojima se susreću prognozeri, a koje se trebaju uvažiti i riješiti, su:

- prognoza potrošnje električne energije,
- prognoza vršnih (maksimalnih) snaga, kao i
- prognoza krivulje trajanja opterećenja.

U novije vrijeme za rješavanje ovih problema pojavio se novi pristup temeljen na primjeni tehnika umjetne inteligencije za simboličku analizu obrade podataka

Tim modelima obrađuje se velik broj podataka puno brže, a rezultati su točniji i precizniji nego pri korištenju klasičnih metoda, prema [1]. Različiti modeli opterećenja mogu se riješiti različitim tehnikama predviđanja opterećenja.

Temeljni cilj kratkoročnog prognoziranja opterećenja je:

- da osigura predviđanje opterećenja za funkcije planiranja temeljne proizvodnje,
- za procjenu sigurnosti djelovanja elektroenergetskog sustava i
- za povremene informacije dispečerima.

Poznato je da kratkoročno prognoziranje igra važnu ulogu u tradicionalnim monopolističkim elektroenergetskim sustavima.

Postoje dvije različite kategorije prognoziranja opterećenja, a one su:

- prognoziranje opterećenja radi planiranja elektroenergetskog sustava i
- prognoziranje opterećenja radi vođenja elektroenergetskog sustava.

1 INTRODUCTION

Load forecasting in an EPS is one of very important and crucial activities. A need for accurate load forecasts stems from the very nature of electric power which cannot be stored, but which is recently treated on the market like any other product. Load forecasting requires an assessment of future consumption, in both the planning of generation facilities and the purchasing of electricity, with economic and other criteria to be taken into consideration.

The initial activity in load forecasting consists in planning the progress of electricity consumption. This should be done as a prerequisite for planning the development of generation and transmission facilities. Knowing this information may enable us to take the next step towards the planning and developing of all the rest of the parts of the EPS.

The basic quantities encountered by the forecasters that must be heeded and solved are:

- electricity consumption forecast,
- peak (maximum) power forecast, and
- load duration curve forecast.

In addressing these problems, a new approach has emerged recently, one based on the application of artificial intelligence techniques for a symbolic analysis of data processing.

By means of these models a great number of data is processed much faster and the results are more accurate and precise than is the case with the use of classical methods, according to [1]. Various load models can be addressed by means of various load forecasting techniques.

The main goal of short-term load forecasting is to:

- ensure load forecasts for the functions of planning the basic generation,
- assess the operating safety of an electric power system, and
- provide occasional information to dispatchers.

It is well known that the short-term forecasting plays a major role in the traditional monopolistic electric power systems.

There are two different load forecasting categories:

- load forecasting for EPS planning, and
- load forecasting for EPS management.

Pri izradi modela kojim bi se kratkoročno prognoziralo opterećenje, moraju se uvažiti zahtjevi koji se pred njega postavljaju. U ovom radu istraživana je model kratkoročnog prognoziranja opterećenja, zasnovan na utjecaju vremenskih i meteoroloških faktora.

2 KRATKOROČNO PROGNOZIRANJE OPTEREĆENJA

Kratkoročno prognoziranje opterećenja poglavito dobiva sve veću važnost porastom konkurencije na tržištu električne energije. Prognoze opterećenja dobivaju značajnu ulogu u oblikovanju cijena (u budućem privatiziranom i dereguliranom tržištu), te postaju od vitalnog značenja za opskrbu potrošača [2].

Prognoziranje opterećenja je međutim vrlo težak zadatak. Prvo radi toga jer su podaci o opterećenju kompleksni i razlikuju se za različita godišnja doba. Opterećenje u danom satu nije ovisno samo o opterećenju prethodnog sata, nego i o opterećenju istog sata prethodnog dana, kao i o opterećenju istog sata pojedinog dana iz prethodnog tjedna. Drugo, budući da postoje mnoge značajne uzročne varijable koje se moraju razmotriti, potrebno je istaknuti varijable koje su povezane s vremenom.

Vremenska analiza vrlo je efikasna metoda za kreiranje matematičkog modela kojim se može riješiti široki spektar kompleksnih problema. Ti modeli koriste se za prepoznavanje ili predviđanje karakteristika fenomena predstavljenog pomoću niza promatranja. Međutim, izrada jednog preciznog modela vremenske analize koji predstavlja nelinearne procese ili procese koji imaju vrlo široka odstupanja vrlo je teška.

Umjetne neuronske mreže uspješno se koriste za rješavanje širokih odstupanja unutar razmatranih podataka kod zahtijevanih linearnih ili nelinearnih procesa. Uspješnost aplikacije umjetne neuronske mreže leži u činjenici da su te mreže pravilno trenirane i dobro konfigurirane, te omogućuju dobru aproksimaciju bilo koje mjerene vrijednosti.

Neuroni uče obrasce skrivene u podacima i čine poopćenje tih obrazaca bilo prisustvom šuma ili pri mogućem izostanku pojedinih mjerenja. Predviđanja se obavljaju na promatranim mjerenim vrijednostima s umjetnim neuronskim mrežama. Jedan primjer predviđanja problema vremenske analize koji se može riješiti s umjetnom neuronskom mrežom je predviđanje opterećenja. Precizne metode predviđanja opterećenja vode do porasta efikasnosti opskrbe kupaca električnom energijom. Nadalje, točna predviđanja mogu uštedjeti troškove opskrbljivača električnom energijom.

In preparing a model for short-term load forecasting, one must make allowance for the requirements set on the model. The present work explores a short-term load forecasting model based on the impact of weather and meteorological factors.

2 SHORT-TERM LOAD FORECASTING

Short-term load forecasting is gaining in importance with rising competition in electricity market. Load forecasts are assigned a significant pricing role (in the future privatized and deregulated market) and are becoming vital in terms of consumer supply [2].

Load forecasting, however, is not an easy job at all. First, because load data are highly complex and they differ from season to season. Load in a given hour depends not only on the load of the previous hour, but also on the load of the same hour of the day before, as well as the load of the same hour in a particular day of the previous week. Second, in view of the existence of many significant causal variables to be considered, it is necessary to single out the weather-related variables.

Weather analysis is a very efficient method for creating a mathematical model with which a broad spectrum of complex problems can be solved. These models are used for the identification or anticipation of the characteristics of a phenomenon presented through a series of observations. However, a precise weather analysis model representing nonlinear processes or processes with wide deviations is very hard to provide.

Artificial neural networks are successfully used in dealing with wide deviations within studied data when it comes to demanding linear and nonlinear processes. The success of the application of an artificial neural network lies in the fact that these networks are correctly trained and well configured and thus allow a good approximation of any measured value.

Neurons learn patterns hidden in data and generalize these patterns either through the presence of noise or the absence of some measurements. Forecasts are made on the observed measured values with artificial neural networks. An example of forecasting a weather analysis problem that can be solved by means of the artificial neural network is load forecasting. Precise load forecasting methods lead to greater efficiency in consumer electricity supply. Furthermore, accurate forecasts can save the costs of electricity suppliers.

3 OPIS MODELA NEURON-SKIH MREŽA

Danas je poznato da se ljudski mozak sastoji od velikog broja živčanih stanica (neurona), koji pri obradi različitih vrsta informacija rade paralelno. Neurofiziološka istraživanja daju naslutiti da je modelu mozga najbliži model u kojem brojni procesni elementi podatke obrađuju paralelno.

Umjetna neuronska mreža umjetna je replika ljudskog mozga kojom se nastoji simulirati postupak učenja. Analogija s pravim biološkim uzorom zapravo je dosta slaba, jer uz mnoga učinjena pojednostavljena postoje još mnogi fenomeni živčanog sustava koji nisu modelirani umjetnim neuronskim mrežama, kao što postoje i karakteristike mreža koje se ne slažu s onima bioloških sustava.

Neuronske mreže odlično rješavaju probleme klasifikacije i predviđanja, odnosno općenito sve probleme kod kojih postoji odnos između ulaznih i izlaznih varijabli, bez obzira na visoku složenost te veze (nelinearnost).

3.1 Biološki neuron

Za razumijevanje sposobnosti mozga nužno je upoznati građu njegovih sastavnih dijelova: neurona (živčane stanice). Četiri su osnovna dijelova neurona: tijelo stanice (soma), skup dendrita (ogranaka), aksona (dugačke cjevčice koja prenosi električne signale) i niza završnih članaka. Mali razmak između završetka aksona prethodnog neurona i dendrita ili tijela sljedećeg neurona naziva se sinapsa. Slika 1 prikazuje građu neurona.

3 THE NEURAL NETWORK MODEL


Today we know that the human brain consists of a vast number of nervous cells (neurons) which in the processing of various types of information operate in parallel. Neurophysiological investigations suggest that the model most similar to the model of the human brain is one in which numerous processing elements are handling data in parallel.

The artificial neural network is an artificial replica of the human brain with which it is attempted to simulate the learning process. Analogy with the real biological model is in fact quite weak, because with all the simplifications that have been made there are still many phenomena of the nervous system which are not modeled by the artificial neural networks, just as there are network features that do not match those of the biological systems.

The neural networks splendidly cope with the problems of classification and forecasting, generally, with all the problems in which a relationship between input and output variables is involved, irrespective of the high complexity of that link (nonlinearity).

3.1 The biological neuron

Understanding the brain's faculties requires a foreknowledge of its constituents: the neurons (nervous cells). A neuron consists of four basic parts: the cell body (soma), a set of dendrites (branches), axons (long cable-like projections conducting electrical impulses) and a series of extensions. A small junction between the ending of the axon of the preceding neuron and dendrite or the body of the next neuron is called synapse. The structure of neurons is shown in Figure 1.



Slika 1 — Građa neurona
Figure 1 — Neuron structure

Funkcionalnost biološkog neurona, prema [3] imitira McDulloch–Pitts-ov model umjetnog neurona. Model koristi sljedeću analogiju: signali su opisani numeričkim iznosom i na ulazu u neuron množe se težinskim faktorom koji opisuje jakost sinapse. Signali pomnoženi težinskim faktorima zatim se analogno sumiraju u tijelu stanice, a ako je dobiveni iznos iznad definirana praga, neuron daje izlazni signal.


3.2 Umjetni neuron

Umjetni neuron umjesto funkcije praga može imati i neku drugu funkciju, tzv. prijenosnu funkciju ili aktivacijsku funkciju. Općeniti model umjetnog neurona prikazuje slika 2.

The functionality of the biological neuron, according to [3] is imitated by the McCulloch-Pitts neural model. The model makes use of the following analogy: the signals are described by a numerical amount and at the entrance to the neuron are multiplied by the weight factor which describes the strength of the synapse. The signals multiplied by the weight factors are then analogously summed in the cell body and if the obtained amount is above the defined threshold, the neuron gives an output signal.

3.2 Artificial neuron

The artificial neuron can have a function other than the threshold function, the so-called transmission or activation function. The general artificial neuron model is shown in Figure 2.



Slika 2 — Umjetni neuron
Figure 2 — Artificial neuron

Ulazni signali, njih ukupno n , označavaju se sa x_1, x_2, \dots, x_n . Težine se označavaju sa w_1, w_2, \dots, w_n . Ulazni signali općenito su realni brojevi u intervalu $[-1, 1]$ ili $[0, 1]$. Težinska suma *net* dana je sa:

Input signals, totaling nn , are denoted x_1, x_2, \dots, x_n . The weights are denoted w_1, w_2, \dots, w_n . Input signals, generally, are real numbers on the interval $[-1, 1]$ or $[0, 1]$. The weight sum *net* is given by:

$$net = w_1x_1 + w_2x_2 + \dots + w_nx_n - \theta, \quad (1)$$

ali se zbog kompaktnosti često dogovorno uzima da je vrijednost praga $\theta = -\omega_0$, te se dodaje ulazni signal x_0 s fiksiranom vrijednošću 1, pa je jednostavniji izraz:

But for the sake of compactness it is often agreed that the threshold value is $\theta = -\omega_0$, and the input signal x_0 is added with the fixed value of 1, so we get the following simplified expression:

$$net = w_0x_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n = \sum_{i=0}^n w_i x_i, \quad (2)$$

dok je za izlaz y rezultat prijenosne funkcije primijenjen na izraz (2):

whereas for the output y the result of the transmission function applied to expression (2) is:

$$y = f\left(\sum_{i=1}^n w_i x_i\right) = f(\text{net}). \quad (3)$$

3.3 Aktivacijske funkcije

Model umjetnog neurona, prema slici 2, može se razmatrati prema ugrađenoj prijenosnoj funkciji. Izlaz iz sumatora povezuje se na ulaz aktivacijske funkcije, koja na svom izlazu producira izlaz umjetnog neurona.

Aktivacijske funkcije mogu biti linearne i nelinearne. Kod linearnih, izlaz sumatora množi se s nekim faktorom (pojačanjem) i tako dobiva izlaz neurona. Nelinearne aktivacijske funkcije mogu poprimiti različite oblike, ali se najčešće koriste: funkcije praga osjetljivosti, sigmoidalne, hiperbolične i harmoničke funkcije.

Pored mnogobrojnih prijenosnih funkcija za izradu modela kratkoročnog prognoziranja opterećenja izabrana je sigmoidalna funkcija (slika 3). Ova funkcija je odabrana budući da je derivabilna, što je bitna prednost pri postupku učenja umjetne neuronske mreže. Višeslojna neuronska mreža sa sigmoidalnom funkcijom kao prijenosnom funkcijom procesnih elemenata bit će u stanju predstaviti nelinearne odnose ulaznih i izlaznih podataka. Sigmoidalna funkcija je definirana kao:

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

gdje parametar a određuje nagib funkcije.


3.3 Activation functions

Artificial neural model, shown in Figure 2, can be studied according to the installed transmission function. The output from the summator is linked to the input of the activation function which at its output produces the output of the artificial neuron.

The activation functions can be linear and nonlinear. With the linear functions the summator output is multiplied with a certain factor (enhancement) and thus the neural output is obtained. The nonlinear activation functions may assume different shapes, but mostly used are: sensitivity threshold functions, sigmoidal, hyperbolic and harmonic functions.

Alongside many transmission functions for preparing short-term load forecasting models, the sigmoidal function (Figure 3) has been selected, because it is derivable, and that is a crucial advantage in the learning process of an artificial neural network. A multiple neural network with the sigmoidal function as the transmission function of processing elements will be able to present nonlinear relations of input and output data. The sigmoidal function is defined as:

where parametar a defines the gradient of the function.



Slika 3 — Aktivacijska sigmoidalna funkcija
Figure 3 — Sigmoidal activation function

U slučaju da se od neuronske mreže zahtijeva rad s podacima čije vrijednosti bilo na njezinom ulazu ili izlazu nisu u uobičajenom intervalu $[-1,1]$ najjednostavnije je rješenje provesti pred-procesiranje, odnosno post-procesiranje podataka.

If the neural network is expected to work with data the values of which are not within the usual interval $[-1,1]$ whether at its input or its output, the simplest solution is to undertake data pre-processing and data post-processing respectively.

3.4 Učenje mreže

Prije postupka obrade podataka umjetnu neuronsku mrežu je potrebno naučiti ili trenirati. Za razliku od konvencionalnih tehnika obrade podataka gdje je postupak obrade potrebno analitički razložiti na određeni broj algoritamskih koraka, kod neuronske mreže takav algoritam ne postoji. Znanje o obradi podataka pohranjeno je implicitno u težinama veza između neurona. Te se težine postupno prilagođavaju kroz postupak učenja neuronske mreže sve do trenutka kada je izlaz iz mreže, provjeren na skupu podataka za testiranje, zadovoljavajući.

Pod postupkom učenja kod neuronskih mreža podrazumijeva se iterativan postupak predočavanja ulaznih primjera i eventualno očekivana izlaza.

Ovisno o tome da li je u postupku učenja znan izlaz iz mreže, pa se pri učenju mreže koristi uz svaki ulazni primjer ili je točan izlaz nepoznat, razlikuju se dva načina učenja:

- učenje s učiteljem – gdje se učenje mreže provodi u obliku para (ulaz, izlaz),
- učenje bez učitelja – gdje mreža uči bez poznavanja izlaza.

Skup primjera za učenje često se dijeli na tri odvojena skupa:

- skup za učenje,
- skup za testiranje,
- skup za provjeru (validaciju).

Primjeri iz skupa za učenje služe za učenje u užem smislu, tj. za podešavanje težinskih faktora. Pomoću primjera iz skupa za testiranje tijekom učenja vrši se provjera rada mreže s trenutnim težinskim faktorima kako bi se postupak učenja zaustavio u trenutku degradacije performansi mreže. Umjetnu je neuronsku mrežu moguće pretrenirati, nakon određenog broja iteracija, te mreža gubi svojstvo generalizacije i postaje stručna za obradu podataka iz skupa primjera za učenje dok preostale podatke obrađuje loše. Točnost i preciznost obrade podataka moguće je na kraju provjeriti nad trećim skupom primjera, a to je skup za validaciju.

Kod učenja umjetne neuronske mreže postoji još i iteracija koja kazuje korak u algoritmu postupka za učenje u kojem se odvija podešavanje težinskih faktora. Epoha predstavlja jedan cjelokupni skup za učenje.

Pregled funkcija za provedbu treniranja iz Matlab-ovih alata, prema [4] dan je u tablici 1.

3.4 The network's learning

Prior to data processing, the artificial neural network must be taught and trained. Unlike the conventional data processing techniques where the processing procedure should be analytically broken down into a certain number of algorithmic steps, with the neural network there is no such algorithm. The knowledge about data processing is implicitly stored in the weights of interneural links. These weights are gradually adapted through the learning process of the neural network up to the moment when the network output, validated on the set of test data, is satisfactory.

Meant by the learning process when it comes to the neural networks is the iterative process of presenting input examples and an expected output, if any.

Depending on whether the network output is known in the learning process, so that in the network's learning it is used with every input example, or the exact output is unknown, there are two learning modes:

- learning with the teacher – where the network's learning is conducted in the form of a pair (input, output),
- learning without the teacher – where the network learns without knowing the output.

A set of examples for learning is often divided into three separate sets:

- learning set,
- testing set,
- validation set.

Examples from the learning set serve for learning in the narrower sense of the word, i.e., for adjusting the weight factors. By means of the examples from the testing set the network's operation is validated with current weight factors so as to stop the learning process at the moment of the network's performance degradation. The artificial neural network can be pre-trained after a certain number of iterations and the network will lose the generalization property and will become competent for data processing from the set of learning examples, whereas for other data its processing will be poor. The accuracy and precision in data processing can be validated at the end on the third set of examples, and that is the validation set.

With the learning of the artificial neural network there is also an iteration which tells the step in the learning process algorithm in which the weight factors are being adjusted. The epoch is one whole learning set.

A survey of training functions in Matlab Toolbox, according to [4] is given in Table 1.

Tablica 1 – Prikaz funkcija treniranja iz programskog paketa Matlab
Table 1 – Training functions in Matlab Toolbox

Ime funkcije / Function name	Algoritam / Algorithm
Trainb	Skupina treniranja s težinama i postavljenim pravilima učenja / Batch training with weight and bias learning rules
Trainbfg	BFGS Newton-ov backpropagation algoritam / BFGS Newton backpropagation algorithm
Trainbr	Bayes-ova regularizacija / Bayesian regularization
Trainc	Algoritam s cikličkim slijedom prirasta treniranja težina odn. funkcija učenja / Cyclical order weight/bias training
Traincgb	Powell-Beale-ov konjugirano gradijentni backpropagation / Powell-Beale conjugate gradient backpropagation
Traincgf	Fletcher-Powell-ov konjugirano gradijentni backpropagation / Fletcher-Powell conjugate gradient backpropagation
Traincgp	Polak-Ribier-ov konjugirano gradijentni backpropagation / Polak-Ribier conjugate gradient backpropagation
Traingd	Gradijentno opadajući backpropagation / Gradient descent backpropagation
Traingdm	Gradijentno opadajući backpropagation s inercijom / Gradient descent with momentum backpropagation
Traingda	Gradijentno opadajući backpropagation s prilagodljivom brzinom učenja / Gradient descent with adaptive learning backpropagation
Traingdx	Gradijentno opadajući backpropagation s inercijom i prilagodljivom brzinom učenja / Gradient descent with momentum and adaptive learning backpropagation
Trainlm	Levenberg-Marquardt-ov backpropagation / Levenberg-Marquardt backpropagation
Trainoss	Sekantni backpropagation jediničnog koraka / One-step secant backpropagation
Trainr	Algorithm sa slučajnim slijedom prirasta treniranja težina odn. funkcija učenja / Random order incremental training with learning functions
Trainrp	Elastični backpropagation / Resilient backpropagation
Trains	Algorithm sa sekvencijskim slijedom prirasta treniranja težina odn. funkcija učenja / Sequential order incremental training with learning functions
Trainscg	Skalirani konjugirano gradijentni backpropagation / Scaled conjugate gradient backpropagation

Ove funkcije korištene su za treniranje mreže, a kao najbolje za model kratkoročnog prognoziranja krivulja opterećenja pokazale su se: traincgp, traincgf i trainscg. One su imale najbolji odziv prilikom postupka učenja i bile su najslabije izvornim podacima unatoč velikim nesigurnostima ulaznih podataka, pogotovo podataka o temperaturama. Stoga je odabir ovih funkcija treniranja predstavljao dobar izbor za učenje mreže, kao i za njihovu implementaciju u modelu.

These functions are used for network training. For the short-term forecasting model traincgp, traincgf and trainscg have proved to be the most effective. They had the best response during the learning process and were closest to the original data in spite of major uncertainties of input data, especially those on temperatures. That is why the selection of these training functions was a good choice for network learning as well as for their implementation in the model.

4 PRIMJENA UMJETNE NEURONSKE MREŽE NA KRATKOROČNO PROGNOZIRANJE OPTEREĆENJA

Ideja za korištenje modela umjetne neuronske mreže u prognoziranju opterećenja dolazi od zamisli da je buduće opterećenje ovisno o prošlim opterećenjima i utjecaju vanjskih faktora (npr.

4 APPLICATION OF THE ARTIFICIAL NEURAL NETWORKS TO SHORT-TERM LOAD FORECASTING

The idea of using the artificial neural network model in load forecasting comes from the notion that the future load depends on the past loads and the influence of external factors (notably, temperatu-

temperature, vlažnosti, i dr.), te je potrebna mreža za aproksimaciju te ovisnosti. Ulazi u mrežu trebaju sadržavati vrijednosti temperature, prema [5] i vrijednosti opterećenja prethodnih dana, a za izlaz trebaju se dobiti vrijednost opterećenja (npr. vrijednosti opterećenja pojedinih dana ili vrijednost opterećenja pojedinih godišnjih doba).

Radeći na izradi takvog modela opterećenje se može prepoznati kao nelinearni sustav kojeg je potrebno riješiti. Prilikom određivanja strukture modela potrebno je obuhvatiti ulazne varijable i odrediti mrežnu strukturu. Ovdje se moraju uzeti u obzir brze promjene u karakteristikama ponašanja opterećenja, te mogućnosti prepoznavanja obrasca ponašanja opterećenja i temperatura. Ti zahtjevi i ulazi u mrežu potrebni su za prepoznavanje uvjeta koje je potrebno provesti za treniranje mreže, te pronalazak prikladnog algoritma učenja prilagođenog podacima za treniranje mreže.

Model koji je sposoban riješiti postavljene zahtjeve bio bi model višeslojne unaprijedne neuronske mreže, koja je definirana sa tri sloja: ulaznim, skrivenim i izlaznim.

5 IZRADA POČETNOG MODELA

5.1 Arhitektura umjetne neuronske mreže

Kod dizajniranja umjetne neuronske mreže za kratkoročno prognoziranje opterećenja, prema [6] ulazni parametri definirani su kako slijedi:

$$L = L_n + L_\omega + L_s + L_r, \quad (5)$$

gdje je:

- L – ukupno opterećenje sustava,
- L_n – predstavlja normalni dio opterećenja koje je određeno standardiziranom krivuljom opterećenja za svaki tip dana u bilo kojem dijelu godine,
- L_ω – predstavlja meteorološki promjenjivi dio opterećenja, koji je u čvrstoj povezanosti s godišnjim dobom unutar godine,
- L_s – predstavlja posebne događaje (manifestacije) koji su slučajni, neuobičajeni sa znatnim odstupanjem od tipičnog ponašanja krivulje opterećenja,
- L_r – je potpuno nasumični uvjet koji predstavlja bijeli šum.

Za ulaze modela kratkoročnog prognoziranja op-

re, humidity, etc.), so a network is required for the approximation of this dependence. Network inputs should contain temperature values, according to [5] and load values of the preceding days, whereas for the output the load values (e.g., load values of particular days or load values of particular periods of the year) are required.

While working on such a model, load can be perceived as a nonlinear system requiring a solution. In defining the structure of the model it is necessary to include input variables and define the network's structure. What must be taken here into account are fast changes in the load behavior characteristics and the possibility of identifying the behavioral pattern of loads and temperatures. These requirements and network inputs are needed for identifying the network training conditions to be created and for finding a suitable learning algorithm adapted to network training data.

A model capable of meeting the set requirements would be one of multilayer feedforward neural network defined by three layers: input, hidden and output layers.

5 MAKING THE INITIAL MODEL

5.1 Architecture of the artificial neural network

In designing the artificial neural network for short-term load forecasting, according to [6] the input parameters are defined as follows:

where:

- L – total system load,
- L_n – normal part of the load defined by the standardized load curve for every type of day in any part of the year,
- L_ω – meteorologically variable part of the load firmly linked to the season within a year,
- L_s – special events (manifestations) which are random, unusual, with considerable deviations from the typical shape of the load curve,
- L_r – a complete random condition representing white noise.

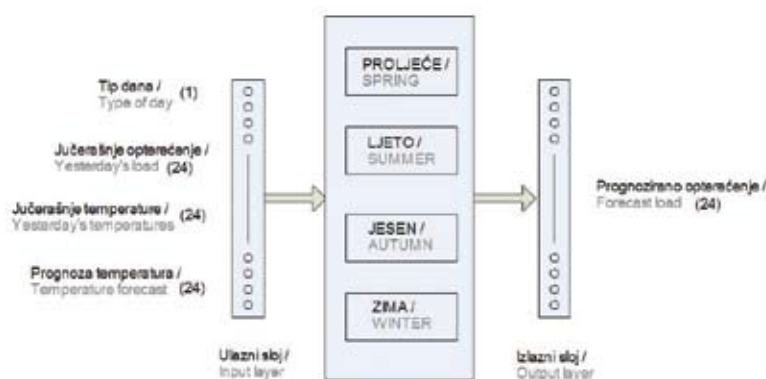
For the inputs of the short-term load forecasting model two parameters were used: the loads of previous days and temperatures. Load forecasting for special days in the year was not carried out,

terećenja koristila su se dva parametra: opterećenja prethodnih dana i temperature. Prognoziranje opterećenja za posebne dane u godini nije provedeno, već su svi dani obuhvaćeni jednim sezonskim modelom. Ti dani ne moraju biti samo posebni dani u godini, već oni mogu obuhvaćati i pojedine kvarove u mreži ili remonte u trafostanicama. Za njihovo prognoziranje bilo bi potrebno izraditi zaseban model. Blok dijagram za predloženu arhitekturu umjetne neuronske mreže prikazan je na slici 4. U ulaznom sloju definirano je 73 neurona. Prvi neuron koristi se za unos oznake dana u tjednu koji se prognozira. Dani u tjednu raspoređeni su prema sljedećem kriteriju:

- radnim danima (ponedjeljak, utorak, ... , petak) dodijeljene su vrijednosti 0,1
- subotama su dodijeljene vrijednosti 0,5, a
- nedjeljama su dodijeljene vrijednosti 1.

instead all the days were covered with a single seasonal model. These days do not need to be only the special days in the year, they can also include particular defects in the network or repair works in the substations. For their forecasting it would be necessary to make a separate model. A block diagram for the proposed architecture in shown in Figure 4. In the input layer 73 neurons are defined. The first neuron is used to enter the marker of the day in the week being forecast. The days in the week are arranged according to the following criterion:

- workdays (Monday, Tuesday, ... , Friday) are assigned values 0,1
- Saturdays are assigned values 0,5, and
- Sundays are assigned values 1.



Slika 4 — Predložena arhitektura umjetne neuronske mreže za prognoziranje opterećenja
Figure 4 — Proposed architecture the artificial neural network for load forecasting

Ulaz sljedećih 24 neurona predstavlja dnevno satno opterećenje prethodnog dana. Ovdje se mogu i unijeti podaci o opterećenju cijelog prethodnog tjedna. Time se drastično povećava mreža i gubi točnost.

Sljedećih 48 neurona koristi se za uvid u efekt temperature. Prva 24 neurona koriste se za dnevne temperature prethodnog dana, a sljedeća 24 neurona za prognozu temperature prognoziranog dana. U skrivenom sloju koriste se četiri sezonske mreže. Izlazni sloj svih sezonskih mreža sadrži 24 neurona. Ti neuroni predstavljaju 24 sata u danu za koje se vrši prognoziranje.

U ovom radu razrađena su dva modela za kratkoročno prognoziranje opterećenja, a to su:

- model sezonske umjetne neuronske mreže i
- model višestrukog prognoziranja dana.

The input of the next 24 neurons represents the daily hourly load of the previous day. Here one can also enter load data of the whole previous week. Thereby the network is drastically expanded and loses in accuracy.

The next 48 neurons are used for an insight into the temperature effect. The first 24 neurons are used for daily temperatures of the previous day, and the next 24 neurons for forecasting the temperature of the forecast day. In the hidden layer four seasonal networks are used. The output layer of all seasonal networks contains 24 neurons. These neurons represent 24 hours in the day in which forecasting is done.

The present work elaborates on two short-term load forecasting models, viz.:

- seasonal artificial neural network model, and
- multiple day forecasting model.

5.2 Sezonska umjetna neuronska mreža

Za izradu ovog modela uzimaju se u obzir četiri modela umjetne neuronske mreže za:

- proljeće,
- ljeto,
- jesen i
- zimu.

Svako pojedino godišnje doba predstavlja se sa svojim modelom, koji su neovisni jedan o drugom u prognoziraju opterećenja. Pri procesu treniranja svakoj mreži dostupni su podaci opterećenja pojedinog godišnjeg doba, a za treniranje uzeto je u obzir dvogodišnje razdoblje.

Četiri sezonske mreže imaju iste arhitekture, koje su unaprijedne neuronske mreže s tri sloja. To je prikazano na slici 5, gdje je za ulazni sloj korišteno 73 neurona, za skriveni sloj 90 neurona, a za izlazni sloj 24 neurona.

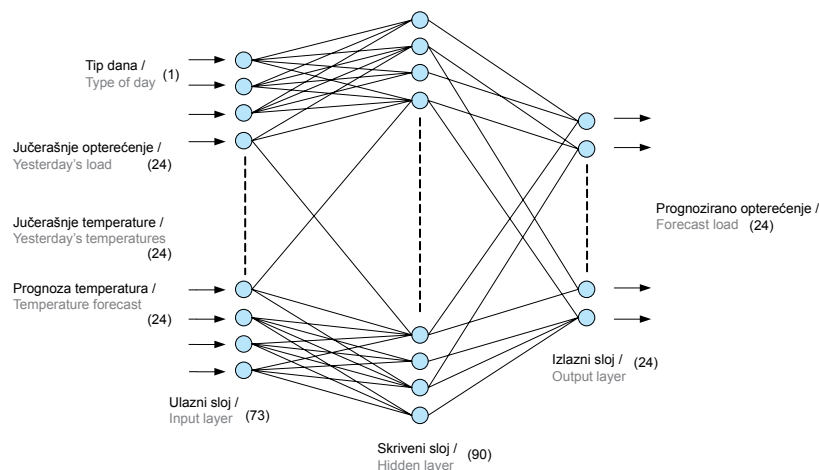
5.2 Seasonal artificial neural network

In designing this model, four artificial neural network models are taken into account for:

- spring,
- summer,
- autumn, and
- winter.

Each season is represented by its own model and each model is independent of the other in load forecasting. In the training process each network has access to the load data of a particular season, and for training a two-year period is taken into consideration.

Four seasonal networks share the same architecture which are three-layered feedforwarding networks. This is shown in Figure 5, where for the input layer 73 neurons are used, for the hidden layer 90 neurons, and for the output layer 24 neurons.



Slika 5 — Sezonska mrežna arhitektura za prognoziranje opterećenja
Figure 5 — Seasonal network architecture for load forecasting

Broj neurona u ulaznom i izlaznom sloju je fiksni i temelji se na izboru ulaznih i izlaznih podataka. Broj neurona u skrivenom sloju određen je prema ranije predloženim pravilima, a treniranje mreže vršilo se postupno počevši s manjim brojem neurona, pa sve do konačnog određivanja broja neurona. Mreža je trenirana s raznim brojem neurona skrivenog sloja, a pokazalo se da u skrivenom sloju ne smije biti manje od 50 neurona niti više od 150 neurona, jer se drastično povećava pogreška. Shodno tome, došlo se do odgovarajućeg broja neurona u skrivenom sloju za kojeg je odlučeno da bude 90 neurona, a koji se temelji na vremenu i rezultatima treniranja.

The number of neurons in the input and output layers is fixed and based on the choice of input and output data. The number of neurons in the hidden layer is defined by the previously proposed rules. Network training was carried out gradually beginning with a smaller number of neurons until the number of neurons was finally defined. The network was trained with a varying number of neurons in the hidden layer. It turned out that in the hidden layer there must be no less than 50 neurons and not more than 150 neurons, otherwise the error is rising dramatically. Thus a proper number of neurons in the hidden layer had to be arrived at, decided to be 90, a number based on the timing and results of training.

5.3 Višestruko prognoziranje dana

Pored navedenog modela sezonske umjetne neuronske mreže izrađen je i model višestrukog prognoziranja opterećenja za nekoliko dana unaprijed. Ovaj model može se predočiti sa sljedećom strategijom:

Prognoziranje opterećenja za dan $d + 1$ izvodi se s opterećenjem prethodnog dana (d) i s temperaturom prethodnog dana (temperatura (d))

Ovo se izvodi dok je dostupna prognoza temperature dana ($d + k$), a taj se postupak može ponavljati do ($d + k$) puta.

U ovom modelu postoji mogućnost za dvije varijante:

- varijanta 1 – gdje se u mrežu vraćaju oni podaci koji su stvarno izmjereni i koji su referenca za ono što bismo htjeli dobiti kao stvarni cilj (engl. target) simulacije mreže,
- varijanta 2 – gdje se u mrežu vraćaju podaci koji su simulirani s mrežom, te služe za predikciju budućih ponašanja modela.

Ilustracija ovog modela dana je na slici 6.

5.3 Multiple day forecasting

Apart from the artificial neural network model, a multiple load forecasting model for several days in advance has been made. This model can be presented with the following strategy:


Load forecasting for day $d + 1$ is performed with the load of the previous day (d) and with the temperature of the previous day (temperature (d))

This is done while the day temperature forecast is accessible ($d + k$), and that procedure can be repeated up to ($d + k$) times.

This model can accommodate two variants:

- Variant 1 – where those data return to the network which have been actually measured and which serve as reference for what we would like to get as a real target of the network simulation,
- Variant 2 – where those data return to the network which have been simulated with the network and serve for predicting the model's future behavior.

This model is illustrated in Figure 6.



Slika 6 – Višestruko prognoziranje dana
Figure 6 – Multiple day forecasting

Premda se može prognozirati i za više od sedam dana unaprijed, uglavnom se ne preporuča zbog kumulativnih pogrešaka. Budući da će svako prognoziranje imati pogrešku koja je povezana sa stvarnim opterećenjem, prognoziranje opterećenja za šire vremensko razdoblje imat će zajedničke pogreške, koje za duže vrijeme čine prognoziranje neprecizno. Sljedeći razlog zašto se ne prognozira duže od sedam dana je raspoloživost prognoze temperatura. Satnu prognozu temperature za više od sedam dana rijetko se čini u meteorološkim stanicama. Čak i kad su podaci i dostupni, prognoza neće biti vjerodostojna.

While it is possible to make forecasts even for more than seven days in advance, that is not recommended due to cumulative errors. As any forecasting will have an error linked to the real load, load forecasting for a longer period of time will have common errors which make longer-term forecasting imprecise. Another reason why forecasts are not made for a period of time longer than seven days is the availability of temperature forecasts. An hourly temperature forecast for more than seven days is rarely made at weather stations. Even if data are available, such a forecast will lack credibility.

5.4 Kriterij zaustavljanja procesa treniranja

Kriterij zaustavljanja procesa treniranja zasniva se na pogrešci dobivenoj od umjetne neuronske mreže. Za određivanje pogreške koristi se:

- apsolutna postotna pogreška i
- srednja apsolutna postotna pogreška,

koje su definirane kao:

5.4 Criterion of stopping the training process

The criterion of stopping the training process is based on an error received from the artificial neural network. Used for error definition are:

- absolute percentage error, and
- mean absolute percentage error,

defined as:

$$|APE| = \frac{|L_f - L_a|}{L_a} \times 100 \% , \quad (6)$$

$$\overline{MAPE} = \frac{1}{N_h} \sum_{N_h} APE , \quad (7)$$

gdje je:

$|APE|$ – apsolutna postotna pogreška,
 L_f – prognozirano opterećenje,
 L_a – stvarno opterećenje,
 \overline{MAPE} – srednja apsolutna postotna pogreška,
 N_h – broj sati u periodu prognoziranja.

Svaki model trenira se sa svojim vlastitim podešenjem treniranja za određenu točnost, koja se zadaje. Nakon maksimalnog broja epoha koji model može dostići, model je treniran i dobivaju se rezultati treniranja. Nakon toga ubacuju se podaci za testiranje te se dobivaju simulirane vrijednosti mreže, na osnovi realnih mjerenih vrijednosti.

Kada se usporede simulirane vrijednosti mreže nakon testiranja sa stvarno izmjerenim vrijednostima mjerenja na sabirnicama može se izračunati APE i $MAPE$. Svaki model postiže svoju točnost. Prihvatljiva točnost modela kreće se oko 5 %.

Postignuta točnost nije jednaka za sve modele, a razlozi mogu biti razni. Veličina vektora treniranja, odabrana funkcija treniranja, nadalje razlog može biti razlika temperatura u svakom modelu. Veća razlika u temperaturama može otežati raspoznavanje strukture umjetne neuronske mreže. Jednako tako na točnost utječu i posebni dani, kao što su vjerski ili državni blagdani i dr.

where:

$|APE|$ – absolute percentage error,
 L_f – forecast load,
 L_a – real load,
 \overline{MAPE} – mean absolute percentage error,
 N_h – number of hours in the forecasting period.

Each model is trained with its own training adjustment for a certain given accuracy. After a maximum number of epochs that a model can reach, the model is trained and the training results are obtained. Then the test data are entered and the network's simulated values are obtained, based on really measured values.

When the network's simulated values are compared after testing with the really measured values on busbars APE and $MAPE$ can be computed. Each model attains its level of accuracy. The acceptable accuracy of a model varies at about 5 %.

The attained accuracy is not the same for all models, and the reasons can be multifarious, such as the size of the training vector, the selected training function, or a temperature difference in any model. A greater temperature difference may adversely affect the discrimination of the structure of the artificial neural network. Likewise, accuracy is influenced by special days, such as religious or national holidays, etc.

6 MODELI KRATKOROČNOG PROGNOZIRANJA OPTEREĆENJA

6.1 Model sezonske mreže – jeseni

Za sezonsku mrežu jeseni izračunata vrijednost srednje apsolutne postotne pogreške (*MAPE*) iznosi: 3,64 %.

Na slikama 7 i 8 prikazana je krivulja opterećenja jednog slučajno odabranog dana srijede 26. listopada 2005. godine, kao i vrijednost učenja mreže istog dana. Učenje mreže provedeno je na cijelom skupu podataka.

Učenje mreže s pokazateljima točnosti treniranja, testa i validacije prikazuje slika 9.

Pogreške cijelog skupa podataka, cijelog razdoblja jeseni, prikazuje slika 10, a pogreška učenja odabranog dana, srijede 26. listopada 2005., označeno je crvenom bojom.

6 SHORT-TERM LOAD FORECASTING MODELS


6.1 Seasonal network model – autumn

For the autumn season network the computed value of the mean absolute percentage error (*MAPE*) amounts to: 3,64 %.


Figures 7 and 8 show the load curve of a randomly selected day of Wednesday the 26th of October 2005, as well as the value of network learning of the same day. Network learning has been conducted on the whole set of data.

Network learning with training, test and validation accuracy indices are shown in Figure 9.


The errors of the whole set of data, the whole autumn season, are shown in Figure 10, and the learning error of the selected day, Wednesday 26th of October 2005 is marked red.



Slika 7 — Prikaz izmjerene vrijednosti krivulje opterećenja i vrijednosti dobivene učenjem mreže
Figure 7 — The measured value of the load curve and the values obtained by network learning



Slika 8 — Pogreške vrijednosti mjenog opterećenja i opterećenja naučenog neuronskom mrežom za srijedu, 26. listopada 2005. godine
Figure 8 — Errors of the values of the measured load and the load learned by neural network for Wednesday the 26th of October 2005



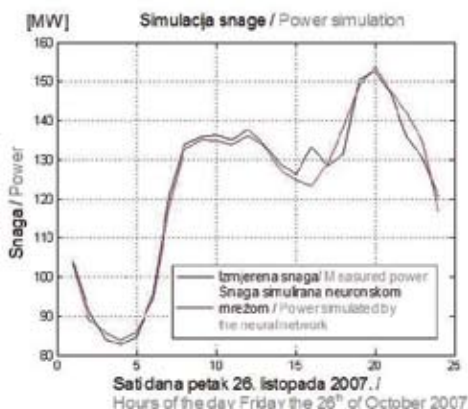
Slika 9 – Prikaz treniranja sezonske mreže jeseni, saprikazom postignute točnosti treniranja, testa i validacije
 Figure 9 – Training of the autumn season network and the attained training, test and validation accuracy




Slika 10 – Prikaz treniranja sezonske mreže jesen, s prikazom pogrešaka srijede, 26. listopada 2005. godine (crveno), kao i svih ostalih dana
 Figure 10 – Training of the autumn season network and the errors of Wednesday the 26th of October (red) and all other days

Prognozu opterećenja za 2007. godinu po završetku procesa testiranja za isti datum, 26. listopada prikazuje slika 11, gdje se uočava prognozirano opterećenje, te uspoređuje s izmjerenom vrijednošću. Slika 12. prikazuje pogreške simuliranog i mjenog opterećenja za promatrani dan, petak 26. listopada 2007.

The load forecast for the year 2007 upon completion of the testing process for the same date, the 26th of October, is shown in Figure 11, where the forecast load is detected and compared with the measured value. Figure 12 shows the errors of simulated and measured loads for the observed day, Friday the 26th of October 2007.



Slika 11 – Prognoza opterećenja po završetku procesa testiranja za dan petak 26. listopada, te usporedba s izmjerenom vrijednošću
 Figure 11 – Load forecast upon completion of the testing process for the day Friday the 26th of October and a comparison with the measured value



Slika 12 — Pogreške simuliranog i mjenenog opterećenja za promatrani dan
Figure 12 — Errors of simulated and measured loads for the observed day

Pogreške svih sezonskih mreža su u granicama do 5 %, jedino za neke pojedine dane pogreške odstupaju više od 5 %. Kada se proanaliziraju koji su to dani dobivaju se neradni dani u godini koji su vjerski ili državni praznici, kao primjerice: 1. siječnja (Nova godina), Uskrs, 1. svibanj (Praznik rada), 15. kolovoza (Velika Gospa), 1. studeni (Svi sveti), 25. i 26. prosinca (Božić), i neki drugi. Te dane potrebno je ili posebno prognozirati ili ih zanemariti, te praviti posebne prognoze opterećenja samo za njih. U sezonskim modelima korištena funkcija treniranja je logsig, gdje su podaci normirani u vrijednosti [0, 1].

6.2 Model višestrukog prognoziranja

Ovaj model, za treniranje, koristi jednogodišnje podatke – cjelokupnu 2006. godinu. Jednako tako i za provjeru skupa – za testiranje koriste se jednogodišnji podaci za 2007. godinu.

Višestruko prognoziranje provedeno je za dvije varijante:

- s povratom stvarno izmjerenih podataka i
- s povratom simuliranih podataka.

Promatrana su četiri godišnja doba u kojima se vršilo prognoziranje, te su dobivene pogreške prognoziranja na osnovi cijelog skupa podataka (za svaku sezonu – oko 90 dana).

U modelima za višestruko prognoziranje dana korištena funkcija treniranja je tansig, gdje su podaci normirani u vrijednosti [-1, 1].

Temperatura u ovom modelu bila je određivana aproksimativno, budući da nisu bile poznate prognoziranje vrijednosti temperatura za svaki sat. S poznavanjem podataka o vrijednostima temperatura svakog sata povećala bi se točnost modela.

The errors of all seasonal networks are within 5 % margin, only for some days they exceed 5 %. When analyzed which days they are, it turns out that they are rest days, specifically the religious and national holidays, for example: January 1 (New Year), Easter Day, May 1 (May Day), August 15 (Assumption of the Virgin Mary), November 1 (All Saints' Day), December 25 and 26 (Christmas), and other. These days should be either separately forecast or ignored, or separate load forecast should be made only for them. The training function used in the seasonal models was logsig, where data are standardized in value [0, 1].

6.2 Multiple forecasting model

This training model is using one-year data – the whole year 2006. Likewise, for set validation – for testing, one-year data of 2007 are used.

Multiple forecasting has been carried out for two variants:

- with return of really measured data, and
- with return of simulated data.

Four periods of the year were observed in which forecasts were made, and forecast errors were obtained on the basis of the whole set of data (for each season – about 90 days).

In the models for multiple day forecasting the used training function was tansig, where data are standardized in value [-1, 1].

Temperature in this model was defined approximately, because the forecast temperature values were not known for every hour. The knowledge of data on temperature values of every hour would enhance the accuracy of the model. The accuracy of this model stands at about 5 %, so it can be

Točnost ovog modela kreće se oko 5 %, te se može reći da model zadovoljava. U literaturi se tolerira točnost do 5 %.

Prikaz pojedinih modela u ovisnosti o promatranom razdoblju, za razdoblje jeseni, predložen je na slikama 13 i 14.

Na slici 13 dan je prikaz pogreški višestrukog prognoziranja s povratom izmjerenih podataka za razdoblje jeseni.


Na slici 14 dan je prikaz višestrukog prognoziranja s povratom simuliranih vrijednosti podataka za razdoblje jeseni.

described as satisfactory. In literature a margin of up to 5 % is tolerated.

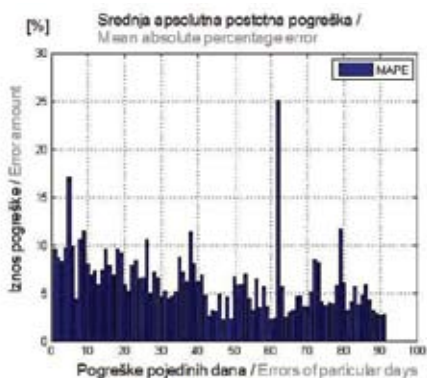
Figures 13 and 14 show individual models in dependence on the observed period for the autumn season.

Figure 13 shows errors of multiple forecasting with return of measured data for the autumn season.

Figure 14 shows multiple forecasting with return of simulated values of autumn data.



Slika 13 — Prikaz pogreški višestrukog prognoziranja s povratom izmjerenih podataka za razdoblje jeseni
Figure 13 — Errors of multiple forecasting with return of measured data for the autumn season



Slika 14 — Prikaz pogreški višestrukog prognoziranja s povratom simuliranih vrijednosti podataka za razdoblje jeseni
Figure 14 — Errors of multiple forecasting with return of simulated values of autumn data

7 ZAKLJUČAK

U ovom radu razmatrana je izrada modela za kratkoročno prognoziranje opterećenja primjenom umjetne neuronske mreže, kao i njegova šira primjena i implementacija.

Korišteni model prognozira opterećenje za jedno distribucijsko područje napajanja na sabirnicama

7 CONCLUSION

This work examines the way of making a short-term load forecasting model by using the artificial neural network, as well as its wide application and implementation.

The model is used for load forecasting for a distribution area supplied over 110 / x kV busbars,

110 / x kV, koje je u ovom radu primijenjeno na HEP ODS Elektroslavoniju Osijek.

Model se može aplicirati i za različita druga distribucijska područja, te na širi dio mreže s drugim naponskim razinama, sve do praćenja cjelokupnog elektroenergetskog sustava. S drugim parametrima modela i poznatim ulaznim mjernim podacima moguće je kombinirati modele kratkoročnog prognoziranja opterećenja radi planiranja, održavanja itd.

Obrađen je model za jedan sustav sabirnica, ali se na ovaj način može razmatrati i više istodobnih sustava koji se mogu sinkronizirati i istodobno razmatrati.

Model se može nadopunjavati, a za šire potrebe i razdvojiti s mogućnosti razmatranja pojedinih kategorija potrošača: industrije, kućanstva ili poslovnih subjekata, te mu se može i povećati točnost s aktualnim podacima o satnim temperaturama. Važno je za napomenuti da se eliminacijom loših podataka može povećati točnost modela, kao što su smetnje prilikom kvarova, te svakako razdvajanjem prazničnih dana od radnih dana.

Implementacija oba modela omogućuje kratkoročno prognoziranje opterećenja u budućim tržišnim uvjetima kojima se osigurava:

- planiranje proizvodnje,
- sigurnost elektroenergetskog sustava,
- osiguranje rezervne proizvodnje u elektroenergetskom sustavu,
- osiguranje informacija za dispečere, te
- funkcioniranje tržišta.

Uštede primjenom ovog modela mogu biti jako velike. Povećanje točnosti predviđanja potrošnje direktno utječe na optimiranje tokova snaga, rezultat čega mogu biti manji troškovi djelatne snage. Sa smanjenjem pogreške prognoziranja opterećenja u iznosu od 1 % smanjenje djelatnih troškova može biti znatno. Radi toga interesantna je daljnja nadogradnja modela, a njegova točnost može se poboljšati nastavkom praćenja svih relevantnih podataka, te njihovim uvrštenjem u već postojeće modele.

applied in this work to HEP ODS Elektroslavonija Osijek.

The model is also applicable to other distribution areas and a wide part of the network with other voltage levels up to the point of monitoring the whole electric power system. With other parameters of the model and known input measuring data it is possible to combine the short-term load forecasting models for planning, maintenance and other purposes.

The model has been prepared for one system of busbars, but in this way a number of simultaneous systems can be studied that can be synchronized and simultaneously reviewed.

The model can be supplemented, as well as separated into parts for wider needs with a possibility of analyzing particular consumer categories: industries, households or businesses, and its accuracy can be improved by means of topical data on hourly temperatures. It is important to note that the accuracy of the model can be enhanced by eliminating bad data, such as disturbances in the case of defects, and by separating holidays from working days.

The implementation of both models allows short-term load forecasting in future market conditions to ensure:

- production planning,
- EPS security
- stand-by power generation in the EPS,
- information for dispatchers, and
- a functioning market.

The application of the model may result in huge savings. Improved prediction accuracy has a direct effect on the optimization of power flows, the result of which may be lower active power costs. A reduced load forecasting error of just 1 % can result in major reductions in active costs. For that reason further upgrade of the model is certainly of interest. Its accuracy can be improved by continued monitoring of all relevant data and its incorporation into the existing models.

LITERATURA / REFERENCES

- [1] HIPPERT, H.S., PEDREIRA, C.E., SOUZA, R.C., Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, IEEE Trans. Power System, Vol. 16, No. 1, 2001
 - [2] SHAHIDEHPOUR, M., YAMIN, H., LI, Z., Market operations in Electric power systems- Forecasting, Scheduling, and Risk Management, Wiley Interscience, A John Wiley & Sons, Inc., Publication, New York, 2002
 - [3] NOVAKOVIĆ, B., Umjetne neuronske mreže, Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
 - [4] DEMUTH, H., Neural Network Toolbox (For Use with MATLAB), The MathWorks, 1997
 - [5] <http://radar.dhz.hr/~hep/prognoze.php?id=meteogram¶m>
 - [6] FEINBERG, E.A., GENETHLIOU, D., Load Forecasting: Applied Mathematics for Restructured Electric Power Systems: Optimization, Control, and Computational Intelligence, Springer USA, 2006
-

Adrese autora:

Mr. sc. **Krešimir Tačković**
kresimir.tackovic@hep.hr
HEP ODS d.o.o. Elektroslavonija
Šetalište kardinala F. Šepera 1a
31000 Osijek
Hrvatska

Doc. dr. sc. **Vedran Boras**
vboras@pmfst.hr
Sveučilište u Splitu
Prirodoslovno matematički fakultet
Teslina 12
21000 Split
Hrvatska

Prof. dr. sc. **Srete Nikolovski**
srete.nikolovski@etfos.hr
Sveučilište Josipa Jurja Strossmayera u Osijeku
Elektrotehnički fakultet
Kneza Trpimira 2b
31000 Osijek
Hrvatska

Authors' Addresses:

Krešimir Tačković, MSc
kresimir.tackovic@hep.hr
HEP ODS d.o.o. Elektroslavonija
Šetalište kardinala F. Šepera 1a
31000 Osijek
Croatia

Ass Prof **Vedran Boras**, PhD
vboras@pmfst.hr
University of Split
Faculty of Science
Teslina 12
21000 Split
Croatia

Prof **Srete Nikolovski**, PhD
srete.nikolovski@etfos.hr
Josip Juraj Strossmayer University of Osijek
Faculty of Electrical Engineering
Kneza Trpimira 2b
31000 Osijek
Croatia

Uredništvo primilo rukopis:
2008-10-27

Prihvaćeno:
2008-11-28

Manuscript received on:
2008-10-27

Accepted on:
2008-11-28