

Marek Novák, Pavol Belány, Peter Braciník, Marek Roch

## Návrh neurónovej siete pre predikciu spotreby elektrickej energie

Predikcia spotreby elektrickej energie je v posledných rokoch významnou témou. Nárast množstva obnoviteľných zdrojov energie má dopad na disharmóniu medzi výrobou a spotrebou. Preto predikčné modely či už spotreby alebo výroby elektrickej energie nachádzajú svoje uplatnenie stále častejšie. Hlavným cieľom tohto článku je predstaviť návrh predikčného modelu spotreby elektrickej energie založenom na neurónovej sieti. Model overovaný na základe dát z inteligentných meracích systémov vykazuje veľmi presnú predpoveď pri krátkej dobe tréningu a agregovaní spotreby elektrickej energie odberných miest.

Kľúčové slová: predikcia; neurónová sieť; spotreba elektrickej energie

Prediction of electricity consumption has been an important topic in recent years. Increasing amount of renewable energy sources has an impact on the disharmony between production and consumption. Therefore, prediction models of consumption or production of electricity are finding their application more and more often. The main goal of this paper is to present a proposal for a predictive model of electricity consumption based on a neural network. The model verified on the basis of data from intelligent metering systems shows a very accurate prediction with a short training time and aggregation of electricity consumption of consumption points (**Design of a neural network for prediction of electricity consumption**)

Keywords: prediction; neural network; electricity consumption


### I. ÚVOD

Predikcia spotreby elektrickej energie hrá v ekonomike prevádzky inteligentných sietí rozhodujúcu úlohu. Presné predpovedanie spotreby elektrickej energie je nevyhnutné pre tvorbu plánov výroby elektrickej energie a celkovú bilanciu v inteligentnej sieti. Variabilita dát a premenných v čase však bráni v dosahovaní uspokojivej presnosti predikcie [1]. Existuje veľa metód používaných na predikciu základného tvaru priebehu spotreby el. energie, avšak väčšina metód nie je dostatočne presná na úrovni domácností a malých podnikov [2]. Mnohé štúdie sa zaoberali využitím strojového učenia, ako je podporná vektorová regresia a neurónové siete [3, 4]. Taktiež existuje veľa štúdií porovnávajúcich presnosť predikcie jednotlivých metód. Autori článku [5] porovnávajú regresný model s umelou neurónovou sieťou (ANN) a podporného vektora najmenších štvorcov ako metódy strojového učenia (LS-SVM), pričom odporúčajú LS-SVM, kde stredná kvadratická chyba (RMSE) nadobudla hodnotu 0,412 pre predikciu spotreby elektrickej energie avšak zároveň uznávajú, že ANN sa blížila presnosti LS-SVM pri dostatočnom natrénovaní (RMSE 1,76). V článku [6] je porovnanie regresnej analýzy, rozhodovacieho stromu a ANN, kde v letnom období bola presnejšia metóda rozhodovacieho stromu no v zimnom umelá neurónová sieť. V [7] predstavujú prístup k predikcii zaťaženia v sieti pomocou ANN, kde priemerné absolútne chyby hodinovej a 24 hodinovej predikcie boli 1,40 % a 2,06 % a porovnali výsledky s konvenčne používanou prognostickou technikou, kde priemerná chyba nadobudla hodnotu 4,22 % pre 24-hodinovú predikciu. Z vyššie spomenutých štúdií vyplýva, že každý zo spomenutých modelov má svoje výhody aj nevýhody. Avšak rozhodnutie výberu umelej neurónovej siete podnietila práve popularizácia tejto metódy a nasadzovanie v mnohých vedných odboroch [8], [9], [10], [11], [12].

### II. NEURÓNOVÁ SIETĚ

Neurónová sieť je séria algoritmov, ktoré sa snažia rozpoznať základné vzťahy v súbore údajov prostredníctvom procesu, ktorý napodobňuje fungovanie ľudského mozgu. V tomto zmysle sa neurónové siete týkajú systémov neurónov, buď organickej alebo umelej povahy. Neurónové siete sa môžu prispôbiť meniacemu sa vstupu. Sieť tak vytvára najlepší možný výsledok bez toho, aby bolo potrebné prepracovať výstupné kritériá.

Na začiatku neurónová sieť vykoná náhodné predpovede. Tieto predpovede sa spoja so správnym výstupom a následne sa vypočíta chyba alebo rozdiel medzi predpokladanými hodnotami a skutočnými hodnotami. Funkcia, ktorá zistí rozdiel medzi skutočnou hodnotou a predikovanou, sa nazýva nákladová funkcia. Cena tu označuje chybu. Cieľom je minimalizovať nákladovú funkciu. Tréning neurónovej siete má za úlohu minimalizovať nákladovú funkciu. Neurónová sieť s jednou vstupnou a jednou výstupnou vrstvou sa nazýva perceptrón. Perceptrón však nedokáže nájsť nelineárne rozhodovacie hranice. Neurónové siete v reálnom svete, ktoré sú schopné vykonávať zložité úlohy, obsahujú okrem vstupnej a výstupnej vrstvy aj skryté vrstvy. Takáto ANN sa nazýva aj MPL - z angl. multilayer perceptron a je schopná nájsť nelineárne riešenie. ANN pozostáva z vrstiev obsahujúcich neuróny a váh medzi neurónmi, kde sa informácie prenášajú vpred. Model umelého neurónu je znázornený na obrázku 1.



Obr. 1. Model umelého neurónu.

Umelé neuróny ANN sa skladajú z 3 hlavných komponentov: váh spájajúcich uzly, sumačnej funkcie v uzle a prenosovej funkcie. V tomto modeli sme sa rozhodli pre ANN s jednou skrytou vrstvou, pretože ako bolo spomenuté, MLP ANN dokáže riešiť nelineárny problém [13].

### III. METODIKA NÁVRHU NEURÓNOVEJ SIETE

Metodika pozostávala z prípravy dát zaťaženia odberných miest získaných od Stredoslovenskej distribučnej, a. s. (SSD), spracovania dát do vhodnej formy, definície vstupných premenných, predikcie a overenia presnosti predikcie. Pre potreby tréningu a overovania modelu boli vybrané hodnoty zaťaženia z inteligentných meracích systémov (IMS) 56 odberných miest z piatich rôznych lokalít z rokov 2018 a 2019. Hodnoty zaťaženia boli s krokom 15 minút pre jednotlivé odberné miesta a obsahovali hodnoty činného a jalového výkonu a tiež napätia v jednotlivých fázach. Zo získaných dát boli zostavené tabuľky sumárneho činného odberu. Potom ako vstupy ANN pre krátkodobú predikciu spotreby el. energie boli definované:

- hodnota odberu v rovnaký deň, v rovnakej hodine v predchádzajúcom týždni pred dňom predikcie,
- hodnota odberu v rovnaký deň, 1 hodinu pred hodinou predikcie v predchádzajúcom týždni pred dňom predikcie,
- hodnota odberu v predchádzajúcom dni, v rovnakej hodine predikcie pred dňom predikcie,
- hodnota odberu v predchádzajúcom dni, 1 hodinu pred hodinou predikcie pred dňom predikcie,
- hodnota predstavujúca pracovný deň/víkend pred dňom predikcie,
- hodnota predstavujúca pracovný deň/víkend v deň predikcie.

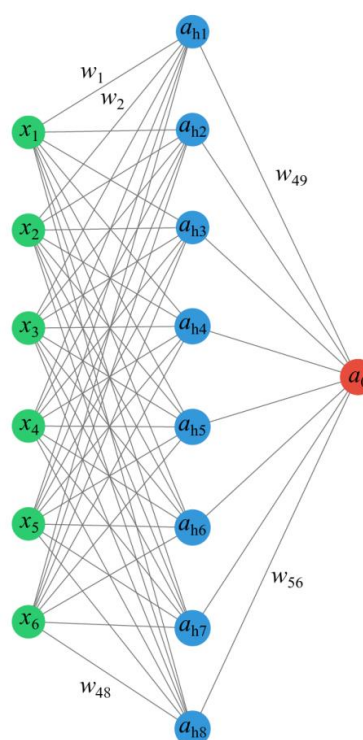
V ďalšom kroku bol zostavený predikčný model v jazyku Python v prostredí Spyder 3.3.6.

Z tabuliek sumárneho odberu zostavených na začiatku procesu boli postupne vybrané intervaly s krokom 2 týždne a po natrénovaní ANN bola realizovaná predikcia pre nasledujúci deň. Výsledkom predikcie bol priebeh odberu, ktorého chybu popisovala chyba RMSE a percentuálna chyba.

### IV. NÁVRH NEURÓNOVEJ SIETE PRE PREDIKCIU

Vybraná neurónová sieť typu MLP obsahuje 15 neurónov v troch vrstvách a 56 váh spájajúcich jednotlivé neuróny. Architektúra neurónovej siete je zobrazená na obrázku 2.

Neurónová sieť na obrázku je zostavená zo 6 vstupov - neurónov, v skrytej vrstve je 8 neurónov a výstupná vrstva má 1 neurón, pretože riešením je hodnota zaťaženia. Postup výpočtu je nezávislý od počtu neurónov a skrytých vrstiev. Začína sa dopredným výpočtom (z angl. feed forward), kde sa vstupy z predchádzajúcej vrstvy násobia zodpovedajúcimi váhami a prechádzajú aktivačnou funkciou, aby sa získala konečná hodnota pre zodpovedajúci neurón v nasledujúcej vrstve. Tento proces sa opakuje až po výpočet výstupnej hodnoty. Potom nasleduje úprava váh pomocou výpočtu spätného šírenia chyby (z angl. back propagation). Úprava váh predstavuje učenie/tréning ANN a vykonáva sa pomocou algoritmu Levenberg-Marquardta. Vo fáze spätného šírenia chyby sa predikovaný výstup porovná so skutočným výstupom a vypočíta sa chyba predikcie. Účelom je minimalizovať nákladovú funkciu.



Obr. 2. Topológia navrhovanej neurónovej siete.

#### DOPREDNÝ VÝPOČET

Aby bolo možné vypočítať hodnoty pre každý neurón v skrytej vrstve, je potrebné vynásobiť vstup zodpovedajúcimi váhami neurónu, pre ktorý je realizovaný výpočet. Pre  $z_{h1}$  platí:

$$z_{h1} = x_1 \cdot w_1 + x_2 \cdot w_2 + x_3 \cdot w_3 + x_4 \cdot w_4 + x_5 \cdot w_5 + x_6 \cdot w_6 \quad (1)$$

kde  $w_1$  až  $w_6$  sú zodpovedajúce váhy neurónu. Potom výpočet konečnej hodnoty pre prvý neurón v skrytej vrstve, ktorý je označený ako  $a_{h1}$ , je nasledovný:

$$a_{h1} = \frac{1}{1 + e^{-z_{h1}}} \quad (2)$$

Pre výpočet hodnoty výstupnej vrstvy platí rovnaká metóda, kde hodnoty pre neuróny skrytej vrstvy sa považujú za vstupy. Potom túto operáciu možno matematicky vyjadriť nasledovne:

$$z_0 = a_{h1} \cdot w_{49} + a_{h2} \cdot w_{50} + a_{h3} \cdot w_{51} + a_{h4} \cdot w_{52} + a_{h5} \cdot w_{53} + a_{h6} \cdot w_{54} + a_{h7} \cdot w_{55} + a_{h8} \cdot w_{56} \quad (3)$$

Potom pre  $a_0$  platí:

$$a_0 = \frac{1}{1 + e^{-z_0}} \quad (4)$$


#### VÝPOČET SPÄTNÉHO ŠÍRENIA CHYBY

Vo fáze spätného šírenia chyby sa najskôr definuje stratová funkcia. Použili sme funkciu strednej kvadratickej chyby. Matematicky ju možno vyjadriť ako:

$$MSE = \frac{1}{n} \sum_{i=1}^n (PH - SH)^2, \quad (5)$$

kde  $n$  je počet hodnôt,  $PH$  predikovaná hodnota a  $SH$  skutočná hodnota zaťaženia.

V prvej fáze spätného šírenia chyby je potrebné aktualizovať váhy výstupnej vrstvy, a to  $w_{49}$  až  $w_{56}$ . Takže sa zatiaľ uvažuje, že neuronová sieť má nasledujúcu časť:



Obr. 3. Časť neuronovej siete pre výpočet prvej fázy spätného šírenia chyby.

#### Prvá fáza výpočtu

Účelom prvej fázy spätného šírenia chyby je aktualizovať hmotnosti  $w_{49}$  až  $w_{56}$  takým spôsobom, aby sa minimalizovala konečná chyba. Je potrebné nájsť funkčné minimum pre nákladovú funkciu. Na nájdenie minima funkcie sme použili metódu gradientu. Možno ju matematicky vyjadriť ako:

$$w_j = w_j - \alpha \cdot \frac{\partial}{\partial w_j} \cdot J \cdot (w_0, w_1, \dots, w_n), \quad (6)$$

kde výpočet sa vykonáva až po konvergenciu.

Potom pre predikovaný výstup  $a_0$  je nákladová funkcia vyjadrená ako:

$$J = \frac{1}{n} \sum_{i=1}^n (a_0 - s)^2, \quad (7)$$

kde  $s$  je skutočná hodnota.

Pre minimalizovanie nákladovej funkcie musia byť aktualizované hodnoty jednotlivých váh tak, aby sa hodnota výsledku nákladovej funkcie znižovala. Na to je potrebná parciálna derivácia nákladovej funkcie s ohľadom na každú váhu. V prvej fáze výpočtu spätného šírenia chyby sa uvažuje s váhami výstupnej vrstvy. Derivácia nákladovej funkcie vzhľadom na váhy vo výstupnej vrstve môže byť matematicky vyjadrená nasledovne:

$$\frac{\partial J}{\partial w_0} = \frac{\partial J}{\partial a_0} \cdot \frac{\partial a_0}{\partial z_0} \cdot \frac{\partial z_0}{\partial w_0} \dots, \quad (8)$$

kde parciálna derivácia nákladovej funkcie podľa  $a_0$  je:

$$\frac{\partial J}{\partial a_0} = -2 \cdot (1 - a_0) \quad (9)$$

Rovnako pre  $a_0$  sa parciálna diferenciácia podľa  $z_0$  vypočíta ako:

$$\frac{\partial a_0}{\partial z_0} = \text{sigmoid}(z_0) \cdot (1 - \text{sigmoid}(z_0)), \quad (10)$$

kde sigmoid predstavuje sigmoidnú aktivačnú funkciu.

Parciálnej derivácie  $z_0$  podľa  $w_0$  je vyjadrená ako:

$$\frac{\partial z_0}{\partial w_0} = a_h, \quad (11)$$

kde  $a_h$  predstavuje hodnoty neurónov v skrytej vrstve.

#### Druhá fáza výpočtu

Predstavuje výpočet pre vstupnú vrstvu, kde sa chyba prenesie späť pre úpravu váh  $w_1$  až  $w_{48}$  skrytej vrstvy. Potom parciálnu deriváciu nákladovej funkcie podľa váhy v skrytej vrstve možno vyjadriť ako:

$$\frac{\partial J}{\partial w_h} = \frac{\partial J}{\partial a_h} \cdot \frac{\partial a_h}{\partial z_h} \cdot \frac{\partial z_h}{\partial w_h} \dots, \quad (12)$$

kde parciálna derivácia nákladovej funkcie podľa  $a_h$  sa vypočíta ako:

$$\frac{\partial J}{\partial a_h} = \frac{\partial J}{\partial z_0} \cdot \frac{\partial z_0}{\partial a_h}, \quad (13)$$

a parciálna derivácia  $a_0$  podľa  $z_0$ :

$$\frac{\partial J}{\partial z_0} = \frac{\partial J}{\partial a_0} \cdot \frac{\partial a_0}{\partial z_0} \quad (14)$$

Pre  $z_0$  platí:

$$z_0 = a_{01} \cdot w_{49} + a_{02} \cdot w_{50} + a_{03} \cdot w_{51} + a_{04} \cdot w_{52} + a_{05} \cdot w_{53} + a_{06} \cdot w_{54} + a_{07} \cdot w_{55} + a_{08} \cdot w_{56} \quad (15)$$

Z parciálnej derivácie  $z_0$  podľa  $a_h$  sa potom získajú váhy výstupnej vrstvy ako:

$$\frac{\partial z_0}{\partial a_h} = w_0 \dots \quad (16)$$

Potom je možné nájsť parciálnu deriváciu  $a_h$  podľa  $z_h$ :

$$\frac{\partial a_h}{\partial z_h} = \text{sigmoid}(z_h) \cdot (1 - \text{sigmoid}(z_h)) \quad (17)$$

Nakoniec parciálna derivácia  $z_h$  podľa  $w_h$  sú vstupné hodnoty:

$$\frac{\partial z_h}{\partial w_h} = x \quad (18)$$

#### V. OVERENIE PRESNOSTI PREDIKCIE

Predikčný model zostavený na základe vyššie uvedených výpočtov riešenia neuronových sietí bol overovaný na základe metodiky spomínanej v kapitole III. Overenie presnosti predikcie reprezentuje RMSE a percentuálna chyba, kde boli porovnávané predikované

hodnoty činného odberu el. energie so skutočným činným odberom pre rovnaký čas.

Pre RMSE platí:

$$\text{RMSE} = \sqrt{\frac{\sum_{t=1}^T (P_R - P_{\text{predik}})^2}{T}}, \quad (19)$$

kde  $T$  je počet hodnôt pre výpočet RMSE,  $P_R$  predstavuje reálny odber elektrickej energie a  $P_{\text{predik}}$  predikovaný odber.

Pre percentuálnu chybu *Error* platí:

$$\text{Error} = \frac{P_R - P_{\text{predik}}}{P_R} \cdot 100, \quad (20)$$

Overenie predikčného modelu bolo realizované na vzorkách dvojtýždňových dát ako vstupu pre model. Následne bol vykonaný tréning neurónovej siete a nasledovala predikcia pre nasledujúci deň a taktiež pre nasledujúce dva týždne. Hodnoty predikovaného a skutočného odberu. Výsledné priemerné chyby predikcie pre nasledujúci deň v závislosti od počtu epoch učenia predstavuje tabuľka 1, Rovnako pre predikciu dvojtýždňových dát, výsledky predikcie sú zosumarizované v tabuľke 2.

TABUĽKA 1  
Predikcia pre nasledujúci deň

Epoch	Čas [s]	RMSE	Error [%]
1	12	0,598	1,919
5	33	0,523	1,813
10	66	0,501	1,955
15	103	0,461	2,552
100	649	0,629	2,260

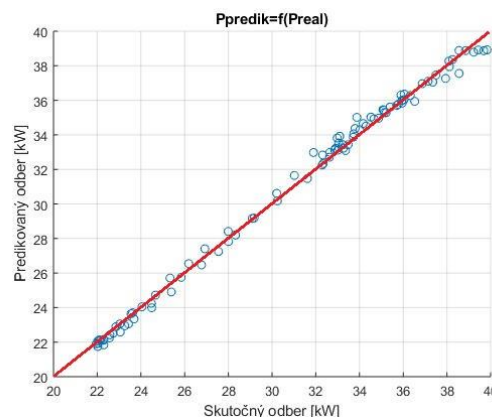
TABUĽKA 2  
Predikcia pre nasledujúce dva týždne

Epoch	Čas [s]	RMSE	Error [%]
1	12	1,847	5,445
5	33	1,445	4,538
10	66	1,503	4,542
15	103	1,569	4,807
100	649	1,595	4,882

Potom pre vybraný jeden deň sú priebehy predikovaného a skutočného odberu a tiež rozptylu odberov nasledovné:



Obr. 4. Priebeh predikovaného a skutočného odberu pre vybraný deň z dataset-u.



Obr. 5. Rozptyl predikovaného a skutočného odberu pre vybraný deň z dataset-u.

## VI. ZÁVER

Príspevok sa zameriava na návrh modelu predikcie spotreby elektrickej energie. Realizovaný model bol podrobený sérii experimentov na postavených na dátach spotreby z inteligentných meracích systémov z 56 odberných miest. Z analýzy dát bolo zistené, že ideálny počet epoch tréningu danej neurónovej siete bol 5 až 15 vzhľadom na presnosť predikcie a tiež krátky čas potrebný na natréňovanie. Zároveň z tabuliek 1 a 2 je zrejme, že predikcia vždy pre nasledujúci deň z natréňovaných dát predchádzajúcich dvoch týždňov, je zaťažená trojnásobne menšou chybou ako predikcia nasledujúcich dvoch týždňov. Chyba RMSE v rozsahu 5 až 15 epoch a im zodpovedajúce časy tréningu sú akceptovateľné pri porovnaní chýb vyššie spomenutých predikčných modelov. Navrhovaný predikčný model spotreby elektrickej energie tým zabezpečuje dostatočne vysokú presnosť pre využitie napríklad vo virtuálnych elektrárnach pre zabezpečenie reakcie dopytu. Kde spoločne s aplikáciou predikčného modelu krátkodobej predikcie výroby elektrickej energie z obnoviteľných zdrojov môže tvoriť základ nového konceptu riadenia odberu v inteligentnej sieti.

## POĎAKOVANIE

Táto práca bola podporovaná Agentúrou na podporu výskumu a vývoja na základe Zmluvy č. APVV-16-0505 Krátkodobá PREDIKcia výroby fotovoltaickej energie pre potreby napájania inteligentných budov - PREDICON.

## LITERATÚRA

- [1] K. Li, T. Zhang, "Forecasting Electricity Consumption Using an Improved Grey Prediction Model", August 2018, Information, 9, 204, doi: 10.3390/info9080204.
- [2] T. Hong, T. "Energy Forecasting : Past , Present , and Future", The International Journal of Applied Forecasting, vol. Winter 2014, pp. 43–49, 2014.
- [3] R. E. Edwards, J. New, L. E. Parker, "Predicting future hourly residential electrical consumption: A machine learning case study", Energy and Buildings, vol. 49, pp. 591–603, Jún. 2012.
- [4] R. K. Jain a kol, "Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy", Applied Energy, vol. 123, pp. 168–178, Jún, 2014.
- [5] F. Kaytez, M. Taplamacioglu, E. Çam, F. Hardalac, "Forecasting electricity consumption: A comparison of regression analysis, neural networks and least squares support vector machines", International

- Journal of Electrical Power & Energy Systems. 67, doi: 10.1016/j.ijepes.2014.12.036.
- [6] K.F. Geoffrey, K. Tso, Y. K.W., "Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks", *Energy*, Volume 32, Issue 9, 2007, pp 1761-1768, ISSN 0360-5442, doi: 10.1016/j.energy.2006.11.010.
- [7] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas and M. J. Damborg, "Electric load forecasting using an artificial neural network," in *IEEE Transactions on Power Systems*, vol. 6, no. 2, pp. 442-449, Máj 1991, doi: 10.1109/59.76685.
- [8] S. A. Khaparde, P. B. Kale and S. H. Agarwal, "Application of artificial neural network in protective relaying of transmission lines," *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*, Seattle, WA, USA, 1991, pp. 122-125, doi: 10.1109/ANN.1991.213509.
- [9] L. D. Zhang, L. Jia and W. X. Zhu, "Overview of traffic flow hybrid ANN forecasting algorithm study," *2010 International Conference on Computer Application and System Modeling (ICCASM 2010)*, Taiyuan, 2010, pp. V1-615-V1-619, doi: 10.1109/ICCASM.2010.5620414.
- [10] R. Karunakaran and G. G. Karady, "Artificial neural networks as a dispatcher's aid in alarm processing," *Proceedings of the First International Forum on Applications of Neural Networks to Power Systems*, Seattle, WA, USA, 1991, pp. 169-173, doi: 10.1109/ANN.1991.213484.
- [11] U. Braun and K. Feser, "Restoring current signals in real time using feedforward neural nets," [1993] *Proceedings of the Second International Forum on Applications of Neural Networks to Power Systems*, Yokohama, Japan, 1993, pp. 441-446, doi: 10.1109/ANN.1993.264308.
- [12] T. Matsumoto, S. Kitamura, Y. Ueki and T. Matsui, "Short-term load forecasting by artificial neural networks using individual and collective data of preceding years," [1993] *Proceedings of the Second International Forum on Applications of Neural Networks to Power Systems*, Yokohama, Japan, 1993, pp. 245-250, doi: 10.1109/ANN.1993.264283.
- [13] S. Singh, S. Hussain and M. A. Bazaz, "Short term load forecasting using artificial neural network," *2017 Fourth International Conference on Image Information Processing (ICIIP)*, Shimla, 2017, pp. 1-5, doi: 10.1109/ICIIP.2017.8313703.

#### ADRESY AUTOROV

Ing. Marek Novák, Žilinská univerzita, Katedra elektroenergetiky a elektrických pohonov, Univerzitná 1, Žilina, SK 01026, Slovenská Republika, [marek.novak@feit.uniza.sk](mailto:marek.novak@feit.uniza.sk)

Ing. Pavol Belány, PhD., Žilinská univerzita, Výskumné centrum, Divízia výskumu inteligentných budov a obnoviteľných energií, Univerzitná 1, Žilina, SK 01026, Slovenská Republika, [pavol.belany@rc.uniza.sk](mailto:pavol.belany@rc.uniza.sk)

doc. Ing. Peter Bracínik, PhD., Žilinská univerzita, Katedra elektroenergetiky a elektrických pohonov, Univerzitná 1, Žilina, SK 01026, Slovenská Republika, [peter.bracinik@feit.uniza.sk](mailto:peter.bracinik@feit.uniza.sk)

doc. Ing. Marek Roch, PhD., Žilinská univerzita, Katedra elektroenergetiky a elektrických pohonov, Univerzitná 1, Žilina, SK 01026, Slovenská Republika, [marek.roch@feit.uniza.sk](mailto:marek.roch@feit.uniza.sk)