

Predikcia spotových cien elektriny

Róbert Magyar, Viera Rozinajová

Ústav informatiky, informačných systémov a softvérového inžinierstva, FIIT STU v Bratislave
Ilkovičova 2, 842 16 Bratislava

xmagyarr@is.stuba.sk
viera.rozinajova@stuba.sk

Abstrakt. Každodenné rozhodovanie účastníkov v biznise si vyžaduje informácie o budúcom vývoji určitej premennej dôležitej pre biznis. Dostatočne presná predikcia prináša nové príležitosti modifikácie nákupných a predajných stratégií a lepšiu možnosť kontrolovania rizika. Aplikáciou prístupov objavovania znalostí a umelej inteligencie dokážeme vytvárať zaujímavé prediktívne modely využiteľné v mnohých doménach. Naozajstná výzva sa ale nachádza v zakomponovaní týchto nástrojov do skúmania správania sa predpovedanej spojitej premennej, ktorá je charakteristická krátkodobými skokmi. V tomto článku prezentujeme úvodný návrh riešenia problému krátkodobých skokov v doméne spotových cien elektriny.

Kľúčové slová: predikcia, umelá inteligencia, objavovanie znalostí, spotové ceny elektriny

1 Úvod

Predikovaná spojitá premenná sa často vyznačuje určitými charakteristikami. Tieto charakteristiky môžu zásadne pozitívne alebo negatívne ovplyvniť schopnosť aplikovanej metódy a zvoleného prístupu predikcie dosahovať uspokojivé výsledky.

Cena elektriny sa vyznačuje charakteristikami, ktorých správne pochopenie vytvára príležitosť na tvorbu presnejších predikčných systémov. Medzi charakteristiky vývoja ceny elektriny patrí tendencia návratu ceny k priemeru, sezónnosť, vysoká volatilita a rapidne cenové skoky [3].

Nekontrolované, krátkodobé a rapidne zmeny ceny zapríčiňujú nárast rizika pre nakupujúcich aj predávajúcich. Výskyt krátkodobých cenových skokov je ovplyvnený faktormi ako je teplota, vlhkosť, porucha nízko nákladových elektrární, obmedzenia prenosu a výroby elektriny [2][4]. Elektrina ako komodita sa neskladuje v významných množstvách, čo je spôsobené nákladmi na skladovanie [3]. Kombinácia týchto faktorov podporuje zvýšenie volatility a krátkodobé cenové skoky, ktoré vytvárajú potrebu čoraz presnejšej predikcie cien a dopytu po elektrickej energii nie len zo strany dodávateľa ale aj ďalších účastníkov trhu, ktorí vstupujú do procesu nákupu a predaja.

*J. Steinberger, M. Zíma, D. Fiala, M. Dostal, M. Nykl (eds.)
Data a znalosti 2017, Plzeň, 5. - 6. října 2017, pp. 162-165.*

Cieľom tohto článku je nielen ukážka prístupu predikcie spojitej premennej, ktorá sa vyznačuje krátkodobými a rapidnými zmenami vo vývoji ale aj navrhnutie vylepšení v tomto unikátnom prístupe k predikcii. Predpovedanie tohto javu má za cieľ zvýšiť presnosť celkovej predikcie.

2 Predikcia spotových cien a krátkodobých skokov

Od roku 2000, kedy vzrástol záujem o výskum v oblasti predpovede spotových cien elektriny sa začali využívať rôzne modely na tvorbu predikčných nástrojov, medzi ktoré patria multi-agentové systémy, fundamentálne modely, reduced-form modely, štatistické modely a modely založené na umelej inteligencii [1]. V zásade delíme práce na tie, ktoré sa zaoberajú celkovou predikciou spotových cien elektriny [5–7] a tie, ktoré predpovedaním cenových skokov získavajú určitú výhodu pri celkovej predikcii cien [4,8,9].

Zpracovanie predikcie cenových skokov do celkovej predikcie spotových cien elektriny sa ukázalo ako správny krok v dosahovaní cieľov predikčnej úlohy aj keď efekt predikcie krátkodobých skokov na presnosť finálneho riešenia je zatiaľ iba marginálny z dôvodu náročnosti správnej identifikácie cenových skokov [10] [11]. Množina dostupných prístupov identifikácie krátkodobých skokov je dominantná nasledujúcou identifikáciou [4][11]:

$$P_{prah} = \mu + 2\delta \quad (1)$$

Kde P_{prah} reprezentuje prahovú cenu, μ reprezentuje priemer hodnoty ceny (zväčša priemer cien z predchádzajúceho roka), δ je smerodajná odchýlka hodnôt časového radu. Okrem tohto prístupu identifikácie môžeme spozorovať aj identifikáciu krátkodobých skokov pomocou fixného prahu, prahu stanoveného fixnou alebo variabilnou percentuálnou zmenou ceny, identifikáciou skokov pomocou wavelet transformácie a iné [9].

V práci [4] sa krátkodobé skoky identifikovali prístupom (1) a natrénovali tri dopredné neurónové siete (ANN), pričom jedna ANN slúžila ako klasifikátor skokov a zvyšné dva predpovedali hodnoty časového radu. V práci [8] s rovnakou identifikáciou skokov sa autori zamerali aj na tvorbu atribútov ako je existencia skoku 24 hodín pred predpoveďou alebo zachytávanie informácie o počte skokov v určitom intervale.

V našom návrhu sa zameriavame na automatizáciu identifikácie krátkodobých cenových skokov a na využitie sekvenčnej informácie časového radu v hybridnom predikčnom modeli. Máme za cieľ transformovať časový rad spôsobom, ktorý by mal napomôcť efektívnejšie extrahovať sekvenčnú informáciu z časového radu, čo by v konečnom dôsledku mohlo pozitívne vplyvať na presnosť finálneho predikčného modelu.

3 Návrh

Náš výskum je v počiatočnom štádiu, čo znamená, že úspešnosť navrhovaného prístupu sa bude v blízkej budúcnosti overovať na reálnych dátach.

Hlavnou myšlienkou tohto návrhu je separácia a reprezentácia časového radu spôsobom, ktorý zefektívni extrakciu sekvenčnej informácie z časového radu a využije danú informáciu vo finálnej predikcii s cieľom zvýšiť presnosť finálneho predikčného modelu.

Vhodná separácia úsekov časového radu, vyznačujúcich sa odlišným vývojom, môže vytvárať príležitosť špecializovať predikčné modely na tieto úseky a takto pozitívne ovplyvňovať schopnosť vyhnúť sa nedoučeniu algoritmu v problémových častiach časového radu. V doméne elektriny, vhodnou aplikáciou separácie skokového vývoja ceny od vývoja bez skokov, môžeme pozitívne ovplyvniť presnosť predikčného modelu vo fázach trhu, ktoré sa vyznačujú prudkými krátkodobými skokmi.

Nová reprezentácia časového radu vznikne zgrupovaním podobných hodnôt časového radu do zhlukov. Zaradenie hodnôt časového radu do tried sa prvotne vykoná zhlukovacím algoritmom, kde finálny počet zhlukov určuje počet potrebných predikčných modelov zameraných na predikciu rozdielnych úsekov časového radu. Správnym zaradením cien do zhlukov získame možnosť špecializovať predikčné modely na určité úseky časového radu, čo by malo pozitívne ovplyvniť modelovanie cien v prudkých krátkodobých zmenách predikovanej premennej. Identifikácia skokov vykonaná zgrupovaním cien podľa podobnosti má výhodu oproti identifikačným metódam popísaných v kapitole 2 z dôvodu schopnosti naučenia sa reprezentácie skoku samotným algoritmom, čím sa vytratí potreba manuálne definovať krátkodobé skoky. Výsledkom identifikačnej fázy je transformovaný časový rad popisujúci sekvenciu úsekov pôvodného časového radu.

Transformovaný časový rad sa stáva vstupnou množinou pre natrénovanie rekurentnej neurónovej siete RNN-LSTM (Long Short Term Memory) s konečným cieľom extrahovania a využitia sekvenčnej informácie z novej reprezentácie časového radu. Finálna predikcia sa stanoví kombináciou jednotlivých predikčných modelov, modelov dedikovaných pre predikciu určitých časových úsekov a rekurentnej neurónovej siete, ktorá predpovedá sekvenciu týchto úsekov.

Finálne riešenie má za cieľ dosiahnuť presnejšie výsledky v podobe zmenšenia priemernej absolútnej percentuálnej chyby ako riešenie bez navrhovaných zmien, teda i) bez využitia zhlukovania pri extrakcii sekvenčnej informácie vo finálnej predikcii a ii) bez využitia sekvenčnej informácie vo finálnej predikcii. Prínos návrhu je v automatickej identifikácii krátkodobých skokov, v reprezentácii časového radu pomocou úsekov a v snahe o zefektívnenie extrakcie sekvenčnej informácie v časovom rade.

4 Záver

V tejto práci sme sa zamerali na dôležitosť problému predikcie spotových cien elektriny, poukázali na možný spôsob riešenia krátkodobých skokov a navrhli sme vylepšenia doterajšieho prístupu k predikcii v doméne cien elektriny. Veríme, že navrhova-

né zmeny v predspracovaní a v modelovaní budú viesť k dosiahnutiu presnejších výsledkov. Overenie prínosu týchto návrhov je ďalším krokom v našom výskume.

Literatúra

1. Weron, R. : Electricity price forecasting: A review of the state-of-the-art with a look into the future, *Int. J. Forecast.* 30 (2014) 1030–1081.
2. European Wind Energy Association : Wind Energy and Electricity Prices Exploring the “merit order effect” (n.d.). <http://www.ewea.org/fileadmin/files/library/publications/reports/MeritOrder.pdf> (cit 16. máj 2017).
3. Weron, R. : Modeling and forecasting electricity loads and prices: A statistical approach, Chichester, 2006.
4. Sandhu, H.S., Fang, L., Guan, L. : Forecasting day-ahead price spikes for the Ontario electricity market, *Electr. Power Syst. Res.* 141 (2016) 450–459.
5. Lahouar, A., Slama, J.B.H. : Comparative study of learning machine predictors for half-hour and day-ahead electricity price forecast in deregulated markets, v: 2016 7th Int. Renew. Energy Congr., IEEE, 2016: s. 1–6.
6. Shiri, A., Afshar, M., Rahimi-Kian, A., Maham, B. : Electricity price forecasting using Support Vector Machines by considering oil and natural gas price impacts, v: 2015 IEEE Int. Conf. Smart Energy Grid Eng., IEEE, 2015: s. 1–5.
7. Dudek, G. : Multilayer perceptron for GEFCom2014 probabilistic electricity price forecasting, *Int. J. Forecast.* 32 (2016) 1057–1060.
8. Amjady, N., Keynia, F. : A new prediction strategy for price spike forecasting of day-ahead electricity markets, *Appl. Soft Comput. J.* 11 (2011) 4246–4256.
9. Janczura, J., Truck, S., Weron, R., Wolff, R.C. : Identifying spikes and seasonal components in electricity spot price data: A guide to robust modeling, *Energy Econ.* 38 (2013) 96–110.
10. Christensen, T.M., Hum, A.S., Lindsay, K.A. : Forecasting spikes in electricity prices, *Int. J. Forecast.* 28 (2012) 400–411.
11. Zhao, J.H., Dong, Z.Y., Li, X., Wong, K.P. : A framework for electricity price spike analysis with advanced data mining methods, *IEEE Trans. Power Syst.* 22 (2007) 376–385.
12. Paralič, J. : Objavovanie znalostí v databázach, Košice, 2003.

Annotation:

Prediction of electricity spot prices

In this paper, prediction of electricity spot prices incorporating different way of pre-processing data and prediction of price spikes is briefly described. Proposed enhancements of classic prediction process in electricity domain should improve overall accuracy of prediction. Goal was to separate different phases of development of electricity prices by creating models focusing only on parts of price movement. Phases are defined by probability of price spike occurrences. Proposed improvements of classic prediction method in electricity domain are going to be tested separately in future work.