

Katarzyna Halicka
Politechnika Białostocka

PROGNOZOWANIE CEN ENERGII ELEKTRYCZNEJ Z WYKORZYSTANIEM SSN NA TOWAROWEJ GIEŁDZIE ENERGII SA*

1. Wstęp

Przedsiębiorstwa obrotu i dystrybucji, kupując/sprzedając energię, mogą korzystać z różnych form obrotu. Mogą one zawierać transakcje w segmencie kontraktowym, bilansującym, giełdowym oraz przez inne formy obrotu (kantory energii, platformy internetowe). Wśród przedsiębiorstw obrotu i dystrybucji coraz większą popularnością cieszy się giełda energii.

Prawidłowe przygotowanie oferty giełdowej wymaga znajomości prognozy przyszłego zapotrzebowania na energię oraz jej cen. Obecnie krajowe przedsiębiorstwa obrotu i dystrybucji dysponują z reguły programami komputerowymi prognozującymi zapotrzebowanie na energię elektryczną, nie mają natomiast skutecznych narzędzi prognozowania cen energii.


W artykule zaproponowano wykorzystanie sztucznych sieci neuronowych do prognozowania cen energii elektrycznej na giełdzie energii w Polsce. Początkowo zbudowano trzy predyktory neuronowe mające na wejściu kilkanaście zmiennych objaśniających, a następnie, po wykorzystaniu zbudowanych modeli, wyznaczono prognozy cen energii oraz dokonano oceny jakości otrzymanych prognoz.

2. Zasady funkcjonowania TGE SA

W Polsce działa tylko jedna giełda energii – Towarowa Giełda Energii SA (TGE SA). Jest ona miejscem, gdzie na zasadach wolnorynkowych kupujący

* Artykuł zrealizowano w ramach pracy własnej nr W/WZ/3/02.

i sprzedający finalizują transakcje poprzez aukcję elektroniczną [Halicka, Nazarko, Jurczuk 2003; Jurczuk, Halicka 2003]. Obecnie TGE SA prowadzi trzy rynki (rys. 1). Wśród nich są rynek dnia następnego (RDN), rynek terminowy (RT) i parkiet jednodniowy (PJ).



Rys. 1. Struktura TGE SA
Źródło: opracowanie własne.

Rynek terminowy (*futures*) uruchomiony został jako platforma dająca możliwość zawierania kontraktów terminowych, stanowiących formę efektywnego zarządzania ryzykiem rynkowym [<http://www.polpx.pl...>]. W odróżnieniu od RDN rozliczenie transakcji jest wyłącznie finansowe. Obecnie w obrocie giełdowym znajdują się kontrakty z tygodniowym i miesięcznym okresem wykonania. W fazie obrotu kontraktem na zakończenie każdej sesji jest dokonywane rozliczenie bieżącej wartości kontraktu w stosunku do dziennego kursu rozliczeniowego. W fazie wykonania kontraktu dla każdego dnia dostawy następuje rozliczenie wartości kontraktu ustalonej na podstawie ostatecznego kursu rozliczeniowego w stosunku do kursu referencyjnego ustalonego na RDN (tzw. *fixing* RDN) [<http://www.polpx.pl...>; Szczegółowe ...].

Parkiet jednodniowy jest najpóźniej uruchomionym rynkiem przez giełdę energii. Podobnie jak na rynku RDN realizacja transakcji jest związana z fizyczną dostawą energii. Pojedynczy kontrakt ma charakter pasmowy i opiewa na 72 MWh w dobie wykonania (tj. 3 MWh w każdej godzinie doby). Obrót na tym rynku odbywa się na dwie doby przed dniem dostawy.

Najdłużej, od 1 lipca 2000 r., na giełdzie energii działa rynek dnia następnego (RDN). Składa się on z 24 niezależnych rynków godzinowych, na których uczestnicy mogą kupować i sprzedawać energię elektryczną. Uczestnicy giełdy energii mogą składać oferty już sześć dni przed fizyczną dostawą energii. W praktyce jednak oferty giełdowe są składane w ostatniej chwili przed zamknięciem przyjmowania ofert (przed godz. 8:30). Kilkaście minut po zamknięciu sesji uczestnikom sesji są udostępnione wyniki. Około godz. 13 są one opublikowane na stronie internetowej giełdy energii.

Oferty giełdowe, tzn. zlecenia kupna bądź sprzedaży energii elektrycznej na każdą godzinę doby handlowej, mają formę bloków o zdefiniowanym wolumenie oraz cenie. Bloki zlecenia wytwórcy są ustawiane w kolejności, o której decyduje cena – od ceny najniższej do najwyższej – i tworzą funkcję schodkową, nazywaną profilem podaży. Bloki zlecenia nabycia energii są ustawiane w kolejności zależnej od ceny: od najwyższej do najniższej (profil popytu). Za giełdową cenę


rozliczeniową dla danej godziny handlowej przyjmuje się cenę, w której zachodzi równowaga między popytem a podażą (profile popytu i podaży przecinają się).

Do tworzenia ofert giełdowych jest niezbędna znajomość zapotrzebowania na energię i przyszłych cen energii elektrycznej. W dalszej części artykułu przedstawiono metodykę prognozowania ceny energii na giełdzie energii.

3. Budowa modeli prognostycznych

Do budowy modelu prognozującego cenę energii elektrycznej na giełdzie energii wykorzystano sztucznie sieci neuronowe. Jednym z czynników decydujących o wyborze metody było to, że w konstruowaniu prognozy za pomocą SSN wiedza niezbędna do sporządzenia prognozy ogranicza się do wyboru właściwego rodzaju sieci neuronowej oraz sposobu interpretacji rezultatów [Chraślowska, Halicka 2003; Halicka 2003].

Konstrukcja predyktora neuronowego przebiegała w kilku etapach. Początkowo skonstruowano trzy modele prognostyczne, za pomocą których można wyznaczyć, dzień przed fizyczną dostawą energii, cenę energii elektrycznej dla każdej godziny doby handlowej. Wyróżnia się kilka rodzajów sieci neuronowych, m.in.: RBF – sieci o radialnych funkcjach bazowych, MLP – perceptron wielowarstwowy, PNN – sieci probabilistyczne, GRNN – sieci realizujące uogólnioną regresję [Tadeusiewicz 2001]. Do prognozowania najczęściej stosowane są jednak sieci typu MLP. Dlatego też w budowie modeli prognostycznych wykorzystano perceptron wielowarstwowy MLP (ang. *multilayer perceptron*).



Rys. 2. Podział analizowanych danych

Źródło: opracowanie własne.

Dane wykorzystywane do budowy modeli pochodziły z okresu od 1 stycznia do 30 listopada 2003 r. (rozpatrzono 8017 przypadków). Dane z okresu od 1 grud-

nia do 31 grudnia 2003 r. (744 przypadków) były wykorzystywane do weryfikacji otrzymanych prognoz. Na rysunku 2 przedstawiono podział analizowanych danych.


Podczas budowy modeli testowano sieci neuronowe o różnej architekturze. Podstawowe parametry tych sieci przedstawiono w tab. 1. Wszystkie skonstruowane sieci neuronowe miały jedną warstwę wejściową, jedną wyjściową i dwie warstwy ukryte. Różniły się liczbą zmiennych wejściowych, liczbą neuronów w poszczególnych warstwach oraz metodą uczenia.

Tabela 1. Podstawowe parametry wybranych sieci neuronowych

	MLP 10: 240-39-6-1 :1	MLP 6: 144-27-5-1 :1	MLP 9: 216-37-7-1 :1
Zmienne wejściowe	cena energii, wolumen, prędkość wiatru, opady temperatura, zachmurzenie, prognoza temperatury, prognoza zachmurzenia, prognoza prędkości wiatru, prognoza opadów	cena energii, wolumen, prędkość wiatru, opady temperatura, zachmurzenie	cena energii, wolumen, prędkość wiatru, opady temperatura, zachmurzenie, godzina transakcji, sobota, niedziela
Zmienne wyjściowe	cena energii elektrycznej		
Liczba wejść	10	6	9
Liczba wyjść	1	1	1
Liczba warstw ukrytych	2	2	2
Liczba neuronów w warstwie wejściowej	240	144	216
Liczba neuronów w warstwie ukrytej	I 39 II 6	27 5	37 7
Liczba neuronów w warstwie wyjściowej	1	1	1
Liczba wartości opóźnionych	24	24	24
Czas	24	24	24
Funkcja agregująca	I warstwa (wejściowa): liniowa II warstwa (ukryta): liniowa III warstwa(ukryta): liniowa IV warstwa (wyjściowa): liniowa		
Funkcja aktywacji: I warstwa (wejściowa) II warstwa (ukryta) III warstwa(ukryta) IV warstwa (wyjściowa)	liniowa hiperboliczna hiperboliczna logistyczna	logistyczna logistyczna logistyczna logistyczna	
Metoda uczenia	metoda wstecznej propagacji błędów	I etap uczenia: metoda wstecznej propagacji błędów II etap: metoda gradientów sprzężonych; <i>sieć douczona</i>	I etap uczenia: metoda wstecznej propagacji błędów II etap: metoda gradientów sprzężonych; <i>sieć douczona</i>

Źródło: obliczenia własne.

Pierwszy skonstruowany model miał dziesięć zmiennych na wejściu, na wyjściu zaś – jedną zmienną (rys. 3). Wszystkie zmienne były mierzone dla każdej godziny doby handlowej, np. cena energii elektrycznej dla godziny 1, 2, 3,..., 23, 24. Zmienne określające pogodę (temperatura, prędkość wiatru, opady, zachmurzenie) pochodziły z sześciu stacji metrologicznych w Polsce: z Poznania, Rzeszowa, Suwałk, ze Szczecina, z Warszawy i Wrocławia.




Rys. 3. Budowa pierwszego modelu prognostycznego

Źródło: opracowanie własne.

Zbudowana sieć neuronowa składała się z jednej warstwy wejściowej (mającej 240 neurony), dwóch warstw ukrytych (39 neuronów w pierwszej i 6 neuronów w drugiej warstwie ukrytej) oraz jednej warstwy wyjściowej (1 neuron – zob. tab. 1).


W drugim modelu nie brano pod uwagę zmiennych określających prognozę pogody. Na wejście sieci podano tylko 6 zmiennych (rys. 4).



Rys. 4. Budowa drugiego modelu prognostycznego


Źródło: opracowanie własne.

Do budowy modelu prognostycznego wykorzystującego sztuczne sieci neuronowe nie jest konieczna analiza danych wejściowych, często jednak poprawia ona jakość modelu. Dlatego też trzeci model prognostyczny skonstruowano po wstępnej analizie danych wejściowych.



Rys. 5. Średnia cena energii elektrycznej w zależności od dnia tygodnia i godziny transakcji
Źródło: opracowanie własne.

Na podstawie wizualnej analizy wykresu ceny energii elektrycznej można stwierdzić, że zależy ona od godziny oraz dnia tygodnia, w którym energia jest kupowana/sprzedawana (rys. 5). Na rysunku 5 można wyróżnić trzy profile kształtowania się średniej ceny energii: średnia cena energii elektrycznej w dni robocze, sobotę i niedzielę. Na wejście trzeciego modelu prognostycznego wprowadzono trzy dodatkowe zmienne, określające odpowiednio dzień tygodnia (nazwano je *sobota* i *niedziela*) oraz godzinę transakcji (rys. 6).



Rys. 6. Budowa trzeciego modelu prognostycznego
Źródło: opracowanie własne.

Na podstawie tak skonstruowanych modeli prognostycznych wyznaczono prognozy ceny energii elektrycznej, a następnie dokonano oceny jej trafności.

4. Ocena jakości prognozy

Po skorzystaniu z trzech predyktorów neuronowych (MLP 10:240-39-6-1:1, MLP 6:144-27-5-1:1, MLP 9:216-37-7-1:1) wyznaczono cenę energii elektrycznej w poszczególnych godzinach dla całego grudnia 2004 r. Uzyskane wyniki porównano z wartościami rzeczywistymi cen energii elektrycznej w tym okresie, dokonano weryfikacji zbudowanej prognozy (tab. 2).

Tabela 2. Ocena trafności prognoz wyznaczonych dla grudnia 2003 r.

	MLP 10: 240-39-6-1 :1 ↓	MLP 6: 144-27-5-1 :1	MLP 9: 216-37-7-1 :1 ↑
ME	-1,87 zł	-0,94 zł	-0,12 zł
MAE	7,44 zł	6,53 zł	1,56 zł
RMSE	10,56 zł	8,55 zł	2,12 zł
MAPE	7,59%	6,56%	1,55 %
MdAPE	4,97%	4,85%	1,13%

Źródło: obliczenia własne wykonane za pomocą programu Statistica Neural Network™ PL.


W ocenie trafności prognoz brano pod uwagę następujące statystyki:

- ME (ang. *mean error*) – średni błąd prognozy *ex post*,
- MAE (ang. *mean absolute error*) – średnia wartość modułu błędu prognozy *ex post*,
- RMSE (ang. *root mean square error*) – pierwiastek ze średniego kwadratowego błędu prognozy *ex post*,
- MAPE (ang. *mean absolute percentage error*) – średni błąd procentowy,
- MdAPE (ang. *median absolute percentage error*) – wartość środkowa modułu procentowego błędu prognozy.

Analizując otrzymane wyniki, można zauważyć, że największe wartości błędów otrzymano w sieci mającej dziesięć zmiennych na wejściu (MLP 10:240-39-6-1:1), zatem wprowadzenie do modelu dodatkowych zmiennych określających prognozę pogody znacznie pogorszyło jakość prognozy. Najmniejsze wartości błędów otrzymano w przypadku sieci neuronowej mającej na wejściu dziewięć zmiennych (MLP 9:216-37-7-1:1). Przeprowadzenie analizy danych i uwzględnienie zależności ceny energii od dnia tygodnia, w którym jest kupowana/sprzedawana, znacznie poprawiło jakość prognozy. W tym przypadku przeciętne odchylenia prognoz cen energii od wartości rzeczywistych wynoszą zaledwie 2,12 zł. Stanowi to ok. 1,55% zmiennej prognozowanej. Nieznaczna różnica, wynosząca 0,56 zł, pomiędzy średnią wartością modułu błędu prognozy (MAE) a pierwiastkiem ze średniego kwadratowego błędu prognozy (RMSE) wynika z własności tych dwóch miar. Bliska zeru wartość średniego błędu prognozy (ME) świadczy, że model ani systematycz-

nie nie doszacowuje, ani nie przeszacowuje wartości prognoz. Prognoza otrzymana za pomocą tego modelu nie jest obciążona błędem systematycznym. Biorąc pod uwagę wartości błędów, uzyskane wyniki obliczeń można uznać za zadowalające.

Dopasowanie modelu można również ocenić wizualnie. Na rysunku 7 przedstawiono wartości rzeczywiste oraz prognozy cen energii elektrycznej na TGE SA.



Rys. 7. Wartości rzeczywiste oraz prognozy cen energii elektrycznej na TGE SA w grudniu 2004 r.

Źródło: opracowanie własne

Po dokonaniu wstępnej oceny rys. 7 można zauważyć, że otrzymane prognozy są bliskie wartościom rzeczywistym cen energii, zatem model jest dobrze dopasowany do danych rzeczywistych.

5. Wnioski

W artykule przedstawiono zastosowanie sztucznych sieci neuronowych do prognozowania cen energii elektrycznej na giełdzie energii. Otrzymane wyniki (niewielka wartość średniego modułu względnego błędu prognozy, nieznaczące odchylenie wartości rzeczywistej od wartości prognozowanej) dowodzą, że sztuczne sieci neuronowe mogą być użytecznym narzędziem prognozowania, znajdującym zastosowanie w praktyce.

Należy podkreślić, że w budowie modelu SSN nie była wymagana analiza danych dotyczących ceny energii i wolumenu obrotów na giełdzie energii, jednak przeprowadzenie takiej analizy i uwzględnienie jej wyników w budowie modelu znacznie poprawiło jakość prognozy.

Niepodważalną zaletą sztucznych sieci neuronowych jest to, że zastosowania raz wytrenowanej sieci jest bardzo proste i szybkie. Aby wykorzystać wyuczoną sieć neuronową, nie trzeba mieć wiedzy z dziedziny metod sztucznej inteligencji.

Jest to istotne dla przedsiębiorstw energetycznych, które do działu obrotu energią elektryczną nie muszą zatrudniać wyspecjalizowanych analityków z dziedziny sztucznej inteligencji.

Oprócz licznych, wspomnianych w artykule, zalet sieci neuronowych należy również wspomnieć o kilku wadach tych sieci. Do konstrukcji oraz trenowania sieci konieczna jest szczegółowa wiedza z dziedziny metod sztucznej inteligencji. Poza tym trenowanie sieci neuronowych wykorzystywanych do prognozowania jest często czasochłonne. Na przykład sieci wykorzystane w artykule były trenowane średnio ok. 4 godz. Ponadto sieci neuronowe nie wskazują na wewnętrzną strukturę badanego szeregu i nie objaśniają mechanizmów jego generowania. Mimo wspomnianych wad, sieci neuronowe są chętnie wykorzystywane do prognozowania.

Podsumowując przeprowadzone badania, należy zauważyć, że przedsiębiorstwo energetyczne, które chce się utrzymać się na rynku i osiągnąć przewagę konkurencyjną, może z powodzeniem prognozować cenę energii elektrycznej dzięki wykorzystaniu sztucznych sieci neuronowych.

Literatura

- Chrabołowska J., Halicka K., *Prognozowanie wielkości przychodów ze sprzedaży z wykorzystaniem SSN oraz modeli ARIMA*, Zeszyt Naukowy nr 8 Wydziału Zarządzania Politechniki Białostockiej, „Ekonomia i Zarządzanie”, Białystok 2003, s. 103-117.
- Halicka K., *Prognozowanie wielkości sprzedaży z wykorzystaniem SSN*, [w:] *Komputerowo zintegrowane zarządzanie*, red. R. Knosala, t. 1, Wydawnictwo Naukowo-Techniczne, Warszawa 2003, s. 368-375.
- Halicka K., Nazarko J., Jurczuk A., *Zarządzanie portfelem zakupów na rynku dnia następnego*, „Zagadnienia Techniczno-Ekonomiczne”, kwartalnik AGH, t. 48, z. 1, Kraków 2003, s. 111-123.
- <http://www.polpx.pl>, 10 lipca 2004 r.
- Jurczuk A., Halicka K., *Present Situation of the Polish Energy Market*, Proceedings of Seminar „Technology evolution for future European markets”, PR5 EU, Wielka Brytania-Rumunia 2003, s. 18-25.
- Regulamin Towarowej Giełdy Energii SA, tekst jednolity uchwalony Uchwałą Rady Nadzorczej nr 88/23/II/03 z dnia 15 grudnia 2003 r., zmiany zatwierdzone Uchwałą Rady Nadzorczej nr 90/24/II/03 z dnia 30 grudnia 2003 r.
- Szczegółowe zasady obrotu i rozliczeń dla energii elektrycznej na rynku dnia następnego, Towarowa Giełda Energii SA, zmiany zatwierdzone uchwałą Zarządu nr 60/37/2003 z dnia 31 października 2003 r. wchodzi w życie w dniu 17 listopada 2003 r.
- Tadeusiewicz R., *Wprowadzenie do sieci neuronowych*, Statsoft Polska, Kraków 2001.

FORECAST OF ENERGY PRICES ON POLISH POWER EXCHANGE WITH USE OF NEURAL NETWORK

Summary

In this paper the use of neural network to forecast prices of energy on Polish Power Exchange is presented. Three prognostic models, with different input variables and number of neurons in layers, were build. The following variables were used in the neural network as input: demand for energy, air temperature, wind speed, cloud conditions and rainfall. On the basis of constructed models the prediction of energy prices was done and then evaluation of forecasts quality was performed.