

Joanna EJDYS, Katarzyna HALICKA
Politechnika Białostocka
Wydział Zarządzania
j.ejdys@pb.edu.pl, k.halicka@pb.edu.pl

Justyna GODLEWSKA
Multi Packaging Solutions Białystok Sp. z o.o.
godlewskajustyna@wp.pl

PROGNOZOWANIE CEN ENERGII ELEKTRYCZNEJ NA GIEŁDZIE ENERGII

Streszczenie. Zasadniczym celem artykułu było wyznaczenie prognozy ceny energii elektrycznej na Rynku Dnia Następnego Towarowej Giełdy Energii. Kolejnym istotnym celem badań było przeprowadzenie analizy porównawczej jakości otrzymanych prognoz i dokonanie rekomendacji zbudowanych modeli prognostycznych.

Początkowo przeanalizowano zebrane dane, przeprowadzono dekompozycję analizowanego szeregu czasowego. Następnie wyznaczono prognozę ceny energii elektrycznej na giełdzie energii, wykorzystując takie metody, jak model Holta-Wintersa oraz sztuczne sieci neuronowe.

Słowa kluczowe: prognozowanie, giełda energii, cena energii, model Holta-Wintersa, sztuczne sieci neuronowe.

FORECASTING THE PRICE OF ELECTRICITY ON THE ENERGY EXCHANGE

Summary. The main objective of this paper was to determine the forecast of the price of electricity on the POLPX Day Ahead Market. Another important aim of the study was to conduct a comparative analysis of the quality of the forecasts and make recommendations concerning the constructed forecasting models.

Initially the collected data was analyzed, and the decomposition of the analyzed time series was performed. Then the forecast of electricity prices on the energy exchange was determined using methods such as the Holt-Winters model and artificial neural networks.

Keywords: forecasting, energy exchange, energy price, model Holt-Winters, artificial neural networks.

1. Wprowadzenie

Historia kształtowania się rynków energii nie jest długa i wiąże się z pojawieniem się zapotrzebowania na energię elektryczną, na paliwa do silników spalinowych oraz na ciepło pochodzące ze źródeł scentralizowanych. W Polsce przełomowym momentem w dążeniu do pełnej liberalizacji sektora elektroenergetycznego było uruchomienie pod koniec 1999 roku Towarowej Giełdy Energii S.A. Jednym z zasadniczych zadań giełdy energii elektrycznej jest umożliwienie uczestnikom rynku dostępu do informacji o kształtowaniu się cen energii elektrycznej. Na podstawie tej wiedzy, a także przez jej zgłębianie w kontekście charakteru zjawiska oraz czynników na nie wpływających uzyskuje się podstawę do prognozowania przyszłych wartości cen energii elektrycznej. Prawdopodobnie wyznaczona prognoza może być kluczowym czynnikiem ułatwiającym podjęcie decyzji i może też wskazywać kierunek podejmowanych działań.

Zasadniczym celem badań przeprowadzonych w ramach niniejszego artykułu jest wyznaczenie prognozowanej ceny energii elektrycznej na Rynku Dnia Następnego TGE S.A. na dzień 1 maja 2013 roku. Celem szczegółowym jest wykorzystanie zarówno metod klasycznych, jak i metod sztucznej inteligencji do prognozowania cen energii elektrycznej oraz zarekomendowanie metody najlepiej dopasowanej do danych rzeczywistych.

W celu wyznaczenia krótkookresowej prognozy cen energii elektrycznej na Rynku Dnia Następnego TGE S.A. wykorzystano dane historyczne dotyczące cen energii elektrycznej (PLN/MWh). Analizowane dane pochodziły z okresu od 1 stycznia 2012 roku do 30 kwietnia 2013 r. Na RDN notowania odbywają się w systemie kursu jednolitego: fixing 1, fixing 2, fixing 3, oraz w systemie notowań ciągłych. Po obliczeniu całkowitego wolumenu sprzedaży energii elektrycznej dla każdego rodzaju notowań w analizowanym okresie zauważono, że najwięcej energii sprzedano w systemie fixingu 1, dlatego też prognozę ceny energii elektrycznej wyznaczono dla tego notowania.

2. Metodologia

Prognozowanie cen na konkurencyjnych rynkach energii elektrycznej ma kluczowe znaczenie dla konsumentów i producentów w planowaniu działań i zarządzaniu ryzykiem cenowym, a także odgrywa znaczącą rolę w ekonomicznej optymalizacji w sektorze energii elektrycznej¹. Przeglądając literaturę, zauważono, że wielu autorów w swych opracowaniach podejmowało próby wyznaczenia prognozy ceny energii elektrycznej przy wykorzystaniu

¹ P. Mandal, T. Senjyu, N. Urasaki, T. Funabashi, A. Srivastava: A Novel Approach to Forecast Electricity Price for PJM Using Neural Network and Similar Days Method. IEEE Transactions on Power Systems, Nov2007, Vol. 22, Issue 4, p. 2058-2065.

różnych metod. Skuteczne narzędzie prognostyczne powinno uchwycić długoterminowe współzależności w historycznych danych rynkowych^{2,3}. Do prognozowania cen energii elektrycznej wykorzystywano między innymi modele ARIMA⁴, modele klasy Garch⁵, sztuczne sieci neuronowe⁶. Ostatnie badania wykazały, że skutecznym narzędziem prognozowania cen energii elektrycznej jest także funkcjonalna analiza głównych składowych (FPCA)⁷.

W niniejszym artykule do wyznaczenia ceny energii elektrycznej na giełdzie energii autorki wykorzystywały zarówno metody klasyczne, tj. multiplikatywny model Holta-Wintersa, dla szeregu czasowego z tendencją rozwojową oraz wahaniami sezonowymi, jak i metodę sztucznych sieci neuronowych – perceptron wielowarstwowy (MLP – Multi Layer Perceptron). Bardzo ważnym elementem przeprowadzonego badania jest szczegółowa analiza porównawcza błędów otrzymanych prognoz.

Model Holta-Wintersa należy do grupy metod wygładzania wykładniczego. Wygładzanie (lub inaczej wyrównywanie) wykładnicze jest jednym ze sposobów wyznaczania prognoz krótkookresowych. Charakterystyczną cechą tej metody jest ciągłe uaktualnianie prognoz wraz z pojawieniem się nowych informacji o zaobserwowanych wartościach zmiennej prognozowanej oraz o trafności prognoz wcześniejszych. Przyszłe wartości zmiennej są ustalane na podstawie średniej ważonej wszystkich dotychczasowych obserwacji. Wagi dobierane są zgodnie z zasadą, że wartość informacyjna obserwacji maleje wykładniczo wraz z upływem czasu.

Wygładzanie wykładnicze może być oparte na różnych modelach, odpowiednich do rodzaju składowych danego szeregu czasowego. W przeprowadzonym badaniu ze względu na charakter składowych analizowanego szeregu czasowego (wahań sezonowych o rosnącej amplitudzie i tygodniowym cyklu sezonowym, malejącego trendu liniowego oraz wahań przypadkowych) zdecydowano się na użycie multiplikatywnej wersji modelu Holta-Wintersa⁸.

Kolejną wykorzystaną metodą były sztuczne sieci neuronowe (SSN). Sztuczna sieć jest zbiorem wzajemnie połączonych elementów nazywanych neuronami. Sztuczny neuron można

² A. Arash, A. Farid: Multi-step ahead forecasts for electricity prices using NARX: A new approach, a critical analysis of one-step ahead forecasts. *Energy Conversion & Management*, Mar2009, Vol. 50, Issue 3, p. 739-747.

³ Y. Dong, J. Wang, H. Jiang, J. Wu: Short-term electricity price forecast based on the improved hybrid model. *Energy Conversion & Management*, Aug2011, Vol. 52, Issue 8/9, p. 2987-2995.

⁴ J. Contreras, R. Espinola, F.J. Nogales, A.J. Conejo: ARIMA Models to Predict Next-Day Electricity Prices. *IEEE transactions on power systems*, Vol. 18, No. 3, August 2003, p. 1014-1020.

⁵ R.C. Garcia, J. Contreras, M. Akkeren, J.B. Garcia: A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices. *IEEE transactions on power systems*, Vol. 20, No. 2, May 2005, p. 867-874.

⁶ D. Menniti, N. Scordino, N. Sorrentino: A Novel Approach to Forecast Day-Ahead Electricity Prices by Means of Neural Networks Using Groups of Similar Hours; *International Review of Electrical Engineering (I.R.E.E.)*, Vol. 7, No. 4, July – August 2012, p. 5119-5133.

⁷ H.C. Wu, S.C. Chan, K.M. Tsui, Y. Hou: A New Recursive Dynamic Factor Analysis for Point and Interval Forecast of Electricity Price. *IEEE Transactions on Power Systems*, Aug2013, Vol. 28, Issue 3, p. 2352-2365.

⁸ J. Nazarko (red.): Prognozowanie w zarządzaniu przedsiębiorstwem. Cz. III, Prognozowanie na podstawie modeli adaptacyjnych. Wydawnictwo Politechniki Białostockiej, Białystok 2005, s. 36.

postrzegać jako prosty system przetwarzania wartości sygnałów wprowadzanych na jego wejścia w pojedynczą wartość wyjściową, wysyłaną na jego jedynym wyjściu. Sieć uczy się działać prawidłowo na podstawie przedstawianych jej przykładów realizacji badanych obiektów bądź zjawisk. Opierając się na prezentowanych rzeczywistych przypadkach, sieć stara się odkryć i zapamiętać ogólne prawidłowości cechujące te obiekty bądź kierujące przebiegiem analizowanych zjawisk. Sztuczna sieć neuronowa przechowuje rozpoznane reguły w postaci zakodowanej w wartościach współczynników wagowych neuronów.

Wykorzystany w niniejszym opracowaniu perceptron wielowarstwowy to jednolita, wielowarstwowa, jednokierunkowa sieć o nieliniowych funkcjach aktywacji. Jedyną różnicą w działaniu poszczególnych warstw polega na rodzaju funkcji aktywacji. Argumentem przemawiającym za wyborem SSN jest fakt, że są one bardzo skutecznym narzędziem prognostycznym ze względu na swoją zdolność do generalizacji wiedzy dla nowych danych⁹. Ponadto sztuczne sieci neuronowe nie wymagają programowania, ponieważ wykorzystują proces uczenia i mogą być stosowane wszędzie tam, gdzie algorytm rozwiązania zadania nie jest do końca znany lub musi być często i szybko modyfikowany.

3. Wyniki badań

Pierwszą metodą wykorzystaną w celu wyznaczenia ceny energii elektrycznej był model multiplikatywny Holta-Wintersa. Jest on stosowany, gdy w szeregu czasowym relacje między składowymi systematycznymi są wyrażone iloczynem. Model multiplikatywny jest opisany równaniem¹⁰:

$$y_{t+m}^* = (L_t + b_t m) S_{t-s+m} \quad (1)$$

gdzie:

y_{t+m}^* – prognoza zmiennej Y wyznaczona na moment lub okres $t+m$,

L_t – wygładzona ocena wartości poziomu szeregu na moment lub okres t ,

b_t – wygładzona ocena wartości przyrostu trendu szeregu na moment lub okres t ,

S_{t-s+m} – wygładzona ocena wartości wskaźnika sezonowości na moment lub okres $t-s+m$,

s – długość cyklu sezonowego (liczba faz w cyklu sezonowym).

Wartości poszczególnych składowych wyznacza się przy wykorzystaniu wzorów opartych na modelu prostego wygładzania wykładniczego¹¹:

⁹ K. Halicka: Ocena skuteczności prognozowania na giełdzie energii, Przegląd Elektrotechniczny, 2010, nr 4, s. 322.

¹⁰ J. Nazarko (red.): Prognozowanie w zarządzaniu..., op.cit., s. 38.

¹¹ Ibidem, s. 37.

$$L_t = \alpha \frac{y_t}{S_{t-s}} + (1-\alpha)(L_{t-1} + b_{t-1}) \quad (2)$$

$$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1} \quad (3)$$

$$S_t = \gamma \frac{y_t}{L_t} + (1-\gamma)S_{t-s} \quad (4)$$

gdzie α , β , γ – parametry modelu o wartościach z przedziału (0,1).

Zgodnie z zastosowaną metodą prognoza ceny energii elektrycznej za 1 MWh wyznaczona na dzień 01.05.2013 r. wyniosła 147,78 PLN. Wartość średniego modułu względnego błędu prognozy (MAPE) wynosi 37,32%, natomiast pierwiastek ze średniokwadratowego błędu prognozy *ex post* osiąga wartość 76,44 PLN.

Drugą użytą metodą prognostyczną były sztuczne sieci neuronowe. Do wyznaczenia prognozy ceny energii elektrycznej tą metodą posłużono się programem STATISTICA. Wytrenowano pięć sieci typu MLP i wybrano sieć charakteryzującą się najwyższą jakością uczenia i testowania. Następnie oceniono ich trafność, porównano uzyskane wyniki i wskazano sieć, która pozwoliła uzyskać prognozę obarczoną najmniejszymi błędami (tabela 1). Zauważono, że sieć numer 4 jest najlepszą siecią ze względu na przyjęte założenia, czyli spełnia kryteria najlepszej jakości uczenia, testowej w odniesieniu do czterech pozostałych sieci. Wyniki wytrenowania pięciu sieci przedstawiono w tabeli 1.


Tabela 1

Podsumowanie wytrenowanych sieci neuronowych typu MLP

Nr	Jakość	Jakość (testowanie)	Błąd (uczenia)	Błąd (testowania)
1	0,705743	0,726399	374,1666	443,6428
2	0,897847	0,907034	536,7164	689,0615
3	0,768062	0,800290	305,9172	340,6653
4	0,938556	0,950492	87,0137	88,9143
5	0,759299	0,785008	371,0568	440,0824

Źródło: opracowanie własne przy wykorzystaniu oprogramowania STATISTICA.

Po wyborze najlepszej sieci przeanalizowano ją pod kątem jej trafności. Prognoza ceny energii elektrycznej za 1 MWh wyznaczona na dzień 01.05.2013 r. za pomocą sztucznych sieci neuronowych wyniosła 173,17 PLN. Przeciętnie prognoza różniła się od wartości rzeczywistej o 13,12 PLN (błąd RMSE), co stanowi 4,71% (błąd MAPE) wartości rzeczywistej. Wartości rzeczywiste oraz wartości prognozowane dla arbitralnie wybranego tygodnia zaprezentowano na rysunku 1.



Rys. 1. Cena oraz prognoza ceny energii elektrycznej na giełdzie energii w okresie od 24.04.2013 r. do 30.04.2013 r.

Fig. 1. Price and forecast prices of electricity on the power exchange in the period from 24.04.2013 to 30.04.2013

Źródło: opracowanie własne.

Dokonując analizy wizualnej prognozy uzyskanej przy wykorzystaniu sztucznych sieci neuronowych, można stwierdzić, że wartości prognozowane bardzo dobrze odwzorowują wartości rzeczywiste. Kształt wykresu prognozy pokrywa się z kształtem wykresu obserwacji.

4. Dyskusja wyników

W celu oceny trafności wyznaczonych prognoz wzięto pod uwagę następujące miary^{12,13}:

- ME (ang. Mean Error) – błąd średni,
- MAE (ang. Mean Absolute Error) – średnia z modułu błędu,
- max AE (ang. Maximum Absolute Error) – maksymalny błąd bezwzględny,
- RMSE (ang. Root Mean Square Error) – pierwiastek ze średniego kwadratowego błędu,
- MAPE (ang. Mean Absolute Percentage Error) – średni względny błąd,
- MdAPE (ang. Median Absolute Percentage Error) – mediana względnego błędu,
- max APE (ang. Maximum Absolute Percentage Error) – maksymalny względny błąd.

¹² E. Chodakowska, K. Halicka, A. Kononiuk, J. Nazarko: Prognozowanie cen energii elektrycznej na Towarowej Giełdzie Energii SA z wykorzystaniem modeli ARIMA, [w:] Technologie informatyczne i prognozowanie w zarządzaniu: wybrane zagadnienia, J. Nazarko, L. Kiełtyka (red.), Wydawnictwo Politechniki Białostockiej, Białystok 2005, s. 240.

¹³ K. Halicka, C. Wieńkowski: Wykorzystanie metod wygładzania wykładniczego do prognozowania kursu sprzedaży EUR. *Ekonomia i Zarządzanie*, Oficyna Wydawnicza Politechniki Białostockiej, Białystok. T. 5, nr 2 (2013) s. 77.

Powyższe błędy zostały obliczone dla całego analizowanego okresu, tj. od 01.01.2012 r. do 30.04.2013 r., i przedstawiono je w tabeli 2.

Tabela 2

Błędy prognoz

Błędy	Model Holta-Wintersa	Sieć MLP 7-2-1
ME	-0,75 PLN	-0,02 PLN
MAE	59,39 PLN	7,93 PLN
max AE	1004,35 PLN	300,05 PLN
MAPE	37,32%	4,71%
RMSE	76,44 PLN	13,12 PLN
MdAPE	30,48%	3,07%
max APE	282,12%	50,03%

Źródło: opracowanie własne.

Analizując otrzymane wyniki, można stwierdzić, że model prognostyczny opracowany przy użyciu metody Holta-Wintersa nie jest dobrze dopasowany do danych. Znacznie różniąc się od 0 wartość błędu MAE świadczy o tym, że występuje systematyczne przeszacowanie prognozy. Wysoka wartość pierwiastka ze średniego kwadratowego błędu wskazuje na wysokie przeciętne odchylenia prognoz od wartości rzeczywistych. Z kolei średnie odchylenie od wartości rzeczywistych (błąd MAPE) w całym analizowanym okresie stanowi aż 37,32% wartości rzeczywistej. Wysoka wartość maksymalnych błędów – max AE i max APE – świadczy o tym, że wartości otrzymane z modelu znacznie odbiegają od wartości rzeczywistych.

Na podstawie wyników uzyskanych za pomocą sztucznych sieci neuronowych stwierdzono, że zbudowany model prognostyczny jest dobrze dobrany do danych. Nieznacznie różniąc się od 0 wartość błędu MAE świadczy o tym, że nie występuje systematyczne przeszacowanie bądź niedoszacowanie prognozy. Pierwiastek ze średniego kwadratowego błędu wskazuje na niewielkie przeciętne odchylenia prognoz od wartości rzeczywistych. Średnie odchylenie od wartości rzeczywistych w całym analizowanym okresie stanowi zaledwie 4,71% wartości rzeczywistej, jednakże zdarzają się sytuacje, w których wartości uzyskane z modelu znacznie różnią się od wartości rzeczywistych, na co wskazują wysoka wartość błędów – max AE i max APE.

5. Wnioski

Celem badania było wyznaczenie prognozy ceny energii elektrycznej Rynku Dnia Następnego giełdy energii. Rynek Dnia Następnego składa się z 24-godzinowych rynków, na których notowane są po jednym rodzaju kontraktu godzinowego, dlatego też prognoza została wyznaczona z horyzontem równym 24. Zatem należało wybrać metody prognostyczne, które umożliwiają prognozowanie z większym niż jednokrokovym horyzontem czasowym.

Pierwszą zastosowaną metodą była metoda wygładzania wykładniczego – model Holta-Wintersa. Zdecydowano się na nią, ponieważ składowe analizowanego szeregu czasowego są odpowiednie dla tej metody, a ponadto umożliwia ona prognozowanie z większym niż jednokrokovym horyzontem czasowym.

Kolejną metodą były sztuczne sieci neuronowe. Do wyznaczenia prognozy wybrano sieć typu MLP. Za wyborem tej metody przemawiało wiele argumentów, a między innymi fakt, że jest to metoda szybka w stosowaniu.

Ponadto postanowiono skonfrontować dwa różne rodzaje metod, aby móc wybrać lepszą w przypadku prognozowania zmiennej, jaką jest cena energii elektrycznej.

Prognoza wyznaczona z wykorzystaniem modelu Holta-Wintersa była obciążona bardzo dużymi błędami, znacznie przekraczającymi przeciętne – średnie odchylenie od wartości rzeczywistych w całym analizowanym okresie stanowiło aż 37,32% wartości rzeczywistej. Duże błędy mogły być spowodowane koniecznością przyjęcia za wartości rzeczywiste wartości prognoz wygasłych.

Natomiast prognoza wyznaczona przy użyciu sztucznych sieci neuronowych charakteryzuje się niewielkimi błędami – średnie odchylenie od wartości rzeczywistych w całym analizowanym okresie stanowiło zaledwie 4,71% wartości rzeczywistej. Ponadto analiza wizualna wyznaczonej prognozy potwierdziła dobre dopasowanie modelu do danych.

W kontekście uzyskanych wyników do prognozowania ceny energii elektrycznej autorki rekomendują stosowanie sztucznych sieci neuronowych. Ponadto jednorazowo wytrenowana sieć może być wielokrotnie wykorzystywana. Sztuczne sieci neuronowe są metodą uniwersalną i cechują się zdolnością do generalizowania zdobytej wiedzy.

Podsumowując, można stwierdzić, że cel badania został osiągnięty, wyznaczono prognozę ceny energii elektrycznej, wykorzystując dwie różne metody. Tylko jedna z nich pozwoliła na uzyskanie zadowalających wyników. Mimo szczegółowej dekompozycji szeregu i zastosowania metod odpowiednich do zaobserwowanych składowych analizowanego szeregu wybrana metoda – szczególnie przy znacznym horyzoncie – nie zawsze okazuje się metodą właściwą do prognozowania danego zjawiska.

Bibliografia

1. Arash A., Farid A.: Multi-step ahead forecasts for electricity prices using NARX: A new approach, a critical analysis of one-step ahead forecasts. *Energy Conversion & Management*, Mar2009, Vol. 50, Issue 3.
2. Chodakowska E., Halicka K., Kononiuk A., Nazarko J.: Prognozowanie cen energii elektrycznej na Towarowej Giełdzie Energii SA z wykorzystaniem modeli ARIMA, [w:] *Technologie informatyczne i prognozowanie w zarządzaniu: wybrane zagadnienia*, Nazarko J., Kiełtyka L. (red.), Wydawnictwo Politechniki Białostockiej, Białystok 2005.

3. Contreras J., Espinola R., Nogales F. J., Conejo A. J., ARIMA Models to Predict Next-Day Electricity Prices. *IEEE transactions on power systems*, Vol. 18, No. 3, August 2003.
4. Dong Y., Wang J., Jiang H., Wu J.: Short-term electricity price forecast based on the improved hybrid model. *Energy Conversion & Management*, Vol. 52, Issue 8/9, Aug 2011.
5. Garcia R. C., Contreras J., Akkeren M., Garcia J. B.: A GARCH Forecasting Model to Predict Day-Ahead. *Electricity Prices. IEEE transactions on power systems*, Vol. 20, No. 2, May 2005.
6. Halicka K.: Ocena skuteczności prognozowania na giełdzie energii. *Przegląd Elektrotechniczny*, nr 4, 2010.
7. Halicka K., Wieńkowski C.: Wykorzystanie metod wygładzania wykładniczego do prognozowania kursu sprzedaży EUR. *Ekonomia i Zarządzanie*, Oficyna Wydawnicza Politechniki Białostockiej, Białystok. T. 5, nr 2 (2013).
8. Wu H. C., Chan S. C., Tsui K. M., Hou Y.: A New Recursive Dynamic Factor Analysis for Point and Interval Forecast of Electricity Price. *IEEE Transactions on Power Systems*, Aug2013, Vol. 28 Issue 3.
9. Mandal P., Senjyu T., Urasaki N., Funabashi T., Srivastava A.: A Novel Approach to Forecast Electricity Price for PJM Using Neural Network and Similar Days Method. *IEEE Transactions on Power Systems*, Nov2007, Vol. 22, Issue 4.
10. Menniti D., Scordino N., Sorrentino N.: A Novel Approach to Forecast Day-Ahead Electricity Prices by Means of Neural Networks Using Groups of Similar Hours. *International Review of Electrical Engineering (I.R.E.E.)*, Vol. 7, No. 4, July – August 2012.
11. Nazarko J. (red.): *Prognozowanie w zarządzaniu przedsiębiorstwem. Cz. III, Prognozowanie na podstawie modeli adaptacyjnych*. Wydawnictwo Politechniki Białostockiej, Białystok 2005.

Abstract

The purpose of this article was to determine the forecast of the price of electricity on the POLPX Day Ahead Market using the method of exponential smoothing - Holt-Winters model and artificial neural networks.

The forecast determined using the Holt-Winters model was fraught with major errors, far exceeding the average. In contrast, the forecast determined with the use of artificial neural networks yielded satisfactory results in the form of small errors - the average deviation from the actual values in the entire analyzed period accounted for 4.71% of the actual value. In the context of the obtained results, the authors recommend the use of artificial neural networks for forecasting the price of electricity on the energy exchange, even more because a once trained network can be used repeatedly.