

Tomasz Jasiński*, **Agnieszka Ścianowska****
Politechnika Łódzka

SZEREGI CZASOWE NA RYNKU ENERGII ELEKTRYCZNEJ

STRESZCZENIE

W artykule przedstawiono możliwości przewidywania zapotrzebowania na energię elektryczną oraz jej cen na rynku hurtowym przy wykorzystaniu narzędzi z dziedziny sztucznej inteligencji, a także opisano możliwości minimalizacji ekstremów popytowych i cenowych poprzez wprowadzenie inteligentnych liczników w obszarze detalicznego rynku energii. W badaniach wykorzystano m.in. sztuczne sieci neuronowe wspomagane innymi technikami przekształcania danych, jak np. klasyczna analiza techniczna oraz dyskretna transformata falkową.

Słowa kluczowe: rynek energii, przewidywanie, ceny, sztuczne sieci neuronowe

Wprowadzenie

Wobec faktu, że założenie o doskonałej konkurencyjności rynku energii w Polsce nie jest spełnione, gdyż generacja jest skupia się w kilku dużych grupach energetycznych, ich strategia może wpływać na cenę rynkową. Dlatego przy prognozowaniu ceny na polskim rynku stosuje się modele statystyczne korygujące otrzymywane

* Adres e-mail: tomasz.jasinski@p.lodz.pl

** Adres e-mail: agnieszka.scianowska@p.lodz.pl

wyniki modeli fundamentalnych. Celem opracowania jest przedstawienie realnych możliwości przewidywania, a co za tym idzie – optymalizacji funkcjonowania rynków energii zarówno detalicznych, jak i hurtowych poprzez zastosowanie nowoczesnych narzędzi analizy i predykcji, w szczególności sztucznych sieci neuronowych. Praca ma także na celu wskazanie tych zmiennych objaśniających modeli prognostycznych, które w istotnym stopniu umożliwiają podwyższenie jakości otrzymywanych wyników.

W tym aspekcie istotnym czynnikiem jest zwiększenie precyzji w przewidywaniu występowania ekstremów cenowych. W modelu regresji liniowej opracowanym przez Sadowskiego, Zawiszę i Kamińskiego do modelowania typowego zachowania poziomu cen na rynku autorzy, określając wpływ najważniejszych zmiennych objaśniających na prawdopodobieństwo wystąpienia ekstremum cenowego, stwierdzili dużą siłę oddziaływania kosztu krańcowego ostatniej elektrowni pokrywającej zapotrzebowanie oraz sytuacji występowania niewielkiej nadwyżki podaży na popytem. Jednocześnie stwierdzono niewielki wpływ zmiennych objaśniających na prawdopodobieństwo wystąpienia ekstremum cenowego w postaci niskich wartości popytu pozostałego do pokrycia. Można to uzasadnić przygotowaniem wytwórców do pokrycia zapotrzebowania, kiedy jest ono bardzo wysokie (nie planują na takie okresy remontów i nadmierna podaż obniża cenę na rynku bilansującym). Natomiast gdy zapotrzebowanie jest umiarkowane, a wytwórcy nie są w gotowi interweniować – ekstrema mogą występować¹.

1. Detaliczny rynek energii – inteligentne liczniki

Wobec opisanego wyżej ryzyka występowania ekstremów cenowych dużego znaczenia nabiera problem utrzymania pod kontrolą szczytowego zapotrzebowania na energię. Jest to możliwe między innymi poprzez optymalizację zachowań odbiorców i prosumentów, tym bardziej że udział odbioru statystycznie rozproszonego w kształtowaniu krzywej obciążenia w najbardziej newralgicznych godzinach roku jest znaczący.

Jako narzędzie bieżącego zarządzania zapotrzebowaniem na energię można wykorzystać system tzw. inteligentnych liczników, w przypadku których comie-

¹ J. Sadowski i in., *Główne przyczyny występowania ekstremów cenowych na rynku bilansującym*, „Rynek Energii” 2012, nr 2.

sięczny odczyt ma funkcjonować równolegle z odczytami piętnastominutowymi profili zużycia energii elektrycznej. Aby mogły spełniać swoją funkcję, optymalizowania zachowań odbiorców ze względu na koszt zaopatrzenia w energię, konieczne jest uzupełnienie systemu o funkcję dostarczenia do odbiorcy informacji zwrotnych. Dodatkowym uzupełnieniem, istotnym zwłaszcza z perspektywy bilansowania KSE i zapewniania ciągłości dostaw, jest zarządzanie z poziomu operatorów sieci zasobami rozproszonymi (DR) w warunkach przed- i awaryjnych².

Podsystem liczników inteligentnych jest zatem elementem systemu pomiarowo-rozliczeniowego Advanced Metering Infrastructure (AMI) składającego się z aplikacji centralnej, infrastruktury komunikacji dwukierunkowej, infrastruktury pomiarowej oraz pozostałych elementów służących do zdalnego pomiaru, przesyłania, przechowywania i przetwarzania danych pomiarowych dotyczących energii elektrycznej oraz innych mediów, stosownych informacji i komend³. Aby system oparty na AMI mógł pełnić funkcje kluczowe dla prognozowania zapotrzebowania na energię i ciągłości dostaw, musi zapewniać dotarcie ze stosowną informacją, komendą i pomiarem do wszystkich odbiorców końcowych, także najbardziej rozproszonych w segmencie usług (SME) oraz w gospodarstwach domowych⁴.

Oznacza to konieczność wyposażenia ostatecznego odbiorcy w sieć urządzeń komunikujących się inteligentnym licznikiem będącym elementem systemu AMI. Centralny element sieci domowej stanowi tzw. Panel Sieci Domowej (Home Area Network – HAN) zapewniający komunikację z licznikiem i odbiornikami odbiorcy oraz umożliwiający odbiorcy odbiór informacji rynkowych i sygnałów DSR, przy czym DSR oznacza reakcję strony popytowej na sygnał cenowy lub inną informację określoną w trybie kontraktowym.

Należy oczekiwać, że dużą rolę w bilansowaniu produkcji i zapotrzebowania na energię będą odgrywać Operatorzy Systemu Dystrybucyjnego Elektroenergetycznego (OSD E)⁵. Wynika to z faktu, że w przypadku umowy sprzedaży lub kompleksowej dane pomiarowe pobierane z liczników u odbiorców, w cyklu dobowym

² *Koncepcja dotycząca modelu rynku opomiarowania w Polsce, ze szczególnym uwzględnieniem wymagań wobec Operatora Informacji Pomiarowej*, Warszawa 9.02.2012, s. 10.

³ Tamże, s. 30

⁴ *Stanowisko Prezesa URE w sprawie niezbędnych wymagań wdrażanych przez OSD E inteligentnych systemów pomiarowo-rozliczeniowych z uwzględnieniem funkcji celu oraz proponowanych mechanizmów wsparcia przy postulowanym modelu rynku*, Warszawa 31.05.2011, s. 10.

⁵ B. Olek, M. Wierzbowski, *Optymalizacja jako element smart grid*, „Rynek Energii” 2013, nr 1.

będą przekazywane do Aplikacji Centralnych AMI tych OSD E, do których sieci jest przyłączony odbiorca, a następnie retransmitowane do Centralnego Repozytorium Rynkowych Danych Pomiarowych (CRD). Sprzedawca będzie pozyskiwał z CRD dane pomiarowe obsługiwanego odbiorcy na podstawie umowy zawartej z OSD E⁶. W przypadku odrębnej umowy dystrybucyjnej dane pomiarowe pobierane z licznika odbiorcy w cyklu dobowym będą przekazywane do Aplikacji Centralnej, a następnie retransmitowane do CRD. OSD E będzie rozliczał odbiorcę w zakresie usługi dystrybucyjnej samodzielnie lub korzystając z outsourcingu.

W Polsce podmiotem odpowiedzialnym za magazynowanie, przetwarzanie oraz udostępnianie uprawnionym podmiotom danych pomiarowych pochodzących od poszczególnych OSD E na potrzeby rozliczeń oraz kreowania ofert rynkowych i zestawień statystycznych ma być Operator Informacji Pomiarowej (OIP), który na podstawie umowy zawartej przez odbiorcę ze sprzedawcą lub równoważnego upoważnienia, za określoną opłatą, będzie udostępniał dane pomiarowe dotyczące tego odbiorcy. Dodatkowo OIP będzie publikował dane zagregowane według zdefiniowanych prawem kryteriów⁷. Zapewniony dzięki temu dostęp sprzedawców do informacji źródłowych pozwoli konstruować własne oferty dedykowane do określonych grup odbiorców⁸, kierowane do nich z wykorzystaniem ogólnych kanałów komunikacji. Odpowiednio skonstruowane oferty, zaakceptowane przez odbiorców, mogą stanowić skuteczne narzędzie zarządzania popytem na energię pod warunkiem zwolnienia sprzedawców z obowiązku przedkładania do zatwierdzenia przez prezesa URE taryf dla odbiorców w grupach G⁹.

W sytuacji gdy cena energii nie jest ustalona z góry, tylko podlega bieżącemu indeksowaniu, a kontrakt ustala tylko mechanizm indeksacji, podstawą kalkulacji ceny przewidywanej np. na następną godzinę lub następne godziny mogą być informacje historyczne (np. ekstrapolacja pozwalająca przewidzieć przekroczenie wartości krytycznej) lub informacje bieżące (np. z giełdy energii lub od OSP)¹⁰.

Informacja przetworzona lub wykorzystana przez sprzedawców jest przekazywana przez liczniki odbiorców do Panelu Sieci Domowej, który korzystając

⁶ *Stanowisko Prezesa URE w sprawie niezbędnych wymagań...*, s. 17.

⁷ Tamże, s. 21.

⁸ Tamże.

⁹ Tamże, s. 23.

¹⁰ Tamże.

z przechowywanej w jego pamięci informacji o elementach stałych aktualnie obowiązującej taryfy dystrybucyjnej oraz cennika energii, będzie prezentował odbiorcy aktualny, bieżący lub przewidywany na następną godzinę koszt zapotrzebowania w energię jako funkcję aktualnych stawek i cen oraz bieżącego zużycia¹¹.

Odpowiedź odbiorcy na zmieniającą się cenę jest obserwowana z opóźnieniem dobowym na podstawie informacji napływających do CRD dla celów rozliczeniowych. Statystycznie opracowany obraz odpowiedzi odbiorców na zmianę cen energii, uwzględniający jej szybkość i amplitudę, jest (obok kosztu zakupu energii na rynku hurtowym) podstawą decydującą o kształtowaniu przez przedsiębiorstwa obrotu ofert na kolejne okresy¹², informację o bieżącym zużyciu energii przekazuje się bowiem do CRD, a następnie sprzedawcy.

W ramach sieci inteligentnej funkcja zarządzania poziomem szczytowego zapotrzebowania na energię jest realizowana również poprzez opcję przekazywania do Panelu Sieci Domowej odbiorcy informacji o pozostałym kredycie na podstawie ekstrapolacji dotychczasowego zużycia. Należy przy tym podkreślić, że mankamentem tej metody jest to, iż tryb opcjonalnego ostrzeżenia o wyczerpywaniu się kredytu pozwala na zachowanie ograniczonej precyzji oceny przesłanek zaprzestania dostaw, spowodowanej koniecznością oparcia się na interpolacji wewnątrz doby. Ewentualne wyrównanie długu następuje z kolejnej wypłaty, jeżeli z rozliczenia tej doby będzie wynikało, że wyłączenie nastąpiło po przekroczeniu kredytu.

Utrzymanie limitów zapotrzebowania na energię zapobiegające tzw. ekstremom cenowym dokonuje się też poprzez realizację w ramach sieci inteligentnej opcji ograniczenia mocy dostępnej dla odbiorcy. Inwestycja w system AMI jest zatem najważniejsza dla uruchomienia całej palety narzędzi zarządzania popytem niezbędnych w ramach bilansowania mocy w systemie¹³. Stała obserwacja cen energii przez odbiorców zachęca do uzyskiwania wysokich oszczędności w zakupach energii poprzez ich ograniczenia w najbardziej niewralgicznych przedziałach czasowych¹⁴.

¹¹ Tamże.

¹² Tamże, s. 25.

¹³ Tamże, s. 43.

¹⁴ Sz. Kosiński, *Rynek energii 2014 – wybrane aspekty*, „Energetyka Ciepła i Zawodowa” 2014, nr 2, s. 1.

2. Szeregi czasowe na hurtowym rynku energii

Szeregi czasowe stanowią jeden z podstawowych typów danych na rynku energii. Wśród tych najczęściej wymienianych pojawiają się m.in. szeregi dotyczące cen energii oraz zapotrzebowania na nią. Dane te mogą posłużyć do prognoz krótko- i długoterminowych. W przypadku tych pierwszych szczególnie istotne są prognozy dwugodzinne, a także pięciominutowe. Za ich pomocą możliwe jest przewidywanie cen energii powstałych jako wynik gry rynkowej popytu i podaży. Zasady rządzące hurtowym rynkiem energii elektrycznej zostały opisane na przykładzie miasta Ontario oraz IESO (Independent Electricity System Operator). Ceny na rynku hurtowym typowo są ustalane z pięciominutowym interwałem. Zazwyczaj polega to na przyjmowaniu z odpowiednim wyprzedzeniem (np. do wspomnianych dwóch godzin) ofert sprzedaży energii od generatorów i importerów. W pierwszej kolejności wykorzystuje się te, których cena była najniższa, a następnie kolejne oferty o wyższych cenach. Wszystkim oferentom wypłaca się jedną wspólną cenę za energię równą najwyższej przyjętej ofercie (zależnej od rzeczywistego zapotrzebowania). Należy także pamiętać, że dodatkowe opłaty płacone są także tym generatorom, od których zakup nie został zrealizowany w ramach tzw. rezerwy operacyjnej. Inaczej mówiąc, dostają pieniądze za gotowość do dostarczenia energii. Zapobiega to sytuacji kryzysowej, jeżeli któryś ze zwycięskich generatorów lub importerów nie byłby w stanie wywiązać się z oferty np. ze względu na awarię bądź nastąpiłby nieoczekiwany wzrost zapotrzebowania na energię¹⁵.

Równie istotne są prognozy o charakterze dobowym. Przewiduje się w nich nie tylko średnie lub całkowite zapotrzebowanie na energię z horyzontem predykcji o odległości dwudziestu czterech godzin, lecz także szczytowe zapotrzebowanie. Jak powszechnie wiadomo, to ta wartość jest najważniejszym elementem wpływającym na ceny energii, a przede wszystkim na ciągłość jej dostaw. Analizy są prowadzone powszechnie przez praktycznie wszystkich operatorów, generatorów oraz importerów. Zazwyczaj podaje się, że wartość błędu predykcji nie przekracza 2%.

Kolejny typ prognoz ma charakter długoterminowy. O ile analizy o krótkim horyzoncie predykcji są wręcz niezbędne do poprawnego funkcjonowania rynku w danej chwili, o tyle nie zapewniają jego właściwego działania w przyszłości. Decyzje o charakterze strategicznym wymagają informacji daleko wykraczającej poza

¹⁵ Strona internetowa www.ieso-public.sharepoint.com (dostęp 15.03.2014).

chwilę obecną. Bez analiz o charakterze długoterminowym wręcz niemożliwe byłoby budowanie strategii rozwoju rynków energii, w tym również odpowiedzi na jedno z głównych pytań: Jak należy skonstruować rynek energii, żeby w długim okresie był rynkiem bezpiecznym? Podstawowym elementem wydaje się stworzenie takich rozwiązań ekonomiczno-prawnych, które zapewnią odpowiedni poziom inwestycji, co z kolei przełoży się na wymagany stopień niezawodności rynków¹⁶.

Zależnie od wybranego horyzontu prognozy stosuje się różne modele matematyczne. Zarówno przy prognozach krótko-, jak i długoterminowych coraz powszechniej wykorzystuje się narzędzia z rodziny sztucznej inteligencji, przede wszystkim sztuczne sieci neuronowe (Artificial Neural Networks – ANN).

3. Zasada funkcjonowania oraz rodzaje ANN

ANN stanowią próbę naśladowania biologicznych komórek nerwowych. Zbudowane są z wielu połączonych ze sobą sztucznych neuronów. Każda z komórek została tak zdefiniowana, by budową i działaniem przypominała komórkę biologiczną. Warto w tym miejscu nadmienić, że opisywane narzędzie ma początek w 1943 roku, kiedy po raz pierwszy opisano model sztucznego neuronu¹⁷. Publikacja *A Logical calculus of the ideas immanent in nervous activity* zawierała matematyczny opis zasad funkcjonowania sztucznej komórki nerwowej¹⁸. Omawiany sztuczny neuron, podobnie jak biologiczny, ma wejścia wprowadzające sygnały do jej wnętrza (odpowiedniki dendrytów) oraz wyjście przekazujące informację wyjściową do innych neuronów (analogia do biologicznego aksonu). Sygnały pojawiające się na wejściu komórki mają w istocie charakter cyfrowy – są to liczby rzeczywiste. Z każdym wejściem neuronu jest związana tzw. waga. To liczba rzeczywista, która podlega w procesie nauki odpowiednim modyfikacjom. Właściwie dobrane wagi wszystkich

¹⁶ Opis najbardziej istotnych modeli funkcjonowania rynku energii pod kątem stopnia ich niezawodności można odnaleźć m.in. w: T. Jasiński, *Niezawodność oraz metody jej zwiększania w różnych modelach rynku*, w: A.T. Szablewski, M. Martin (red.), *Ekonomiczne, regulacyjne, strukturalne i technologiczne uwarunkowania bezpieczeństwa energetycznego* Wydawnictwo Politechniki Łódzkiej, Łódź 2011, s. 199–219.

¹⁷ D. Witkowska, *Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe*, C.H. Beck, Warszawa 2002, s. 1; S. Osowski, *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwa Naukowo-Techniczne, Warszawa 1996, s. 15.

¹⁸ W.S. McCulloch, W. Pitts, *A Logical calculus of the ideas immanent in nervous activity*, „Bulletin of Mathematical Biophysics” 1943, vol. 5, s.11–133.

neuronów w sieci stanowią o jej inteligencji i możliwościach działania. Sygnały wejściowe są mnożone przez sprzężoną z danym wejściem wagę. Następnie wszystkie takie iloczyny docierające do komórki są sumowane i modyfikowane poprzez użycie tzw. funkcji aktywacji. Warto w tym miejscu nadmienić, że choć zwykło się uważać, że pełni ona funkcję jądra komórki, w rzeczywistości wspomniane przekształcenie przejmuje pewne funkcje biologicznego połączenia synaptycznego. Ponieważ komunikacja w biologicznej synapsie ma charakter potencjału czynnościowego, którego przebieg jest w rzeczywistości pewną funkcją ciągłą, zatem funkcje aktywacji stosowane w ANN także najczęściej mają taki charakter. Okazuje się, że funkcje dwustanowe nie sprawdzają się w zastosowaniach rzeczywistych, powodując, że duże części struktury sztucznego modelu pozostają nieaktywne. Wśród najbardziej popularnych funkcji aktywacji wymienia się funkcję logistyczną, tangensa hiperbolicznego, sinus lub Gaussa¹⁹.

Opisane komórki nerwowe mogą zostać połączone ze sobą na wiele różnych sposobów. Jednym z podstawowych kryteriów podziałów jest kierunek przepływu sygnałów wewnątrz sieci. Neurony łączone są ze sobą w tzw. warstwy. Jeżeli informacje przepływają tylko w jednym kierunku – od wejście do wyjścia – wówczas takie ANN nazywa się sieciami jednokierunkowymi. W przypadku istnienia połączeń zwrotnych (sygnały wracają do neuronów tej samej lub wcześniejszej warstwy) ANN są nazwane sieciami rekurencyjnymi (Recurrent Neural Network – RNN). W obu przypadkach pierwsza z warstw nazywa się wejściowa. Jej zadanie polega na pobraniu danych z zewnątrz i rozprowadzeniu ich wewnątrz modelu. Cechą charakterystyczną neuronów tej warstwy jest brak możliwości nauki. Ich wagi nie ulegają modyfikacjom. Ostatnia z warstw jest zwana warstwą wyjściową. To z niej dane wyprowadza się na zewnątrz modelu. Pomiędzy opisanymi warstwami mogą znajdować się tzw. warstwy ukryte. Ich neurony, podobnie jak te w warstwie wyjściowej, biorą czynny udział w procesie nauki, a tym samym ich wagi podlegają zmianom.

W przypadku sieci jednokierunkowych w zależności od tego, czy występują warstwy ukryte, rozróżnia się sieci jednokierunkowe jednowarstwowe (mają dwie warstwy: wejściową oraz wyjściową; tylko jedna – wyjściowa – bierze udział w procesie nauki) oraz jednokierunkowe wielowarstwowe (Multilayer Perceptron – MLP;

¹⁹ Szczegółowy opis zasady działania różnych modeli ANN znajduje się m.in. w: R. Tadeusiewicz, *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.

mają minimum jedną warstwę ukrytą). W praktyce najczęściej spotyka się MLP mające jedną lub dwie warstwy ukryte, choć w literaturze przedmiotu można odnaleźć liczne przykłady poprawnie funkcjonujących modeli zbudowanych na podstawie MLP o większej ich liczbie, np. trzech.

4. Prognozowanie na rynku energii

Istnieje wiele czynników, które mają wpływ na przyszłe zapotrzebowanie na energię. Wśród nich często wymienia się czasowe (godzinę, numer dnia, numer tygodnia, miesiąc, rok, specyfikę danego dnia, wskaźniki sezonowości), przeszłe i przewidywane rezerwy, historyczne ceny, przeszłe i prognozowane zapotrzebowanie na energię, wymianę energii między sąsiednimi rejonami (szczególnie kontrakty długoterminowe), parametry klimatyczne (np. zmiany temperatury, temperatura punktu rosy), ceny innych surowców energetycznych (ropy, gazu) oraz paliw²⁰. Innym spotykanym podziałem jest wyodrębnienie danych opisujących rynek (historyczne obciążenie, rezerwy, zdolności wytwórcze generatorów, import, eksport, ograniczenia przesyłowe linii), niestrategicznej niepewności (w tym przede wszystkim przewidywane zapotrzebowanie oraz rezerwy, a także wymienione wcześniej czynniki pogodowe i ceny innych surowców paliw), pozostałe czynniki losowe (w tym m.in. przerwy w dostawach prądu, stan linii przesyłowych, wskaźniki przeciążenia), wskaźniki zachowania rynku (m.in. przeszłe ceny, wskaźniki elastyczności popytu, strategie aukcyjne), czasowe (okres rozliczeniowy oraz inne wcześniej wymienione czasowe)²¹.

W literaturze przedmiotu można odnaleźć przykłady badań, podczas których zostały skonstruowane osobne modele prognostyczne przewidujące zachowanie się rynku energii podczas tygodnia, w sobotę oraz w niedzielę. Taki podział został poddyktowany różnym zachowaniem rynku w ciągu trzech wymienionych okresów. Badania autorstwa Chahkandi Nejad, Mahvy, Jahani wykazały, że podczas okresu letniego precyzja prognozy zapotrzebowania szczytowego dokonana przy użyciu MLP

²⁰ H. Chahkandi Nejad i in., *Electricity Market Prediction Using Improved Neural Network*, „Australian Journal of Basic and Applied Sciences” 2011, vol. 5(9), s. 932; S. Kumar Aggarwal i in., *Electricity price forecasting in deregulated markets: A review and evaluation*, „Electrical Power and Energy Systems” 2009, vol. 31, s. 15.

²¹ S. Kumar Aggarwal i in., *Electricity price...*, s. 15.

jest w ujęciu procentowym (średni bezwzględny błąd procentowy, Mean Absolute Percentage Error – MAPE) zbliżona we wszystkich wymienionych okresach czasowych, wahając się między 10,8% a 11,3%. Zapotrzebowanie średnie również zostało poddane prognozie ze stosunkowo niewielką różnicą poprawności otrzymanych wyników. Zdecydowanie większe rozbieżności MAPE uzyskane zostały podczas prognoz, które objęły okres zimowy. Największe błędy dotyczyły przewidywania szczytowego zapotrzebowania podczas dni roboczych (prawie 6,8%), natomiast najmniejsze – popytu na energię w soboty (nieco ponad 2,9%). Zdaniem autorów, jedną z możliwości poprawy jakości uzyskanych wyników jest zastosowanie dyskretnej transformaty falkowej (Discrete Wavelet Transform – DWT) na etapie wstępnego przetwarzania danych wejściowych modelu²². Jak wynika z badań przeprowadzonych przez autorów niniejszego opracowania, szczególnie przydatne okazują się DWT oparte na falkach biortogonalnych $6/8$ ²³.

Podstawowym elementem wpływającym na jakość uzyskiwanych wyników jest zestaw zmiennych objaśniających. Badania empiryczne i te o charakterze literaturowym wykazały, że można odnaleźć wiele różnych kombinacji wejściowych szeregów czasowych, na podstawie których można dokonać poprawnych symulacji. Liczba danych użytych na wejściu modelu w większości badań opisanych w literaturze przedmiotu waha się między jeden a dziesięć²⁴. W literaturze przedmiotu można znaleźć badania potwierdzające zasadność budowy modelu prognostycznego nawet na podstawie wyłącznie jednego rodzaju danych wejściowych. Za przykład posłużyć może opracowanie autorstwa Xu, Dong oraz Liu. Autorzy w analizach oparli się jedynie na danych wejściowych w postaci wartości temperatury powietrza, uznając ten czynnik za najważniejszy podczas prognoz zarówno cen energii, jak i zapotrzebowania na nią²⁵. W procesie badań potwierdzono, że jednym z głównych elementów poprawnie funkcjonującego modelu jest użycie opisaną powyżej DWT. Narzędzie

²² H. Chahkandi Nejad i in., *Electricity Market...*, s. 933–934.

²³ Więcej informacji na temat optymalizacji ANN przy użyciu DWT można odnaleźć m.in. w: T. Jasiński, *Zastosowanie dyskretnej transformaty falkowej do poprawy wyników uzyskiwanych przez sztuczne sieci neuronowe*, Oficyna Wydawnicza SGH, Warszawa 2004, s. 23–32.

²⁴ S. Kumar Aggarwal i in., *Electricity price forecasting...*, s. 18.

²⁵ Należy jednak nadmienić, że dość ograniczony zestaw zmiennych wejściowych może okazać się niewystarczający na wielu innych rynkach energii, choć dostępne są liczne publikacje prezentujące analizy na podstawie jedynie bądź głównie czynnika pogodowego. Można przypuszczać, że wykorzystanie jedynie wartości temperatury w dużej mierze wiąże się ze specyfiką danego rynku energii (Queensland, Australia).

to połączone zostało z ANN²⁶ oraz innymi technikami prognostycznymi, m.in. z maszyną wektorów nośnych (zwaną także metodą/maszyną wektorów wspierających/podtrzymujących, w skrócie SVM – Support Vector Machine). Wyniki badań potwierdziły przydatność obu wymienionych technik. DWT we współpracy z SVM osiągnęły lepsze wyniki podczas przewidywania w okresie letnim, natomiast prognozy w okresie zimowym były dokładniejsze przy użyciu modelu zbudowanego na podstawie DWT i ANN²⁷.

Podsumowanie

Przedstawione możliwości minimalizacji ekstremów popytowych i cenowych poprzez wprowadzenie inteligentnych liczników w obszarze detalicznego rynku energii pozwalają dostrzec korzyści z ujawnionej elastyczności popytu jako narzędzia łagodzącego amplitudy wahań w zakresie zapotrzebowania na energię. Korzystny wpływ na przewidywanie popytu ma wyraźna reakcja klienta na wzrost cen w godzinach szczytu w postaci obniżenia konsumpcji, która dodatkowo zostaje wzmocniona przez przystąpienie odbiorcy do zautomatyzowanego systemu reagowania na sygnały rynkowe i komendy tzw. programu DSR. Retransmitowane i pobierane przez innych użytkowników infrastruktury AMI dane o szybkości i intensywności reakcji klienta pozwalają na budowanie precyzyjnych prognoz odnośnie do kształtowania się popytu w przyszłości.

Natomiast w przewidywaniach dotyczących zapotrzebowania na energię elektryczną oraz jej cen na rynku hurtowym przy wykorzystaniu narzędzi z dziedziny sztucznej inteligencji dużą rolę odgrywają zarówno prognozy krótko- (dwugodzinne, a także pięciominutowe), jak i długoterminowe. Te ostatnie są szczególnie istotne dla budowania strategii rozwoju rynków i zapewniania bezpieczeństwa rynków energii, gdyż w dużym stopniu determinują poziom przeprowadzanych na nich inwestycji.

²⁶ Zastosowano ANN typu MLP o architekturze 8-4-1 uczone metodą gradientów sprzężonych z regularyzacją (Scaled Conjugate Gradient – SCG).

²⁷ Z. Xu i in., *Neural Network Models For Electricity Market Forecasting*, w: D. Wang, N.K. Lee (red.), *Neural Networks Applications in Information Technology and Web Engineering*, Borneo Publishing Co., Sarawak, Malaysia 2005.

Wykorzystane w badaniach modele prognostyczne przewidujące zachowanie się rynku energii podczas tygodnia, w sobotę oraz w niedzielę wykazały podobną precyzję prognozy dotyczącą zarówno zapotrzebowania szczytowego podczas okresu letniego, jak i zapotrzebowania średniego, dokonaną przy użyciu MLP. Natomiast przewidywania szczytowego zapotrzebowania dla okresu zimowego cechowały się największymi błędami podczas dni roboczych i najmniejszymi dla sobót. Na zwiększenia precyzji szacunków pozytywny wpływ ma zastosowanie dyskretnej DWT na etapie wstępnego przetwarzania danych wejściowych modelu.

Literatura

- Chahkandi Nejad H., Mahvy M., Jahani R., *Electricity Market Prediction Using Improved Neural Network*, „Australian Journal of Basic and Applied Sciences” 2011, vol. 5(9).
- Jasiński T., *Zastosowanie dyskretnej transformaty falkowej do poprawy wyników uzyskiwanych przez sztuczne sieci neuronowe*, Oficyna Wydawnicza SGH, Warszawa 2004.
- Jasiński T., *Niezawodność oraz metody jej zwiększania w różnych modelach rynku*, w: A.T. Szablewski, M. Martin (red.), *Ekonomiczne, regulacyjne, strukturalne i technologiczne uwarunkowania bezpieczeństwa energetycznego*, Wydawnictwo Politechniki Łódzkiej, Łódź 2011.
- Koncepcja dotycząca modelu rynku opomiarowania w Polsce, ze szczególnym uwzględnieniem wymagań wobec Operatora Informacji Pomiarowej*, Warszawa 9.02.2012.
- Kosiński Sz., *Rynek energii 2014 – wybrane aspekty*, „Energetyka Ciepła i Zawodowa” 2014, nr 2.
- Kumar Aggarwal S., Saini L., Kumar A., *Electricity price forecasting in deregulated markets: A review and evaluation*, „Electrical Power and Energy Systems” 2009, vol. 31.
- McCulloch W.S., Pitts W., *A Logical calculus of the ideas immanent in nervous activity*, „Bulletin of Mathematical Biophysics” 1943, vol. 5.
- Olek B., Wierzbowski M. *Optymalizacja jako element smart grid*, „Rynek Energii” 2013, nr 1.
- Osowski S., *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
- Sadowski J., Zawisza M., Kamiński B., *Główne przyczyny występowania ekstremów cenowych na rynku bilansującym*, „Rynek Energii” 2012, nr 2.
- Stanowisko Prezesa URE w sprawie niezbędnych wymagań wdrażanych przez OSD E inteligentnych systemów pomiarowo-rozliczeniowych z uwzględnieniem funkcji celu oraz*

proponowanych mechanizmów wsparcia przy postulowanym modelu rynku, Warszawa 31.05.2011.

Strona internetowa: www.ieso-public.sharepoint.com.

Tadeusiewicz R., *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.

Witkowska D., *Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe*, C.H. Beck, Warszawa 2002.

Xu Z., Dong Z.Y., Liu W.Q., *Neural Network Models For Electricity Market Forecasting*, w: D. Wang, N.K. Lee (red.), *Neural Networks Applications in Information Technology and Web Engineering*, Borneo Publishing Co., Sarawak, Malaysia 2005.

TIME SERIES ON THE ENERGY MARKET

Abstract

The paper presents the possibility of predicting the demand for electric energy and its price in the wholesale market using tools of artificial intelligence, and describes the possibilities to minimize the peaks of demand and pricing through the introduction of smart grid in the retail energy market. In the studies have been used artificial neural network supported by other techniques of data transforming, such as the classic technical analysis and discrete wavelet transform.

Translated by Tomasz Jasiński, Agnieszka Ścianowska

Keywords: energy market, forecasting, prices, artificial neural networks

JEL Code: Q47

