



### **Tomasz Jasiński**

Politechnika Łódzka  
Wydział Organizacji i Zarządzania  
Instytut Nauk Społecznych  
i Zarządzania Technologiami  
Zakład Ekonomii  
tomasz.jasinski@p.lodz.pl

### **Agnieszka Ścianowska**

Politechnika Łódzka  
Wydział Organizacji i Zarządzania  
Instytut Nauk Społecznych  
i Zarządzania Technologiami  
Zakład Ekonomii  
agnieszka.scianowska@p.lodz.pl

## **POPYT, CENY ORAZ STOPIEŃ ICH ZAWYŻENIA NA WYBRANYCH RYNKACH ENERGII**

**Streszczenie:** Opracowanie opisuje możliwości przewidywania popytu i cen na detalicznym rynku energii elektrycznej przy zastosowaniu narzędzi z dziedziny sztucznej inteligencji, jakimi są sztuczne sieci neuronowe. Wiedza ta pozwala na optymalizację ekonomiczną zarówno w podmiotach funkcjonujących po stronie popytu, jak i podaży. Dalsza optymalizacja rynku wymaga zmniejszenia szczególnie zapotrzebowania szczytowego, co możliwe jest m.in. na podstawie systemu zmiennych cen. W artykule omówiono możliwość wprowadzenia tego typu rozwiązań, opierając się na zaawansowanej infrastrukturze pomiarowej, będącej elementem tzw. systemów inteligentnych.

**Słowa kluczowe:** detaliczny rynek energii, prognozowanie, ceny, popyt, sztuczne sieci neuronowe, zaawansowana struktura pomiarowa.

### **Wprowadzenie**

Prawie wszystkie rynki poddawane są w chwili obecnej licznym próbom modelowania i predykcji. Powszechnie stosowane są w tym celu metody matematyczne i narzędzia informatyczne. Jednymi z nich są sztuczne sieci neuronowe (ANN – Artificial Neural Networks)<sup>1</sup>. Także rynek energii stanowi popularny obszar badań z użyciem wspomnianego narzędzia z obszaru sztucznej inteligencji. W literaturze przedmiotu można odnaleźć liczne publikacje omawiające

<sup>1</sup> Więcej na temat zastosowania ANN w modelowaniu ekonomicznym można odnaleźć m.in. w: [Jasiński, 2008, 2009, 2010, 2011].

możliwości użycia ANN zarówno w analizach krótko-, jak i długoterminowych. [Jasiński, 2014a; Jasiński i Ścianowska, 2014]. Zazwyczaj badania dotyczą rynku jako całości, nie dokonując jego analizy w zależności od rodzaju uczestników rynku.

Przyszłe zachowania rynków energii, jak i ich precyzyjne prognozy stanowią jeden z kluczowych elementów wpływających zarówno na efektywność ekonomiczną przedsiębiorstw (której zależność od np. zmian cen energii można również modelować za pomocą ANN [Granell, Axon i Wallom, 2014]), jak i na bezpieczeństwo funkcjonowania systemów energetycznych. W niniejszym opracowaniu szczególnie nacisk został położony na modelowanie detalicznych rynków energii. Oczywiście popyt generowany przez pojedynczego, małego konsumenta nie jest istotny z punktu widzenia rynku energii jako całości, natomiast sytuacja panująca na całym detalicznym rynku energii ma już kolosalne znaczenie. Można wyodrębnić wielu jego kluczowych uczestników, których popyt należy uznać za istotny, a modelowanie jego zmian za wysoce pożądane. Za przykład mogą posłużyć sklepy z żywnością. Są one dużym odbiorcą energii ze względu na zainstalowane urządzenia chłodnicze, oświetlenie i ogrzewanie [Datta i Tassou, 1998]. Szacuje się, że na terenie Wielkiej Brytanii sklepy z żywnością pobierają około 3% całej zużytej energii [Spyroua i in., 2014].

Celem opracowania jest przedstawienie możliwości modelowania detalicznego rynku energii opierając się na ANN, w szczególności w obszarze zapotrzebowania na energię elektryczną oraz jej cen, a także przedstawienie możliwości i zasadności ekonomicznej wprowadzenia w przedsiębiorstwach Zaawansowanej Infrastruktury Pomiarowej (AMI), która umożliwi opracowanie i wdrożenie innowacyjnych struktur taryfowych, obejmujących: ceny i rabaty w okresie krytycznie ekstremalnego zapotrzebowania oraz ceny w czasie rzeczywistym. W tym kontekście celem było również podkreślenie roli, jaką pełni procedura ustalenia cen dla minimalnych rezerw operacyjnych oraz rezerw przekraczających poziom niezbędny dla osiągnięcia standardów wiarygodności.

## **1. Modelowanie detalicznego rynku energii przy użyciu sztucznych sieci neuronowych**

Jak wykazały badania [Jasiński, 2014b], ANN umożliwiają skuteczne modelowanie cen rynkowych zarówno w ujęciu bezwzględnym, jak i przede wszystkim kierunku ich zmian. Jak już wspomniano, zmiany cen energii rzutują na efektywność ekonomiczną przedsiębiorstw, który to wpływ zależy od stopnia zużycia energii przez firmy. Oczywista jest zatem zależność między jej cenami a sy-

tuacją finansową przedsiębiorstw. Możliwość prognozy jednego z kluczowych czynników kosztotwórczych należy uznać za niezwykle istotną z punktu widzenia optymalizacji kosztów funkcjonowania podmiotów gospodarczych<sup>2</sup>. Z drugiej strony prognoza zapotrzebowania generowanego przez odbiorców wpływa na możliwość optymalizacji funkcjonowania rynku energii, dostosowania wielkości dostaw do rzeczywistego popytu, utrzymywania odpowiednio niskich rezerw zapewniających ciągłość dostaw<sup>3</sup>, a co za tym idzie minimalizacji kosztów pozyskania energii. W zależności od siły rynkowej podmiotów na rynku energii w mniejszym lub większym stopniu przekłada się to na jej ceny, jak i zyski. Jak zatem widać, zależności te są dwukierunkowe.

Czynniki skorelowane z zapotrzebowaniem na energię można podzielić na: fizyczne, operacyjne oraz regionalne. Pierwsze z wymienionych mogą być reprezentowane m.in. przez całkowitą powierzchnię sprzedaży. Innym istotnym parametrem jest charakterystyka termofizyczna budynku, która jednak zazwyczaj nie jest w prosty sposób możliwa do określenia w procesie badań. Jak dowodzi literatura przedmiotu, pewnym substytutem może być rok produkcji budynku, statystycznie związany z zastosowaną technologią. Wśród czynników operacyjnych warto wymienić godziny i czas otwarcia sklepów, wielkość sprzedaży, zużycie energii (całkowite oraz związane z urządzeniami chłodniczymi – dane opóźnione), temperaturę i względną wilgotność wewnątrz budynku. Jako czynniki regionalne należy uwzględnić m.in. temperaturę zewnętrzną i wilgotność (które bezpośrednio wpływają na zapotrzebowanie na energię systemów chłodzenia i ogrzewania, alternatywnie można stosować liczbę dni grzewczych oraz dni wymagających włączenia klimatyzacji), natężenie promieniowania słonecznego [Datta i Tassou, 1998; Spyroua i in., 2014].

Model ANN<sup>4</sup> autorstwa Datta i Tassou [1998] uczony na danych zbieranych w odstępach 15-minutowych dokonywał stosunkowo skutecznych prognoz popytu na energię, osiągając dla najlepszego modelu (MLP) MAPE na poziomie 4,59<sup>5</sup>.

<sup>2</sup> Więcej na temat budowania modeli ANN prognozujących czynnik kosztotwórczy w postaci cen energii można odnaleźć w: [Jasiński, 2015].

<sup>3</sup> Szczególnie istotna jest prognoza szczytowego zapotrzebowania na energię. Przykład modelu ANN dokonującego tego typu przewidywania dla australijskiego rynku energii znajduje się w: [Dev i Martin, 2014].

<sup>4</sup> Zastosowano architekturę jednokierunkową, wielowarstwową, czyli tzw. perceptron wielowarstwowy (MLP – Multilayer Perceptron) zbudowany z wykorzystaniem funkcji aktywacji w postaci tangensa hiperbolicznego i uczony za pomocą algorytmu wstecznej propagacji błędów oraz sieci o radialnych funkcjach bazowych (RBF – Radial Basis Function). Więcej na temat rodzajów ANN wykorzystywanych w analizach ekonomicznych można odnaleźć w: [Jasiński, 2003].

<sup>5</sup> Najlepszy model opierał się na 6 zmiennych wejściowych w postaci temperatur i wilgotności na zewnątrz oraz wewnątrz sklepów, a także dnia tygodnia i pory dnia. MLP posiadała strukturę 6-4-1.

Cena energii na rynku detalicznym zazwyczaj nie ulega aż tak częstym zmianom. Taryfy w większości krajów są stosunkowo stabilne. Niemniej jednak możliwe jest również ich przewidywanie za pomocą ANN. Dodatkowo o ile w przypadku odbiorców indywidualnych typowo ilość taryf jest względnie niewielka (zazwyczaj jest to pojedyncza lub kilka stawek za kWh oferowanych przez konkretny podmiot), o tyle w przypadku przedsiębiorstw system taryfowy może być dużo bardziej rozbudowany i ulegać dużo częstszym zmianom [Wezenberg i Dewe, 1995]. Uwzględniając zatem zróżnicowanie cen energii, odbiorcom opłaca się nie tylko optymalizować np. jej zużycie w czasie, ale także pod kątem zmieniających się taryf. Przykład takiego modelu został zaprezentowany przez Wezenberga i Dewe'a [1995] na podstawie ANN o architekturze rekurencyjnej<sup>6</sup>. Zakontraktowanie przez duże przedsiębiorstwa dostawy energii po określonej cenie nie jest zawsze tożsamy z pewnością jej utrzymania. Nader często przekroczenie zaplanowanego poboru w pewnym okresie skutkuje naliczeniem dodatkowych opłat, a zatem możliwość predykcji tego typu sytuacji stanowi kolejny element optymalizacji ekonomicznej przedsiębiorstwa i jednocześnie umożliwia określenie pewnej średniej ceny, po której odbiorca końcowy pozyska energię. ANN przewidujące wystąpienie i czas trwania tego typu sytuacji zostały opisane przez Verona i Ceraolo [1998]. Użyte przez autorów sieci typu RBF umożliwiały precyzyjne przewidywanie szczytowego zapotrzebowania na energię w ciągu dnia przy założeniu horyzontu 7 minut, co można uznać w wielu przypadkach za wystarczające do podjęcia działań ograniczających pobór prądu. Oczywiście możliwość dokonania tego typu prognozy z większym wyprzedzeniem byłaby dużo bardziej pożądana przez przedsiębiorstwa, choć z pewnością także trudniejsza do przeprowadzenia i zapewne obciążona większym błędem.

## **2. Zaawansowana infrastruktura pomiarowa jako czynnik zwiększania elastyczności popytu**

Jak zostało wcześniej podkreślone, prognoza zapotrzebowania generowanego przez odbiorców wpływa na możliwość optymalizacji funkcjonowania rynku energii, dostosowania wielkości dostaw do rzeczywistego popytu oraz utrzymania odpowiednio niskich rezerw zapewniających ciągłość dostaw, dlatego ważnym elementem poprawiającym jakość prognozy jest nadanie stronie popytowej większej wrażliwości na zmiany cen [Baldick i in., 2005]. Na wielu ryn-

---

<sup>6</sup> Zastosowane zostały sieci Elmana zawierające tzw. warstwę kontekstową, więcej na ich temat można odnaleźć w: [Jasiński, 2003].

kach obserwowane są wysiłki w kierunku zwiększenia elastyczności popytu na podstawie dynamicznych i zróżnicowanych w czasie cen detalicznych i inwestycji w Zaawansowaną Infrastrukturę Pomiarową, będących częścią tzw. Inteligentnej Sieci (Smart Grid). Wspomniane inicjatywy mogą prowadzić do wykreowania dużej puli popytu, który w sposób przewidywalny odpowiada na wahania cen hurtowych [Centolella, 2010], dlatego zmiana zachowań konsumentów detalicznych dzięki wdrożeniu nowych technologii polega na modyfikacji zapotrzebowania w zależności od poziomu cen, jeśli dostawy nie są scentralizowane, lub zgłaszaniu zróżnicowanego popytu na rynkach zarządzanych przez Regionalne Organizacje Przesyłowe (RTO – Regional Transmission Organizations). Wdrożenie AMI dla małych klientów komercyjnych i rezydualnych umożliwia zatem opracowanie i wprowadzenie innowacyjnych struktur stawek detalicznych obejmujących: ceny i rabaty w okresie krytycznie ekstremalnego zapotrzebowania oraz ceny w czasie rzeczywistym. Pierwszy z wymienionych elementów systemu cenowego pozwala na wzrost stawek dla klientów detalicznych, kiedy ceny na rynku hurtowym przekroczą poziom krytyczny, drugi oznacza wprowadzenie kredytów dla konsumentów, którzy redukują swoje zużycie poniżej bazowej ilości w danym okresie. Trzecia z wymienionych stawek jest natomiast taryfą domyślną dla dużych klientów, lecz może być także dostępna dla innych konsumentów.

Wskazane rozwiązania, zapewniając niezbędną ekspozycję na ceny rynkowe, redukują konsumpcję w okresach wysokiego popytu, co przyczynia się do powstania znaczących korzyści systemowych. Polegają one głównie na: redukcji kosztów, wynikającej z możliwości odroczenia w czasie inwestycji w elektrownie i niektórych przypadków modernizacji, oraz ograniczeniu strat wynikających z transmisji i dystrybucji w okresie szczytowego zapotrzebowania na skutek dużego obciążenia linii przesyłowych. Inną formą korzyści z elastycznego popytu jest zmniejszenie kosztów ogólnych systemu poprzez: lepsze wykorzystanie aktywów na skutek zwiększenia poziomu konkurencji na rynku w godzinach szczytowego zużycia oraz redukcję ryzyka biznesowego uczestników rynku na skutek złagodzenia wahań cen. Potwierdza to zasadę leżącą u podstaw procesu deregulacji rynku, że zwiększenie poziomu konkurencji będzie stymulowało innowacje, umożliwiając stworzenie bardziej efektywnego systemu z bardziej przystępnymi cenami [Negrete-Pincetic, de Castro i Pulgar-Painemal, 2015].

Ze względu na to, że inwestycje związane z wdrożeniem AMI wymagają dużych nakładów finansowych, uzasadnieniem dla ich podjęcia jest możliwość pomiaru wartości popytu reagującego na ceny, generująca wspomniane wcześniej korzyści. Wartość ta jest determinowana: możliwością uniknięcia wymogów w zakresie tworzenia dodatkowych mocy produkcyjnych, obniżaniem kosztów do-

staw energii i usług pomocniczych w okresach wzrostu cen, redukcją częstotliwości i skali incydentów w postaci niedoboru energii i ogólną poprawą efektywności działania poprzez uwzględnienie informacji o relacji między cenami a popytem w procesie podejmowania decyzji operacyjnych przez uczestników systemu.

Regionalne Organizacje Przesyłowe budowały swoje rynki na podstawie założenia, że popyt będzie nieelastyczny i nie będzie reagował na zmiany cen na rynku dnia następnego lub na rynkach rozliczanych w czasie rzeczywistym [Centolella, 2010]. Wykreowanie zatem popytu reagującego na wahania cen oznacza konieczność modyfikacji budowanych przez nie prognoz oraz programów dotyczących: zobowiązań elektrowni, ograniczonej względami bezpieczeństwa dystrybucji energii, jej wyceny i zasad rozliczenia. Proces reform scentralizowanych rynków energii został szeroko opisany przez Kelly i Caplan [2008].

Tradycyjne prognozowanie traktuje popyt tak jakby był on sztywny względem ceny w krótkim okresie, dlatego dla odzwierciedlenia popytu elastycznego wobec ceny może ono być uzupełnione o dodanie modyfikatora prognozy popytu elastycznego względem ceny. Aby właściwie rozpoznać popyt reagujący na ceny, odpowiednie władze planujące rezerwy [Aghaei, Shayanfar i Amjadi, 2009] kalkulowałyby wymogi dotyczące zasobów i rezerw, poczynając od punktu cena/ ilość na prognozowanej krzywej reakcji popytu. Wybrany punkt cena/ ilość mógłby dotyczyć wysokiej ceny na poziomie niższym niż wartość odzwierciedlająca wielkość utraconego popytu (VOLL – Value of Lost Load), która oznacza, że przy takich stawkach korzystniejszym rozwiązaniem dla klientów jest rezygnacja z dostaw energii. Taki system stawek powoduje, że konsumenci reagujący na popyt są niezależni od systemu w aspekcie finansowym oraz fizycznym. Pierwszy z nich oznacza możliwość unikania wysokich cen na rynku transakcji bieżących poprzez zawieranie terminowych transakcji zabezpieczających, natomiast drugi oznacza właściwe określenie poziomu rezerw.

Jednym z elementów, który to umożliwia jest skonstruowanie Krzywej Popytu na Rezerwy Operacyjne, stanowiące także podstawę reformy cen występujących w warunkach niedoboru. Jej zadaniem jest podniesienie cen energii i usług pomocniczych, zanim dostępne rezerwy operacyjne osiągną poziom minimalny, oraz kreowanie bodźców do zakupu dodatkowych rezerw operacyjnych.

Obecne taryfy ustalane przez RTO nieefektywnie dostosowują popyt i podaż dla okresów niedoboru energii, ponieważ prawdopodobieństwo wystąpienia braku rezerw nie jest obecnie sygnalizowane poprzez wzrost cen energii lub dostępnych rezerw, co skutkuje szybkim i skokowym wzrostem cen w przypadku awarii. Cena minimalnych rezerw operacyjnych powinna więc być ustalona na wystarczająco wysokim poziomie, żeby wywołać dobrowolną redukcję popytu,

minimalizując tym samym ryzyko przymusowych ograniczeń jednostek obsługujących popyt [Centolella, 2010].

Dla rezerw przekraczających poziom niezbędny dla osiągnięcia standardów wiarygodności krzywa popytu powinna z kolei odzwierciedlać marginalną Wartość Oczekiwanej Niedostarczonej Energii (VEUE – Value of Expected Unserved Energy). Może ona być obliczona jako efekt pomnożenia VOLL przez warunkowe prawdopodobieństwo utraty popytu na tym poziomie rezerw, zakładając wystąpienie wybranych zdarzeń, takich jak wymuszony brak dostaw na poziomie 100 MW lub wyższym [Centolella, 2010]. Opracowana w ten sposób dwuczęściowa Krzywa Popytu na Rezerwy Operacyjne, ze stałym cenami VOLL dla poziomu minimalnych rezerw i wartością probabilistyczną opartą na wycenie dodatkowych rezerw, odzwierciedlałaby oczekiwaną wartość rezerw operacyjnych dla konsumentów.

Umożliwienie konsumentom zabezpieczenia się przed ryzykiem wysokich cen w warunkach niedoboru będzie wymagało synchronizacji cen niedostatku i stawek rekompensujących koszty dodatkowych mocy produkcyjnych. Problem budowy dodatkowych mocy produkcyjnych w wystarczającej ilości jest istotny nie tylko z punktu widzenia wiarygodności systemu, ale także konieczności wyeliminowania sytuacji, kiedy jeden lub kilku generatorów poprzez nadużywanie siły rynkowej może doprowadzić do załamania rynku [Blumsack, Perekhodtsev i Lave, 2002]. Inne metody łagodzenia zjawiska nadużywania siły rynkowej zostały opisane przez Willemsa i De Corte [2008] oraz Greniera [1999]. Budowa dodatkowych mocy produkcyjnych jest wysoce kosztownym rozwiązaniem, przyczyniającym się do wzrostu cen, dlatego w ramach reformy systemu stawek w warunkach niedoboru proponuje się przesunięcie przychodów uzyskiwanych na rynkach energii i usług pomocniczych na rynek dodatkowych mocy produkcyjnych, uwzględniające ceny, które obowiązywały na rynkach w chwili pozyskiwania dodatkowych mocy produkcyjnych.

## Podsumowanie

Przewidywanie przyszłego zachowania konsumentów jest jednym z podstawowych zadań, które stoją przed analitykami rynków energii. W konsekwencji może ono doprowadzić do optymalizacji ich funkcjonowania. Także odbiorcy detaliczni (szczególnie ci więksi) dzięki takiej wiedzy mogą minimalizować koszty funkcjonowania przedsiębiorstwa. Jak wykazały badania, nowoczesne techniki prognostyczne działające na podstawie sztucznej inteligencji stanowią

skuteczne narzędzia prognostyczne. Okazuje się jednak, że sama wiedza o wysokości popytu zaczyna być niewystarczająca. Coraz częściej próbuje się sięgać po narzędzia, które są w stanie odpowiednio go kształtować na rynkach detalicznych, tak by współgrał on z sytuacją na rynku hurtowym. Jednym z używanych bodźców jest cena. Możliwość jej dynamicznych zmian niesie ze sobą wprowadzanie systemów inteligentnych sieci wraz z AMI. Należy oczekiwać, że trend ten będzie kontynuowany i w konsekwencji doprowadzi do urealnienia w funkcji czasu cen detalicznych, a co za tym idzie minimalizacji jej szczytowej konsumpcji.

## Literatura

- Aghaei J., Shayanfar H., Amjady N. (2009), *Multi-objective Market Clearing of Joint Energy and Reserves Auctions Ensuring Power System Security*, „Energy Conversion and Management”, No. 50.
- Baldick R., Helman U., Hobbs B.F., O’Neill R.P. (2005), *Design of Efficient Generation Markets*, „Proc IEEE”, No. 93(11).
- Blumsack S., Perekhodtsev D., Lave L.B. (2002), *Market Power in Deregulated Wholesale Electricity Markets: Issues in Measurement and the Cost of Mitigation*, „The Electricity Journal”, No. 15(9).
- Centolella P. (2010), *The Integration of Price Responsive Demand into Regional Transmission Organization (RTO) Wholesale Power Markets and System Operations*, „Energy”, No. 35.
- Datta D., Tassou S.A. (1998), *Artificial Neural Network Based Electrical Load Prediction for Food Retail Stores*, „Applied Thermal Engineering”, No. 18.
- Dev P., Martin M.A. (2014), *Using Neural Networks and Extreme Value Distributions to Model Electricity Pool Prices: Evidence from the Australian National Electricity Market 1998-2013*, „Energy Conversion and Management”, No. 84.
- Federal Energy Regulatory Commission – FERC (2008), *In the Matter of Wholesale Competition in Regions with Organized Electric Markets*, 125 FERC 61,071.
- Granell R., Axon C.J., Wallom D.C.H. (2014), *Predicting Winning and Losing Businesses when Changing Electricity Tariffs*, „Applied Energy”, No. 133.
- Grenier E.J. (1999), *Auctions and Rates: An End-user Perspective*, „Natural Gas”, Vol. 15, Iss. 7.
- Jasiński T. (2003), *Przegląd architektur sztucznych sieci neuronowych wykorzystywanych w ekonomii do przewidywania szeregów czasowych*, „Studia i Prace Kolegium Zarządzania i Finansów”, nr 35, Oficyna Wydawnicza SGH, Warszawa.
- Jasiński T. (2008), *The Usage of Neural Networks on a Foreign Exchange Market* [w:] L. Kiełtyka (red.), *Technologie i systemy komunikacji oraz zarządzania informacją i wiedzą*, Difin, Warszawa.



- Jasiński T. (2009), *Wykorzystanie sztucznej inteligencji w prognozowaniu zjawisk ekonomicznych*, „Prace naukowe Katedry Nauk Ekonomicznych”, tom VIII, Politechnika Gdańska, Gdańsk.
- Jasiński T. (2010), *Sztuczna inteligencja w MSP*, „Nierówności społeczne a wzrost gospodarczy”, Wydawnictwo Uniwersytetu Rzeszowskiego, Rzeszów.
- Jasiński T. (2011), *The Usage of Artificial Neural Networks on the Energy Market* [w:] L. Kiełtyka (red.), *IT Tools in Management and Education. Selected Problems*, Wydawnictwo Politechniki Częstochowskiej, Częstochowa.
- Jasiński T. (2014a), *Dane wejściowe sztucznych sieci neuronowych prognozujących krótkoterminowe zapotrzebowanie na energię*, „Logistyka”, nr 6.
- Jasiński T. (2014b), *Prognozowanie szeregów czasowych za pomocą sieci neuronowych na przykładzie rynku energii* [w:] P. Łebkowski (red.), *Zarządzanie Przedsiębiorstwem. Teoria i praktyka 2014*, AGH, Kraków.
- Jasiński T. (2015), *Budowa modelu prognostycznego cen zasobów produkcyjnych z wykorzystaniem sztucznych sieci neuronowych* [w:] Z. Leszczyński, T. Jasiński (red.), *Inżynieria kosztów*, ODDK, Toruń.
- Jasiński T., Ścianowska A. (2014), *Analiza i modelowanie rynku energii w perspektywie długoterminowej. Systemy aukcji i przewidywanie popytu*, „Logistyka”, nr 6.
- Kelly S., Caplan E. (2008), *Time for a Day 1,5 Market: A Proposal to Reform RTO-run Centralized Wholesale Electricity Markets*, „Energy Law Journal”, Vol. 29, No. 2.
- Negrete-Pincetic M., de Castro L., Pulgar-Painemal H.A. (2015), *Electricity Supply Auctions: Understanding the Consequences of the Product Definition*, „Electrical Power and Energy Systems”, No. 64.
- Spyroua M.S., Shanksc K., Cooka M.J., Pitcherb J., Leeb R. (2014), *An Empirical Study of Electricity and Gas Demand Drivers in Large Food Retail Buildings of a National Organisation*, „Energy and Buildings”, No. 68.
- Verona F.B., Ceraolo M. (1998), *Use of Neural Networks for Customer Tariff Exploitation by Means of Short-term Load Forecasting*, „Neurocomputing”, No. 23.
- Wezenberg H., Dewe M.B. (1995), *Adaptive Neural Networks for Tariff Forecasting and Energy Management* [w:] IEEE International Conference on Neural Networks, Proceedings, Vol. 2.
- Willems B., De Corte E. (2008), *Market Power Mitigation by Regulating Contract Portfolio Risk*, „Energy Policy”, No. 36.

#### DEMAND, PRICES AND THE DEGREE OF THEIR INFLATION IN SELECTED ENERGY MARKETS

**Summary:** The paper reveals the possibility to predict demand and prices in the retail electricity market using tools from the field of artificial intelligence, which are artificial neural networks. This knowledge allows to optimize the economic operating of entities on both sides of the market: demand and supply. Further optimization of the market re-

quires a reduction especially peak demand, which is possible by the system of variable prices. This paper discusses the possibility of implement this type of solutions based on advanced measurement infrastructure, which is part of smart grid systems.

**Keywords:** retail energy market, forecasting, prices, demand, artificial neural networks, advanced metering infrastructure.