

Prof. dr hab. inż. Grzegorz Dudek
Katedra Automatyki, Elektrotechniki i Optoelektroniki
Wydział Elektryczny
Politechnika Częstochowska
Al. Armii Krajowej 17
42-200 Częstochowa

Częstochowa, dn. 29 listopada 2023 r.

RECENZJA

rozprawy doktorskiej mgr. Grzegorza Jarosława Marcjasza pt. *Deep learning in point, probabilistic and ensemble forecasting of electricity prices*

Formalną podstawą opracowania recenzji jest pismo Przewodniczącego Rady Dyscypliny Naukowej Nauki o Zarządzaniu i Jakości na Politechnice Wrocławskiej, prof. dr hab. inż. Rafała Weron, z dnia 28.09.2023 r. Oceny rozprawy doktorskiej dokonano według kryteriów określonych w ustawie z 20 lipca 2018 r. *Prawo o szkolnictwie wyższym i nauce*. Promotorem rozprawy doktorskiej jest prof. dr hab. inż. Rafał Weron.

Charakterystyka rozprawy

Rozprawę doktorską stanowi zbiór pięciu powiązanych tematycznie artykułów naukowych opatrzonych częścią wstępną. Część wstępna zawiera streszczenia w języku polskim i angielskim, rozdziały wprowadzające, które dotyczą rynków energii elektrycznej i sztucznych sieci neuronowych, opis wyników zamieszczonych w poszczególnych artykułach, opis wyników dodatkowej pracy badawczej Autora, wnioski i bibliografię (ok. 80-90 pozycji). Rozprawa napisana jest w języku angielskim. Część wstępna liczy 42 strony.

Zbiór artykułów i deklarowane przez Autora udziały:

- [1] G. Marcjasz (2021), Forecasting Electricity Prices Using Deep Neural Networks: A Robust Hyper-Parameter Selection Scheme, *Energies*, 13(18), 4605.

JCR classification: Energy & Fuels. Scopus classification: Mathematics: Control and Optimization; Engineering; Energy. IF = 3.2. MEiN: 140 pts, assigned to the Management and Quality Studies (NZJ) discipline.

- [2] J. Lago, G. Marcjasz, B. De Schutter, R. Weron (2021) Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark, *Applied Energy*, 293, 116983.

JCR classification: Energy & Fuels; Engineering. Scopus classification: Engineering; Environmental Science: Management, Monitoring, Policy and Law; Energy. IF = 11.2, MEiN: 200 pts, assigned to the Economics & Finance discipline.

Author's contribution amounted to ca. 30% and concerned designing the study, developing the methods, concluding analyses and drafting the paper.

- [3] K. Olivares, C. Challu, G. Marcjasz, R. Weron, A. Dubrawski (2022), Neural basis expansion analysis with exogenous variables: Forecasting electricity prices with NBEATSx, *International Journal of Forecasting*, 39(2), 884-900.

JCR classification: Economics; Management. Scopus classification: Business, Management and Accounting. IF = 7.9, MEiN: 140 pts, assigned to the Management and Quality Studies (NZJ) discipline.

Author's contribution amounted to ca. 25% and concerned designing the study, taking part in method development, validating the results and drafting the paper.

- [4] G. Marcjasz, M. Narajewski, R. Weron, F. Ziel (2023), Distributional neural networks for electricity price forecasting, *Energy Economics*, 125, 106843.

JCR classification: Economics. Scopus classification: Economics, Econometrics and Finance; Energy. IF = 12.8. MEiN: 200 pts, assigned to the Management and Quality Studies (NZJ) discipline.

Author's contribution amounted to ca. 30% and concerned designing the study, developing and testing the models, analyzing the results and drafting the paper.

- [5] G. Marcjasz, T. Serafin, R. Weron, Trading on short-term path forecasts of intraday electricity markets with distributional neural networks. Submitted to *Energy Economics* (under review)

Author's contribution amounted to ca. 40% and concerned designing the study, preparing and testing the DDNN model, analyzing the results and drafting the paper.

Artykuł [5] nie został jeszcze opublikowany. W świetle komunikatu Rady Doskonałości Naukowej nr 19/2020 w sprawie składania rozpraw doktorskich „dopuszczalne jest, aby rozprawa doktorska, jako praca pisemna, składała się po części z prac opublikowanych, jak i takich, których wyniki jeszcze nie zostały opublikowane”.

Opinia na temat rozprawy – uwagi krytyczne i polemiczne

Energia elektryczna jest towarem będącym przedmiotem handlu na konkurencyjnym rynku energii, a jej ceny ustalane są na podstawie ofert kupna i sprzedaży. Wynikają nie tylko z cen surowców energetycznych i uprawnień do emisji CO₂, ale także w coraz większym stopniu, z trudno przewidywalnych warunków pogodowych determinujących generację ze źródeł odnawialnych. Dokładne prognozy cen energii są niezbędne dla uczestników rynku, w tym wytwórców, przedsiębiorstw obrotu i odbiorców końcowych. Pozwalają im zoptymalizować strategie handlowe oraz harmonogramy produkcji i poboru energii elektrycznej. W miarę obserwowanego w ostatnich latach wzrostu udziału źródeł energii odnawialnej w miksie energetycznym, prognozowanie cen energii staje się jeszcze większym wyzwaniem. Energię odnawialną cechuje duża dynamika, która przekłada się na zmienność ceny energii, wprowadzając znaczący komponent losowy i nagłe skoki cen. W tym kontekście tematyka podjęta w rozprawie jest bardzo istotna, aktualna i potrzebna. Autor proponuje modele oparte na sieciach neuronowych do punktowych i probabilistycznych prognoz cen energii elektrycznej. Te ostatnie odgrywają kluczową rolę w zarządzaniu ryzykiem. Pozwalają uczestnikom rynku zabezpieczać się przed zmiennością cen energii i ograniczać ryzyko finansowe związane z jej nagłymi zmianami.

Tytuł rozprawy jest odpowiednio zwarty i komunikatywny. W pełni oddaje najistotniejsze elementy treściowe rozprawy. Problem badawczy jest jasno sformułowany: celem badań jest opracowanie

metodyki prognozowania cen energii elektrycznej w ujęciu punktowym, probabilistycznym i zespołowym za pomocą głębokich sieci neuronowych. Szczegółowe cele badawcze mają postać (podrozdz. 1.2):

Objective 1: Identify the most common problems encountered in EPF machine learning research, present a set of best practices and publish open access codes for well-performing benchmark models.

Objective 2: Develop an interpretable DNN model for point EPF that outperforms state-of-the-art benchmarks.

Objective 3: Construct distributional DNNs that directly yield predictive distributions and are superior to state-of-the-art probabilistic models in terms of both statistical and economic measures.

Objective 4: Develop a decision support method that uses distributional DNNs to generate trajectories of ID prices, then use it to construct profitable trading strategies.

W rozdziale pierwszym części wstępnej pracy Autor przekonująco uzasadnia podjęcie tematu i pokazuje ewolucję modeli prognostycznych dla cen energii elektrycznej: od liniowych z ograniczoną liczbą zmiennych wejściowych po głębokie sieci neuronowe. Definiuje cele pracy i, odwołując się do artykułów [1]-[5], objaśnia, w jaki sposób zamierza je osiągnąć. W dalszej części, nie pozostawiając wątpliwości, uzasadnia związek tematyki pracy z dyscypliną nauki o zarządzaniu i jakości.

Rozdział drugi omawia rynki energii elektrycznej – rynek dnia następnego (*day-ahead market*) i bieżącego (*intraday market*). Autor objaśnia czynniki kształtujące ceny energii i zwraca uwagę na dużą zmienność tych cen. Na przykładzie rynku niemieckiego pokazuje zależność cen od miksu energetycznego i podkreśla duży wpływ niestabilnej generacji ze źródeł odnawialnych na ceny energii.

W rozdziale trzecim przedstawiono wiadomości wstępne na temat sztucznych sieci neuronowych. Ograniczono się do jednej architektury – wielowarstwowego perceptronu (MLP). Tę architekturę Autor wykorzystuje w swoich pracach [1]-[5]. Omówiono problematykę treningu sieci, doboru okna kalibracji, przeuczenia modelu, optymalizacji hiperparametrów i konstrukcji modelu prognostycznego dla rynku dnia następnego. Omawiając sposoby zapobiegania przeuczeniu, Autor wymienia dwie metody: wcześniejsze zatrzymanie treningu (*early stopping*) i dobór długości okresu treningowego. O ile ta pierwsza metoda jest powszechnie stosowana, to ta druga wymaga wyjaśnienia. W tym miejscu zabrakło charakterystyki innych popularnych metod zapobiegania przeuczeniu, takich jak regularyzacja, *dropout*, czy podejście zespołowe.

W rozdziale czwartym Autor streszcza artykuły [1]-[5]. Charakteryzuje podejmowane w tych pracach problemy badawcze, omawia metody ich rozwiązania i osiągnięte wyniki. Opis niektórych artykułów pozostawia jednak niedosyt. Na przykład zawartość obszernej pracy [2] nie została dostatecznie streszczona, a opis unikalnego modelu prognostycznego i wyników zaprezentowanych w [3] Autor zawarł w jednym, krótkim akapicie.

Rozdział piąty zawiera opis dodatkowej pracy badawczej Autora. Praca ta jest udokumentowana dziesięcioma publikacjami w znakomitych czasopismach naukowych, takich jak IEEE Transactions on Sustainable Energy, Energy Economics, International Journal of Forecasting i IEEE Power and Energy Magazine. W czterech publikacjach nazwisko autora znajduje się na pierwszej pozycji, a w pięciu na

drugiej, co świadczy o jego dużym zaangażowaniu. Wszystkie prace dotyczą prognozowania cen energii elektrycznej. Dorobek Doktoranta robi duże wrażenie i zasługuje na uznanie.

W szóstym rozdziale Autor przedstawia podsumowanie. Analizuje osiągnięcie czterech postawionych celów i objaśnia, w jaki sposób zostały one zrealizowane w artykułach [1]-[5]. W dalszej części zamieszcza te artykuły.

W [1] Autor podejmuje tematykę doboru hiperparametrów w modelu neuronowym zaprojektowanym do prognozowania cen energii elektrycznej. W części wstępnej słusznie zauważa, że rynkowe ceny energii mają rozkłady z ciężkimi ogonami i ich szeregi czasowe charakteryzują się nagłymi skokami (*spikes*). Aby poprawić dokładność prognozowania, zaleca wyrównywać ich wariancję poprzez odpowiednie transformacje. W sekcji 3.5 proponuje do tego celu odpowiednią normalizację i przekształcenie za pomocą funkcji area sinus hiperboliczny. Architektura sieci neuronowej, jaką rozważa w tej pracy, to wielowarstwowy perceptron (*multilayer perceptron*, MLP) z dwiema warstwami ukrytymi. Autor stawia sobie za cel optymalizację tej sieci, tj. znalezienie odpowiednich wartości hiperparametrów, do których zalicza metodę optymalizacji parametrów, typ funkcji aktywacji, liczbę epok i rozmiar próby wsadowej (*batch size*). Optymalizację hiperparametrów przeprowadza metodą przeszukiwania siatki (*grid search*), którą używa się standardowo w takich przypadkach obok metody optymalizacji bayesowskiej. Oryginalnym problemem badawczym podjętym przez Autora jest zastosowanie hiperparametrów optymalnych dla jednego zbioru danych w predykcji innego zbioru. Wyniki są zaskakujące: we wszystkich przypadkach hiperparametry wybrane dla zbioru A i zastosowane dla zbioru B dają mniejszy błąd prognozy niż hiperparametry optymalne dla B. Szkoda, że Autor nie podał zestawienia optymalnych wartości hiperparametrów dla różnych zbiorów danych (mam nadzieję, że uzupełni ten brak w trakcie obrony pracy). Aby poprawić właściwości modelu, Autor stosuje podejście zespołowe (*ensemble*) w dwóch wariantach: uśredniając wyniki prognoz dla trzech długości okna kalibracji (długości okresów treningowych) oraz uśredniając wyniki prognoz uzyskanych przy kilku najkorzystniejszych zestawach hiperparametrów. Warto zwrócić uwagę, że ten drugi sposób nie wymaga dodatkowych nakładów obliczeniowych, ponieważ wykorzystuje wyniki przeprowadzonej optymalizacji hiperparametrów. Wyniki prac badawczych zaprezentowane są w czytelnej formie, dogłębnie przedyskutowane i opatrzone poprawnymi wnioskami.

Uwagi i pytania do [1]:

- 1) Do podstawowych hiperparametrów sieci neuronowej zalicza się liczbę warstw i liczbę neuronów ukrytych. Autor pomija te hiperparametry w optymalizacji. Dlaczego? Przyjęte rozmiary obu warstw ukrytych (po 100 neuronów) wydają za duże. Nadmiarowa architektura ma tendencję do przeuczania się, szczególnie w przypadku braku mechanizmów, które temu zapobiegają, takich jak regularyzacja czy *dropout*.
- 2) Nie jest jasne, jak oceniano model neuronowy przy różnych wartościach hiperparametrów w procedurze przeszukiwania siatki. Autor nie wspomina o zbiorze walidacyjnym standardowo wydzielanym ze zbioru treningowego w celu estymacji błędu generalizacji, który służy do oceny zestawu hiperparametrów. Do doboru hiperparametru w modelu LASSO używa się walidacji krzyżowej, ale czy to jest poprawne rozwiązanie w kontekście problemów prognostycznych?
- 3) Hiperparametry dobrane dla próby treningowej nie zawsze są optymalne dla próby testowej. Może to wynikać zarówno z różnicy rozkładów danych treningowych i testowych, jak i ze stochastycznej natury modelu. Czy Autor może zaproponować jakieś środki zaradcze, które zredukują ten problem?
- 4) Sekcja 6.3 ma błędnie tę samą treść co sekcja 6.2.

- 5) Do porównania wyników generowanych przez różne modele należało zastosować odpowiednie testy statystyczne, wykazując, że różnice w błędach są istotne statystycznie.

W artykule [2] dokonano przeglądu literatury dotyczącej prognozowania cen energii elektrycznej. Przedstawiono najnowsze osiągnięcia w dziedzinie algorytmów i najlepsze praktyki, a także zaproponowano modele i dane referencyjne. Opisując model prognostyczny, Autorzy dzielą je na kilka kategorii: statystyczne, wykorzystujące uczenie głębokie, hybrydowe i modele *state-of-the-art*. Kategoria modeli hybrydowych zawiera modele łączące dekompozycję, selekcję cech, klasteryzację, kilka modeli prognostycznych i algorytmy optymalizujące. W sekcji 5 zamieszczono wskazówki i najlepsze praktyki w prognozowaniu cen energii elektrycznej. Wskazówki te dotyczą m.in. doboru długości okresu testowego, doboru odpowiednich modeli referencyjnych, udostępniania algorytmów i danych, metryk jakości prognoz, testów statystycznych do porównywania prognoz, optymalizacji i zapewnienia warunków powtarzalności eksperymentów. Wskazówki i uwagi Autorów, podsumowane w sekcji 7, są bardzo wartościowe, wynikają z ich bogatego doświadczenia badawczego. Cenną inicjatywą Autorów jest opracowanie i udostępnienie kodów źródłowych dwóch modeli referencyjnych: LASSO i sieci neuronowej (MLP). Wraz z modelami udostępniają pięć zbiorów danych do testów oraz wyniki własnych prognoz. Zbiory danych zawierają zmienne egzogeniczne, a właściwie ich prognozy. Udostępnione kody, dane i wyniki stwarzają środowisko do testowania i obiektywnego porównywania (łącznie z wykonaniem testów statystycznych) modeli proponowanych przez różnych badaczy. Zarówno modele referencyjne, jak i dane są w pracy szczegółowo opisane, łącznie z procedurami wstępnego przetwarzania danych, optymalizacji i treningu. Przedstawiono wyniki prognoz oraz ich dogłębną analizę.

Uwagi i pytania do [2]:

- 1) W sekcji 2.4, jako modele *state-of-the-art* Autorzy wymieniają dwa: model liniowy LASSO oraz sieć neuronową MLP. Nazwanie tych modeli *state-of-the-art* jest dość dyskusyjne. Z pewnością są to modele najbardziej popularne, ale już nie najnowsze. Gwałtowny rozwój uczenia maszynowego obserwowany w ostatnich latach „zrodził” wiele bardziej zaawansowanych rozwiązań.
- 2) Podział modeli prognostycznych w sekcji 2 na statystyczne, wykorzystujące uczenie głębokie i hybrydowe pomija liczną grupę modeli uczenia maszynowego (z wyjątkiem podgrupy modeli głębokich). Dlaczego?
- 3) W sekcji 4.3.3 opisano hiperparametry modelu referencyjnego opartego na sieci neuronowej. Ich liczba, 19, świadczy o ogromnej przestrzeni rozwiązań. Jak poradzić sobie z jej przeszukiwaniem? Czy stosowano tu jakieś uproszczenia lub heurystyki?

W [3] przedstawiono model sieci głębokiej NBEATSx dedykowany prognozowaniu cen energii elektrycznej. Model ten stanowi rozszerzenie modelu NBEATS o zmienne egzogeniczne – w tym konkretnym zastosowaniu są to prognozy zapotrzebowania na energię elektryczną oraz prognozy generacji ze źródeł odnawialnych. Cenną cechą tego modelu jest konfiguracja interpretowalna, generująca prognozy w postaci zdekomponowanej na składowe poziomy, trendu i sezonowości oraz identyfikująca efekt zmiennych egzogenicznych. W artykule szczegółowo opisano budowę modelu, jego konfigurację, optymalizację, trening i procedury prognozowania zespołowego (*ensembling*). Do generowania dywersyfikacji modeli w podejściu zespołowym zastosowano dwa pomysłowe podejścia. Pierwsze polega na odpowiednim próbkowaniu danych uczących w trakcie treningu, a drugie na zróżnicowanej liczbie epok treningu. Wyniki prognoz modelu NBEATSx porównano z wynikami kilku modeli referencyjnych, używając testu Giacomini-White’a. We wnioskach podkreślono zalety modelu

NBEATSx – szybką optymalizację, interpretowalne wyniki, możliwość wprowadzenia zmiennych egzogenicznych i wysoką dokładność. W załączniku do artykułu Autorzy dzielą się swoją wiedzą na temat optymalizacji hiperparametrów zdobytą w trakcie badań symulacyjnych. To bardzo wartościowa część pracy, pozwalającą innym badaczom wykorzystującym ten model zaoszczędzić czas na jego optymalizację, która jest najbardziej żmudnym elementem procesu budowy modelu uczenia maszynowego.

Uwagi i pytania do [3]:

- 1) W sekcji 4.3.5 opisano, lecz dość ogólnie, dwie metody dywersyfikacji modeli bazowych w prognozowaniu zespołowym. Czy Autor mógłby dokładnie omówić te metody? Jakie inne metody dywersyfikacji można by jeszcze zastosować?
- 2) We wnioskach zwrócono uwagę, że model NBEATSx jest łatwy w optymalizacji. Jak należy to rozumieć w kontekście ogromnej liczby hiperparametrów (Tabela 2)? Jaki był przeciętny czas optymalizacji modelu?
- 3) Z punktu widzenia budowy modelu NBEATSx w wersji interpretowalnej, kluczowym jest definicja poszczególnych składników dekompozycji – wzory (5)-(7). We wnioskach wskazano na możliwość wykorzystania teorii falek i enkodera splotowego do definicji tych składowych. Czy Autor mógłby przybliżyć te pomysły?

W pracy [4] przedstawiono parametryczne podejście do prognozowania probabilistycznego przy użyciu sieci neuronowych MLP. MLP jest rozbudowana o warstwę wyznaczającą parametry rozkładu prawdopodobieństwa. Rozważa się dwa typy rozkładów: normalny i Johnsona SU. Ten drugi, opisany czterema parametrami, jest asymetryczny, zapewnia więc dokładniejsze modelowanie niż rozkład normalny, co Autorzy pokazują w sekcji 3, analizując dane rzeczywiste i w sekcji 5, analizując wyniki prognoz. Aby zapobiec przeuczeniu sieci, wprowadzono dość rozbudowany mechanizm regularyzacji. Zawiera on kary zależne od wielkości wag, progów (*bias*, *b*) i odpowiedzi warstw ukrytych (*H*). Każdy składnik kary wyposażony jest we własny współczynnik. Daje to większe możliwości sterowania regularyzacją, ale z drugiej strony zwiększa liczbę hiperparametrów. Zestaw zmiennych wejściowych zawiera oprócz prognoz zapotrzebowania na energię elektryczną i prognoz generacji ze źródeł odnawialnych także ceny uprawnień do emisji CO₂ i ceny paliw. Część eksperymentalna pracy jest bardzo rozbudowana, zawiera opis mierników jakości prognoz, opis testów statystycznych, opis oceny ekonomicznej prognoz (to cenny element pracy, rzadko spotykany w tego typu artykułach, który pozwala przełożyć wyniki prognoz na zyski), prezentację i dyskusję wyników. Autorzy zwracają uwagę na bardzo istotny problem z doбором hiperparametrów. Przy różnych ich zestawach obserwuje się zbliżone wyniki na próbie uczącej. Ta obserwacja jednak nie przekłada się na próbę testową, gdzie obserwuje się znacznie większe zróżnicowanie. Rodzi to pytanie, jak skutecznie przeprowadzać optymalizację hiperparametrów.

Uwagi i pytania do [4]:

- 1) Mechanizm regularyzacji (4) zawiera składniki karne zależne od wag, progów (*bias*, *b*) i odpowiedzi warstw ukrytych (*H*). O ile kara za duże wagi nie budzi zastrzeżeń (małe wagi przekładają się na płaskie funkcje aktywacji, co zmniejsza „elastyczność” modelu i tym samym jego „skłonność” do przeuczania się), to wyjaśnienia wymagają kary za duże progi i odpowiedzi warstw ukrytych.
- 2) Czy zysk z takiej rozbudowanej regularyzacji rekompensuje wzrost złożoności obliczeniowej?

Identyfikacja modelu prognostycznego jak w [4] zastosowano w [5] do przewidywania cen energii elektrycznej na rynku dnia bieżącego (*intraday market*). To zadanie jest bardziej wymagające w porównaniu do prognozowania cen na rynku dnia następnego. W przeciwieństwie do rynków aukcyjnych handel na rynku dnia bieżącego jest ciągły i nie obowiązuje tu jedna cena za produkt (w tym przypadku dostawę określonej ilości energii elektrycznej w danym okresie). Cena zależy od momentu wejścia na rynek i wyraża się w postaci trajektorii. Zaproponowany model generuje pasma predykcji (*prediction bands*) pokrywające te trajektorie z zadaniem prawdopodobieństwem. Na podstawie tych pasm podejmowane są decyzje dotyczące momentów transakcji kupna i sprzedaży. Zbiór zmiennych wejściowych zawiera oprócz cen energii i indeksów cenowych, poziom generacji wiatrowej, zapotrzebowanie na energię elektryczną i historyczne wartości zmiennej prognozowanej (*volume-weighted average prices*). Warto podkreślić, że podobnie jak w pracach [2-4], Autorzy jako danych wejściowych używają nie tylko wartości historycznych, lecz także prognoz generacji wiatrowej i zapotrzebowania na energię. Powinno się to przekładać na zwiększenie dokładności prognoz. Takie podejście rzadko spotyka się w literaturze z powodu trudności w dostępie do prognoz tych zmiennych wejściowych. Do ocen prognoz Autorzy proponują trzy miary statystyczne odpowiednie dla prognoz ścieżkowych (*path forecasts*) generowanych przez zespół modeli. Dodatkowo oceniają prognozy pod względem ekonomicznym, definiując odpowiednie strategie handlowe.

Uwagi i pytania do [5]:

- 1) Użycie jako zmiennych wejściowych prognoz generacji wiatrowej i zapotrzebowania na energię elektryczną powinno się przełożyć na poprawę prognoz. Czy Autor może to skomentować?

Układ redakcyjny rozprawy nie budzi zastrzeżeń. Artykuły napisane są bardzo wnikliwie, co zasługuje na pochwałę. Drobiazgowo opisano problemy badawcze, proponowane rozwiązania i uzyskane wyniki oraz wyciągnięto poprawne wnioski. Język pracy jest profesjonalny z właściwym słownictwem specjalistycznym i odpowiednią ścisłością sformułowań. Sekwencja treści prezentowanych w kolejnych rozdziałach części wstępnej jest właściwa: od informacji wstępnych, wprowadzających w tematykę, poprzez opis problemu badawczego, charakterystykę modelu, podsumowanie poszczególnych artykułów, przedstawienie aktywności badawczej Autora i wnioski. Źródła literaturowe dobrane są właściwie.

Warto zwrócić uwagę, że cykl prac [1]-[5] opublikowano w renomowanych czasopismach o wysokich współczynnikach wpływu. Udział Autor w pracach wieloautorskich [2]-[5] jest znaczący, waha się od 25 do 40 %. Oczekuję, że Autor w trakcie obrony szczegółowo omówi swój udział w tych pracach.

Nie mam wątpliwości, że Autor rozwiązał postawione problemy i osiągnął założone cele, używając właściwych metod. Oryginalność rozprawy polega na opracowaniu nowych metod prognozowania cen energii elektrycznej. Metody te wykorzystują sieci głębokie i umożliwiają prognozy punktowe i probabilistyczne. Rozprawa wykorzystuje aktualne osiągnięcia w dziedzinie prognozowania cen energii elektrycznej opisane w literaturze światowej. Autor wykazał umiejętność poprawnego i przekonującego przedstawienia uzyskanych wyników.

Oceniam wysoko znaczenie uzyskanych wyników dla rozwoju dyscypliny nauki o zarządzaniu i jakości, zwłaszcza w kontekście ich potencjalnych zastosowań w energetyce, przed którą stoją nowe wyzwania związane z ograniczeniem bazy surowców energetycznych oraz rozwojem systemów lokalnych, odnawialnych źródeł energii i elektromobilności.

Wniosek końcowy

Rozprawa doktorska mgr. Grzegorza Jarosława Marcjasza stanowi oryginalne rozwiązanie problemu naukowego i wskazuje na wysoki poziom wiedzy teoretycznej Autora z dyscypliny nauki o zarządzaniu i jakości, a także na umiejętność samodzielnego prowadzenia przez niego pracy naukowej. Pomimo zamieszczonych powyżej uwag krytycznych moja generalna opinia o pracy jest pozytywna i oceniam ją wysoko.

Stwierdzam, że opiniowana rozprawa doktorska spełnia wymogi ustawy z 20 lipca 2018 r. *Prawo o szkolnictwie wyższym i nauce*. Wnoszę o dopuszczenie mgr. Grzegorza Jarosława Marcjasza do publicznej obrony pracy doktorskiej i wyróżnienie rozprawy doktorskiej.

