



POLITECHNIKA BIAŁOSTOCKA
Wydział Inżynierii Zarządzania

ROZPRAWA DOKTORSKA
mgr Radosław Marłęga

Identyfikacja i metaidentyfikacja systemu zarządzania
Towarową Giełdą Energii Elektrycznej

PROMOTOR
DR HAB. INŻ. JERZY TCHÓRZEWSKI, PROF. UPH W SIEDLCACH

PROMOTOR POMOCNICZY
DR HAB. INŻ. ARKADIUSZ JURCZUK

Białystok 2022

SPIS TREŚCI

WYKAZ DEFINICJI, SKRÓTÓW I OZNACZEŃ.....	5
WPROWADZENIE	7
1. RYNEK DNIA NASTĘPNEGO TGE S.A. JAKO SYSTEM ZARZĄDZANIA	17
1.1. System Rynku Energii Elektrycznej w Polsce	17
1.2. Towarowa Giełda Energii S.A. jako podsystem na Rynku Energii Elektrycznej .	23
1.3. Rynek Dnia Następnego jako system zarządzania	27
2. MODELOWANIE IDENTYFIKACYJNE W UJĘCIU SYSTEMOWYM	31
2.1. Istota identyfikacji	31
2.2. Istota modeli systemów oraz modelowania systemów TGE S.A.....	33
2.3. Modelowanie identyfikacyjne systemu Rynku Dnia Następnego.....	37
2.4. Krytyczny przegląd literatury z zakresu metod modelowania systemu Rynku Dnia Następnego	41
3. METODYKA BADAŃ IDENTYFIKACYJNYCH I METAIDENTYFIKACYJNYCH SYSTEMU RYNKU DNIA NASTĘPNEGO	51
3.1. Opis procesu badawczego	51
3.2. Ujęcie systemowe Rynku Dnia Następnego.....	61
3.3. Efektywność systemu Rynku Dnia Następnego.....	65
3.4. Skuteczność modelu systemu Rynku Dnia Następnego.....	67
3.5. Krzepkość systemu Rynku Dnia Następnego.....	70
4. IDENTYFIKACJA SYSTEMU RYNKU DNIA NASTĘPNEGO TGE S.A.....	72
4.1. Założenia dotyczące identyfikacji i metaidentyfikacji systemu RDN	72
4.2. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2015 r. do 30.06.2015 r.....	74
4.3. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2013 r. do 30.04. 2016 r.....	83
4.4. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2016 r. do 31.12.2019 r.....	105
5. METAIDENTYFIKACJA SYSTEMU RYNKU DNIA NASTĘPNEGO TGE S.A.	110
6. BADANIA SYMULACYJNE, KOMPARATYSTYCZNE ORAZ BADANIA WRAŻLIWOŚCI SYSTEMU RYNKU DNIA NASTĘPNEGO	118

6.1. Model symulacyjny Rynku Dnia Następnego	118
6.2. Badania komparatystyczne oraz badanie wrażliwości modelu	135
6.3. Wyniki badania efektywności, skuteczności i krzepkości modelu i systemu RDN	138
7. BADANIE I INTERPRETACJA PARAMETRÓW ORAZ BADANIE JAKOŚCI MODELI	146
7.1. Interpretacja parametrów modeli.....	146
7.2. Ocena jakości modelu i systemu	151
7.3. Badanie efektywności w zależności od wolumenu ee.....	152
7.4. Badanie skuteczności w zależności od wolumenu ee.....	156
7.5. Badanie skuteczności od średnioważonej wolumenem ceny ee.....	160
7.6. Badanie krzepkości w zależności od wolumenu ee.....	162
PODSUMOWANIE, WNIOSKI I KIERUNKI DALSZYCH BADAŃ	169
LITERATURA.....	175
WYKAZ RYSUNKÓW	196
WYKAZ TABEL	200
DODATEK A.....	202
DODATEK B.....	217
DODATEK C	221

WYKAZ DEFINICJI, SKRÓTÓW I OZNACZEŃ

System Rynku Dnia Następnego (system RDN) Towarowej Giełdy Energii S.A. (TGE S.A.) – podsystem TGE S.A. (jako system zarządzania), który na podstawie informacji o dostarczonym i sprzedanym na RDN wolumenie energii elektrycznej (ee) będącym wielkością wejściową do systemu [MWh] generuje decyzję dotyczącą średnioważonej wolumenem ceny sprzedanej energii elektrycznej notowanej na RDN będącą wielkością wyjściową z systemu [PLN/MWh].

Model systemu Rynku Dnia Następnego TGE S.A. – model systemu uzyskany w wyniku identyfikacji parametrycznej na podstawie wielkości wejściowych typu wolumen energii elektrycznej (ee) w każdej godzinie doby (24 wielkości wejściowe) oraz wielkości wyjściowych typu średnioważona wolumenem cena dostarczonej i sprzedanej ee w konkretnej godzinie doby (jedna wielkość wyjściowa spośród 24 możliwych wielkości wyjściowych).

Metamodel systemu Rynku Dnia Następnego TGE S.A. – metamodel systemu uzyskany w wyniku metaidentyfikacji parametrycznej na podstawie wielkości wejściowych do metamodelu typu współczynniki modelu systemu związane z wielkościami wejściowymi do modelu systemu dla każdej godziny doby oraz na podstawie wielkości wyjściowych z metamodelu typu współczynniki modelu systemu związane z wielkościami wyjściowymi z modelu systemu dla każdej godziny doby w modelu kroczącym, z krokiem jednej godziny.

Rozwój systemu, modelu i metamodelu – zmiany parametryczne lub/i strukturalne odpowiednio systemu, modelu lub metamodelu systemu w czasie długim θ .

θ – czas długi jako zmienna niezależna procesu zmian parametrycznych lub/i strukturalnych systemu i modelu [tydzień, miesiąc, kwartał, półrocze, rok itp.].

t – czas krótki jako zmienna niezależna dynamiki zmian parametrycznych lub/i strukturalnych systemu i modelu [godzina, dzień].

Identyfikacja – proces prowadzący do uzyskania modelu systemu RDN TGE S.A. na podstawie serii wartości wielkości wejściowych i serii wartości wielkości wyjściowych.

Metaidentyfikacja – proces prowadzący do uzyskania metamodelu systemu RDN TGE S.A. na podstawie serii wartości wielkości parametrów związanych z wielomianami $B_i(z)$ jako wielkości wejściowych i wartości wielkości parametrów związanych z wielomianami $A_j(z)$ jako wielkości wyjściowych.

System informacyjny (SI) – podsystem systemu zarządzania, który przetwarza informację o wolumenie dostarczonej i sprzedanej ee na RDN (wielkości wejściowe) na informacje niezbędne do przeprowadzenia analizy przed podjęciem decyzji o średnioważonej wolumenie cenie sprzedanej ee (wielkości wyjściowe).

System analityczny (SA) – podsystem systemu zarządzania, który przetwarza informację niezbędną do przeprowadzenia analizy (wielkości wejściowe) na informację niezbędną do podejmowania decyzji (wielkości wyjściowe).

System decyzyjny (SD) – podsystem systemu zarządzania, który przetwarza informację niezbędną do podejmowania decyzji (wielkości wejściowe) na podejmowane decyzje o sprzedaży ee w poszczególnych godzinach doby (wielkości wyjściowe).

System wykonawczy (SW) – system realizacyjny wykonujący zadania związane z dostarczeniem i sprzedażą ee.

Macierz formatu theta (macierz th) – macierz używana w środowisku MATLAB-a jako macierz wyników identyfikacji, to jest zawierająca pełną informację o modelu systemu RDN jako systemu zarządzania (informacje o modelu systemu, jego strukturze i estymatorach parametrów wraz z ich oszacowaniem za pomocą odpowiedniej metody [218, 260]).

Estymacja – wiąże się z potrzebą przybliżenia modelu do prawdziwych (rzeczywistych) wartości (ang. estimate – ocena, szacowanie), co łączy się też z weryfikacją modelu (ang. validation).

TGE S.A. – spółka, która powstała z inicjatywy byłego Ministra Skarbu Państwa jako niezbędny element liberalizacji Rynku Energii Elektrycznej (REE) na podstawie dokumentu pt. „Zasady działania rynku energii elektrycznej w Polsce w roku 2000 i w latach następnych” [229].

MAPE (ang. Mean Absolute Percentage Error) – średni procentowy błąd względny.

WPROWADZENIE

W ostatnich latach obserwuje się wyraźny wzrost zainteresowania różnych podmiotów funkcjonujących na rynku energii elektrycznej koncepcjami i metodami dotyczącymi metamodelowania oraz szeroko rozumianego modelowania procesów biznesowych. Zasadniczą przesłanką ich wykorzystania jest dążenie do jednoznacznego opisu, zrozumienia oraz analizy i oceny określonych procesów organizacji. Zapewnia to wsparcie planowania, realizacji procesów decyzyjnych, a w rezultacie efektywną i skuteczną adaptację całej organizacji do zmieniających się wyzwań rynku i jego uczestników. Jest to szczególnie widoczne w kontekście obecnych wyzwań i zachodzących zmian na Rynku Energii Elektrycznej (REE) oraz na Towarowej Giełdzie Energii Elektrycznej (TGEE), która stanowi podsystem Towarowej Giełdy Energii S.A. (TGE). Wzrost zainteresowania modelowaniem systemu REE wiąże się z dynamicznie zmieniającymi się uwarunkowaniami międzynarodowymi, w tym zmianami strukturalnymi wywołanymi początkowo przez SARS COVID-19, a następnie przez kryzys energetyczny wywołany konfliktami międzynarodowymi o zasoby energii [168, 171–172, 199]. Zmiany strukturalne zachodzące na REE dotyczą m.in. funkcjonowania i zarządzania systemem Rynku Dnia Następnego (RDN) stanowiącego podsystem TGEE, a w nim wolumenu energii elektrycznej (ee) i średnioważonych wolumenem cen ee w każdej godzinie doby [229].

Ostatnia lata, a zwłaszcza rok 2021 był rokiem rosnących kosztów zakupu energii elektrycznej na rynku hurtowym. Wartość kontraktów zawieranych na Towarowej Giełdzie Energii (TGE) potwierdza, że w 2021 roku cena energii – zarówno z dostawą na rok 2022, jak i na kolejne lata – gwałtownie wzrosła. Jeszcze w listopadzie 2020 r. cena energii w kontraktach terminowych oscylowała na poziomie 242 zł/MWh, by w listopadzie 2021 r. osiągnąć poziom 470 zł/MWh. Drugim czynnikiem kosztowym przekładającym się na ceny energii w Polsce, były i są nadal koszty zakupu uprawnień do emisji dwutlenku węgla, gdyż polska energetyka w 80% opiera się na energii elektrycznej (ee) pochodzącej z węgla. Jednocześnie koszty uprawnień w okresie od maja 2019 r. do listopada 2021 r. wzrosły od 100 do 310 zł za tonę. Wysokie hurtowe ceny energii oraz koszty zakupu praw do emisji CO₂ były głównymi przyczynami wzrostu detalicznych cen energii elektrycznej na poziomie odbiorcy finalnego. Przyjęta przez Rząd RP w lutym 2021 roku Polityka energetyczna Polski

do 2040 roku¹ oraz przedłożony Komisji Europejskiej Krajowy Plan Odbudowy (KPO)², zapowiadają liczne działania modernizacyjne i restrukturyzacyjne, które nie pozostaną bez wpływu na bieżące funkcjonowanie oraz koszty finansowe ponoszone między innymi przez przedsiębiorstwa energetyczne. Zmiany, jakim już podlega polska energetyka, czego przykładem jest intensywny rozwój odnawialnych źródeł energii, stanowią wyzwanie dla wszystkich uczestników rynku, w tym dla uczestników systemu RDN.

Szczególnie ważne z punktu widzenia rozwoju i zarządzania Rynkiem Energii Elektrycznej jest sytuacja na Rynku Dnia Następnego. Gwałtowne zmiany dokonujące się na RDN sprawiają, że wszyscy jego uczestnicy, a więc zarówno dostawcy jak też odbiorcy i prosumenci, a także pośrednicy handlu energią poszukują rozwiązań, które pozwolą im zrozumieć specyfikę zachodzących zmian i tym samym przygotować się do zawarcia określonych transakcji. Jednym ze sposobów sprostania tym wyzwaniom jest niewątpliwie wykorzystanie właściwych dziedzinowo modeli i symulacja kształtowania się przewidywanych średnioważonych wolumenem cen energii elektrycznej. Jest to jednocześnie jeden z zasadniczych powodów zwiększonego zainteresowania wspomnianych interesariuszy rynku energii możliwościami wykorzystania modeli systemu RDN jako narzędzia wspierającego efektywną i skuteczną realizację procesów decyzyjnych.

Przenosząc kontekst przedmiotowych rozważań na grunt nauk o zarządzaniu i jakości można obecnie wyróżnić dwa główne kierunki badań związanych z wykorzystywaniem modeli: badania związane z podejściem organizacyjno-technicznym dotyczącym inżynierii zarządzania, obejmującej zjawiska o charakterze w głównej mierze ilościowym oraz badania związane z podejściem ekonomiczno-społecznym, obejmujące zjawiska o charakterze w głównej mierze jakościowym [49, 59]. Modele mogą być uzyskiwane w różny sposób, od metod analitycznych, poprzez metody identyfikacyjne, aż po metody sztucznej inteligencji, takie jak: sztuczne sieci neuronowe, systemy rozmyte, metody heurystyczne czy też algorytmy ewolucyjne [1–6, 39, 41, 48, 66, 71, 81, 118, 119, 122, 125, 129, 132, 148, 165, 210, 226, 235, 250–251].

¹ Dokument został opracowany na podstawie art. 15a ust. 1 ustawy - Prawo energetyczne (Dz. U. z 2020 r. poz. 833, ze zm.) oraz zgodnie z ustawą o zasadach prowadzenia polityki rozwoju (Dz. U. z 2019 r. poz. 1295, ze zm.).

² 01.06.2022 r. Krajowy Plan Odbudowy i Zwiększania Odporności został zaakceptowany przez Komisję Europejską, a 17.06.2022 r. przez Radę UE.

W świetle przedstawionych rozważań, głównym wyzwaniem niniejszej rozprawy jest właściwa identyfikacja Rynku Dnia Następnego umożliwiająca opracowanie modelu systemu RDN, który może efektywnie i skutecznie wspierać procesy decyzyjne związane z zarządzaniem tym rynkiem. Istotność tego problemu, a jednocześnie jego złożoność wynika z faktu, iż system Rynku Dnia Następnego obok systemu Rynku Dnia Bieżącego jest jednym z podstawowych podsystemów systemu Towarowej Giełdy Energii Elektrycznej na TGE S.A. Z kolei system Towarowej Giełdy Energii Elektrycznej jest podsystemem systemu Rynku Energii Elektrycznej w Polsce. Co więcej, system RDN jest systemem zarządzania, który w kategorii inżynierii systemów może być systemem o wielu strumieniach wejściowych i wielu strumieniach wyjściowych. W przypadku modelowanego w rozprawie systemu RDN, posiada on na wejściu strumień wolumenu dostarczonej i sprzedanej energii elektrycznej, a na wyjściu – strumień średnioważonej wolumenem ceny dostarczonej i sprzedanej energii elektrycznej.

Przyjęta w rozprawie koncepcja zakłada, że w wyniku identyfikacji otrzymuje się model systemu RDN w kategoriach inżynierii systemów, jako model systemu zarządzania. Przyjęte podejście wpisuje się zatem w organizacyjno-techniczny nurt nauk o zarządzaniu i jakości, wskazujący na kluczową rolę inżynierii zarządzania. Ponadto niniejsza rozprawa prezentuje propozycję oryginalnego podejścia do metaidentyfikacji systemu RDN, przeprowadzoną z wykorzystaniem zestawu modeli otrzymanych w wyniku identyfikacji kroczącej. Wyznaczone z wykorzystaniem tego podejścia parametry oraz modele pozwoliły na zbudowanie w efekcie metamodelu systemu Rynku Dnia Następnego jako wyniku przedmiotowej metaidentyfikacji systemu RDN [74, 197]. Ten aspekt badań zawartych w niniejszej rozprawie wpisuje się w praktyczny nurt dyscypliny nauk o zarządzaniu i jakości na poziomie zarządzania operacyjnego, w zakresie wspomagania decyzji kierowniczych oraz zarządzania procesami i projektami z wykorzystaniem modeli systemów Rynku Dnia Następnego³.

Podjęta próba metaidentyfikacji i opracowania modelu systemu RDN jest odpowiedzią na zapotrzebowania na nowoczesne narzędzia, wspierające kluczowych interesariuszy rynku energii. Na tego typu modele i metamodele systemu RDN wspierające procesy decyzyjne oczekują decydenci odpowiedzialni za zarządzanie TGE S.A., a także uczestnicy giełdy

³ Subdyscypliny w naukach o zarządzaniu i jakości 2.0 [15].

energii. Potencjalnymi beneficjentami modeli i metamodeli mogą być praktycznie wszystkie strony biorące udział w transakcjach sprzedaży – kupna energii elektrycznej (ee), to jest między innymi dostawcy ee (wytwórcy systemowi oraz coraz częściej prosumenci), odbiorcy ee (przemysłowi i indywidualni, będący często jednocześnie prosumentami) oraz przede wszystkim TGE S.A.

Ponadto potrzeba opracowywania coraz doskonalszych modeli i metamodeli systemów jako nowej formy modelowania systemu RDN, wynika nie tylko z oczekiwań wspomnianych uczestników rynku, lecz również z wyzwań, przed którymi stają, w obliczu coraz mniej stabilnego światowego rynku energii, współczesne gospodarki i społeczeństwo. Oprócz tego rola modelowania rośnie z uwagi na postępującą automatyzację, robotyzację i powstawanie elastycznych systemów produkcyjnych rozwijających się w ślad za rozwojem nanotechnologii i systemów inteligentnych przejawiających się w integracji elektronicznego systemu zarządzania z elastycznym systemem elektroenergetycznym, w tym z systemem informacyjno-komunikacyjnym, informatycznymi systemami zarządzania procesowego, systemem automatyki elektroenergetycznej i systemami typu smart grid i smart metering, itp. [17, 24–26, 47, 53, 73, 81–82, 84, 86, 99, 138, 211, 241–243].

Przeprowadzony krytyczny przegląd literatury przedmiotu wykazał, że prowadzone obecnie badania koncentrują się w zdecydowanej większości na opracowaniu modeli prognozowania cen ee. Jednakże widoczny jest nowy trend badań dotyczący modelowania systemu RDN w oparciu o różne metody, w tym metody: identyfikacji, modelowania neuralnego, modelowania rozmytego i inne [48, 66, 108–109, 122, 125, 165, 186–187, 235, 244]. Przeprowadzona analiza wybranych wyników badań dotyczących systemu Rynku Dnia Następnego oraz systemu Nord Pool Spot⁴ wykazała m.in., że:

1) stosowane są najczęściej dwa podejścia do modelowania, tj. pierwszy: z wykorzystaniem szeregów czasowych cen – multiplikatywny model Holta-Wintersa [48], modele Wintersa, Holta i trendu pełzającego z wagami harmonicznymi [165], modele np: SARIMA oraz SARIMA-GARCH [140], natomiast drugi: z wykorzystaniem modelowania identyfikacyjnego oraz modelowania neuronalnego (to jest modele neuronalne oparte

⁴ Istnieją też wyniki badań dla rynków w Nowej Anglii, Ontario, Nowej Zelandii, Stanie czy też państwach skandynawskich [76–78, 111, 185].

o Perceptronową Sztuczną Sieć Neuronową z różną liczbą neuronów wejściowych i wyjściowych) [66, 186–187],

2) przyjmowana jest różna długość i szczegółowość danych wykorzystywanych w modelowaniu, w tym czas mierzony w godzinach, dniach, tygodniach (pełnych lub bez weekendów i świąt) itp. [88, 66, 165, 186–187, 235],

3) zakładany jest różny godzinowy horyzont modelowania w okresie: miesiąc, kwartał, pół roku, rok, kilka lat aż do całego okresu funkcjonowania giełdy [48, 186–188],

4) zakładany jest różny godzinowy horyzont prognozowania w okresie: dnia, tygodnia, miesiąca [88, 66, 165, 235],

5) stosowane są różne mierniki pomiaru dopasowania modelu do systemu (do danych rzeczywistych): z reguły są to dokładność dopasowania (jakość) i skuteczność [48, 66, 165, 186–187, 235],

6) wyznaczane są różne błędy prognozowania, m.in.: ME, MAE, MAPE, MSE, RMSE, MdAPE, MR,

7) wykorzystywane są różne środowiska do wspomagania modelowania: Statistica, MATLAB i Simulink oraz własne programy itp.

Odnosząc te spostrzeżenia do przedmiotu badań, w kontekście wykorzystanej metody modelowania należy stwierdzić, że obecnie prowadzone badania koncentrowały się głównie na dwóch rodzajach modeli systemu Rynku Dnia Następnego TGE S.A., w tym m.in.:

- modelach prognostycznych opracowywanych z wykorzystaniem wyników analizy szeregów czasowych cen notowanych na RDN [23, 37, 48, 142, 165],

- modelach identyfikacyjnych, w tym neuronalnych otrzymywanych na bazie różnych wielkości wejściowych i wyjściowych, tak dotyczących wolumenu ee, jak też średnioważonej wolumenem ceny dostarczonej i sprzedanej na RDN energii elektrycznej, a także innych czynników (zwłaszcza wykorzystywanych jako wielkości wejściowe), w tym: ekonomicznych, klimatycznych, społecznych itp. [14, 48, 66, 165, 186–187, 235].

W świetle przeprowadzonych studiów literatury należy stwierdzić, że brak jest jakichkolwiek wyników badań dotyczących metamodelowania identyfikacyjnego systemów prowadzących do otrzymania metamodeli w ogóle, w tym zwłaszcza do otrzymania metamodeli RDN, poza pracami będącymi wynikami badań własnych, w których brał udział

autor rozprawy [121, 209]. Ponadto wyniki analizy istniejącego stanu wiedzy w zakresie identyfikacji systemu Rynku Dnia Następnego wskazują, że dotychczas prowadzone badania dotyczą uzyskiwania modeli identyfikacyjnych z wykorzystaniem danych godzinowych, dziennych, tygodniowych, miesięcznych i kwartalnych. Spotyka się też próby uzyskiwania wyżej wymienionych modeli identyfikacyjnych z wykorzystaniem danych półrocznych i rocznych, przy czym brak jest w tym zakresie opublikowanych wyników badań wystarczająco potwierdzających dokładność otrzymanych modeli systemu RDN. Istnieje zatem naturalna potrzeba prowadzenia tego typu badań, z wykorzystaniem danych godzinowych w okresie półrocznym i rocznym, które pozwolą wypełnić zidentyfikowaną lukę. Ponadto istniejące metody identyfikacyjne, zwłaszcza wzmocnione modelowaniem neuronalnym i symulacyjnym, stwarzają także duże możliwości teoretyczne i implementacyjne wykorzystania ich do modelowania systemu RDN.

Można zatem stwierdzić, że występuje specyficzna **luka badawcza** wynikająca z rozbieżności pomiędzy zapotrzebowaniem na modele i metamodely systemu RDN a istniejącymi możliwościami teoretycznymi i implementacyjnymi utworzenia takich modeli i metamodeli za pomocą metod teorii sterowania i inżynierii systemów, w tym metod identyfikacji i metaidentyfikacji systemów zarządzania.

Biorąc powyższe stwierdzenia pod uwagę motywacją podjęcia badań w zakresie modelowania i metamodelowania identyfikacyjnego wzmocnionego modelowaniem neuronalnym była potrzeba, wynikająca z luki badawczej, opracowania metody metaidentyfikacji umożliwiającej uzyskiwanie metamodeli systemu Rynku Dnia Następnego. Uzasadnieniem tego kierunku badań jest bezpośrednia możliwość dysponowania metamodelem do tworzenia modeli systemu RDN na okresy przyszłe, a nie tylko dysponowaniem gotowymi modelami uzyskanymi na przykład w procesie identyfikacji, czy też uzyskanymi w procesie badań z wykorzystaniem szeregów czasowych na potrzeby generowania prognozy ceny ee. W tym zakresie rozprawa posiada nowatorski i oryginalny charakter.

A zatem **podstawowym problemem badawczym** (naukowym) rozwiązywanym w niniejszej rozprawie doktorskiej jest **przeprowadzanie modelowania identyfikacyjnego** (zwanego krócej: identyfikacją) i **modelowania metaidentyfikacyjnego** (zwanego krócej: metaidentyfikacją), na gruncie teorii i inżynierii systemów, w tym z wykorzystaniem zwłaszcza inżynierii systemów zarządzania w zakresie ujęcia systemu Rynku Dnia Następnego

Towarowej Giełdy Energii S.A. jako systemu zarządzania. Z uwagi na zidentyfikowane ograniczenia obecnych badań podjęto próbę przeprowadzenia identyfikacji systemu RDN TGE S.A. z wykorzystaniem danych półrocznych i rocznych z punktu widzenia uzyskania zarówno możliwości określania średnioważonych wolumenem cen ee na następne okresy półroczne i roczne, jak też z punktu widzenia uzyskania na drodze metaidentyfikacji metamodeli do określania modeli możliwych do wykorzystania w prognozowaniu średnioważonych wolumenem cen ee.

Dodatkowy problem badawczy, którego rozwiązanie prezentuje niniejsza rozprawa, wynika z braku jednoznacznej oceny jakości otrzymywanych modeli systemów. W związku z tym **opracowano nowe kryterium oceny jakości modeli systemów**, w tym jakości modeli systemu RDN, które nazwano krzepkością łączącą w swoistą równowagę efektywność i skuteczność modelu systemu. Warto także dodać, że przeprowadzone badania umożliwiły sformułowanie dla systemu RDN jako systemu zarządzania takich nowych pojęć jak: poziom zarządzania oraz system organizacji wewnętrznej, które wykorzystano do oceny systemu RDN jako systemu i modelu zarządzania.

W toku prowadzonych badań wystąpiły różnego typu ograniczenia, wynikające między innymi z braku ogólnie dostępnych danych dotyczących notowań na rynkach światowych, jak na przykład notowań na RDN, które mogłyby zostać wykorzystane w badaniach porównawczych, a także ograniczenia wynikające z metod identyfikacji, które w wielu przypadkach udało się poprawić za pomocą sztucznych sieci neuronowych wykorzystanych w niniejszej rozprawie.

Zidentyfikowane problemy badawcze wiążą się z potrzebą uzyskania modeli i metamodeli systemu Rynku Dnia Następnego, co prowadzi do zdefiniowania **celu ogólnego** rozprawy w kategoriach systemowych w postaci procesu identyfikacji i metaidentyfikacji systemu RDN funkcjonującego jako systemu zarządzania na TGE S.A.

Z wyżej wymienionym celem ogólnym rozprawy związane są następujące **cele szczegółowe**:

- 1) umiejscowienie systemu Rynku Dnia Następnego w ujęciu inżynierii systemów i nauk o zarządzaniu i jakości na tle problematyki badań dotyczącej systemu Rynku Energii Elektrycznej,

- 2) przegląd metod modelowania identyfikacyjnego w ujęciu systemowym, w tym: opis istoty identyfikacji, przegląd możliwości uzyskiwania modeli systemów, przegląd metod wykorzystywanych w modelowaniu systemów TGE S.A., opis modelowania identyfikacyjnego systemu RDN, przeprowadzenie krytycznego przeglądu literatury przedmiotu w zakresie uzyskiwania wystarczająco dokładnych modeli systemu RDN,
- 3) opracowanie metodyki badań identyfikacyjnych i metaidentyfikacyjnych systemu RDN, w tym opis etapów procesu badawczego, ujęcie systemowe RDN jako systemu zarządzania oraz jego oceny w kategoriach efektywności, skuteczności i krzepkości,
- 4) przeprowadzenie identyfikacji i wygenerowanie katalogu modeli parametrycznych dyskretnych i ciągłych systemu RDN oraz katalogu modeli ciągłych w przestrzeni stanów,
- 5) przeprowadzenie metaidentyfikacji i wygenerowanie metamodeli parametrycznych dyskretnych i ciągłych systemu RDN oraz metamodeli ciągłych w przestrzeni stanów,
- 6) zbudowanie modeli symulacyjnych, a następnie przeprowadzenie z ich wykorzystaniem badań symulacyjnych, komparatystycznych oraz badania wrażliwości z punktu widzenia sformułowanych kryteriów dokładności modelu i systemu, z uwzględnieniem błędów względnych oraz błędów MAPE, a także z punktu widzenia efektywności i krzepkości modelu i systemu oraz skuteczności modelu do systemu RDN,
- 7) przeprowadzenie interpretacji parametrów modeli oraz badanie zmiany jakości modelu, w tym: w zakresie przebiegów skuteczności, efektywności i krzepkości w funkcji zasobów jakim jest wolumen dostarczonej i sprzedanej na RDN energii elektrycznej w badanej godzinie doby,
- 8) sformułowanie wniosków końcowych oraz dalszych kierunków badań.

W rozprawie doktorskiej przedmiotem weryfikacji teoretycznej i empirycznej będą zatem następujące **hipotezy** badawcze:

- 1) Identyfikacja przeprowadzona z wykorzystaniem inżynierii systemów, a w szczególności z wykorzystaniem metod identyfikacji, umożliwia budowę modeli systemu RDN TGE S.A. o stosunkowo wysokim stopniu dokładności do systemu rzeczywistego.

- 2) Zastosowanie metod identyfikacji parametrycznej z wykorzystaniem danych liczbowych w układzie krocącym umożliwia uzyskanie katalogu modeli systemu RDN, stanowiących źródło danych dla potrzeb przeprowadzenia procesu jego metaidentyfikacji.

Zaproponowane metody badań jakościowych i ilościowych pozwoliły na realizację postawionych celów badawczych. Realizacji tak sformułowanych celów ogólnych oraz szczegółowych podporządkowano strukturę rozprawy. W rozdziale 1 omówiono Rynek Dnia Następnego TGE S.A. jako system zarządzania, w tym: system Rynku Energii Elektrycznej funkcjonujący Polsce, zakres działania Towarowej Giełdy Energii S.A., mechanizmy działania Rynku Dnia Następnego jako systemu zarządzania.

Z kolei rozdział 2 dotyczy stosowanego w rozprawie modelowania identyfikacyjnego w ujęciu systemowym, w tym: omówiono istotę identyfikacji, dokonano przeglądu możliwości uzyskiwania modeli systemów, przybliżono metody wykorzystywane w modelowaniu systemów TGE S.A., opisano modelowanie identyfikacyjne systemu Rynku Dnia Następnego oraz zamieszczono wyniki badań w zakresie krytycznego przeglądu literatury przedmiotu, między innymi w zakresie metod modelowania systemu Rynku Dnia Następnego.

W rozdziale 3 opisano metodykę badań identyfikacyjnych i metaidentyfikacyjnych systemu Rynku Dnia Następnego, między innymi: proces badawczy, ujęcie systemowe RDN, efektywność, skuteczność i krzepkość systemu i modelu RDN.

Rozdziały 4 i 5 dotyczą wyników procesu identyfikacji i metaidentyfikacji systemu RDN. I tak w rozdziale 4 sformułowano założenia dotyczące systemu Rynku Dnia Następnego TGE S.A., sposób przeprowadzania identyfikacji systemu RDN TGE S.A., w tym proces i wyniki identyfikacji systemu RDN z wykorzystaniem danych z okresu: od 1 stycznia 2015 r. do 30 czerwca 2015 r. z okresem identyfikacji o długości 184 dni, od 1 stycznia 2013 r. do 30 kwietnia 2016 r. z okresem identyfikacji o długości 184 dni, od 1 stycznia 2016 r. do 31.12.2019 r. z okresem identyfikacji o długości 365 dni. Zwrócono w szczególności uwagę na trzy rodzaje modeli, to jest: modele parametryczne dyskretne, modele parametryczne ciągłe oraz modele ciągłe w przestrzeni stanów. Z kolei rozdział 5 zawiera opis procesu i wyniki metaidentyfikacji w postaci metamodelu systemu Rynku Dnia Następnego TGE S.A.

Rozdział 6 zawiera wyniki budowy modelu symulacyjnego RDN wykorzystanego do przeprowadzenia badań symulacyjnych, komparatystycznych oraz badania wrażliwości systemu Rynku Dnia Następnego i jego modeli, w szczególności dokładanie omówiono takie subsystemy modelu symulacyjnego systemu Rynku Dnia Następnego jak: separator wolumenu ee danych godzinowych systemu RDN, generator efektywności godzinowych systemu, miernik przebiegu efektywności godzinowych systemu RDN, miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN, separator ceny ee danych godzinowych systemu RDN, miernik błędu względnego efektywności pomiędzy modelem i systemem RDN, generator wskaźników oceny jakości modelu do systemu RDN, model godzinowy systemu RDN, Perceptronowa SSN jako korektor wielkości wyjściowych modelu systemu RDN. Ponadto w rozdziale tym zamieszczono także wyniki badań komparatystycznych modelu w stosunku do systemu RDN, wyniki badania wrażliwości modelu systemu RDN, wyniki badania efektywności, skuteczności i krzepkości modelu i systemu RDN.

Przeprowadzone badania i interpretacja parametrów oraz badania jakości modeli przedstawiono w rozdziale 7. Zwrócono szczególną uwagę na bardzo duży potencjał informacji analitycznej, który posiadają uzyskane modele parametryczne i modele zmiennych stanu, a także zastosowane kryteria oceny jakości dopasowania modeli systemów, takie jak: kryterium efektywności, skuteczności i krzepkości. Przedstawiono także wagę metamodelowania identyfikacyjnego w tworzeniu modeli systemów. Uzyskane wnioski i odnotowane kierunki dalszych badań zamieszczono w odrębnym, kolejnym rozdziale rozprawy.

1. RYNEK DNIA NASTĘPNEGO TGE S.A. JAKO SYSTEM ZARZĄDZANIA

1.1. System Rynku Energii Elektrycznej w Polsce

Rynek Energii Elektrycznej (REE) jest systemem obejmującym dostawców, pośredników i odbiorców energii elektrycznej (ee), a także w ostatnich latach prosumentów. W skład systemu REE wchodzi między innymi następujące podsystemy: wytwórcy energii elektrycznej (elektrownie systemowe, elektrownie przemysłowe, odnawialne źródła energii, prosumenci itp.), pośrednicy (operatorzy przemysłowo-handlowi itp.) oraz odbiorcy ee (przemysłowi, indywidualni i inni) [10, 45–46, 130, 147, 158–159, 161–162, 196, 223, 228, 246–247, 253]. Równoprawny udział w Rynku Energii Elektrycznej ww. rodzajów podmiotów powoduje, że rynek stał się rynkiem konkurencyjnym związanym z [171]:

- umożliwieniem uczestnikom rynku samodzielnego decydowania o doborze podmiotów handlowych i o warunkach zawieranych z nimi transakcji na obrót energią elektryczną,
- wprowadzeniem konkurencji związanej ze wzrostem efektywności działania podmiotów sektora energetycznego wraz z zachowaniem bezpieczeństwa dostaw ee,
- wyznaczeniem rzeczywistej wartości ceny ee wraz z umożliwieniem wiarygodnej wyceny przedsiębiorstw energetycznych w procesie prywatyzacji.

Zasadniczym wymaganiem wdrożenia systemu REE było oddzielenie ee jako produktu od jej przesyłu i rozdziału (transportu) ee jako usług systemowych i sieciowych. Wdrażanie systemu REE realizowane jest w specyficznych warunkach fizycznych wytwarzania i dostawy ee przy uwzględnieniu konieczności utrzymania stabilności KSE oraz niezawodności i jakości dostaw ee. Działanie systemu REE związane jest ze swoistą specyfiką wynikającą z działania KSE, na co składają się [160, 246, 252]:

- konieczność zapewnienia równoważenia popytu i podaży,
- zapewnienie elastyczności cenowej popytu,
- brak możliwości magazynowania ee,
- ograniczona elastyczność zmiany produkcji ee,
- zapewnienie niezawodności działania KSE,
- podatność na monopolizację rynku ee.

Rynek energii elektrycznej działa na dwóch poziomach. Pierwszym z nich jest rynek hurtowy, w którym uczestniczą producenci energii elektrycznej i nabywcy hurtowi, a także

bezpośredni odbiorcy. Z kolei drugim poziomem jest rynek detaliczny, gdzie producenci energii oferują odbiorcom dostawę energii, konkurując ze sobą ceną, warunkami dostawy oraz usługami dodatkowymi.

Struktura przedmiotowa systemu REE składa się z trzech podstawowych podsystemów [233]:

- systemu REE czynnej (rynek konkurencyjny), który z kolei dzieli się na trzy segmenty: kontraktowy, giełdowy, bilansujący,
- systemu rynku technicznego (rynek regulowany), w którego skład wchodzi: regulacyjne usługi systemowe, generacja wymuszona,
- systemu rynku finansowego, gdzie przedmiotem obrotu są kontrakty finansowe i instrumenty pochodne.

W świetle powyższego można stwierdzić, że przez system REE na ogół rozumie się strukturę złożoną z uczestników biorących udział w transakcjach oraz procesów zachodzących pomiędzy nimi, to jest pomiędzy odbiorcami końcowymi a producentami, z udziałem operatorów systemów sieciowych i pośredników. W zasadzie w chwili obecnej konkurencyjność w systemie REE ogranicza się do części hurtowej, przy czym odbiorcy końcowi są traktowani na zasadach odbiorców hurtowych. Funkcjonujący w Polsce model systemu REE jest modelem w znacznej części zdecentralizowanym, przy czym bardziej zdecentralizowane rynki ee zostały wdrożone tylko w takich krajach jak w: USA (Kalifornia), Szwecji, Norwegii, Finlandii i częściowo w Australii, Anglii i Walii. Warto zauważyć, że możliwość wdrożenia rynku zdecentralizowanego pojawiła się dzięki znacznemu postępowi w rozwoju technologii informacyjnych i telekomunikacyjnych, a cyberbezpieczeństwa [160].

W modelu zdecentralizowanym odbiorcy pozataryfowi, to jest odbiorcy z prawem dostępu do usług przesyłowych i rynku konkurencyjnego, oraz wytwórcy wspomagani przez operatorów handlowych (giełdy, przedsiębiorstwa obrotu, operatorzy przemysłowo-handlowi itp.) i doradców, zawierają umowy sprzedaży energii elektrycznej bezpośrednio między sobą lub za pośrednictwem giełd czy też przedsiębiorstw obrotu.

Fizyczną realizację zawartych umów sprzedaży energii elektrycznej prowadzą operatorzy systemowi na podstawie zgłoszeń umów sprzedaży energii, określających w każdym podstawowym okresie handlowym (godzinie) wielkość produkcji jednostek wytwórczych

i wielkość poboru energii w określonym miejscu dostarczania [87, 91, 101, 103, 106, 130, 145, 153, 160–161, 245, 247].


Z punktu widzenia przedmiotu obrotu wyróżniamy następujące rynki ee:

- rynek energii elektrycznej czynnej, na którym przedmiotem obrotu jest ee czynna w określonej ilości, cenie i czasie oraz w miejscu dostarczania,
- rynek techniczny, na którym przedmiotem obrotu są regulacyjne usługi systemowe, niezbędne dla umożliwienia przesyłu zakontraktowanej energii, a także energia elektryczna produkowana w określonych jednostkach wytwórczych, w których generacja jest wymuszona technicznymi ograniczeniami działania systemu elektroenergetycznego,
- rynek finansowy, na którym przedmiotem obrotu są kontrakty finansowe dotyczące dostaw ee.

Warto w tym miejscu zauważyć tendencje wzrostu wagi ee w gospodarce krajowej. Otóż, pomimo że wolumen krajowej produkcji energii elektrycznej ogółem brutto w 2020 r. ukształtował się na nieco niższym poziomie w stosunku do roku 2019 i wyniósł 152 308 GWh (spadek o 4,1% w porównaniu z 2019 r.), to nie mniej w ostatnich latach, a szczególnie w okresie pandemii, nastąpiło generalne lekkie zmniejszenie zużycia ee. I tak w 2020 r. krajowe zużycie energii elektrycznej brutto wyniosło 165 532 GWh i zmniejszyło się o 2,3% w porównaniu z 2019 r. W 2020 r. w krajowym bilansie przepływów fizycznych energii elektrycznej udział importu stanowił 11,8% całkowitego przychodu, zaś udział eksportu wyniósł 4,2% rozchodu ee. W porównaniu z 2019 r. udział importu wzrósł o 1,7 punktu procentowego, zaś udział eksportu wzrósł o 0,1 punktu procentowego. Struktura produkcji energii elektrycznej w 2020 r. nie zmieniła się znacznie w stosunku do 2019 r. Zdecydowana większość wytwarzania oparta jest nadal na paliwach konwencjonalnych, tj. węgla kamiennym oraz węgla brunatnym, jednak ich udział zmniejszył się nieznacznie z 75% do 72%, przy czym liderem produkcji w segmencie OZE pozostawała nadal generacja wiatrowa. W 2020 r. moc zainstalowana w KSE wyniosła 49 238 MW, a moc osiągalna 49 095 MW, co stanowi wzrost odpowiednio o 5,2% oraz o 4,4% w stosunku do 2019 r. [171].

Na koniec 2020 r. w procesach rynku bilansującego uczestniczyło 127 podmiotów, w tym: 23 wytwórców, 10 odbiorców końcowych, 11 odbiorców sieciowych, 75 przedsiębiorstw obrotu, 2 giełdy energii, 5 OSD oraz PSE S.A. jako OSP. Dane techniczno-handlowe były zgłaszane przez 48 operatorów rynku i dotyczyły 347 jednostek grafikowych. Na rysunku 1.1

przedstawiono przebieg wolumenu energii bilansującej nieplanowanej, ale odebranej z rynku bilansującego oraz przebieg cen rozliczeniowych niezbilansowania na tym rynku w poszczególnych miesiącach 2020 r.



Rysunek 1.1. Wolumen energii bilansującej nieplanowanej, ale odebranej z rynku bilansującego oraz przebieg cen rozliczeniowych niezbilansowania dla poszczególnych miesięcy 2020 r.

Uwaga: oznaczenia w tekście podrozdziału 1.1.

Źródło: [171].

W 2020 r. spośród prawie 18 milionów odbiorców na rynku detalicznym, ok. 88% stanowili odbiorcy, którzy dokonują zakupu energii w celu jej zużycia w gospodarstwie domowym. Pozostała grupa odbiorców końcowych to odbiorcy należący do grup taryfowych A, B i C⁵. Odbiorcy energii elektrycznej są uprawnieni do otrzymywania energii elektrycznej w sposób ciągły i niezawodny od wybranego sprzedawcy tej energii. Na rynku energii elektrycznej funkcjonowało pięciu dużych OSD, objętych obowiązkiem rozdziału prawnego, których sieci są bezpośrednio przyłączone do sieci przesyłowej oraz 178 przedsiębiorstw wyznaczonych przez OSD, których sieci nie mają bezpośrednich połączeń z siecią przesyłową.

W 2020 r. działało 666 sprzedawców z urzędu, prowadzących sprzedaż energii elektrycznej na rzecz gospodarstw domowych w ramach obowiązku publicznoprawnego oraz

⁵ Grupy A i B stanowią odbiorcy zasilani z sieci wysokiego i średniego napięcia i są to tzw. odbiorcy przemysłowi z grupy A i B, natomiast do grupy C należą odbiorcy przyłączeni do sieci niskiego napięcia, pobierający energię elektryczną dla celów prowadzonej działalności gospodarczej, tzw. odbiorcy biznesowi.

sprzedaż rynkową (ze swobodnie ukształtowaną ceną) do gospodarstw domowych i innych grup odbiorców. Drugą grupę stanowili sprzedawcy w podmiotach zintegrowanych pionowo, będących jednocześnie operatorami systemów dystrybucyjnych (w 2020 r. było ich 178), a trzecią – niezależni sprzedawcy energii elektrycznej – podmioty niezwiązane z działalnością dystrybucyjną na terenie Polski.

W 2020 r., po rocznym okresie zamrożenia cen energii elektrycznej (rok 2019), nastąpiły istotne wzrosty tych cen, zwłaszcza w grupie odbiorców przyłączonych do sieci niskich napięć. Na poziom cen w 2020 r., oprócz rosnących cen węgla i wysokich kosztów uprawnień do emisji CO₂, wpływ miało także zmniejszenie zapotrzebowania na energię w systemie, wskutek wybuchu epidemii COVID-19, poprzez wzrost kosztów stałych w przeliczeniu na jednostkę energii. Średnie ceny energii elektrycznej w podziale na kryterium zużycia tej energii zostały przedstawione w tabeli 1.1.


Tabela 1.1. Liczba odbiorców, wolumen, wartość oraz średnie ceny energii elektrycznej stosowane do odbiorcy końcowego w zależności od kryterium zużycia dla roku 2020

Kryterium zużycia	Liczba odbiorców [szt.]	Wolumen [MWh]	Wartość [tys. zł]	Średnia cena [zł/MWh]
< 50 MWh	17 629 190	46 266 977	14 859 298	321,16
50-2 000 MWh	140 180	30 421 372	9 702 500	318,94
> 2 000 MWh	1 247	32 746 883	9 136 922	279,02
Razem	17 670 617	109 435 232	33 698 720	307,93

Źródło: [171].

Ze względu na to, że bardzo istotnym elementem REE jest TGE S.A., na rysunku 1.2 przedstawiono ponadto ceny ee na Rynku Dnia Następnego (rynek SPOT) prowadzonym przez TGE S.A., mierzone indeksem IRDN24⁶.


⁶ IRDN24 – indeks przedstawia średnią arytmetyczną cenę ze wszystkich transakcji, z wyjątkiem kontraktów blokowych, na sesji giełdowej RDN, liczoną po dacie dostawy dla całej doby.



Rysunek 1.2. Średniodobowe ceny energii elektrycznej w transakcjach SPOT mierzone indeksem IRDN24 [zł/MWh] oraz wolumen obrotu energią elektryczną na RDN (bez kontraktów blokowych) [MWh] w poszczególnych miesiącach lat 2018–2020

Źródło: [171].

Rynek Dnia Następnego przeprowadza notowania 7 dni w tygodniu jako kontrakty godzinowe w dobie n-2 i n-1, kontrakty blokowe w różnych okresach doby pod nazwą PASMO, EUROSZCZYT, OFFPEAK, jak pokazano na rysunku 1.3 oraz transakcje pozasesyjne (kontrakty godzinowe i blokowe).



Rysunek 1.3. Sposoby notowania przeprowadzane na RDN

Oznaczenia: kolor czerwony – kontrakty godzinowe w ciągu doby, kolor granatowy – jednolite dobowe pasmo kontraktów blokowych, kolor żółty – jednolity kontrakt blokowy zawierany w Euroszczycie, kolor szary – jednolity kontrakt blokowy zawierany jako Offpeak.

Źródło: [166].

Obok RDN funkcjonuje Rynek Dnia Bieżącego (od I połowy 2010 r.), na którym przeprowadzane są kontrakty godzinowe w systemie notowań ciągłych na 3 godziny przed terminem dostawy.

1.2. Towarowa Giełda Energii S.A. jako podsystem na Rynku Energii Elektrycznej

Towarowa Giełda Energii S.A. jest spółką zajmująca się handlem energią elektryczną w Polsce, która powstała z inicjatywy Ministra Skarbu Państwa jako niezbędny element rynku energii elektrycznej. Organizację i uruchomienie giełdy energii przeprowadziła firma Elektrim SA, która w dniu 7 grudnia 1999 r. zarejestrowała i uruchomiła jej działalność w oparciu o podstawę prawną – ustawę z dnia 10.04.1997 r. Prawo energetyczne [167]. TGE S.A. jest jedyną licencjonowaną giełdą towarową energii elektrycznej w Polsce (licencja od 2003 r.) posiadającą także licencję na prowadzenie rynku regulowanego od lutego 2015 r. Właścicielem TGE S.A. jest od 2012 r. Giełda Papierów Wartościowych.

TGE S.A. jest członkiem europejskiego rynku Multi-Regional Coupling od lipca 2015 r. oraz inicjatywy projektu Price Coupling of Regions od października 2015 r. W grudniu 2015 r. TGE S.A. została wyznaczona przez Prezesa URE na Nominowanego Operatora Rynku Energii. Zadaniem TGE S.A. jest prowadzenie i rozwój m.in. Rynku Towarów Giełdowych oraz gwarantowanie pewności i bezpieczeństwa rozliczania transakcji na wszystkich prowadzonych przez TGE S.A. rynkach [10–11, 130, 158, 166, 215]. TGE S.A. znajduje się na opublikowanej przez ACER liście platform do raportowania danych transakcyjnych, zgodnie z wymogami Rozporządzenia Parlamentu Europejskiego i Rady nr 1227/2011 z 25 października 2011 r. w sprawie integralności i przejrzystości hurtowego rynku energii (REMIT) [184]. Ponadto TGE S.A. certyfikuje maklerów giełdowych od listopada 2015 r. [229].

TGE S.A. jest aktywnym członkiem następujących międzynarodowych organizacji:

- EUROPEX – Europejskie Stowarzyszenie Giełd Energii,
- APEx – Association of Power Exchanges, organizacja zrzeszająca światowe giełdy energii,
- AFM – Association of Futures Markets, stowarzyszenia giełd towarowo-finansowych.

TGE S.A. współpracuje również z doświadczonym partnerem technologicznym NASDAQ X-Stream Trading Technology [229].

Towarowa Giełda Energii S.A. jest podsystemem systemu Rynku Energii Elektrycznej (REE) funkcjonującym na podstawie dokumentu pt. *„Zasady działania rynku energii elektrycznej w Polsce w roku 2000 i w latach następnych”*, przyjętego i zatwierdzonego przez

Komitet Ekonomiczny Rady Ministrów [158]. Rynek ten początkowo funkcjonował tylko jako rynek natychmiastowy energii elektrycznej, po czym wprowadzono notowania także na Rynku Dnia Następnego, Rynku Dnia Bieżącego, Rynku Terminowym Energii Elektrycznej, Rynku Praw Majątkowych, Rynku Gazu oraz Rynku Uprawnień do Emisji CO₂ [229].

Rynek energii elektrycznej działa przy tym jako rynek hurtowy (ang. Wholesale Market), w którym uczestniczą producenci energii elektrycznej i hurtowi nabywcy, oraz jako rynek detaliczny (ang. Retail Market), na którym dostawcy energii oferują odbiorcom dostawę energii, konkurując ze sobą ceną i warunkami dostawy [116, 130, 246, 253]. Tworząc TGE S.A. funkcjonujący w ramach polskiego Rynku Energii Elektrycznej, brano pod uwagę co najmniej kilka uwarunkowań m.in. [116, 130, 219–221, 239]:

- specyfikę rynku energii elektrycznej wynikającą z fizycznych cech działania systemu ee, w tym konieczność zapewnienia ciągłego równoważenia popytu i podaży w każdym dowolnym okresie, bez możliwości magazynowania energii; oddzielenie energii elektrycznej jako produktu od jej dostaw jako usług sieciowych (przesyłu i dystrybucji);
- sezonowość roczną, tygodniową i dzienną, czyli cyklicznie powtarzające się trendy w wielkościach cen obserwowane na przestrzeni doby, tygodni, miesięcy, lat, a nawet dziesiątków lat;
- tendencję powrotu cen energii elektrycznej do ceny średniej po ominięciu trendów, sezonowości, wahań przypadkowych, zakłóceń itp.;
- nieoczekiwane, gwałtowne skoki cen, które są spowodowane nieprzewidzianymi zdarzeniami, np. usterkami w elektrowniach czy sieciach transmisyjnych, nagłymi zmianami pogody, a w 2020 r. zmianami wywołanymi pandemią SARS COVID-19 itp.;
- ceny nośników energii: ropy, węgla, gazu, paliw ciekłych; ceny emisji gazów cieplarnianych i wiele innych.

Członkami TGE S.A. według stanu na 21.09.2021 r. było 77 podmiotów, m.in. PGE Polska Grupa Energetyczna S.A., PGNiG S.A., GAZ-SYSTEM S.A., TAURON Polska Energia S.A., ENEA S.A., ENERGA Obrót S.A., PKP Energetyka S.A., RWE Polska S.A., EDF Polska S.A., Vattenfall Energy Trading Sp. z o.o., Zespół Elektrowni PAK S.A., Noble Securities S.A., CEZ Towarowy Dom Maklerski Sp. Z o.o., PGE Dom Maklerski S.A.

Ponadto członkowie giełdy mogą, na podstawie osobno zawartej z Giełdą umowy, zobowiązać się do stałego składania zleceń kupna i sprzedaży towarów giełdowych we własnym imieniu i na własny rachunek w celu podtrzymywania płynności obrotu danego towaru giełdowego. Taka rola na giełdzie opisywana jest jako pełnienie funkcji animatora rynku [229]. Umowa o pełnienie funkcji animatora rynku określa zasady jego działania, a w szczególności:

- a) minimalną ilość towarów giełdowych w składanych zleceniach,
- b) maksymalną rozpiętość cenową pomiędzy zleceniami kupna i zleceniami sprzedaży,
- c) czas składania zleceń.

TGE S.A. posiada cztery umowy o pełnienie funkcji animatora rynku, a mianowicie z:

- ENEA SA,
- Tauron Polska SA,
- Polenergia S.A.
- PGNiG.

Wolumen obrotu energią elektryczną na TGE S.A. w 2020 r. wyniósł 243 174 442 MWh, co oznacza wzrost o 6,2% w stosunku do 2019 r. i stanowił najlepszy rezultat w historii obrotu tym towarem na TGE S.A. Zarówno wolumen ee na całym rynku spot (34 849 683 MWh – wzrost o 2,8% r/r), jak i na rynku terminowym (208 324 759 – wzrost o 6,8% r/r) osiągnął jedno z najwyższych odnotowanych do tej pory wartości. Obroty na Rynku Dnia Bieżącego wyniosły ostatecznie ponad 2 111 407 MWh, co okazało się ponad 12-krotnym przekroczeniem wolumenu z 2019 r. Na Rynku Dnia Następnego obroty wyniosły 32 738 277 MWh i tym samym zanotowano niewielki spadek o 3,0 % w stosunku do 2019 r. Średnioważona cena BASE na Rynku Dnia Następnego ukształtowała się w 2020 r. na poziomie 210,11 zł/MWh, co oznaczało spadek o 19,51 zł/MWh względem 2019 r. Z kolei na rynku terminowym średnioważona cena kontraktu rocznego z dostawą pasmową w 2021 r. (BASE_Y-21) wyniosła w całym 2020 r. 231,87 zł/MWh, co stanowiło spadek o 34,53 zł/MWh w stosunku do ceny z notowań kontraktu BASE_Y-20 w 2019 r. Wolumen obrotu energią elektryczną na TGE S.A. wyniósł w grudniu 2020 r. 17 744 361 MWh, co oznaczało wzrost o 15,7% w stosunku do grudnia 2019 r. Miesięczne obroty w grudniu 2020 r. na rynku spot wyniosły 3 280 221 MWh i były o 1,9% wyższe w stosunku do najwyższych dotychczas odnotowanych miesięcznych obrotów w historii rynku. Średnia ważona wolumenem obrotu cena na RDN ukształtowała się w grudniu 2020 r.

na poziomie 258,00 zł/MWh, co stanowiło wzrost o 6,34 zł/MWh w porównaniu do poprzedniego miesiąca. Na Rynku Terminowym Produktów z dostawą energii elektrycznej (RTPE) średnia ważona cena kontraktu rocznego z dostawą pasmową w 2021 r. (BASE_Y-21) wyniosła w grudniu 2020 r. – 235,30 zł/MWh, co stanowi wzrost o 12,84 zł/MWh względem analogicznej ceny z listopada 2020 r. [19–20].

Ponadto TGE S.A. prowadzi zadania w zakresie:

- koncentracji popytu i podaży⁷,
- współpracy z innymi giełdami energii elektrycznej,
- innych rynków towarowych: praw majątkowych, uprawnień do emisji, gazu ziemnego, rolnych etc.,
- rynku finansowego (w oparciu o notowania dla energii elektrycznej).

Od 2 lipca 2015 r. TGE S.A. jest pełnoprawnym członkiem europejskiego rynku Multi Regional Coupling (MRC). Jest to paneuropejski projekt operacyjnej integracji rynków spot energii elektrycznej, funkcjonujący na obszarze o zapotrzebowaniu na energię elektryczną w wysokości powyżej 2800 TWh, co stanowi 85% wielkości europejskiego zapotrzebowania. Natomiast od 15 listopada 2017 r. TGE S.A. jest aktywnym operatorem tego rynku.

TGE S.A. jest także obecne w Price Coupling of Regions⁸ (PCR), który jest projektem zainicjowanym w 2010 r. przez 7 zachodnioeuropejskich giełd energii, do których w 2015 r. dołączyła TGE S.A. Jako równoprawny podmiot w Projekcie PCR jest również współwłaścicielem oprogramowania operacyjnego Rynku Dnia Następnego w modelu PCR.

TGE S.A. występuje też jako Nominated Electricity Market Operator⁹ (NEMO), prowadząc jednolity mechanizm łączenia europejskich rynków energii dnia następnego i dnia bieżącego dla polskiego obszaru cenowego. Status NEMO na polskim rynku mają również

⁷ Koncentracja popytu i podaży oznacza konfrontację w określonym momencie możliwie dużej liczby podmiotów sprzedających i kupujących dany przedmiot obrotu; koncentrację popytu i podaży można osiągnąć poprzez standaryzację przedmiotu obrotu (nadanie waloru wymienności zwiększa liczbę potencjalnych stron transakcji), dobór odpowiedniego systemu notowań (np. fixing), co daje możliwość konfrontacji wszystkich zleceń złożonych na daną sesję w jednym momencie oraz zapewnienie bezpieczeństwa obrotu przy niskich kosztach zawierania transakcji [88].

⁸ Price Coupling of Regions jest modelowym rozwiązaniem cenowego połączenia giełdowych Rynków Dnia Następnego, zaakceptowanym przez KE i ACER jako rozwiązanie docelowe na wszystkich granicach państw UE [229].

⁹ Nominated Electricity Market Operator – Nominowany Operator Rynku Energii Elektrycznej [229].

dwie największe europejskie giełdy – NordPool¹⁰ oraz Epex Spot¹¹. Dzięki połączeniu energetycznym Polski ze Szwecją (SwePol) oraz z Litwą (LitPol), od 2010 r. możliwy jest handel energią elektryczną ze Szwecją, a od 8 grudnia 2015 r. z Litwą.

1.3. Rynek Dnia Następnego jako system zarządzania

Rynek Dnia Następnego był pierwszym rynkiem uruchomionym na TGE S.A. od momentu jej zarejestrowania. Rynek ten funkcjonuje jako samodzielny system od 30 czerwca 2000 r. i jest fizycznym rynkiem spot dla energii elektrycznej. Podstawowym celem jego funkcjonowania jest kreowanie cen energii elektrycznej dla pozostałych kontraktów zawieranych na hurtowym rynku energii elektrycznej w Polsce. Ponadto Rynek Dnia Następnego umożliwia m.in. uczestnikom rynku na wstępne zbilansowanie swoich pozycji kontraktowych, zaś przedsiębiorstwom energetycznym pośrednią wycenę ich wartości (w szczególności dla wytwórców) poprzez wycenę produkowanej przez nich energii elektrycznej. Kolejnym działaniem Rynku Dnia Następnego jest generowanie istotnych kierunków inwestycyjnych w zakresie budowy nowych mocy wytwórczych [19–20, 229]. W rozwiązaniu modelowym, miejsce dla Rynku Dnia Następnego w portfelu zakupowym uczestników Rynku Energii Elektrycznej, znajduje się pomiędzy kontraktami terminowymi z fizyczną dostawą energii elektrycznej, a Rynkiem Dnia Bieżącego i ofertami bilansującymi na Rynku Bilansującym.

Transakcje na RDN odbywają w oparciu o:

- wielkości zapotrzebowania godzinowego z dnia poprzedniego (w rozróżnieniu na dni robocze i świąteczne),
- charakterystykę godzinowego poboru przez odbiorców,
- krótkoterminowe prognozy pogody (temperatura, zachmurzenie, siła wiatru (ten parametr obecnie nabiera coraz większego znaczenia z uwagi na rosnącą liczbę turbin wiatrowych podłączanych do Krajowego Systemu Elektroenergetycznego (KSE)) itp.),

¹⁰ NordPool wiodący europejski rynek energii, który oferuje usługi handlowe, rozliczeniowe, rozrachunkowe i powiązane zarówno na rynkach dnia następnego, jak i dnia bieżącego w 16 krajach europejskich [149].

¹¹ EpexSpot to giełda energii elektrycznej działająca w Austrii, Belgii, Danii, Finlandii, Francji, Niemczech, Wielkiej Brytanii, Luksemburgu, Holandii, Norwegii, Polsce, Szwecji i Szwajcarii [52].

-
- przewidywalne zmiany w wielkości produkcji i zapotrzebowania na energię elektryczną (wynikające z awarii systemowych lub u wytwórców, zmiany zapotrzebowania u największych odbiorców lub innych zdarzeń mających wpływ na produkcję i pobór energii elektrycznej np. remonty).

Przedmiotem obrotu na Rynku Dnia Następnego jest energia elektryczna z dostawą fizyczną. Notowania na Rynku Dnia Następnego prowadzone są z wykorzystaniem następujących instrumentów:

- godzinowych (RDN) – jeden kontrakt odpowiada dostawie 1 MWh energii elektrycznej w konkretnej godzinie doby,
- blokowych: BASE, PEAK, OFFPEAK, BASE_WEEKEND, PEAK_WEEKEND, OFFP_WEEKEND – jeden kontrakt odpowiada dostawie 1 MWh energii w każdej godzinie okresu obowiązywania instrumentu, np. dla instrumentu BASE jest to dostawa w każdej godzinie doby.

Rynek Dnia Następnego na TGE S.A. składa się z 24 godzinowych notowań, na których realizowane są odpowiednie transakcje. Dodatkowo, na rynku RDN notowane są następujące kontrakty blokowe (BASE – kontrakt z dostawą 1 MWh w każdej godzinie doby; PEAK – kontrakt z dostawą 1 MWh energii elektrycznej w każdej godzinie szczytu (7.00–22.00); OFFPEAK – kontrakt z dostawą 1 MWh energii w godzinach doliny zapotrzebowania (0.00–7.00 i 22.00–24.00); BASE_WEEKEND (odpowiadający kontraktowi blokowemu BASE, w trakcie trwania weekendu); PEAK_WEEKEND (odpowiadający kontraktowi blokowemu PEAK, w trakcie trwania weekendu); OFFPEAK_WEEKEND (odpowiadający kontraktowi blokowemu OFFPEAK, w trakcie trwania weekendu)) [20, 229].

Notowania na RDN odbywają się codziennie, zaś każdy uczestnik może nabyć kontrakt na 24 lub 48 godzin przed dostawą energii elektrycznej. Każda godzina dostawy to osobny kontrakt na dostawę energii elektrycznej. Notowania odbywają się według ściśle określonego harmonogramu. W przypadku RDN możliwe jest uczestniczenie w aukcji krajowej oraz aukcji Market Coupling (MC), na połączeniach Polski z Litwą oraz Polski ze Szwecją. Dla aukcji krajowej składanie zleceń dla Fixingu I prowadzone jest pomiędzy godziną 8.00 a 10.30, a następnie do godziny 13.30 prowadzone są notowania ciągłe. Dla aukcji MC przyjmowanie zleceń realizowane jest pomiędzy godziną 8.00 a godziną 12.00, o godzinie 12.00 następuje

zamknięcie bramki na składanie zleceń na MC i do godziny 13.00 publikowane są wyniki MC [20, 166, 229].

Każdy z uczestników TGE S.A. posiada swoje własne konto (portfel) i może złożyć dowolną liczbę zleceń (kontraktów). Każde zlecenie określa m.in. kod instrumentu terminowego danego rodzaju zlecenia, rodzaj zlecenia (zakup lub sprzedaż), portfel, wolumen (ilość energii zakupywanej lub sprzedawanej) itp. Na RDN nie obowiązują ograniczenia wahań kursów. W przypadku, gdy kurs jednolity dla danego instrumentu różni się w sposób istotny od poprzedniego kursu jednolitego, Zarząd lub upoważniony pracownik TGE S.A. może po określeniu kursu jednolitego, przed fazą notowań ciągłych, wprowadzić dodatkową fazę notowań dla tego instrumentu, w której dopuszczalne jest składanie, usuwanie i modyfikowanie zleceń bez zawierania transakcji. Czas trwania dodatkowej fazy notowań nie przekracza 15 min. O wprowadzeniu dodatkowej fazy notowań Członkowie Giełdy są informowani za pomocą systemu informatycznego TGE S.A. Szczegółowe wytyczne dotyczące zawierania transakcji giełdowych są zdefiniowane w *Regulaminie obrotu Rynku Towarów Giełdowych Towarowej Giełdy Energii S.A.*, a także w tzw. *Warunkach obrotu dla programu tygodniowych instrumentów terminowych na energię elektryczną*, czy też w dokumencie pt. *Szczegółowe zasady rozliczeń rynków prowadzonych przez TGE S.A.* [229]. Pierwsze notowania cen energii elektrycznej na RDN (na stronach internetowych TGE S.A.) przeprowadzono w dniu 1 lipca 2000 r. i od tej pory TGE S.A. funkcjonuje bez przerwy.

TGE S.A. oferuje również uczestnikom RDN zgłaszanie i rozliczanie transakcji pozasesyjnych w oparciu o standardowe kontrakty notowane na sesji giełdowej RDN, który podobnie jak pozostałe rynki na TGE S.A., zorganizowany jest w formie elektronicznego rynku giełdowego. Giełda oferuje kompleksową usługę, obejmującą zorganizowanie i prowadzenie notowań w ramach RDN, organizację rozliczeń transakcji zawartych na giełdzie, jak również transakcji pozagiełdowych zgłoszonych do rozliczenia i wykonania przez odpowiedniego Operatora Systemu Przesyłowego.

Obrót na RDN prowadzony jest z dokładnością do 0,01 PLN/MWh. Minimalny wolumen w zleceniu wynosi 0,1 MWh. Notowania odbywają się codziennie, również w dni świąteczne. Sesja dla kontraktów godzinowych prowadzona jest w dwóch rodzajach systemów notujących – w systemie kursu jednolitego (fixing) i systemie notowań ciągłych. Dla kontraktów blokowych sesja odbywa się wyłącznie w systemie notowań ciągłych.

Rynek Dnia Następnego jest rynkiem fizycznym energii elektrycznej, co oznacza, że w wyniku zawartych transakcji następuje fizyczny przepływ i dostarczenie energii elektrycznej do odbiorcy, dlatego też RDN jest przeznaczony w szczególności dla:

- wytwórców energii elektrycznej,
- sprzedawców energii elektrycznej (wydzielonych po 1 lipca 2007 roku z dawnych spółek dystrybucyjnych jako podmioty handlujące energią – działające w oparciu o koncesję na obrót energią elektryczną),
- pozataryfowych odbiorców energii elektrycznej,
- firm hurtowego obrotu energią elektryczną,
- Domów Maklerskich i Towarowych Domów Maklerskich.

Wolumen obrotu energią elektryczną na TGE S.A. wyniósł w styczniu 2022 r. – 12 685 538 MWh, co oznacza wzrost o 1,7 % w stosunku do stycznia 2021 r. Średnioważona wolumenem dostarczonej i sprzedanej ee cena na RDN ukształtowała się w styczniu 2022 r. na poziomie 666,90 zł/MWh (spadek o 163,08 zł/MWh w porównaniu do poprzedniego miesiąca) [229].

2. MODELOWANIE IDENTYFIKACYJNE W UJĘCIU SYSTEMOWYM

2.1. Istota identyfikacji


Modelowanie identyfikacyjne jest procesem prowadzącym do uzyskania modelu systemu Rynku Dnia Następnego jako systemu zarządzania na podstawie uzyskanych pomiarów notowanych na giełdzie, to jest wartości wielkości wejściowych i wyjściowych.

Na potrzeby niniejszej pracy modelowanie identyfikacyjne określane jest także jako identyfikacja. W procesie identyfikacji w ujęciu systemowym można wyodrębnić następujące fazy [26, 30, 51, 120, 141, 197, 218, 260]:

- 1) określenie celu identyfikacji polegające na wyborze struktury modelu oraz doboru liczby i zakresu zmiennych wejściowych i wyjściowych (dobór bazy danych),
- 2) zaplanowanie i przeprowadzenie zabiegów wstępnych na danych (z ang. preprocessing),
- 3) budowa planu identyfikacji, w tym dobór struktury modelu,
- 4) wybór metody identyfikacji dostosowanej do struktury danych,
- 5) estymacja modelu, w tym oszacowanie podstawowych parametrów modelu,
- 6) weryfikacja modelu w odniesieniu do systemu, w tym wyznaczenie dopasowania modelu do systemu oraz jakości modelu.

Identyfikacja może dotyczyć również systemu zarządzania takiego jak system RDN. Warto podkreślić, że identyfikacja systemów zarządzania stanowi ważny element toczącej się w ostatnich latach dyskusji [59–61]. Autor pracy [59] wskazuje, że przez identyfikację złożonego systemu przyjmuje się proces prowadzący do utworzenia obrazu (modelu) przebiegu procesów rzeczowych w systemie. Z kolei w pracy [61] przez identyfikację procesów społeczno-gospodarczych rozumie się stwierdzenie i rozpoznanie stanów oraz zmian zachodzących w kolejnych fazach przebiegu procesu oraz formułowanie jego opisu, przy czym w literaturze przedmiotu rozumie się też ustalanie modelu matematycznego na podstawie badań eksperymentalnych [26]. Obecnie model matematyczny systemu jest ustalany nie tylko w sposób analityczny, czy też z wykorzystaniem identyfikacji, ale coraz częściej z wykorzystaniem sztucznych sieci neuronowych, które uczy się modelu systemu, rzutuje wiedzę, itp. [13, 16, 31–33, 35, 41, 55, 58, 104, 117, 139, 146, 152, 237]. Sytuację systemową podstawowych metod modelowania przedstawiono na rysunku 2.1 za pracę [218],

w której wyróżnia się: modelowanie analityczne, modelowanie identyfikacyjne oraz modelowanie neuronalne.



Rysunek 2.1. Sytuacja systemowa modelowania RDN: analitycznego (matematycznego), identyfikacyjnego (eksperymentalnego) oraz neuronalnego (projektowego)
Oznaczenia: WE – odpowiednie wejście do systemu RDN/modelu systemu RDN, WY – odpowiednie wyjście do systemu RDN/modelu systemu RDN.
Źródło: [218].

Modelowanie identyfikacyjne może być przeprowadzone za pomocą różnych metod, w tym metody parametrycznej, która może być zdefiniowana jako odwzorowanie pomiędzy zbiorem danych eksperymentalnych a wektorem uzyskanych parametrów modelu [26, 197, 260].

2.2. Istota modeli systemów oraz modelowania systemów TGE S.A.

W wyniku modelowania identyfikacyjnego uzyskuje się na podstawie zgromadzonych danych liczbowych odpowiednie modele systemów w zależności od wykorzystanej metody. W teorii sterowania i inżynierii systemów, w wyniku procesu identyfikacji, uzyskuje się następujące klasy modeli [7, 18, 26–27, 36, 51, 79, 120, 197, 218, 260]:

- modele o jednym wejściu i jednym wyjściu (ang. Single Input Single Output, SISO),
- modele wielowymiarowe (ang. Multi Input Multi Output, MIMO, Multi Input Single Output, MISO, Single Input Multi Output, SIMO),
- modele liniowe oraz modele nieliniowe,
- modele parametryczne oraz modele nieparametryczne,
- modele stałe w czasie oraz modele zmienne w czasie,
- modele w dziedzinie czasowej oraz modele w dziedzinie częstotliwościowej,
- modele z czasem ciągłym oraz modele z czasem dyskretnym, a nawet impulsowym,
- modele o parametrach skupionych oraz modele o parametrach rozłożonych,
- modele deterministyczne oraz modele stochastyczne, a także szereg innych modeli.

Z uwagi na cel pracy, w tym ze względu na potrzebę doboru typu procesu identyfikacji z wykorzystaniem odpowiedniej metody, warto zwrócić uwagę na kilka podstawowych i ważnych w identyfikacji otrzymywanych rodzajów modeli.

Należy do nich dynamiczny model liniowy, który może być określony za pomocą dyskretnego sygnału wyjściowego $y(t)$ postaci (rys. 2.2):

$$y(t) = G(z^{-1})u(t) + H(z^{-1})\varepsilon(t), \quad (2.1)$$

gdzie:

$G(z^{-1})$ – charakterystyka toru sterowania,

$H(z^{-1})$ – charakterystyka toru zakłócenia,

$u(t)$ – sygnał wejściowy,

$\varepsilon(t)$ – zakłócenie (szum),

z – operator przesunięcia czasowego,

t – czas krótki jako zmienna niezależna [dni].

Wyrażając $G(z^{-1})$ i $H(z^{-1})$ jako ilorazy wielomianów z^{-1} otrzymuje się modele postaci:

$$A(z^{-1})y(t) = \frac{B(z^{-1})}{F(z^{-1})}u(t) + \frac{C(z^{-1})}{D(z^{-1})}\varepsilon(t), \quad (2.2)$$

$$A(z^{-1}) = 1 + a_1z^{-1} + \dots + a_{na}z^{-na}, \quad (2.3)$$

$$B(z^{-1}) = 1 + b_1z^{-1} + \dots + b_{nb}z^{-nb}, \quad (2.4)$$

$$C(z^{-1}) = 1 + c_1z^{-1} + \dots + c_{nc}z^{-nc}, \quad (2.5)$$

$$D(z^{-1}) = 1 + d_1z^{-1} + \dots + d_{nd}z^{-nd}, \quad (2.6)$$

$$F(z^{-1}) = 1 + f_1z^{-1} + \dots + f_{nf}z^{-nf}, \quad (2.7)$$

gdzie:

z^{-1} – opóźnienie czasowe o jedną jednostkę, np. $y(t) z^{-1} = y(t-1)$,


na – stopień wielomianu $A(z)$,

nb – stopień wielomianu $B(z)$,

nc – stopień wielomianu $C(z)$,

nd – stopień wielomianu $D(z)$,

nf – stopień wielomianu $F(z)$.



Rysunek 2.2. Schemat blokowy modelu parametrycznego w postaci ogólnej

Uwaga: oznaczenia w tekście podrozdziału 2.2.


Źródło: [80, 197].

Kolejnym takim modelem jest model ARX (AutoRegressive with Exogenous Input), który wynika ze wzoru (1.1), jeżeli (rys. 2.3):

$$C(z^{-1}) = D(z^{-1}) = F(z^{-1}) = 1 \quad (2.8)$$

i wówczas otrzymuje się:

$$y(n) = \frac{B(z^{-1})}{A(z^{-1})} u(n) + \frac{1}{A(z^{-1})} \varepsilon(n). \quad (2.9)$$



Rysunek 2.3. Schemat blokowy modelu parametrycznego ARX

Uwaga: oznaczenia w tekście podrozdziału 2.2.

Źródło: [80, 197].

Z punktu widzenia formalizmu obliczeniowego przyjmuje się, że identyfikacja systemów jest procesem wykorzystującym dane pomiarowe, w celu utworzenia modelu systemu.

Z kolei, rozpatrując istotę modelowania z perspektywy TGE S.A, można wyróżnić kilka grup istniejących modeli, wykorzystywanych głównie na potrzeby modelowania prognoz ceny ee. Należy do nich zaliczyć między innymi:

1) **Modele prognozowania cen ee** jako grupa modeli wykorzystywana do ustalania ceny energii elektrycznej z uwzględnieniem konkurencyjności Rynku Energii Elektrycznej w oparciu o symulację funkcjonowania KSE i związanej z nim informacji o kosztach: wytwarzania, przesyłu i użytkowania itp. Głównym utrudnieniem, w tym podejściu, jest wymóg posiadania wystarczająco długiego czasu rzeczywistego do zbierania danych wykorzystywanych w badaniach. Metody takiej symulacji bardzo dobrze działają, jeśli są wykorzystywane przez operatorów rynku i organy regulacyjne, które posiadają upoważnienie do zbierania precyzyjnych danych m.in. o sprzęcie, stratach itp. [12, 29, 43, 48, 65–68, 72, 107, 110, 128, 163–164, 181, 236–237].

2) **Modele kształtowania cen ee** w oparciu o modele wykorzystujące teorię gier, które koncentrują się na wpływie podmiotu licytującego na strategiczne zmiany cen energii elektrycznej. Stwierdzono przy tym m.in., że ceny na rynku energii elektrycznej są ściśle związane ze strategiami składania ofert i ustalania cen przez uczestników rynku [8, 34, 62, 190].

3) **Modele stochastyczne ustalania cen ee** w oparciu o zmodyfikowaną metodę geometrycznych ruchów Browna jako metodę stochastycznego modelowania cen energii elektrycznej. W tego typu modelach trudności obliczeniowe sprawiają procedury związane z uwzględnianiem fizycznych właściwości systemów elektroenergetycznych, takich jak straty, ubytki i zatory transmisyjne, które mogą powodować znaczące niedopasowania wyznaczanych cen ee do notowanych faktycznie cen ee na rynku [9, 28, 133, 157].

4) **Modele szeregów czasowych** wykorzystywane w modelowaniu cen ee, obejmujące dwie główne grupy modeli: modele regresywne, m.in. autoregresji średniej ruchomej (ARMA), funkcji transferu oraz regresji dynamicznej, progowe modele autoregresyjne typu TAR, autoregresji warunkowej typu ARCH, modele Engle'a, modele GARCH i wiele innych modeli, a także coraz częściej modele sztucznej inteligencji (ang. Artificial Intelligence, skrót: AI), m.in. modele neuronalne, modele neuronalne z ewolucyjnym dostrajaniem wag, modele wykorzystujące algorytmy roi, w tym algorytmy mrówkowe, modele wykorzystujące zbiory rozmyte, modele sztucznego życia (ang. Artificial Life), modele uczenia maszynowego, modele hybrydowe, itp. [3–6, 31–32, 38, 40, 50, 54, 56, 69–70, 73, 90, 92, 95, 117–119, 121, 135, 140, 150, 156, 170, 180, 192, 202–206, 222, 230–231, 234, 248, 254–259].

Do tego typu modeli zalicza się także modele parametryczne uzyskiwane w wyniku identyfikacji, w tym metody typu ARX, stosowane od wielu lat, zwłaszcza w naukach technicznych i ekonomicznych, w tym w zakresie zarządzania i sterowania systemem RDN. Stosowane są przy tym różne metody otrzymywania modeli parametrycznych w zależności od obiektu badań (AR, ARX, ARMAX itp.).


W dotychczas prowadzonych badaniach identyfikacyjnych otrzymywano zatem modele prognostyczne, planistyczne czy też programistyczne, w wyniku stosowania znanych w literaturze przedmiotu metod modelowania tego typu systemów jak system Rynek Dnia Następnego na TGE S.A., które były następnie wykorzystywane do poszukiwania nowych

stanów systemu, a więc określonych wielkości wyjściowych w zależności od odpowiednich wielkości wejściowych [112–116].

Należy wyraźnie podkreślić, że w literaturze przedmiotu odczuwa się niedosyt wyników badań z zakresu identyfikacji systemu Rynku Dnia Następnego TGE S.A. z wykorzystaniem teorii sterowania i inżynierii systemów, w tym inżynierii systemów zarządzania, a zwłaszcza z punktu widzenia identyfikacji prowadzonej przy wykorzystaniu modeli parametrycznych. Za takim ujmowaniem systemów przemawia m.in. to, że system Rynku Dnia Następnego TGE S.A. i jego podsystemy w ujęciu techniczno-ekonomicznym stają się coraz ważniejszym partnerem w obrocie ee [130, 171–179, 182, 189, 253].

2.3. Modelowanie identyfikacyjne systemu Rynku Dnia Następnego

Modelowanie identyfikacyjne systemu RDN TGE S.A. wygodnie jest przeprowadzić z wykorzystaniem modelu parametrycznego ARX. Sytuację systemową systemu RDN przedstawiono w kategoriach inżynierii systemów na rysunku 2.4. System RDN (i tym samym model) powiązany jest z otoczeniem bliższym (odbiorcami i dostawcami ee) dwoma typami sprzężeń, to jest sprzężeniem energetycznym oraz sprzężeniem finansowym [21–22, 96, 194, 225]. Sprzężenie energetyczne obejmuje dostarczenie i sprzedaż ee na giełdzie, a sprzężenie finansowe związane jest z zapłatą za dostarczoną ee (poniesiony koszt) oraz uzyskanymi przychodami uzależnionymi od wysokości uzyskanej średniej ceny i sprzedanego wolumenu ee.




Rysunek 2.4. Umiejscowienie systemu RDN w kategoriach inżynierii systemów w otoczeniu bliższym (dostawców i odbiorców ee)

Źródło: opracowanie własne na podstawie [96, 218].

W wyniku przeprowadzonego modelowania identyfikacyjnego (krócej: identyfikacji) oraz metamodelowania identyfikacyjnego (krócej: metaidentyfikacji) uzyskano model i metamodel systemu RDN. W eksperymencie badawczym wykorzystano przykład liczbowy dotyczący systemu RDN na TGE S.A. dla danych liczbowych notowanych na giełdzie od 1 stycznia 2003 r. do 31 października 2020 r. z okresem wynoszącym 184 dni i postępowaniem jednego miesiąca (okresy półroczne). Umożliwiło to uzyskanie katalogu modeli parametrycznych dyskretnych ARX, konwertowanych następnie na modele ciągłe, a tych na modele w przestrzeni stanów. W następstwie uzyskano metamodely dyskretne i ciągłe, a także metamodely w przestrzeni stanów. Otrzymane współczynniki w modelach i metamodelach umożliwiły zbadanie skuteczności i efektywności uzyskanych modeli i metamodeli w odniesieniu do systemów rzeczywistych.

W sposób systemowy proces modelowania i metamodelowania systemu RDN na TGE S.A. pokazano na rysunku 2.5.



Rysunek 2.5. Ilustracja procesu modelowania i metamodelowania systemu RDN TGE S.A.
Oznaczenia: u_i – i -te wejście, y_i – i -te wyjście, gdzie: s – system, m – model, mm – metamodel.
Źródło: opracowanie własne.

W wyniku projektowania systemu RDN uzyskano rzeczywisty system, który funkcjonuje na TGE S.A. Przeprowadzając na nim identyfikację uzyskuje się model systemu RDN, a przeprowadzając metaidentyfikację uzyskuje się metamodel systemu RDN. Metamodel systemu RDN może być dalej wykorzystywany do projektowania modelu systemu RDN.

W sposób sformalizowany identyfikacją systemu RDN nazywa się problem znalezienia odwzorowania macierzy danych pomiarowych notowanych na RDN w postaci:


$$Z^N = [\text{wyjście}, \text{wejście}] \quad (2.10)$$

w wektor parametrów modelu $[\theta]$ zapisanych w macierzy **th** formatu **theta**, przy czym N jest liczbą uporządkowanych obserwacji kolejnych wartości zmiennych wejściowych oraz kolejnych wartości zmiennych wyjściowych [26, 51, 63, 85, 102, 114, 120, 218, 260]. Należy w tym miejscu podkreślić, że brak jest wyników badań dotyczących identyfikacji i metaidentyfikacji systemu Rynku Dnia Następnego na TGE S.A. prowadzonych w celu uzyskania modeli i metamodeli jako schematów zastępczych systemów rzeczywistych.

Niezmierznie ważnym problemem badawczym jest zdefiniowanie zatem samego obiektu badań, czyli systemu RDN jako systemu zarządzania (SZ) na Towarowej Giełdzie Energii S.A.

Przyjmuje się w kategoriach teorii sterowania i systemów, że na strukturę RDN jako systemu zarządzania składają się następujące podsystemy (rys. 2.6):

- system informacyjny (SI), analityczny (SA) oraz decyzyjny (SD),
- system organizacji wewnętrznej (SOW),
- system wykonawczy (SW).



Rysunek 2.6. Ilustracja rysunkowa systemu RDN na TGE S.A.

Oznaczenia w tekście podrozdziału 2.3.

Źródło: opracowanie własne na podstawie [194].

Oznaczenia do rysunku 2.6:

SI – system informacyjny,

SA – system analityczny,

SD – system decyzyjny,

SOW – system organizacji wewnętrznej (system informacyjno-decyzyjny),

SW – system wykonawczy,

U – strumień wielkości wejściowych, czyli wektor wolumenu dostarczonej ee w poszczególnych godzinach doby,

y – strumień wielkości wyjściowych, czyli wektor średnich cen uzyskanych za dostarczoną i sprzedaną ee w poszczególnych godzinach doby,

i_u – strumień informacji o wolumenie dostarczonej ee w poszczególnych godzinach doby,

i_y – strumień informacji o średniej cenie poniesionej za dostarczoną ee w poszczególnych godzinach doby,

d_u – strumień decyzji dotyczącej uzyskanej średniej ceny z tytułu dostarczonej i sprzedanej ee w poszczególnych godzinach doby,

d_y – strumień decyzji dotyczącej uzyskanej średniej ceny z tytułu dostarczonej ee w poszczególnych godzinach doby.

W przeprowadzonych badaniach analitycznych przyjęto tło systemowe według interpretacji stosowanej w inżynierii systemów [96]. Przedmiotem badań jest zatem proces modelowania identyfikacyjnego i metamodelowania identyfikacyjnego. Prowadzony on jest z wykorzystaniem zbioru wartości wielkości wejściowych i wyjściowych systemu RDN, to jest odpowiednio: wolumenu ee dostarczonej i sprzedanej na RDN oraz średniej ważonej wolumenem ceny ee otrzymanej z tego tytułu w poszczególnych godzinach doby. W wyniku identyfikacji uzyskano parametry katalogu modeli, którymi były współczynniki wielomianów $B(z)$ związanych z wielkościami wejściowymi oraz $A(z)$ z wielkościami wyjściowymi, występujące w modelu ARX.

2.4. Krytyczny przegląd literatury z zakresu metod modelowania systemu Rynku Dnia Następnego

W procesie prognozowania cen na giełdach energii elektrycznej stosowanych jest wiele metod modelowania systemów. Takimi metodami są metody: wygładzania Holta, wygładzania Wintersa oraz metoda trendu pełzającego. Metody te zostały wykorzystane w badaniach krótkoterminowych prognoz cen ee na RDN TGE S.A. [48, 165]. W przypadku metody trendu pełzającego stosowany jest model adaptacyjny z wagami harmonicznymi. Wyniki prowadzonych badań [48, 165] wykazały, że prognozowanie jest znacznie utrudnione z uwagi na duże zróżnicowanie cen ee. Wykazano również, że model trendu pełzającego charakteryzuje się największą dokładnością w analizowanym przypadku. Natomiast modele Holta i Wintersa ze względu na dosyć wysokie błędy generowane w prognozie zostały ocenione jako mniej przydatne do budowy prognoz cen ee na RDN TGE S.A.

Dobre wyniki w zakresie prognozowania cen energii elektrycznej na RDN uzyskuje się z wykorzystaniem modelu multiplikatywnego Holta-Wintersa, jak też z wykorzystaniem modeli neuronalnych szczegółowo opisanych i porównanych m.in. w pracy [48]. Pokazano w niej na przykład, że prognoza bazująca na metodzie wygładzania wykładniczego (model Holta-Wintersa) obarczona była bardzo dużymi błędami, znacznie przekraczającymi błędy przeciętne, co prawdopodobnie wynikało z konieczności przyjęcia za wartości rzeczywiste wartości prognoz już wygasłych. Natomiast model neuronalny, to jest wykorzystujący Perceptronową Sztuczną Sieć Neuronową, okazał się bardziej wiarygodny, gdyż błędy MAPE nie przekroczyły poziomu 5% wartości rzeczywistej. Autorzy prac zarekomendowali stosowanie SSN jako metody umożliwiającej precyzyjne prognozowanie cen energii elektrycznej oraz dodatkowo posiadającej możliwość wielokrotnego jej wykorzystywania w prognozowaniu. Porównując wyniki uzyskane przy wykorzystaniu obu wyżej wymienionych modeli zauważono, że za dobry wynik w pierwszej pracy uznano metodę trendu pełzającego, z powodu uzyskania najniższego błędu MAPE nieprzekraczającego 2,14% wartości rzeczywistej, zaś w drugiej pracy poziom ten już wynosił nie więcej niż 4,71% wartości rzeczywistej.

Innymi metodami stosowanymi do uzyskiwania modeli prognostycznych systemów, procesów, obiektów itp. są metody szeregów czasowych, takich jak [1, 7, 18, 27, 39, 41, 48, 66, 71, 81, 118–119, 122, 125, 129, 143–144, 165, 210, 226, 235]:

- metody autoregresji (ARMA) i autoregresji ze średnią ruchomą (ARIMA),
- metody autoregresywne ze średnią ruchomą i zewnętrznym wejściem (Auto Regressive Moving Average with auxiliary input, ARMAX),
- uogólniona metoda autoregresji z heteroskedastycznością¹² warunków (Generalized Auto-Regressive Conditional Heteroskedasticity, GARCH),
- połączona metoda autoregresji (ARMA) z funkcjonalną siecią neuronową Fuzzy Lattice Neural Network (skrót: FLNN).

W artykule [71] przedstawiono hybrydowy model ARMA-FLNN złożony z modelu parametrycznego i modelu neuronalnego z logiką rozmytą, stosowany dla krótkoterminowej prognozy zapotrzebowania i cen energii elektrycznej. Model liniowy ARMA i model rozmytych sztucznych sieci neuronowych są używane do pozyskiwania danych dotyczących popytu i cen z wykorzystaniem danych opartych o szeregi czasowe. Celem weryfikacji jakości prognozowania modelu ARMA-FLNN przeprowadzono badania na kilku rynkach energii elektrycznej, w tym w Pennsylvanii-New Jersey-Maryland (PJM), a także na innych rynkach energii elektrycznej, charakteryzujących się różnymi poziomami zmian cen. Dokładność prognozowania popytu nieprzekraczająca 1% odchylenia od rzeczywistych cen, co było znacznie lepsze niż w przypadku prognozowania opartego na modelach i technikach wykorzystujących SSN.

W literaturze przedmiotu spotyka się również odmienne wyniki badań, z których wynika, że SSN oceniane są właśnie jako odpowiednie metody do prognozowania cen energii elektrycznej, jak w przypadku pracy [119], w której zostały one pozytywnie ocenione ze względu na:

- lepszą dokładność w prognozowaniu (mniejsze odchylenia od pozostałych metod prognozowania),
- uproszczenie istniejących metod SSN o mniejszą liczbę danych wejściowych,
- niezależność trafności prognozowania od popytu (model działa poprawnie zarówno przy niskim, jak i przy wysokim popycie).

¹² Heteroskedastyczność jest to pojęcie z zakresu statystyki odnoszące się do ciągu lub wektora zmiennych losowych. Własność ta jest zaprzeczeniem posiadania przez taki ciąg lub wektor własności homoskedastyczności, tzn. przynajmniej jedna zmienna losowa z ciągu różni się od innych wariancją lub jej wariancja jest nieskończona. Heteroskedastyczność rozważa się w kontekście modeli ekonometrycznych, szczególnie przy estymacji metodą najmniejszych kwadratów, ze względu na jedno z założeń Klasycznego Modelu Regresji Liniowej, mówiącego o homoskedastyczności wariancji składnika losowego [75].

Istotny wkład w badania dotyczące prognozowania cen ee wnoszą modele autoregresyjnej warunkowej heteroskedastyczności (ARCH) wraz z ich różnymi odmianami. Uogólniona autoregresyjna warunkowa heteroskedastyczność (GARCH) to model statystyczny używany do analizowania danych szeregów czasowych, w których uważa się, że błąd wariancji jest seryjnie autokorelowany. Modele GARCH zakładają, że wariancja składnika błędu podąża za autoregresyjnym procesem średniej ruchomej. Modele klasy GARCH są nie tylko najszerszej rozpowszechnionymi modelami, lecz także najbardziej elastycznym narzędziem służącym do modelowania i prognozowania warunkowej wariancji [56, 139, 204, 231].

W pracach [235–237] zostało omówione klasyczne podejście do modelowania i prognozowania cen energii elektrycznej, w którym wykorzystano zestaw danych z fińskiego rynku RDN na Nord Pool Spot, z czego wynika między innymi, że zmiana przebiegu sygnału jest bardzo istotna dla uzyskiwania dokładności modelu. Analiza ścieżek cenowych generowanych przez modele niestosujące techniki zmiany przebiegu sygnału pokazuje, że nie tylko zmiany parametryczne cen, ale również gwałtowne ich skokowe zmiany (zmiany strukturalne) przy wykorzystaniu zwykłych metod modelowania nie są odpowiednio modelowane. Badania wykazały, że nawet model GARCH, który jako jedyny radzi sobie z heteroskedastycznością, nie jest w stanie uwzględniać skokowych zmian wartości zwykle obserwowanych w danych historycznych [75, 235–237].

Analiza przeprowadzona w wyżej wymienionych pracach wykazała, że filtr różnicowy zastosowany w modelu SARIMA nie może dokładnie usunąć lub dodać elementów deterministycznych do modelowania cen poza próbą. Ocena różnych modeli, takich jak modele ARMA/ARMA + GARCH uzupełnione o techniki zmiany przebiegu sygnału, przewyższają inne badane modele w zakresie dopasowania przebiegów dziennych i tygodniowych, a zwłaszcza w przypadku zmienności stochastycznej. Poprawienie wyników jest możliwe na drodze uwzględnienia w modelu takich danych, jak zapotrzebowania na energię elektryczną, moce wytwórcze, ceny paliw itp. i wówczas w modelach takich jak, na przykład modelu ARMAX lub ARX możliwe jest odnotowanie gwałtownych zmian przebiegów sygnału (charakterystycznych zmian strukturalnych). Przed oszacowaniem modelu ARMAX czy też ARX podstawowe dane są wstępnie pozbawiane cech sezonowości oraz nie zawierają wówczas trendów, co umożliwia traktowanie ich analogicznie do cen pozbawionych cech sezonowości.

Dla celów przeprowadzenia studium porównawczego modeli systemu Rynku Dnia Następnego dokonano również celowego doboru sześciu prac najbardziej adekwatnych do istoty badanego zagadnienia modelowania systemu RDN, wybranych spośród dostępnej i niezbyt bogatej literatury przedmiotu [1, 39, 41, 48, 66, 81, 118–119, 122, 125, 129, 165, 186–188, 210, 226, 235].

W badaniach porównawczych wykorzystano przede wszystkim kryteria efektywności, skuteczności i krzepkości, a ponadto ogólne kryterium dopasowania modelu do danych rzeczywistych czy też do systemu. Wyniki zestawiono w tabeli 2.1 [48, 66, 124, 165, 235, 244].

Z przeprowadzonej analizy porównawczej czterech modelowanych systemów Rynku Dnia Następnego oraz systemu Nord Pool Spot wynika m.in., że modelowanie charakteryzuje się następującymi prawidłowościami:

- 1) występują dwa rodzaje modelowania, jeden oparty na szeregach czasowych cen, to jest: multiplikatywny model Holta-Wintersa wykorzystany przez J. Ejdys, K. Halicką i J. Godlewską [48], modele Wintersa, Holta i trendu pełzającego z wagami harmonicznymi wykorzystane przez T. Popławskiego i M. Węźgowieca [165], modele m.in.: SARIMA, SARIMA i GARCH wykorzystane przez S. Voronina [235], a drugi rodzaj to modelowanie identyfikacyjne, w tym modele neuronalne oparte o Perceptronową Sztuczną Sieć Neuronową (z różną liczbą neuronów wejściowych) wykorzystane przez K. Halicką [66] i D. Rucińskiego [186–188],
- 2) przyjmowana jest różna długość i szczegółowość danych wykorzystywanych w modelowaniu, w tym czas mierzony w godzinach, dniach, tygodniach (pełnych lub bez weekendów i świąt) itp. [48, 66, 124, 165, 186–187, 235],
- 3) zakładany jest różny horyzont prognozowania (w godzinach), m.in.: dzień, tydzień, miesiąc [48, 66, 124, 165, 186–188, 235],
- 4) stosowane mierniki pomiaru dopasowania modelu do systemu (do danych rzeczywistych): dokładność dopasowania (jakość) i skuteczność [48, 66, 124, 165, 186–188, 235],
- 5) uzyskiwane błędy prognozowania, m.in.: ME, MAE, MAPE, RMSE, MdAPE, MR,
- 6) wykorzystywane środowisko do wspomagania modelowania: Statistica, MATLAB i Simulink oraz własne programy wykorzystywane w modelowaniu itp.

A zatem z punktu widzenia wykorzystanej metody modelowania uzyskiwane były różne rodzaje modeli systemu Rynku Dnia Następnego TGE S.A., w tym m.in.:

- modele prognostyczne otrzymywane na bazie szeregów czasowych dotyczących cen notowanych na RDN [23, 48, 165],
- modele modelowania identyfikacyjnego, w tym neuralnego otrzymywane na bazie różnych wielkości wejściowych i wyjściowych, tak dotyczących cen, jak też wolumenu dostarczonej i sprzedanej na RDN energii elektrycznej, a także innych czynników (zwłaszcza wykorzystywanych jako wielkości wejściowe), w tym: ekonomicznych, klimatycznych itp. [48, 66, 124, 165, 186–188, 235].

W zakresie doboru rodzaju Sztucznej Sieci Neuronowej oraz długości modelowanego okresu odpowiednie badania przeprowadził D. Ruciński, który w pracach [186–188] zamieścił wyniki modelowania neuralnego systemu Rynku Dnia Następnego Towarowej Giełdy Energii Elektrycznej przy wykorzystaniu danych liczbowych dotyczących ustalonych przedziałów czasu od jednego miesiąca, poprzez kwartał i okres półroczny, aż do okresów rocznych i wieloletnich oraz całego okresu jego funkcjonowania TGE S.A. (lata 2003–2020).

Modelowanie neuronalne Rynku Dnia Następnego przeprowadzono w oparciu o trzy modele sztucznych sieci neuronowych, tj.: Perceptronowej Sztucznej Sieci Neuronowej (tzw. Multi Layer Perceptron), Rekurencyjnej SSN oraz Radialnej SSN. W wyniku modelowania neuralnego otrzymano 1 191 modeli RDN, które zostały poddane ocenie według kryterium najmniejszego błędu MSE oraz według wskaźnika determinacji R^2 [186–187].

Okazało się, że najlepszym modelem neuronowym Rynku Dnia Następnego, który można wykorzystać w badaniach prognostycznych, jest Sztuczna Sieć Neuronowa Perceptronowa, a najlepszymi zakresami modelowania neuronowego pod względem wartości i zmienności były przedziały czasowe zbliżone do połowy roku dla Perceptronowej SSN, w których błąd MSE mieścił się w zakresie od 0,006723 do 0,001065 oraz był nieco mniejszy dla tych samych przedziałów czasowych i wynosił od 0,006723 do 0,00025243 dla Rekurencyjnej SSN, co przemawia za przyjęciem Perceptronowej SSN do modelowania neuronowego RDN TGE S.A. [186–187].

Uzyskane średnie wartości wskaźnika MSE wyniosły odpowiednio dla modelu zawierającego:

- 1) jeden czynnik, tj. zapotrzebowanie: $2,691 \cdot 10^{-5}$,
- 2) wszystkie czynniki, tj.: zapotrzebowanie na energię, czynniki ekonomiczne, takie jak: poziom inflacji, wysokość zadłużenia, bilans wydatków państwa, podaż pieniądza oraz czynniki środowiskowe (temperatura, wilgotność powietrza, zachmurzenie oraz siła wiatru): $2,200 \cdot 10^{-5}$,
- 3) czynniki ekonomiczne: $5,344 \cdot 10^{-5}$,
- 4) czynniki pogodowe: $5,018 \cdot 10^{-5}$,
- 5) czynniki pogodowe i wybrane czynniki ekonomiczne, tj. bilans wydatków państwa: $1,909 \cdot 10^{-5}$.

Natomiast współczynnik determinacji R^2 wyniósł odpowiednio dla modelu zawierającego:

- 1) jeden czynnik, tj. zapotrzebowanie: 0,789,
- 2) wszystkie czynniki, tj.: zapotrzebowanie na energię, czynniki ekonomiczne, takie jak: poziom inflacji, wysokość zadłużenia, bilans wydatków państwa, podaż pieniądza oraz czynniki środowiskowe (temperatura, wilgotność powietrza, zachmurzenie oraz siła wiatru): 0,832,
- 3) czynniki ekonomiczne: 0,493,
- 4) czynniki pogodowe: 0,538,
- 5) czynniki pogodowe i wybrane czynniki ekonomiczne, tj. bilans wydatków państwa: 0,856.

W tabeli 2.1 umieszczono wyniki przeglądu przykładowych prac zawierających metody modelowania systemu Rynku Dnia Następnego.

Warto w tym miejscu dodać, że modele parametryczne dyskretnie systemu można konwertować na modele parametryczne ciągłe, a te na modele ciągłe w przestrzeni stanów [42, 89, 218]. Modele zmiennych stanu stosowane są od wielu lat, zwłaszcza w naukach technicznych i ekonomicznych, w tym: w automatyce, robotyce i elektrotechnice oraz coraz częściej w ekonomii i zarządzaniu. Stosowane były przy tym różne modele i sposoby otrzymywania modeli zmiennych stanu w zależności od obiektu badań. Jedną ze starszych pozycji, aktualną do tej pory jest praca S.H. Żaka pt. *On state-space models for systems described by partial differential equations* [261], w której dokonano analizy porównawczej i zaproponowano wykorzystanie w modelach zmiennych stanu równań różniczkowych cząstkowych.

Prace innych autorów [54, 151, 154–155, 169, 232] dotyczą systemów i układów liniowych lub sprowadzanych do liniowych, modelowanych za pomocą równań stanu i wyjścia dla różnych sytuacji szczegółowych. I tak np. w pracy pt. *A Self-Organizing State Apace Type Microstructure Model for Financial Asset Allocation* [54] przedstawiono samoorganizującą się przestrzeń stanów, którą wykorzystano do modelowania alokacji aktywów finansowych.

Z kolei w pracach [42, 151, 154–155, 169, 232] pokazano typowe rozwiązania modelowania w przestrzeni stanów z wykorzystaniem różnych metod opisu systemów dziedzinowych. Ciekawe podejście w tym względzie zaproponowali T. Kwater & P. Krutys w pracy [105], w której zamieścili propozycję systemowego podziału obiektu w celu decentralizacji obliczeń, co wiąże się z tzw. syntezą estymatorów i prowadzeniem kolejnych obliczeń od ostatniego podsystemu.

Studium porównawcze wybranych metod/modeli systemu Rynku Dnia Następnego zamieszczono w tabeli 2.1.

Tabela 2.1. Studium porównawcze wybranych metod/modeli systemu Rynku Dnia Następnego
Oznaczenia: w tekście podrozdziału 2.5.

System/ obiekt/ układ/ itp.	Metody/ modele	Dane	Horyzont czasowy	Mienniki oceny	Wybrane wyniki oceny	Referencje	Środowisko obliczeniowe
Rynek Dnia Następnego TGE S.A.	Model prognozowania ¹³	1.01.2012–30.04.2013	Jedna doba	ME MAE max AE MAPE RMSE MdAPE max APE	Dla modelu Holta-Wintersa: – ME -0,75 PLN – MAE 59,39 PLN – max AE 1004,35 PLN – MAPE 37,32% – RMSE 76,44 PLN – MdAPE 30,48% – max APE 282,12% Dla Perceptronu Wielowarstwowego: – ME -0,02 PLN – MAE 7,93 PLN – Max AE 300,05 PLN – MAPE 4,71% – RMSE 13,12 PLN – MdAPE 3,07% – max APE 50,03%	J. Ejdyś, K. Halicka, J. Godlewska: Prognozowanie cen energii elektrycznej na giełdzie energii [48]	STATYSTICA

¹³ Multiplikatywny model Holta-Wintersa dla szeregu czasowego z tendencją rozwojową oraz wahaniami sezonowymi Sztuczna Sieć Neuronowa - Perceptron Wielowarstwowy.

Tabela 2.1 cd.

System/ obiekt/ układ/ itp.	Metody/ modele	Dane	Horyzont czasowy	Mierniki oceny	Wybrane wyniki oceny	Referencje	Środowisko obliczeniowe
Rynek Dnia Następnego TGE S.A.	Metody wygładzania, modele adaptacyjne ¹⁴	1.04 – 30.06.2012 (bez weekendów oraz świąt)	5 dni roboczych	MAPE	Błąd średni prognozy MAPE [%]: Model Wintersa: – Addytywny 4,51 – Multiplikatywny 7,01 Model Holta: Model1 2,98 Model2 3,17 Trend pełzający dla: k=3 3,07, k=4 2,69, k=5 2,4, k=6 2,14 Błędy dopasowania modeli MAPE [%]: Model Wintersa: – Addytywny 10,33 – Multiplikatywny 5,89 Model Holta: Model1 5,10 Model2 4,93 Trend pełzający dla ¹⁵ : k=3 4,74, k=4 4,61, k=5 4,53, k=6 4,5	T. Popławski, M. Węzgowiec: Krótkoterminowe prognozy cen na Towarowej Giełdzie Energii z wykorzystaniem modelu trendu pełzającego [165]	-
Rynek Dnia Następnego TGE S.A. Rynek Bilansujący	Metody neuronalne ¹⁶	1.01 – 31.12.2004	1.01 – 31.01.2005	ME MAE max AE MAPE RMSE MdAPE max APE	I Model SSN – ME -0,57 PLN – MAE 4,06 PLN – maxAE 14,96 PLN – RMSE 5,50 PLN – MAPE 3,69% – MdAPE 2,74% – maxAPE 61,77% , II Model SSN – ME -0,14 PLN – MAE 3,70 PLN – maxAE 17,90 PLN – RMSE 5,06 PLN – MAPE 3,35% – MdAPE 2,44% – maxAPE 44,23% (szczegółowe wyniki w tekście) ¹⁷	K. Halicka: Skuteczność prognozowania w zarządzaniu transakcjami na giełdzie energii [66]	STATYSTICA

¹⁴ Model Wintersa, Model Holta, Model trendu pełzającego z wagami harmonicznymi¹⁵ k - parametr wygładzania (od wartości 3 do 6).¹⁶ Sztuczna Sieć Neuronowa - Perceptron Wielowarstwowy (z jedną lub dwoma warstwami ukrytymi), modele MISO: model I (10 neuronów warstwa wejściowa, 1 neuron warstwa wyjściowa), model II (7 neuronów warstwa wejściowa, 1 neuron warstwa wyjściowa).¹⁷ Wyniki oceny dopasowania modelu do danych rzeczywistych w różnych architekturach SSN typu MLP dla Modelu II K. Halickiej [46]

MLP 7:168-7-1:1: ME -0,22 PLN, MAE 4,93 PLN, maxAE 18,85 PLN, RMSE 6,89 PLN, MAPE 4,50%, MdAPE 3,11%, maxAPE 63,69%,

MLP 7:168-30-5-1:1: ME 0,21 PLN, MAE 2,72 PLN, maxAE 12,95 PLN, RMSE 3,75 PLN, MAPE 2,47%, MdAPE 1,83%, maxAPE 39,48%,

MLP 7:168-30-6-1:1: ME -0,14 PLN, MAE 3,70 PLN, maxAE 17,90 PLN, RMSE 5,06 PLN, MAPE 3,35%, MdAPE 2,44%, maxAPE 44,23%.

Tabela 2.1 cd.

System/ obiekt/ układ/ itp.	Metody/ modele	Dane	Horyzont czasowy	Mierniki oceny	Wybrane wyniki oceny	Referencje	Środowisko obliczeniowe
Nord Pool Spot, The Finnish day-ahead electricity market	Modele parametryczne ¹⁸	1999 – 2010 ¹⁹	Rok ²⁰	MAPE	MAPE: - MR - 15.57 - MR bez sezonowości -38.15 - MR no r/s.(ang. without regime-switching) -24.35 - ARMA - 13.74 - GARCH(1,1) no r/s. - 16.17 - ARMA(2,1)+GARCH(1,1) - 12.84 - SARIMA(1,1,1)(1,1,1)24 bez sezonowości -17.81	S. Voronin: Price Spike Forecasting in a competitive day-ahead energy market [235]	-
California, Nord Pool	12 metod szeregów czasowych – m.in. model ARX	California (1999-2000), Nord Pool (1998-1999, 2003-2004)	tydzień ²¹	WMAE ²²	WMAE: - ARX (dla 6 tygodnia) – 8.04, (dla 10 tygodnia) – 7.39 - p-ARX (dla 1 tygodnia) – 2.98, (dla 2 tygodnia) – 4.66, (dla 3 tygodnia) – 8.31, (dla 7 tygodnia) – 9.31, (dla 9 tygodnia) – 12.41 - SNARX (dla 4 tygodnia) – 12.43, (dla 5 tygodnia) – 4.66, (dla 3 tygodnia) – 17.36, (dla 8 tygodnia) – 43.34	R. Weron, A. Misiorek: Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models [244]	-
Rynek Dnia Następnego TGE S.A.	Model ARX, model neuronalny (Perceptronowa Sztuczna Sieć Neuronowa)	Dane do identyfikacji z roku 2019	Rok, miesiąc, miesiąc (dni robocze), tydzień, tydzień (dni robocze)	Błąd względny, MAPE	Bw/MAPE dla h6: - rok - 5.39%/ 5.39% - miesiąc - 3.46% /6.57% - miesiąc (dni robocze) - 2.52%/6.15% - tydzień - 0.71%/ 3.01% - tydzień (dni robocze) - 1.26%/ 2.85%	R. Marłęga: Correction of the parametric model of the Day-Ahead Market system using the Artificial Neural Network [124]	MATLAB i Simulink

Źródło: opracowanie własne na podstawie prac [48, 66, 124, 165, 235, 244].


¹⁸ Model SARIMA, Modele SARIMA+GARCH, MR MR no seas, MR no r/s, ARMA (2,1), GARCH (1,1) no r/s, ARMA(2,1) +GARCH(1,1), SARIMA (1,1,1) (1,1,1) no seas, Wszystkie modele obejmują 24 godziny¹⁹ Cały zestaw danych podzielony jest na zestawy treningowe (60 dni) i testowe (7 dni)²⁰ Badano również inne okresy i modele²¹ Badano również jeden dzień²² WMAE (ang. Weekly-weighted Mean Absolute Error) – Tygodniowy ważony średni błąd bezwzględny

Wykorzystaniem modelowania w przestrzeni stanów zajmuje się także autor niniejszej rozprawy, który opublikował m.in. prace dotyczące modelowania systemu Rynku Dnia Następnego Towarowej Giełdy Energii S.A. [121–122], inspirowany m.in. pracami dotyczącymi wykorzystania metod modelowania w przestrzeni stanów w elektroenergetyce oraz energetyce, w tym do modelowania giełdy energii elektrycznej [191, 211–212, 215, 218, 224].

3. METODYKA BADAŃ IDENTYFIKACYJNYCH I METAIDENTYFIKACYJNYCH SYSTEMU RYNKU DNIA NASTĘPNEGO

3.1. Opis procesu badawczego

Z uwagi na przyjęty zasadniczy cel badań, w tym cele szczegółowe oraz złożoność badań identyfikacyjnych, zaprojektowany proces badawczy składa się z ośmiu etapów działań. Ich przebieg oraz syntetyczny opis przedstawiono na rysunku 3.1.



Rysunek 3.1. Schemat procesu badawczego

Źródło: opracowanie własne.

Proces badawczy zaprojektowany na potrzeby realizacji celu ogólnego oraz celów szczegółowych rozprawy zakłada wykonanie następujących działań w ramach ośmiu wyodrębnionych etapów, tj.:

- 1) **Etap 1.** Na potrzeby przeprowadzenia studiów i badań w zakresie modelowania i metamodelowania identyfikacyjnego (krócej: identyfikacji) systemu Rynku Dnia Następnego TGE S.A. opracowano tabelę 2.1, zawierającą studium porównawcze modelowania o strukturze: modelowany system/obiekt/układ/proces/itp., rodzaj modelowania, w tym wykorzystane metody identyfikacji/prognozowania, dane wykorzystane do modelowania (wejściowe/wyjściowy/okresy itp.), horyzont prognozowania, cel badań (dopasowanie modelu do systemu, to jest do danych rzeczywistych), stosowane mierniki, uzyskane wyniki prognozowania (m.in. rodzaje błędów i ich wartości), autorzy/tytuł książki/artykułu, uwagi, w tym dotyczące środowiska obliczeń informatycznych.
- 2) **Etap 2.** W celu przeprowadzenia eksperymentów należało przeprowadzić analizę procesów zachodzących na RDN, jak również pozyskać dane liczbowe notowane w poszczególnych godzinach doby, to jest dotyczące wolumenu energii elektrycznej dostarczonej i sprzedanej na Rynku Dnia Następnego oraz średnioważonej wolumenem ceny energii elektrycznej uzyskiwanej w poszczególnych godzinach doby, a także przeprowadzenie na danych zabiegów wstępnych, między innymi przeprowadzenie normalizacji danych dla potrzeb modelowania z wykorzystaniem sztucznych sieci neuronowych.
- 3) **Etap 3.** W celu uzyskania katalogu modeli systemu RDN należało zaprojektować i przeprowadzić eksperymenty identyfikacyjne z wykorzystaniem danych liczbowych notowanych na RDN w środowisku MATLAB-a i System Identification Toolbox-a.
- 4) **Etap 4.** Ze względu na potrzebę poprawy parametrów modelu systemu RDN należało dokonać doboru architektury i metody uczenia Sztucznej Sieci Neuronowej w środowisku MATLAB-a oraz Deep Learning Toolbox-a oraz przeprowadzić eksperyment uczenia neuronowego.
- 5) **Etap 5.** Uzyskanie informacji o stopniu organizacji wewnętrznej systemu zarządzania jakim jest system RDN oraz występującego w nim poziomu sterowania należało dokonać konwersji modeli parametrycznych dyskretnych ARX na modele parametryczne ciągłe th

oraz konwersji modeli parametrycznych ciągłych th na modele ciągłe w przestrzeni stanów ss.

- 6) **Etap 6.** W celu uzyskania metamodelu modelu systemu RDN należało zaprojektować i przeprowadzić eksperyment meta identyfikacyjny z wykorzystaniem parametrów katalogu modeli systemu RDN w środowisku MATLABA-a i System Identification Toolbox-a, a także Deep Learning Toolbox-a.
- 7) **Etap 7.** Ocena jakości modelu w stosunku do systemu RDN wymagała wyznaczenia błędów bezwzględnych i względnych, jak też skuteczności modeli systemu RDN, efektywności i krzepkości systemu i modeli systemu RDN, a także zbadania wrażliwości modelu systemu RDN.
- 8) **Etap 8.** Przeprowadzono dyskusję uzyskanych wyników badań oraz sformułowanie wniosków wskazujących w jakim stopniu udało się zrealizować cel pracy i cele szczegółowe, a tym samym udało się udowodnić postawione hipotezy, a także opracowano dalsze kierunki badań.

Na potrzeby realizacji badań przyjęto 24 zadania badawcze, w odniesieniu do których sformułowano pytania badawcze zamieszczone w tabeli 3.1.

Tabela 3.1. Cele i zadania badawcze

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań ²³
Cel szczegółowy nr 1: Umiejscowienie systemu Rynku Dnia Następnego w ujęciu inżynierii systemów i nauk o zarządzaniu i jakości na tle problematyki badań dotyczącej systemu Rynku Energii Elektrycznej	Zadanie badawcze nr 1: Opis systemu Rynku Energii Elektrycznej w Polsce	Jaki jest stan i struktura systemu Rynku Energii Elektrycznej w Polsce? Jakie są wymagania dotyczące wdrożenia systemu REE ? Jakie są modele systemu REE? Jakie występują z punktu widzenia obrotu rynki energii elektrycznej? Jaka jest charakterystyka obrotu ee na rynkach energii elektrycznej?	Badania literatury przedmiotu

²³ Na podstawie [68]

Tabela 3.1 cd.

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań²³
Cel szczegółowy nr 1: Umiejscowienie systemu Rynku Dnia Następnego w ujęciu inżynierii systemów i nauk o zarządzaniu i jakości na tle problematyki badań dotyczącej systemu Rynku Energii Elektrycznej	Zadanie badawcze nr 2: Ujęcie Towarowej Giełdy Energii S.A. jako podsystem na Rynku Energii Elektrycznej	Jaka jest charakterystyka TGE S.A.? Jaki jest stan obrotu ee na TGE S.A.?	Badania literaturowe/ konsultacje indywidualne
	Zadanie badawcze nr 3: Charakterystyka systemu Rynek Dnia Następnego jako system zarządzania	Jaki jest cel i zadania RDN? Jakiego rodzaju transakcje zawierane są na RDN? W jaki sposób odbywają się notowania na RDN? Jacy są uczestnicy RDN?	Badania literaturowe/ konsultacje indywidualne
Cel szczegółowy nr 2: Przegląd metod modelowania identyfikacyjnego w ujęciu systemowym	Zadanie badawcze nr 4: Opis istoty identyfikacji	Na czym polega proces identyfikacji? Jakie są fazy identyfikacji? Jakie jest miejsce modelowania identyfikacyjnego na tle modelowania systemowego?	Badania literatury przedmiotu
	Zadanie badawcze nr 5: Przegląd możliwości uzyskiwania modeli systemów	Jakie klasy modeli można uzyskać w wyniku identyfikacji? Jaki jest opis matematyczny modelu parametrycznego ARX?	Badania literatury przedmiotu
	Zadanie badawcze nr 6: Przegląd metod wykorzystywanych w modelowaniu systemów TGE S.A.	Jakie modele są wykorzystywane w zakresie funkcjonowania giełd towarowych?	Badania literatury przedmiotu
	Zadanie badawcze nr 7: Opis modelowania identyfikacyjnego systemu RDN	Jaka jest sytuacja systemowa RDN? Jaki jest proces modelowania i metamodelowania systemu RDN? Jaka jest definicja systemu RDN jako systemu zarządzania?	Badania jakościowe

²³ Na podstawie [68]

Tabela 3.1 cd.

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań ²³
Cel szczegółowy nr 2: Przegląd metod modelowania i identyfikacyjnego w ujęciu systemowym	Zadanie badawcze nr 8: Przeprowadzenie krytycznego przeglądu literatury przedmiotu w zakresie uzyskiwania wystarczająco dokładnych modeli systemu RDN	Jaki jest stan i kierunki rozwoju modelowania systemu RDN?	Badania literatury przedmiotu
Cel szczegółowy nr 3: Opracowanie metodyki badań identyfikacyjnych i metaidentyfikacyjnych systemu RDN	Zadanie badawcze nr 9: Opis etapów procesu badawczego	Jakie należy wyróżnić etapy procesu badawczego? Jakie katalogi danych należy wykorzystać w procesie badawczym? W jaki sposób należy ująć proces identyfikacji i metaidentyfikacji?	Badania jakościowe
	Zadanie badawcze nr 10: Ujęcie systemowe RDN	Jaka jest istota ujęcia systemowego RDN? W jaki sposób otrzymuje się model systemowy RDN?	Badania jakościowe
	Zadanie badawcze nr 11: Ocena modelu i systemu w kategoriach efektywności, skuteczności i krzepkości	Na czym polega skuteczność modelu? Na czym polega efektywność i krzepkość systemu i modelu?	Badania jakościowe
Cel szczegółowy nr 4: Przeprowadzenie identyfikacji systemu RDN	Zadanie badawcze nr 12: Sformułowanie założeń dotyczących projektowania procesu identyfikacji i metaidentyfikacji systemu RDN	Jakie przyjęto założenia dotyczące modelu systemu RDN? Jakie przyjęto założenia dotyczące identyfikacji systemu RDN? Jakie przyjęto założenia dotyczące metaidentyfikacji systemu RDN?	Badania empiryczne (projektowanie)
	Zadanie badawcze nr 13: Przeprowadzenie identyfikacji systemu RDN z wykorzystaniem danych z okresu od 1.01.2015 r. do 30.06.2015 r.	Jakiego typu modele matematyczne otrzymuje się w wyniku identyfikacji systemu RDN? Jaka jest interpretacja parametrów uzyskanych modeli?	Badania empiryczne (identyfikacja i ocena)

²³ Na podstawie [68]

Tabela 3.1 cd.

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań ²³
Cel szczegółowy nr 4: Przeprowadzenie identyfikacji systemu RDN	Zadanie badawcze nr 14: Przeprowadzenie identyfikacji systemu RDN z wykorzystaniem danych z okresu od 1.01.2013 r. do 30.04. 2016 r.	Jakiego typu modele matematyczne otrzymuje się w wyniku identyfikacji systemu RDN? Jaki katalog modeli otrzymuje się dla potrzeb metaidentyfikacji? Jaka jest interpretacja parametrów uzyskanych modeli? Jaki jest poziom systemu zarządzania oraz stopień wewnętrznej organizacji systemu RDN?	Badania empiryczne (identyfikacja i ocena)
	Zadanie badawcze nr 15: Przeprowadzenie identyfikacji systemu RDN z wykorzystaniem danych z okresu od 1.01.2016 r. do 31.12.2019 r.	Jakiego typu modele matematyczne otrzymuje się w wyniku identyfikacji systemu RDN?	Badania empiryczne (identyfikacja)
Cel szczegółowy nr 5: Przeprowadzenie metaidentyfikacji systemu RDN	Zadanie badawcze nr 16: Przeprowadzenie metaidentyfikacji systemu RDN z wykorzystaniem 35 modeli systemu RDN uzyskanych na podstawie danych z okresu od 1.01.2013 r. do 30.04.2016 r.	Jakiego typu modele matematyczne otrzymuje się w wyniku metaidentyfikacji systemu RDN? Czy istnieje możliwość uzyskania metamodeli systemu RDN w wyniku projektowania i uczenia SSN ?	Badania empiryczne (metaidentyfikacja oraz uczenie SSN)
Cel szczegółowy nr 6: Zbudowanie modeli symulacyjnych i następnie przeprowadzenie z ich wykorzystaniem badań symulacyjnych, komparatystycznych oraz badania wrażliwości	Zadanie badawcze nr 17: Zaprojektowanie i budowa modelu symulacyjnego	Czy istnieje możliwość zaprojektowania i zbudowania modelu symulacyjnego systemu RDN?	Badania empiryczne (badania symulacyjne)

²³ Na podstawie [68]

Tabela 3.1 cd.

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań ²³
Cel szczegółowy nr 6: Zbudowanie modeli symulacyjnych i następnie przeprowadzenie z ich wykorzystaniem badań symulacyjnych, komparatystycznych oraz badania wrażliwości	Zadanie badawcze nr 18: Przeprowadzenie badań symulacyjnych	Czy istnieje możliwość przeprowadzenia badań symulacyjnych z wykorzystaniem modelu symulacyjnego dla dowolnych wartości sygnałów wejściowych (wolumenu dostarczonej i sprzedanej ee)?	Badania empiryczne (symulacyjne)
	Zadanie badawcze nr 19: Przeprowadzenie badań komparatystycznych i badania wrażliwości	Czy istnieje możliwość przeprowadzenia badań komparatystycznych z wykorzystaniem modelu symulacyjnego dla dowolnych wartości sygnałów wejściowych (wolumenu dostarczonej i sprzedanej ee)? Czy istnieje możliwość przeprowadzenia badania wrażliwości?	Badania empiryczne (badania komparatystyczne badanie wrażliwości)
	Zadanie badawcze nr 20: Przeprowadzenie badań efektywności, skuteczności i krzepkości systemu i modelu systemu RDN	Jaka jest efektywność, skuteczność i krzepkość systemu i modelu systemu RDN?	Badania empiryczne (badania efektywności, skuteczności i krzepkości systemu i modelu)
szczególony nr 7: Interpretacja parametrów oraz badanie jakości	Zadanie badawcze nr 21: Interpretacja parametrów modeli	Jaka jest interpretacja parametrów modeli parametrycznych? Jaka jest interpretacja parametrów modeli zmiennych stanu?	Badania empiryczne (badanie parametrów modeli)

²³ Na podstawie [68]

Tabela 3.1 cd.

Cele naukowe rozprawy	Zadanie badawcze	Pytania badawcze	Forma badań²³
Cel szczegółowy nr 7: Interpretacja parametrów oraz badanie jakości modeli	Zadanie badawcze nr 22: Badania jakości modeli	Na czym polega badanie efektywności modelu i systemu? Na czym polega badanie skuteczności modelu do systemu? Na czym polega badanie krzepkości modelu i systemu?	Badania empiryczne (efektywności, skuteczności i krzepkości w zależności od wolumen ee oraz średnioważonej wolumen ceny ee)
Cel szczegółowy nr 8: Sformułowanie wniosków końcowych oraz dalszych kierunków badań	Zadanie badawcze nr 23: Opracowanie wniosków końcowych	Jakie można sformułować wnioski, wskazujące na stopień realizacji celu ogólnego oraz celów szczegółowych pracy? W jaki sposób zostały zweryfikowane postawione hipotezy?	Badania jakościowe
	Zadanie badawcze nr 24: Opracowanie dalszych kierunków badań	Jakie opracowano dalsze kierunki badań?	Badania jakościowe

Źródło: opracowanie własne.

Przyjęte zadania badawcze odpowiadają celom szczegółowym rozprawy, które zostały przedstawione we wprowadzeniu. Do poszczególnych celów badawczych przypisano pytania badawcze oraz zaproponowano adekwatną formę badań.


W procesie badawczym wykorzystano cztery katalogi danych dotyczących systemu Rynku Dnia Następnego TGE S.A., obejmujące następujące dane (Etap 2):

- od 1 stycznia 2015 r. do 30 czerwca 2015 r. z okresem identyfikacji o długości 184 dni, na bazie których otrzymano po 24 modele parametryczne godzinowe, odpowiednio: dyskretne i ciągłe oraz 24 modele ciągłe w przestrzeni stanów, czyli łącznie 72 modele, które wykorzystano w Etapie 3 oraz Etapie 5,

²³ Na podstawie [68]

-
- od 1 stycznia 2013 r. do 30 kwietnia 2016 r. z okresem identyfikacji o długości 184 dni, na bazie których otrzymano po 24 katalogi modeli parametrycznych godzinowych, przy czym każdy katalog zawierał po 35 modeli zadanych w przyjętych okresach kroczących z postępowaniem jednego miesiąca, to jest otrzymano łącznie 840 modeli dyskretnych i ciągłych oraz 840 modeli ciągłych w przestrzeni stanów, które wykorzystano w Etapie 3 oraz Etapach 5–6,
 - od 1 stycznia 2016 r. do 31.12.2019 r. z okresem identyfikacji o długości 365 dni, na bazie których w każdym z czterech lat, to jest dla roku: 2016, 2017, 2018, 2019 roku, otrzymano po 24 modele parametryczne dyskretnie oraz ciągłe, a w ślad za tym 24 modele ciągłe w przestrzeni stanów, czyli łącznie 288 modeli, które wykorzystano w Etapie 3 i Etapie 5, a dla roku 2019 w zakresie poprawek parametrycznych za pomocą SSN w Etapie 4 oraz w badaniu jakości, efektywności, skuteczności i krzepkości w Etapie 7,
 - od 1 stycznia 2020 r. do 31.12.2020 r. z okresem identyfikacji o długości 365 dni, na bazie których zbudowano model symulacyjny do badania wrażliwości 24 modeli parametrycznych dyskretnych oraz ciągłych, a w ślad za tym 24 modeli ciągłych w przestrzeni stanów, czyli łącznie do badania wrażliwości zbudowano 72 modele, które wykorzystano w Etapie 7.

Procesowe ujęcie identyfikacji (Etap 3) i metaidentyfikacji (Etap 6) systemu RDN zilustrowano na rysunku 3.2.




Rysunek 3.2. Schemat procesu identyfikacji i metaidentyfikacji systemu RDN TGE S.A.
Źródło: opracowanie własne na podstawie [126, 218].

W wyniku identyfikacji uzyskuje się katalog modeli parametrycznych arx, których parametry wykorzystuje się do metaidentyfikacji, w wyniku której uzyskuje się metamodel systemu RDN. Identyfikacja systemu RDN i ocena jakości uzyskanych modeli wiąże się z potrzebą ujęcia systemowego RDN oraz zdefiniowania pojęcia efektywności, skuteczności i krzepkości modelu w kategoriach systemowych.

3.2. Ujęcie systemowe Rynku Dnia Następnego

Koncepcję systemu RDN jako systemu zarządzania sformułowano w oparciu o inżynierię systemów i w sposób poglądowy przedstawiono na rysunku 3.3, w którym wyróżniono dwa przepływy: jeden przepływ dotyczący informacji o energii elektrycznej (przepływ dolny) oraz drugi dotyczący środków finansowych (przepływ górny). Oba rodzaje przepływów są przeciwnie do siebie skierowane (po stronie zabezpieczenia przepływ dotyczący zapłaty za dostarczoną energię elektryczną, a po stronie operacyjnej przepływ dotyczący uzyskanego dochodu za sprzedaną energię elektryczną). Przedmiotem niniejszej rozprawy jest jeden z podsystemów tego złożonego systemu zamieszczony na rysunku 3.4. Jest to podsystem, którego wejściem jest wolumen dostarczonej energii elektrycznej, a wyjściem jest średnioważona wolumenem cena sprzedanej energii elektrycznej w poszczególnych godzinach doby TGE S.A.



Rysunek 3.3. Sytuacja systemowa wyróżnienia obszaru badań systemu RDN TGE S.A.

Źródło: opracowanie własne na podstawie prac [21–22, 96, 194, 224–225].

Zatem system Rynku Dnia Następnego w ujęciu systemowym można zobrazować jako system dynamiczny, który ma postać przedstawioną za pracami [21–22, 96, 194, 224–225] na rysunku 3.4, gdzie:

$S_i(\text{RDN})$	– i-ty podsystem Rynku Energii jako System Towarowej Giełdy Energii S.A.,
S_{i+1}	– (i+1)-ty podsystem zintegrowanego odbioru energii elektrycznej z TGE jako system operacyjny dla systemu TGE S.A.,
S_{i-1}	– (i-1)-ty podsystem zintegrowanego dostawcy energii elektrycznej (elektrowni) na TGE S.A. jako system zabezpieczenia dla systemu TGE S.A.,
$SZ_i(\text{RDN})$	– system zarządzania w systemie TGE jako w i-tym podsystemie REE,
$SW_i(\text{RDN})$	– system wykonawczy w systemie TGE jako w i-tym podsystemie REE,
$PK_i(\text{SZ, FD-FI})$	– podsystem kierowania w Systemie Zarządzania w i-tym systemie RDN TGE S.A.,
$PW_i(\text{SZ, IF-DF})$	– podsystem wykonawczy w Systemie Zarządzania w i-tym systemie RDN TGE S.A.,
$PI(\text{PZ, IF-FI})$	– podsystem informacyjny w Systemie Zarządzania w i-tym systemie RDN TGE S.A.,
$PD(\text{PZ, FD-DF})$	– podsystem decyzyjny w Systemie Zarządzania w i-tym systemie RDN TGE S.A.,
$FD(\text{TGE, } t)$	– strumień dochodu użyteczności w i-tym systemie RDN TGE w chwili t ,
$FI(\text{RDN}, \theta, t)$	– strumień nakładu użyteczności w i-tym systemie RDN w czasie długim θ i w chwili t ,
$IF(\text{RDN}, \theta, t)$	– strumień informacyjny w i-tym podsystemie RDN jako systemie TGE w czasie θ i w chwili t , będący informacją o dostarczonym i sprzedanym odbiorcom wolumenie energii elektrycznej $i(\text{RDN}, ee)$,
$DF(\text{RDN}, \theta, t)$	– strumień decyzyjny w i-tym podsystemie RDN jako systemie TGE w czasie θ i w chwili t będący decyzją o średnioważonej wolumenem cenie za 1MW dostarczonej i sprzedanej odbiorcom energii elektrycznej $C(\text{RDN}, \theta, t)$,
$ZI(\text{RDN}, \theta, t)$	– strumień dostarczonej do sprzedaży energii elektrycznej w i-tym podsystemie RDN jako systemie TGE w czasie θ i w chwili t ,
$ZD(\text{RDN}, \theta, t)$	– strumień sprzedanej odbiorcom energii elektrycznej w i-tym podsystemie RDN jako systemie TGE w czasie θ i w chwili t .

System Rynku Dnia Następnego jest zabezpieczany (otrzymuje informacje o dostarczonej i sprzedanej ee) od strony systemu elektrowni i innych źródeł, w tym źródeł odnawialnych, w postaci wolumenu energii elektrycznej [MWh]. W wyniku funkcjonowania giełdy na RDN następuje sprzedaż odbiorcom energii elektrycznej według średniej ważonej ceny dostarczonym wolumenem. Na rysunku 3.4 pokazano trzy rodzaje modeli, to jest model: prakseologiczny (MP), cybernetyczny (MC) oraz systemowy (MS) [21–22, 49, 57, 93–94, 96, 126, 194, 225, 227].

Model prakseologiczny złożony jest z trzech rodzajów systemów, to jest systemu podstawowego, którym jest system RDN, systemu zagregowanego, na który składają się systemy, w tym przypadku dostarczające energię elektryczną, oraz systemu zagregowanego, na który składają się systemy odbiorców energii elektrycznej.

Model cybernetyczny powstaje w wyniku podsystemowania poprzecznego modelu prakseologicznego, to jest między innymi systemu RDN, na dwa podsystemy: system zarządzania (SZ) oraz system wykonawczy (realizacyjny) (SW).


Natomiast **model systemowy** powstaje w wyniku podziału modelu cybernetycznego na podsystemy ze względu na generowane wyjścia, stąd w wyniku takiego podziału otrzymuje się model złożony z czterech podstawowych podsystemów, to jest:

PZ(FD-FI) – podsystem w systemie zarządzania odpowiedzialny za podejmowanie decyzji kierowniczych, w tym między innymi ogólnofinansowych,

PZ(IF-FI) – podsystem w systemie zarządzania odpowiedzialny za generowanie informacji, w tym między innymi finansowania zakupu dostarczonej i sprzedanej energii elektrycznej,

PZ(FD-DF) – podsystem w systemie zarządzania odpowiedzialny za podejmowanie decyzji dotyczących zakupu wolumenu energii elektrycznej,

PZ(IF-DF) – podsystem w systemie zarządzania odpowiedzialny za informowanie kierownictwa o sposobie wykonania decyzji dotyczących zakupu energii elektrycznej.



Rysunek 3.4. Wybrane rodzaje modeli systemu Rynku Dnia Następnego na Towarowej Giełdzie Energii S.A. w ujęciu inżynierii systemów

Oznaczenia: MP(RDN) – model prakseologiczny RDN TGE, MC – model cybernetyczny RDN TGE, MS(SZ) – model systemowy Systemu Zarządzania Rynkiem Dnia Następnego TGE, OTO(FI-FD) – otoczenie systemowe Systemu Zarządzania RDN na TGE.

Uwaga: pozostałe oznaczenia w tekście podrozdziału 3.2.

Źródło: opracowanie własne na podstawie prac [21–22, 96, 126, 194, 225].

Model systemowy RDN posiada sygnał wejściowy będący strumieniem informacyjnym o dostarczonej i sprzedanej odbiorcom wolumenie energii elektrycznej, a sygnał wyjściowy jest strumieniem decyzyjnym będącym średnioważoną wolumenem ceną dostarczonej i sprzedanej odbiorcom energii elektrycznej.

3.3. Efektywność systemu Rynku Dnia Następnego

Efektywność systemu RDN definiuje się jako stosunek uzyskanej wartości dostarczonej i sprzedanej energii elektrycznej mierzonej sumą iloczynów średniej ceny energii elektrycznej i wolumenu sprzedanej ee w każdej godzinie doby w stosunku do wolumenu dostarczonej ee w danej godzinie doby w danym dniu:

$$\text{Efektywność systemu} = \frac{\text{Efekt } [(\text{średnia cena ee}) \cdot (\text{wolumen dostarczonej i sprzedanej ee})]}{\text{Nakład (wolumen dostarczonej do sprzedania ee)}}. \quad (3.1)$$

gdzie:

Efekt – wartość sprzedanej ee mierzona sumą iloczynów średniej ceny i wolumenu sprzedanej ee w każdej godzinie doby (wyjście z systemu RDN),

Nakład – wolumen dostarczonej odbiorcom ee w każdej godzinie doby (wejście do systemu RDN).

Notowania na RDN dotyczą dwóch wielkości, to jest wolumenu dostarczonej i sprzedanej na giełdzie energii elektrycznej w konkretnej godzinie doby oraz średniej ceny ważonej wolumenem dostarczonej i sprzedanej energii elektrycznej. Ze względu na tę specyfikę przyjęto odpowiedni dla ww. sytuacji rodzaj efektywności, który nazwano efektywnością realizacyjną (nie ekonomiczną, ale technologiczną) mierzoną w rozważanym przypadku stosunkiem średniej ważonej wolumenem ceny do wolumenu dostarczonej i sprzedanej energii elektrycznej. Wymiarem takiej relacji jest $[\text{PLN/MWh}] \cdot [1/\text{MWh}]$, a więc cena jednostkowa $[\text{PLN/MWh}]$ odniesiona do wolumenu $[1/\text{MWh}]$.

Zatem w dalszych badaniach wykorzystywane będzie pojęcie efektywności realizacyjnej (dalej w skrócie: efektywność), zdefiniowanej następująco:

$$\text{Efektywność realizacyjna} = \frac{\text{Efekt (średnioważona wolumenem cena dostarczonej i sprzedanej ee)}}{\text{Nakład (wolumen dostarczonej i sprzedanej ee)}}, \quad (3.2)$$

gdzie:

Efekt – średnioważona wolumenem cena dostarczonej i sprzedanej energii elektrycznej (wyjście z systemu RDN),

Nakład – wolumen dostarczonej i sprzedanej odbiorcom energii elektrycznej w każdej godzinie doby (wejście do systemu RDN).

Uzyskanie modelu systemu RDN wiąże się z potrzebą oceny dopasowania modelu do systemu. Jak wynika z przeglądu literatury przedmiotu zamieszczonego w podrozdziale 2.5, do oceny dopasowania modelu do systemu, najczęściej stosowane są takie kryteria jak: kryterium skuteczności i kryterium efektywności. W niniejszej rozprawie podjęto próbę łącznego ujęcia obu kryteriów w ocenie dopasowania modelu do systemu.

W pierwszej kolejności zauważono, że uwzględnienie czynnika ekonomicznego łącznie z czynnikiem technicznym daje dalej możliwość utworzenia charakterystyk techniczno-ekonomicznych, stąd też obok parametrów technicznych można wyróżnić wskaźniki ekonomiczne oraz wielkości zagregowane techniczno-ekonomiczne [200].

Charakterystyki techniczno-ekonomiczne nazywane są charakterystykami uogólnionymi, gdyż dają możliwość porównania wysiłku albo kosztów systemu w stosunku do efektu technicznego uzyskanego np. w systemie RDN. Są one związane z ekonomiczną wartością układu fizycznego, jakim jest system RDN oraz z przepływem środków finansowych jako strumienia użyteczności (dochodów lub nakładów) $F(K, \theta, t)$,

gdzie:

K – parametry systemu RDN,

θ – czas długi (zmienna niezależna rozwoju systemu RDN),

t – czas krótki (zmienna niezależna dynamiki systemu).

Ekonomiczna wartość układu fizycznego, jakim jest system RDN, może być wyrażona za pomocą funkcji ciągłej lub dyskretniej nakładów, tj. $FI(K, \theta, t)$ lub odpowiednio dochodów systemu RDN, tj. $FD(t)$ – rysunek 3.3. Wielkością wiążącą obie charakterystyki jest efektywność jako sprzężenie czynników technicznych z czynnikami ekonomicznymi.

W rozważanym systemie RDN (rys. 3.4) występuje wskaźnik **efektywności realizacyjnej**, nazywany też wskaźnikiem efektywności technologicznej (np. energetycznej), który można zapisać za R. Staniszewskim [200] oraz J. Tchórzewskim [218] jako iloraz funkcji: $DF_s(K, \theta, t)$ i $IF_s(K, \theta, t)$ w następującej postaci:

$$\Lambda_s(K, \theta, t) = \frac{DF_s(K, \theta, t)}{IF_s(K, \theta, t)}, \quad (3.3)$$

gdzie:

$DF_s(K, \theta, t)$ – zmienna wyjściowa, tj. strumień potencjału decyzyjnego jako funkcja użyteczności decyzyjnej typu nakładu decyzyjnego, wyrażona średnią ważoną wolumenem ceną za dostarczoną i sprzedaną na RDN w danym dniu (θ) w danej godzinie doby (w czasie t), charakteryzująca funkcję wysiłku wkładanego w system zarządzania RDN, reprezentująca stronę ekonomiczną procesu funkcjonowania i rozwoju RDN [PLN/MWh],

$IF_s(K, \theta, t)$ – zmienna wejściowa jako strumień potencjału informacyjnego zabezpieczenia systemu RDN typu dochodu informacyjnego, charakteryzująca pod względem informacyjnym proces zarządzania z punktu widzenia technicznego oraz wyznaczająca w sposób informacyjny wartość techniczną (energetyczną) funkcjonowania i rozwoju systemu RDN, to jest dostarczoną i sprzedaną w danym dniu (θ) i w danej konkretnej godzinie doby (w czasie t) energię elektryczną [MWh].

Pojęcie efektywności realizacyjnej, ujmowanej także jako efektywność technologiczna (np. energetyczna) funkcjonowania systemu RDN, pomimo wielu definicji samego pojęcia efektywności, w literaturze przedmiotu [193, 218, 228] nie doczekało się w teorii systemów, w tym w zakresie problematyki zarządzania, jednoznacznej definicji.

A zatem, w rozważanym w niniejszej rozprawie zakresie występuje problematyka efektywności technologicznej (energetycznej) systemu RDN i w ślad za tym modelem systemu RDN, to jest stosunek zmierzonego efektu (uzyskanej wartości średnioważonej wolumenem ceny energii elektrycznej uzyskanej z tytułu dostarczonej i sprzedanej w danej godzinie doby ee w stosunku do zmierzonego nakładu, to jest dostarczonej i sprzedanej ee odbiorcom jako poniesionego nakładu przez system RDN – wyjście z systemu RDN i odpowiednio wyjście z modelu systemu RDN).

3.4. Skuteczność modelu systemu Rynku Dnia Następnego

W ślad za zdefiniowaniem pojęcia efektywności realizacyjnej w podrozdziale 3.3, podjęto też próbę, za pracą Halickiej [66], zdefiniowania pojęcia **skuteczności realizacyjnej systemu RDN**. Na potrzeby niniejszej rozprawy przyjęto, że można ją wyrazić jako stosunek uzyskiwanego efektu, którym jest średnioważona cena wolumenem dostarczonej i sprzedanej ee uzyskanej z modelu systemu RDN w danej godzinie doby w danym dniu, do odpowiedniej średnioważonej ceny energii elektrycznej uzyskiwanej z systemu RDN.

Zaproponowane podejście do oceny skuteczności realizacyjnej systemu RDN można opisać następująco:

$$\Gamma_{ms}(K, t) = \frac{DF_m(K, \theta, t)}{DF_s(K, \theta, t)}, \quad (3.4)$$

gdzie:

$DF_m(K, \theta, t)$ – wyjście z modelu systemu RDN jako średnioważona wolumenem cena za dostarczoną i sprzedaną ee uzyskaną w danej godzinie doby w danym dniu,

$DF_s(K, \theta, t)$ – wyjście z systemu RDN (założony cel) jako średnioważona wolumenem cena za dostarczoną i sprzedaną ee uzyskaną w danej godzinie doby w danym dniu (notowana w toku rzeczywistych transakcji dokonywanych i notowanych w systemie RDN),

K – parametry modelu/systemu,

θ – czas długi jako zmienna niezależna procesu zmian parametrycznych lub/i strukturalnych systemu i modelu [tydzień, miesiąc, kwartał, półrocze, rok itp.].

t – czas krótki jako zmienna niezależna dynamiki zmian parametrycznych lub/i strukturalnych systemu i modelu [godzina, dzień].


W literaturze przedmiotu z jednej strony brak jest ogólnie zaakceptowanych kryteriów mierzenia jakości modelu takich jak m.in. kryterium skuteczności modelu. Niemniej z drugiej strony wyróżnia się następujące modele [98, 207, 216, 218]:

- model systemowo-zasobowy, w którym należy skoncentrować się na zakresie, w jakim system zarządzania jest w stanie zapewnić potrzebne zasoby i nimi wpływać na system zarządzania RDN. Zasobami w rozważanym eksperymencie jest dostarczony i sprzedany wolumen energii elektrycznej w poszczególnych godzinach doby,
- model w zakresie wewnętrznego zorganizowania systemu zarządzania, a więc jego funkcjonowania od strony procesów wewnętrznych, w którym bierze się pod uwagę podsystemy: organizacji wewnętrznej, kierowania oraz wykonawczy, z których jest złożony system RDN TGE S.A. jako system zarządzania,
- model systemowo-celowy, w którym dochodzi do skoncentrowania się na stopniu, w jakim system RDN TGE S.A. osiągnie założone cele, a więc uzyska w danej godzinie doby rezultat w postaci odpowiedniej średnioważonej wolumenem ceny energii elektrycznej dostarczonej i sprzedanej na RDN w każdej godzinie doby.

Każdy z wyżej wymienionych modeli koncentruje się na różnych aspektach funkcjonowania systemu RDN, przy czym odpowiednim podejściem dla modeli systemu identyfikowanych w ramach niniejszej pracy jest rozwiązanie dotyczące podejścia celowego, które koncentruje się w zasadzie na rezultatach, to jest na osiągniętej średnioważonej wolumenem cenie energii elektrycznej.

W takim ujęciu skuteczność modelowania sprowadzona zostaje do stopnia zbliżenia się wyjścia z modelu do wyjścia z systemu RDN, a więc w rozprawie do średnioważonej ceny wolumenem ee notowanej w danej godzinie doby i w danym dniu. Skuteczne jest zatem to, co w określonej dokładności prowadzi do skutku zamierzonego jako cel, czyli miarą skuteczności jest stopień (poziom) zbliżenia się do celu, co ostatecznie oznacza, że w tym kryterium nie jest brany pod uwagę koszt funkcjonowania systemu RDN, lecz przewidywalne skutki uzyskiwane z modelu systemu.

Przyjmuje się przy tym, że w każdym modelu systemu RDN występuje ścisły związek pomiędzy efektywnością i skutecznością np. jak zostało to pokazane za pracami [98, 134, 207] na rysunku 3.5.



Rysunek 3.5. Efektywność jako relacja pomiędzy skutecznością oraz zasobami systemu
Źródło: [134].

Stąd też słuszna jest konstatacja, że najpierw należy badać skuteczność realizacyjną uzyskanego modelu w odniesieniu do systemu w funkcji zasobów, którymi w rozważanym przypadku jest informacja na temat dostarczonej i sprzedanej w każdej godzinie doby energii elektrycznej, a później efektywność realizacyjną systemu RDN, która po podstawieniu

wyznaczonej zmiennej DF_s ze wzoru (3.3) do wzoru (3.4) może zostać sprowadzona do następującej postaci:

$$\Lambda_s(K, \theta, t) = \frac{1}{\Gamma_{ms}(K, \theta, t)} \cdot \frac{DF_m(K, \theta, t)}{IF_s(K, \theta, t)}. \quad (3.5)$$

A zatem, w przypadku wzrostu wolumenu dostarczonej i sprzedanej energii elektrycznej w danej godzinie doby na RDN, co wynika z wartości $IF_s(K, \theta, t)$ zapisanej w mianowniku, utrzymanie średnioważonej ceny za dostarczoną i sprzedaną ee na RDN ($DF_m(K, \theta, t) = \text{const}$) wiąże się ze spadkiem efektywności realizacyjnej przy utrzymaniu skuteczności na stałym poziomie. Należy przy tym zwrócić uwagę na to, iż skuteczność jest uzależniona od posiadanych modeli systemów zarządzania, a zatem modelowanie tych systemów jest niezmiernie ważne w prowadzeniu transakcji na RDN.

3.5. Krzepkość systemu Rynku Dnia Następnego

Pojęcie krzepkości jest pojęciem znanym w literaturze przedmiotu i stosowanym w różnego typu problemach badawczych dotyczących między innymi: systemów o konstrukcji rozwijającej się [64], algorytmów opartych o metody wielocelowe [44], algorytmów wykorzystywanych do przetwarzania tekstów [183], a także zagadnieniach dotyczących algorytmów genetycznych i ewolucyjnych [216].

Krzepekkość systemu RDN jest przyjmowana jako swoista równowaga pomiędzy efektywnością i skutecznością systemu RDN [207, 216].

Przyjmując zgodnie z zależnością (2.14), że:

$$\Lambda_s \Gamma_{ms} = \frac{DF_m(K, \theta, t)}{IF_s(K, \theta, t)}, \quad (3.6)$$

otrzymuje się:

$$DF_m = \Lambda_s \Gamma_{ms} IF_s(K, \theta, t), \quad (3.7)$$

a definiując:

$$\mathcal{E}_{ms} = \Lambda_s \Gamma_{ms} \quad (3.8)$$

jako krzepkość w sensie ww. swoistej równowagi pomiędzy efektywnością oraz skutecznością, można uzyskać katalog przebiegów wskaźnika krzepkości w funkcji informacji o wolumenie dostarczonej i sprzedanej energii elektrycznej na RDN, to jest strumienia $IF_s(K, \theta, t)$ dla różnych wartości decyzji $DF_m(K, \theta, t)$ wyrażonej jako średnioważona wolumenem cena energii elektrycznej dostarczona i sprzedana w poszczególnych godzinach doby.

A zatem ostatecznie wskaźnik krzepkości (krócej: krzepkość) można wyrazić w sposób następujący:

$$\Xi_{ms} = \Lambda_s \Gamma_{ms} = \frac{DF_s(K, \theta, t)}{IF_s(K, \theta, t)} \cdot \frac{DF_m(K, \theta, t)}{DF_s(K, \theta, t)} = \frac{DF_m(K, \theta, t)}{IF_s(K, \theta, t)}, \quad (3.9)$$

a więc, jako stosunek decyzji o uzyskiwanej w modelu średnioważonej wolumenem cenie energii elektrycznej dostarczonej i sprzedanej na RDN w każdej godzinie doby w odniesieniu do informacji o wolumenie dostarczonej i sprzedanej energii elektrycznej w każdej godzinie doby odnotowanej w rzeczywistym systemie RDN.

W niniejszej rozprawie wykorzystano pojęcie efektywności i skuteczności oraz pojęcie krzepkości jako kryteria oceny dopasowania uzyskiwanych modeli do systemu Rynku Dnia Następnego i tym samym odpowiednich metamodeli.

4. IDENTYFIKACJA SYSTEMU RYNKU DNIA NASTĘPNEGO TGE S.A.

4.1. Założenia dotyczące identyfikacji i metaidentyfikacji systemu RDN

W celu otrzymania modelu systemowego przyjęto następujące założenia dotyczące Rynku Dnia Następnego TGE S.A. [121–125, 207–214], a mianowicie:

Aksjomat 1. Występują dwa typy strumieni danych notowanych na RDN:

- łączny wolumen dostarczonej i sprzedanej energii elektrycznej pochodzącej ze wszystkich transakcji notowanych na Rynku Dnia Następnego odrębnie w każdej godzinie doby, będący w swej naturze strumieniem wejściowym do systemu RDN [MWh],
- średnioważona wolumenem cena ze wszystkich transakcji notowanych na Rynku Dnia Następnego odrębnie podczas notowań w każdej godzinie doby (będąca celem funkcjonowania systemu RDN) [PLN/MWh].

Aksjomat 2. W systemie RDN występują dwa typy strumieni: strumienie informacyjne dotyczące wolumenu ee (po stronie zabezpieczenia działania jako informacje dotyczące strumienia dostarczonej ee oraz po stronie operacyjnej jako decyzje dotyczące sprzedanej ee) oraz przeciwnie do nich skierowane strumienie finansowe (po stronie zabezpieczenia jako strumienie zapłaty za dostarczoną ee oraz stronie operacyjnej jako dochody z tytułu sprzedaży ee, które w niniejszej rozprawie są uwzględniane w modelu jako strumienie występujące w podsystemie organizacji wewnętrznej systemu RDN).

Aksjomat 3. Ze względu na specyfikę funkcjonowania systemu Rynku Dnia Następnego przyjmuje się, że strumień sprzedanej ee jest równy strumieniowi dostarczonej ee i ujmowany jest jako strumień dostarczonej i sprzedanej ee, a uzyskiwana cena dotyczy ee dostarczonej i sprzedanej, stąd wolumeny dostarczonej i sprzedanej ee w poszczególnych godzinach doby traktuje się jako wielkości wejściowe (systemu i modelu), a uzyskane średnioważone wolumenem ceny ee w poszczególnych godzinach doby – jako wielkości wyjściowe (systemu i modelu).

Aksjomat 4. Ze względu na dobowy charakter notowań i transakcji giełdowych przyjmuje się 24 zmiennych wejściowych i 24 zmiennych wyjściowych, przy czym w identyfikacji poszukuje się 24 modeli typu MISO (o wielu wejściach i jednym wyjściu) jako modeli podsystemów wyznaczania średnioważonej wolumenem ceny dostarczonej i sprzedanej ee odrębnie w każdej godzinie doby dla wszystkich 24 zmiennych wejściowych.

Aksjomat 5. Dane do eksperymentów przyjmuje się z okresu funkcjonowania RDN TGE S.A., a w szczególności [182, 201, 229]:

- od 1 stycznia 2015 r. do 30 czerwca 2015 r. z okresem identyfikacji o długości 184 dni – **eksperyment 1**,
- od 1 stycznia 2013 r. do 30 kwietnia 2016 r. z okresem identyfikacji o długości 184 dni – **eksperyment 2**,
- od 1 stycznia 2016 r. do 31 grudnia 2019 r. z okresem identyfikacji o długości 365 dni – **eksperyment 3**,

oraz do badania wrażliwości funkcjonowania modelu z eksperymentu 3 z okresu od 1 stycznia 2020 r. do 31 grudnia 2020 r. z okresem identyfikacji o długości 365 dni – **eksperyment 4**.

Aksjomat 6. W celu uzyskania modeli systemu RDN należy przeprowadzić identyfikację parametryczną. Uzyskane modele parametryczne są modelami parametrycznymi dyskretnymi, które w dalszej kolejności należy przekształcić na modele parametryczne ciągłe oraz następnie na modele ciągłe liniowe w przestrzeni stanów.

Aksjomat 7. W celu uzyskania metamodeli systemu RDN należy przeprowadzić metaidentyfikację parametryczną. Uzyskane metamodele parametryczne są metamodelami parametrycznymi dyskretnymi, które w dalszej kolejności należy przekształcić na metamodele parametryczne ciągłe oraz następnie na metamodele ciągłe liniowe w przestrzeni stanów.

Aksjomat 8. W przeprowadzanych eksperymentach należy przyjąć dwie zmienne czasowe: zmienną czasową w sensie krótkim (t) jako czas uwzględniony w identyfikacji dla poszczególnych godzin doby oraz w sensie długim (θ) jako czas uzyskiwania katalogu modeli systemu Rynku Dnia Następnego dla potrzeb metaidentyfikacji.

Aksjomat 9. W celu poprawy dokładności uzyskiwanych modeli w eksperymentach można wykorzystać Sztuczną Sieć Neuronową.

Dobór metody identyfikacji do eksperymentów

W celu przeprowadzenia identyfikacji systemu RDN wykonano badania wstępne polegające na doborze metody identyfikacji. Ze względu na własności systemu RDN, a zwłaszcza na fakt przeprowadzania notowań wolumenu ee jako wielkości wejściowych, oraz notowań średnioważonych wolumenem cen ee jako wielkości wyjściowych, wzięto pod uwagę następujące metody: arx, nlarx, IV4, armax, arxqs, które zostały wykorzystane w analizie z wykorzystaniem SIT MATLABA-a [63].

Z ich wykorzystaniem przeprowadzono identyfikację systemu RDN dla danych z godziny 6 roku 2019. Wyniki zamieszczono w tabeli 4.1.

Tabela 4.1. Stopień dopasowania uzyskanych modeli do danych rzeczywistych za pomocą wybranych metod identyfikacji dla godziny 6 roku 2019

metoda identyfikacji	arx	arxnl	iv4	armax	arxqs
stopień dopasowania	75.66%	54.67%	51.08%	50.75%	66.96%

Źródło: opracowanie własne z wykorzystaniem MATLAB-a i Simulink-a oraz System Identification Toolbox-a [63, 195].

Najlepszą metodą okazała się metoda identyfikacji parametrycznej arx, za pomocą której uzyskano dopasowanie w wysokości 75.66%, a najgorszą metoda armax z dopasowaniem 50.57%. Z tych względów w dalszych badaniach została wykorzystana metoda identyfikacji parametrycznej arx.


4.2. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2015 r. do 30.06.2015 r.

Identyfikację modeli systemu RDN z wykorzystaniem danych z okresu od 1.01.2015 r. do 30.06.2015 r. (eksperyment 1) przeprowadzono w środowisku MATLAB-a i Simulinku z wykorzystaniem SIT, uzyskując po 24 modele MISO, odpowiednio: 24 modele parametryczne dyskretnie, 24 modele parametryczne ciągłe oraz 24 modele ciągłe w przestrzeni stanów (ang. state space, ss). Następnie zbadano zmiany zarówno stopni, jak też zmiany wartości poszczególnych elementów macierzy modelu ss, a przede wszystkim zmiany struktury i parametrów macierzy organizacji wewnętrznej procesu (macierz **A**) i macierzy kierowania (sterowania) systemem zarządzania (macierzy **B**) odrębnie w ciągu poszczególnych godzin doby. Otrzymano wiele interesujących wyników badań, które przedyskutowano i zinterpretowano na gruncie teorii sterowania i inżynierii systemów,

a w szczególności na gruncie inżynierii systemów zarządzania, w tym zinterpretowano otrzymane cztery zmienne stanu modelu systemu zarządzania w przestrzeni stanów oraz przebiegi wszystkich posiadających wartości inne niż zero elementów macierzy **A** oraz siedmiu wybranych elementów macierzy **B**.

W eksperymencie 1, w celu przeprowadzenia identyfikacji systemu RDN TGE S.A., pobrano ze strony Towarowej Giełdy Energii S.A. dane liczbowe dotyczące systemu RDN, wyróżniając 24 wielkości wejściowych dotyczących wolumenu dostarczonej i sprzedanej energii elektrycznej w poszczególnych godzinach doby [MWh] oraz pojedyncze odrębne wielkości wyjściowe dotyczące uzyskanej średnioważonej wolumenem ceny za sprzedaną energię elektryczną w kolejnych godzinach doby [PLN/MWh]. W ten sposób otrzymano 24 modele typu MISO: modele parametryczne dyskretne liniowe typu arx dla 24 wejść (24 godziny) dotyczących wolumenu dostarczonej ee oraz jednego wyjścia jako średniej ceny uzyskanej z tytułu sprzedanej ee w kolejnych godzinach doby. Przykładem modelu parametrycznego dyskretnego dla wyjścia dotyczącego godz. 0–1 (okres θ_1) był model arx01441 (rys. 4.1) postaci:

$$A_1(z) \cdot y_1(t) = \sum_{i=1}^{24} B_i(z) \cdot u_i(t) + e(t), \quad (4.1)$$



Rysunek 4.1. Przebieg wartości wielkości wyjściowej y_{012015} (jako strumienia decyzyjnego DF, średnioważonej wolumenem ceny jednostkowej ee z modelu i z systemu RDN dla 184 dni pomiarowych (próbek do identyfikacji zawierających wartości 24 wielkości wejściowych dotyczących wolumenu ee dostarczonej i sprzedanej na RDN TGE S.A. oraz dla wielkości wyjściowej dotyczącej średnioważonej wolumenem ceny uzyskanej za sprzedaną ee w godzinie 0–1 w okresie θ_1 trwającym od 1.01 do 30.06.2015 r.

Oznaczenia: Time – kolejne dni z okresu θ_1 .

Źródło: opracowanie własne w środowisku MATLAB i Simulink z wykorzystaniem SIT i CST [63, 123, 195].

gdzie:

$$\begin{aligned} A_1(z) &= 1 - 0,6277 \cdot z^{-1} + 0,1453 \cdot z^{-2} - 0,1574 \cdot z^{-3} - 0,3123 \cdot z^{-4}, \\ B_1(z) &= -0,00318 \cdot z^{-1} + 0,01073 \cdot z^{-2} + 0,00245 \cdot z^{-3} + 0,001075 \cdot z^{-4}, \\ B_2(z) &= 0,003684 \cdot z^{-1} + 0,006743 \cdot z^{-2} + 0,003042 \cdot z^{-3} + 0,01046 \cdot z^{-4}, \\ &\dots\dots\dots, \\ B_{24}(z) &= -0,01481 \cdot z^{-1} - 0,006765 \cdot z^{-2} - 0,00133 \cdot z^{-3} - 0,002478 \cdot z^{-4}, \end{aligned}$$

t – dni, $t = 1-184$,

z – operator przesunięcia czasowego (przesuwa czas jako argument funkcji),
np $u(t) z^{-1} = u(t-1)$,

i – godziny doby (0-1, 1-2, ..., 23-24), $i = 1-24$,

$u_i(t)$ – i -te wejście modelu dotyczące wolumenu energii elektrycznej (ee) dostarczonej i sprzedanej w i -tej godzinie doby [MWh],

$y_1(t)$ – wyjście modelu dotyczące średnioważonej wolumenem ceny uzyskanej z tytułu sprzedanej ee w godzinie 0–1 doby,

$e(t)$ – błąd średniokwadratowy modelu (MSE = 31,65%), przy czym dopasowanie modelu do systemu (ang. fit to estimation data) wyniosło 56.36% i w tym eksperymencie nie było wysokie.

Następnie dokonano konwersji modelu parametrycznego dyskretnego liniowego arx – zależność (4.1) na model ciągły liniowy th , a ten na model ciągły liniowy w przestrzeni stanów ss , uzyskując ostatecznie macierze **A**, **B**, **C** i **D** w przestrzeni stanów w postaci jak np. dla godz. 0–1:

$$A(\theta_1) = \begin{bmatrix} 0 & 0 & 0 & -0,2370 \\ 0,2500 & 0 & 0 & -2,6625 \\ 0 & 2,0000 & 0 & -2,3704 \\ 0 & 0 & 4,0000 & -7,6504 \end{bmatrix} \quad (4.2)$$

$$B(\theta_1) = \begin{bmatrix} 0,0132 & 0,0292 & 0,0051 & -0,0268 & 0,0187 & -0,0042 & 0,0003 & -0,0037 & 0,0241 & -0,0246 & 0,0264 & -0,0020 \\ -0,0076 & -0,0106 & 0,0059 & 0,0331 & -0,0058 & -0,0049 & 0,0021 & -0,0011 & -0,0016 & 0,0030 & -0,0123 & 0,0078 \\ -0,0069 & 0,0038 & -0,0175 & 0,0309 & 0,0011 & 0,0040 & -0,0051 & -0,0007 & -0,0037 & -0,0077 & 0,0022 & 0,0097 \\ -0,0127 & -0,0257 & -0,0512 & 0,1402 & -0,0460 & 0,0112 & -0,0086 & -0,0182 & 0,0249 & -0,0277 & -0,0137 & 0,0266 \\ \\ -0,0113 & -0,0168 & 0,0140 & 0,0174 & -0,0350 & 0,0104 & -0,0065 & 0,0002 & 0,0195 & -0,0263 & 0,0208 & -0,0316 \\ 0,0205 & -0,0254 & 0,0155 & -0,0163 & 0,0161 & -0,0059 & 0,0042 & -0,0027 & -0,0014 & -0,0067 & 0,0030 & -0,0055 \\ -0,0031 & -0,0213 & 0,0346 & 0,0027 & -0,0043 & -0,0125 & 0,0101 & -0,0049 & 0,0073 & -0,0103 & 0,0023 & -0,0027 \\ 0,0382 & -0,0734 & 0,0630 & -0,0265 & 0,0165 & -0,0135 & 0,0189 & 0,0082 & -0,0016 & -0,0201 & 0,0011 & 0,0032 \end{bmatrix}, \quad (4.3)$$

$$\mathbf{C}(\theta) = [0 \ 0 \ 0 \ 4], \quad (4.4)$$

$$\mathbf{D}(\theta) \approx 0, \quad (4.5)$$

gdzie:

θ – czas długi (w rozważanym przykładzie obejmujący jeden etap rozwoju wynoszący umownych 184 dni),

A – macierz wewnętrznej organizacji procesu dostarczonej i sprzedanej ee na RDN,

B – macierz sterowania procesem zarządzania jako RDN w związku z dostarczaniem i sprzedażą ee na RDN,

C – macierz oddziaływania wewnętrznej organizacji systemu zarządzania jako systemu RDN na średnioważonej wolumenem cenę ee w każdej odrębnie godzinie doby,

D – macierz sprzężeń systemu RDN z otoczeniem, przy czym okazało się, że $\mathbf{D} \approx 0$.

A zatem ostatecznie otrzymuje się równania w przestrzeni stanów postaci:

$$\begin{bmatrix} \dot{x}_1(K, \theta) \\ \dot{x}_2(K, \theta) \\ \dot{x}_3(K, \theta) \\ \dot{x}_4(K, \theta) \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 & -0,2370 \\ 0,2500 & 0 & 0 & -2,6625 \\ 0 & 2,0000 & 0 & -2,3704 \\ 0 & 0 & 4,0000 & -7,6504 \end{bmatrix} \cdot \begin{bmatrix} x_1(K, \theta) \\ x_2(K, \theta) \\ x_3(K, \theta) \\ x_4(K, \theta) \end{bmatrix} + \mathbf{B} \cdot \begin{bmatrix} u_1(K, \theta) \\ u_2(K, \theta) \\ \dots \\ u_{23}(K, \theta) \\ u_{24}(K, \theta) \end{bmatrix}, \quad (4.6)$$

$$\mathbf{y}_1(K, \theta) = [0 \ 0 \ 0 \ 4,0000] \cdot \begin{bmatrix} x_1(K, \theta) \\ x_2(K, \theta) \\ x_3(K, \theta) \\ x_4(K, \theta) \end{bmatrix},$$

gdzie:

$x_i(K, \theta)$ – i-ta składowa wektora zmiennych stanu dla czasu θ ,

K – zbiór parametrów systemu RDN.

Na gruncie teorii sterowania i inżynierii systemów macierz **A** odpowiadająca za stopień wewnętrznego zorganizowania systemu RDN wiąże wektor stanu z pochodną wektora stanu.

Można zauważyć m.in., że pochodna zmiennej stanu dx_1/dt zależy jedynie od zmiennej stanu x_4 , a pozostałe zależą od poprzedniej zmiennej stanu oraz od zmiennej stanu x_4 ,

natomiast macierz **B** odpowiadająca za poziom sterowania rozwojem RDN jako systemu zarządzania pokazuje wpływ wszystkich wielkości wejściowych, to jest 24 wielkości typu informacja o wolumenie dostarczonej ee na wszystkie zmienne stanu, przy czym wpływ ten jest od jednych wielkości wejściowych ujemny (hamujący), a od innych dodatni (pobudzający).

Na bazie danych liczbowych dotyczących systemu RDN z okresu od 1 stycznia do 30 czerwca 2015 r. wygenerowano katalog odrębnych 24 modeli utworzonych dla 24 wielkości wejściowych dotyczących wolumenu dostarczonej i sprzedanej ee w poszczególnych godzinach doby [MWh] oraz dla kolejnych pojedynczych wielkości wyjściowych dotyczących uzyskanej średnioważonej wolumenem ceny za sprzedaną ee w kolejnych godzinach doby [PLN/MWh]. W ten sposób otrzymano po 24 modele typu MISO: parametrycznych dyskretnych arx, parametrycznych ciągłych th oraz ciągłych w przestrzeni stanów ss [63, 123, 195].

W niniejszej rozprawie zamieszczono wybrane wyniki analizy 24 modeli ciągłych w przestrzeni stanów systemu RDN, a więc wyniki zmian wszystkich elementów macierzy **A** posiadających wartości różne od zera, które zestawiono w tabeli 4.2 oraz wybrane wyniki analizy dotyczące elementów macierzy **B**, które zestawiono w tabeli 4.3.

Tabela 4.2. Przebiegi zmian elementów macierzy **A** w ciągu doby dla danych RDN TGE S.A. z pierwszego półrocza 2015 r.








Oznaczenie	Przebieg zmian elementu a_{ij} w ciągu doby	Interpretacja
a_{14} – wyraża stopień wpływu zmiennej stanu x_4 , to jest mocy związanej z ee sprzedaną w kolejnych godzinach doby na pochodną zmiennej stanu x_1 , to jest częstotliwość zmian mocy w kolejnych godzinach doby		Wartość elementu była ujemna i malała w ciągu doby od maksymalnej wartości w godz. 0–1 wynoszącej -0,2370, osiągnęła minimalną wartość w godz. 17–18 wynoszącą -1,1577, po czym rosła i osiągnęła wartość maksymalną w godz. 21–22 wynoszącą -0,2724
a_{21} – wyraża stopień wpływu zmiennej stanu x_1 , to jest sprzedanej ee w kolejnych godzinach doby na pochodną zmiennej stanu x_2 , to jest moc związaną ze sprzedaną ee w kolejnych godzinach doby		Wartość elementu była dodatnia i rosła w ciągu doby od minimalnej wartości w godz. 0–1 wynoszącej 0,2500, osiągnęła ponownie minimalną wartość w godz. 5–6 wynoszącą 0,2500, po czym rosła i osiągnęła wartość maksymalną w godz. 8–10, 11–14, 15–17, 19–21 wynoszącą 1,0000, z przerwami zmniejszenia wartości do 0,5000

Tabela 4.2 cd.

Oznaczenie	Przebieg zmian elementu a_{ij} w ciągu doby	Interpretacja
a_{24} – wyraża stopień wpływu zmiennej stanu x_4 , to jest mocy związanej ze sprzedaną ee na pochodną zmiennej stanu x_2 to jest moc związaną ze sprzedaną ee w kolejnych godzinach doby		Wartość elementu była ujemna i naprzemiennie rosła i malała, przy czym osiągnęła wartość maksymalną w godz. 6–7 wynoszącą -1,3681 oraz najmniejsze wartości w godz. 11–12, 15–16, 19–21 wynoszące odpowiednio: -3,4627, -3,4057, -3,3966 i -3,6112
a_{32} – wyraża stopień wpływu zmiennej stanu x_2 , to jest sprzedanej ee w kolejnych godzinach doby w odniesieniu do całej doby na pochodną zmiennej stanu x_3 to jest moc związaną ze sprzedaną ee		Wartość elementu była dodatnia i w zasadzie stała wynosząca 2,0000 poza godz. 10–11 oraz 14–15, gdy wzrosła do wartości maksymalnej wynoszącej 4,0000
a_{34} – wyraża stopień wpływu sprzedaży ee w godz. 3–4 na uzyskiwanie średniej ceny ee w godz. 2–3		Wartość elementu była ujemna i osiągnęła największe wartości w godz. 0–1, 6–7, 23–24 wynoszące odpowiednio: -2,3704, -2,0932 i -2,2450 oraz najmniejsze w godz. 3–5 i 10–12 wynoszące odpowiednio -4,8550 i 4,6517 oraz -4,5682, można zauważyć pewne zmiany oscylacyjne o zmniejszającej się amplitudzie
a_{43} – wyraża stopień wpływu sprzedaży ee w godz. 2–3 na uzyskiwanie średniej ceny ee w godz. 3–4		Wartość elementu była dodatnia i w zasadzie stała wynosząca 4,0000 poza godz. 15–19 oraz 21–22, gdy wzrosła do wartości maksymalnej wynoszącej 8,0000
a_{44} – wyraża stopień wpływu sprzedaży ee w godz. 3–4 na uzyskiwanie średniej ceny ee w godz. 3–4		Wartość elementu była ujemna i osiągnęła najmniejsze wartości w godz. 16–19 wynoszące odpowiednio: -18,5473, -15,8325, -17,4335 oraz największe wartości w godz. 6–7 i 23–24 wynoszące odpowiednio -4,8301 i 6,5312, można zauważyć pewne zmiany oscylacyjne o zwiększającej się amplitudzie

Źródło: opracowanie własne w środowisku MATLABA i Simulinka [63, 123, 195].

Tabela 4.3. Przebiegi zmian elementów macierzy **B** w ciągu doby dla danych RDN TGE S.A. i półrocza 2015 r.







Istota elementu a_{ij}	Przebieg zmian elementu a_{ij} w ciągu doby	Interpretacja
b_{11} – wyraża stopień wpływu sprzedaży wolumenu e_e w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu w godz. 12–21 była ujemna i osiągnęła najmniejsze wartości w godz. 17–19 wynoszące odpowiednio: -0,0167 i -0,0152, a pozostałych godzinach doby wartość była dodatnia i osiągnęła największą wartość w godz. 22–23 wynoszącą 0,0235, można zauważyć zmiany oscylacyjne narastające
b_{17} – wyraża stopień wpływu sprzedaży wolumenu e_e w godz. 6–7 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu w godz. 5–10 oraz 22–24 była ujemna i osiągnęła najmniejszą wartość w godz. 7–8 wynoszącą -0,206, a pozostałych godzinach doby wartość była dodatnia i osiągnęła największą wartość w godz. 16–17 i 18–19 wynoszącą odpowiednio: 0,0142 i 0,0146, można zauważyć zmiany oscylacyjne narastające
b_{113} – wyraża stopień wpływu sprzedaży e_e w godz. 12–13 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu była dodatnia i osiągnęła największe wartości w godz. 23–24 wynoszącą 0,07000, można zauważyć pewne zmiany oscylacyjne o zwiększającej się amplitudzie
b_{119} – wyraża stopień wpływu sprzedaży e_e w godz. 18–19 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu była dodatnia (poza okresem godz. 17–19, w którym osiągnęła wartość najmniejszą wynoszącą -0,0161) i osiągnęła największe wartości w godz. 8–9 i 23–24 wynoszące odpowiednio 0,03160 i 0,0309, można zauważyć pewne stałe oscylacje
b_{21} – wyraża stopień wpływu sprzedaży e_e w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu była dodatnia (poza okresem w godz. 0–1, 21–22 i 23–24, gdy osiągnęła wartość najmniejszą wynoszącą odpowiednio: -0,0076, -0,0068 i -0,0538) i osiągnęła największą wartość 0,3990 w godz. 9–10, można zauważyć pewne zmiany paraboliczne
b_{31} – wyraża stopień wpływu sprzedaży e_e w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu była ujemna w okresie godz. 0–6, 21–22 i osiągnęła najmniejsze wartości w godz. 4–6 wynoszące -0,0374, a w pozostałym okresie była dodatnia i osiągnęła największą wartość w godz. 12–13 wynoszącą 0,0568, można zauważyć pewne zmiany oscylacyjne o zwiększającej się amplitudzie i wzrastającej wartości

Tabela 4.3 cd.

Istota elementu a_{ij}	Przebieg zmian elementu a_{ij} w ciągu doby	Interpretacja
b_{41} – wyraża stopień wpływu sprzedaży e_e w godz. 3–4 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby		Wartość elementu była dodatnia (poza godz. 0–1, 21–22 i 23–24) i osiągnęła największą wartość w godz. 17–18 wynoszącą 0,2385, można zauważyć pewne zmiany paraboliczne

Źródło: opracowanie własne w środowisku MATLAB i Simulinka [63, 123, 195].

Z analizy struktury macierzy **A** występującej we wszystkich 24 godzinowych modelach systemu RDN wynika m.in., że o stopniu wewnętrznego zorganizowania systemu RDN w okresie I półrocza 2015 r. decydowały głównie cztery zmienne stanu oraz 7 elementów macierzy **A**, to jest a_{14} , a_{21} , a_{24} , a_{32} , a_{34} , a_{43} i a_{44} na 16 elementów występujących macierzy **A** (43,8%). W celu zbadania natury zmiennych stanu ustalono najpierw, że z macierzy **C** wynika, iż tylko zmienna stanu x_4 miała wpływ na wielkość wyjściową y_1 , czyli na średnioważoną wolumenem cenę uzyskaną z tytułu sprzedaży e_e w poszczególnych godzinach doby, co przy zbliżonych do zera wartościach elementów macierzy **D** prowadzi do równania wyjścia postaci:

$$y_1(K, \theta) = C \cdot x(K, \theta), \quad (4.7)$$

a więc postaci:

$$y_1(K, \theta) = [0 \quad 0 \quad 0 \quad 4,0000] \cdot \begin{bmatrix} x_1(K, \theta) \\ x_2(K, \theta) \\ x_3(K, \theta) \\ x_4(K, \theta) \end{bmatrix} \quad (4.8)$$

gdzie:

C – macierz oddziaływania wewnętrznej organizacji systemu RDN na średnioważoną wolumenem cenę e_e ,

$x(K, \theta)$ – wektor zmiennych stanu,

K – zbiór parametrów systemu RDN,

θ – czas długi (w rozważanym przykładzie [dzień]).

Na podstawie równania wyjścia (zależność 4.3) i spostrzeżenia, że trzy pierwsze elementy macierzy $\mathbf{C}$ są równe zero można zauważyć, że średnioważona wolumenem cena ee w kolejnej godzinie doby zależy jedynie od zmiennej stanu x_4 . Zatem zmienną stanu x_4 zinterpretować jako moc [MW] wynikającą z ee dostarczonej i sprzedanej na RDN [MWh] w kolejnej godzinie doby, przy założeniu, że element c_{14} macierzy $\mathbf{C}$ wyrażony jest w jednostce [PLN/(MWh x MW)], co można zinterpretować jako średnia jednostkowa ważona wolumenem cena ee w kolejnej godzinie doby (w rozważanym przykładzie w godzinie 0–1) przypadająca na jednostkę mocy związanej z ee wyprodukowaną i dostarczoną na RDN w ciągu dnia (w ciągu poszczególnych godzin całej doby).

A zatem element c_{14} można zinterpretować jako szybkość zmiany jednostkowej ceny mocy w danej godzinie w odniesieniu do mocy dostarczonej i sprzedanej w ciągu całej doby. Ze względu na to, że zmienna stanu x_4 została zinterpretowana jako moc związana z ee dostarczoną i sprzedaną na RDN w ciągu kolejnych godzin doby, stąd można dalej wyprowadzić z pierwszego równania stanu (4.3) interpretację zmiennej stanu x_1 , zauważając że:

$$\frac{dx_1}{dt} = -0,2 \cdot x_4 + \sum_{j=1}^{j=24} b_{1j} \cdot u_j, \quad (4.9)$$

a więc zmienna stanu x_1 może zostać zinterpretowana jako ee dostarczona i sprzedana na RDN w ciągu kolejnych godzin doby [MWh]. Następnie z drugiego równania stanu można wyprowadzić interpretację zmiennej stanu x_2 , zauważając że:

$$\frac{dx_2}{dt} = 0,3 \cdot x_1 - 2,7 \cdot x_4 + \sum_{j=1}^{j=24} b_{2j} \cdot u_j, \quad (4.10)$$

a więc zmienna stanu x_2 może zostać zinterpretowana jako ee dostarczona i sprzedana na RDN w ciągu kolejnej godziny doby w okresie przez całą dobę [MWh x doba]. Dalej, z trzeciego równania stanu można wyprowadzić interpretację zmiennej stanu x_3 , zauważając że:

$$\frac{dx_3}{dt} = 2 \cdot x_2 - 1,4 \cdot x_4 + \sum_{j=1}^{j=24} b_{3j} \cdot u_j, \quad (4.11)$$

a więc zmienna stanu x_3 może zostać zinterpretowana jako ee dostarczona i sprzedana na RDN w ciągu kolejnej godziny doby przez całą dobę oraz przez cały okres pomiarowy [MWh x doba x półrocze].

Można dalej, na podstawie czwartego równania stanu postaci:

$$\frac{dx_4}{dt} = 4 \cdot x_3 - 7,7 \cdot x_4 + \sum_{j=1}^{j=24} b_{4j} \cdot u_j, \quad (4.12)$$

wyprowadzić interpretację elementów macierzy: a_{43} i a_{44} odpowiednio jako liczba godzin pomiarowych w okresie identyfikacji θ_1 (w ciągu rozważanego I półrocza 2015 r.) i przyspieszenie zmian sprzedawanej ee w ciągu kolejnych godzin doby [MWh/h].

Możliwe jest zatem uzyskanie modelu systemu RDN w postaci schematu zastępczego uzyskanego w wyniku identyfikacji systemu rzeczywistego na bazie danych liczbowych notowanych na Rynku Dnia Następnego pobranych z TGE S.A.

Proces identyfikacji prowadzi do otrzymania 24 modeli parametrycznych dyskretnych liniowych systemu RDN, które można dalej przekształcić na 24 modele parametryczne ciągłe i dalej na 24 modele ciągłe w przestrzeni stanów.

Zbadano zmiany posiadających wartości różne od zera elementów macierzy **A** oraz wybranych siedmiu elementów macierzy **B**, zauważając wiele prawidłowości rozwoju systemu RDN TGE S.A.

Okazało się, że istnieje możliwość zbudowania na bazie otrzymanych modeli metamodelu rozwoju, przy przyjęciu za wejścia modelu elementy macierzy **B**, a za wyjścia elementów macierzy **A**.

4.3. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2013 r. do 30.04. 2016 r.

Identyfikację modeli systemu RDN z wykorzystaniem danych z okresu od 1.01.2013 r. do 30.04.2016 r. (ekseperyment 2) przeprowadzono w środowisku MATLAB-a i Simulinku z wykorzystaniem SIT, uzyskując w rezultacie 35 modeli systemu RDN.

W celu przeprowadzenia identyfikacji systemu RDN [121–125, 207–214]:

- pobrano dane notowane na RDN Towarowej Giełdy Energii S.A. w okresie od 1 stycznia 2013 r. do 30 kwietnia 2016 r.,

- wyróżniono 24 zmiennych wejściowych dotyczących wolumenu dostarczonej i sprzedanej ee ze wszystkich transakcji przeprowadzonych na sesji giełdowej w poszczególnych godzinach doby (zmienne wejściowe) [MWh],
- wyróżniono pojedyncze wielkości wyjściowe związane z średnioważoną wolumenem ceną dostarczonej i sprzedanej ee we wszystkich transakcjach na sesji giełdowej dla danej godziny doby [PLN/MWh].

W ten sposób otrzymano najpierw parametryczne modele dyskretne liniowe arx, np. dla pierwszego okresu pomiarowego arxp1 (1.01.2013–30.06.2013), które następnie przekształcono na ciągłe modele parametryczne tharxp1, a te wykorzystano do przeprowadzenia metaidentyfikacji i uzyskania 35 metamodeli systemów RDN [121–125, 207–214].

Na podstawie danych dotyczących systemu RDN, to jest na podstawie danych notowanych w okresie od 1.01.2013 r. do 30.04.2016 r. (35 okresów po 184 dni), w wyniku identyfikacji uzyskano 24 katalogi modeli zawierających po 35 modeli każdy, to jest otrzymano 35 x 24 modeli zawierających 24 zmienne wejściowe dla każdego z modeli, które dotyczyły wolumenu dostarczanej i sprzedanej ee w poszczególnych godzinach doby [MWh] oraz zawierających pojedyncze zmienne wyjściowe dotyczące średnich jednostkowych cen sprzedanej ee w kolejnych godzinach doby [PLN/MWh].

Łącznie zatem uzyskano 840 modeli obejmujących 35 okresów po 184 dni na podstawie danych notowanych na RDN TGE S.A., przy czym identyfikację przeprowadzono z postępowaniem jednego miesiąca. W ten sposób uzyskano najpierw parametryczne modele dyskretne typu liniowego arx, na przykład dla okresu p1 trwającego od 1 stycznia 2013 r. do 30 czerwca 2013 r. (okres 01) otrzymano model arxp1441 w postaci:

$$A_1(z) \cdot y_1(t) = \sum_{i=1}^{24} B_i(z) \cdot u_i(t) + e(t), \quad (4.13)$$

gdzie:

$$A_1(z) = 1 - 0,4456 \cdot z^{-1} - 0,2834 \cdot z^{-2} + 0,07714 \cdot z^{-3} - 0,09293 \cdot z^{-4},$$

$$B_1(z) = 0,00546 \cdot z^{-1} + 0,0109 \cdot z^{-2} + 0,0006017 \cdot z^{-3} - 0,006013 \cdot z^{-4},$$

$$B_2(z) = -0,0049 \cdot z^{-1} + 0,0049 \cdot z^{-2} + 0,01305 \cdot z^{-3} + 0,01078 \cdot z^{-4},$$

.....,

$$B_{24}(z) = -0,003674 \cdot z^{-1} - 0,006143 \cdot z^{-2} + 0,0001805 \cdot z^{-3} - 0,002492 \cdot z^{-4},$$

- t** – czas krótki [dzień], $t = 1-184$,
- z** – operator przesunięcia czasowego,
- i** – i-ta godzina danego dnia (0-1, 1-2, ..., 23-24), $i = 1-24$,
- $u_i(t)$** – i-te wejście dotyczące ilości energii elektrycznej (ee) dostarczanej i sprzedanej w i-tej godzinie doby [MWh],
- $y_1(t)$** – wyjście dotyczące średnioważonej wolumenem ceny otrzymanej w wyniku sprzedaży określonego wolumenu ee w danej godzinie doby,
- a_i** – i-ta waga i-tego wyjścia z modelu,
- b_j** – j-ty współczynnik wielomianu B_i , który może być zinterpretowany jako efektywność realizacyjna modelu systemu RDN [PLN/MWh²],
- $e(t)$** – błąd modelu (MSE), stopień dopasowania modelu do systemu rzeczywistego (w następnych etapach pracy będzie podlegał korekcji).

W wyniku przekształcenia liniowego modelu parametrycznego arxp1 otrzymano liniowy model ciągły parametryczny tharxp1 w postaci:

$$A_1(s) \cdot y_1(t) = \sum_{i=1}^{24} B_i(s) \cdot u_i(t) + C_i(s) \cdot e(t), \quad (4.14)$$

gdzie:

$$A_1(s) = s^5 + 2,861 \cdot s^4 + 14,67 \cdot s^3 + 22,2 \cdot s^2 + 28,03 \cdot s + 4,432,$$

$$B_1(s) = -0,02115 \cdot s^4 + 0,02865 \cdot s^3 - 0,1368 \cdot s^2 + 0,3446 \cdot s + 0,1899,$$

$$B_2(s) = 0,02829 \cdot s^4 - 0,05832 \cdot s^3 + 0,2267 \cdot s^2 - 0,5493 \cdot s + 0,0,4137,$$

.....,

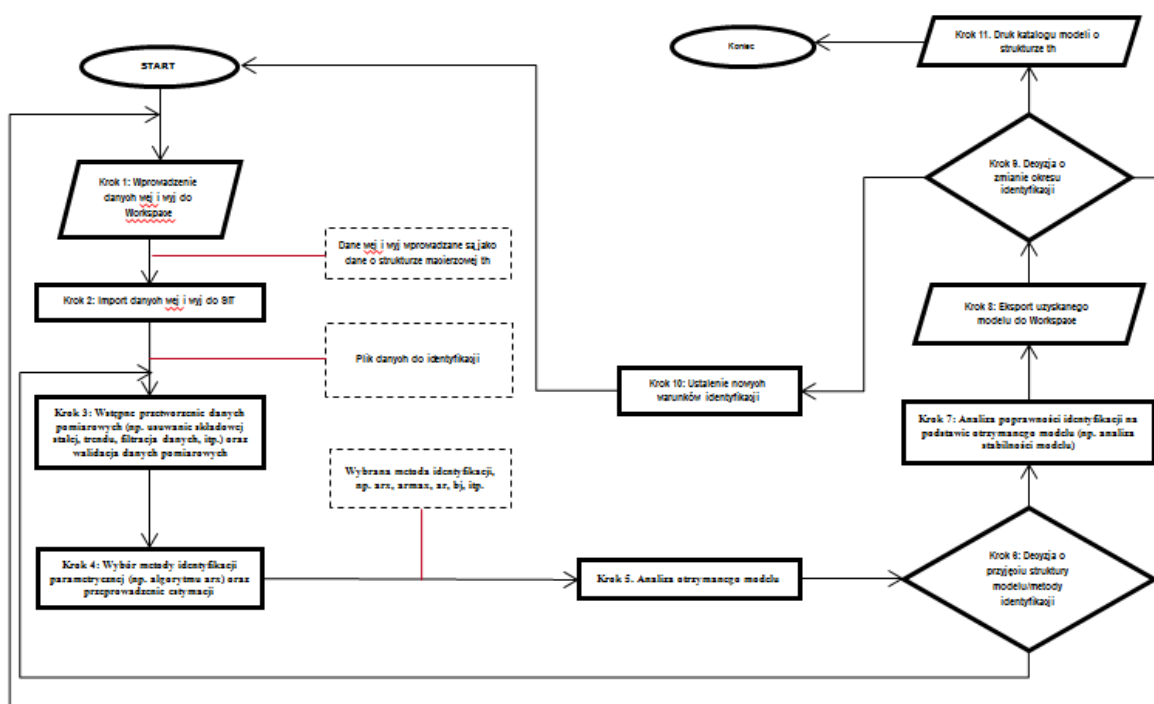
$$B_{24}(s) = -0,0108 \cdot s^4 + 0,006151 \cdot s^3 - 0,1018 \cdot s^2 - 0,04904 \cdot s - 0,2106,$$

$$C(s) = s^5 + 3,532 \cdot s^4 + 15,51 \cdot s^3 + 30,02 \cdot s^2 + 38,12 \cdot s + 17,36,$$

W wyniku identyfikacji parametrycznej z wykorzystaniem metody arx (rys. 4.2) dla wyróżnionych umownych 35 okresów pomiarowych systemu RDN z notowaniami prowadzonymi na Rynku Dnia Następnego otrzymano dla każdej doby po 24 modele x 35 okresów (czas długi θ), które następnie konwertowano na 840 modeli parametrycznych

ciągłych, co dało podstawę do uzyskania wystarczającej informacji w zakresie zmian parametrów i struktury modeli, których wybrane wielkości zestawiono w tabeli 4.4 w przypadku wielomianu $A(z)$ oraz w tabeli 4.5 w przypadku wielomianu $B1(z)$.

Podsumowując, w celu przeprowadzenia identyfikacji systemu RDN na podstawie danych liczbowych notowanych na Rynku Dnia Następnego Towarowej Giełdy Energii S.A. w okresie **od 1 stycznia 2013 r. do 30 kwietnia 2016 r., wyróżniono 24 zmienne wejściowe** w odniesieniu do całkowitej wielkości wolumenu dostarczonej i sprzedanej energii elektrycznej wszystkich transakcji przeprowadzonych na sesji giełdowej w poszczególnych godzinach doby (zmienne wejściowe) [MWh] oraz wyróżniono pojedyncze wielkości wyjściowe związane z otrzymaną średnioważoną wolumenem ceną uzyskaną z tytułu dostarczonej i sprzedanej ee ze wszystkich transakcji na sesji giełdowej dla danej godziny doby [PLN/MWh].



Rysunek 4.2. Schemat blokowy procesu identyfikacji parametrycznej arx systemu RDN
Źródło: opracowanie własne.

Tabela 4.4. Zestawienie wartości współczynników wielomianu $A1(z)$ dla kolejnych modeli systemu RDN
Oznaczenia: p_i – i -ty okres identyfikacji, z^{-i} – i -ty operator przesunięcia czasowego.

Oznaczenie okresu danych do identyfikacji	Opis wartości elementów wielomianu $A1(z)$ stojących przy odpowiednich operatorach z^{-i} dla kolejnych okresów identyfikacji p_i				
p_i	Okres identyfikacji	z^{-1}	z^{-2}	z^{-3}	z^{-4}
p1	01.01.2013-30.06.2013	-0.4456	-0.2834	0.7714	-0.09293
p2	01.02.2013-31.07.2013	-0.4664	-0.1973	-0.03008	-0.7786
p3	01.03.2013-31.08.2013	-0.5432	-0.1906	-0.1013	-0.07133
p4	01.04.2013-30.09.2013	-0.5367	0.1048	-0.2871	-0.1207
p5	01.05.2013-31.10.2013	- 0.5567	0.1634	- 0.3345	- 0.1133
p6	01.06.2013-30.11.2013	- 0.6487	0.1482	0.1482	- 0.06986
p7	01.07.2013-31.12.2013	- 0.7101	- 0.1043	0.09777	- 0.1602
p8	01.08.2013-31.01.2014	- 0.4376	- 0.2277	- 0.0399	- 0.1126
p9	01.09.2013-28.02.2014	- 0.3099	- 0.22	- 0.04345	- 0.1078
p10	01.10.2013-31.03.2014	- 0.4153	- 0.02393	- 0.07533	- 0.02967
p11	01.11.2013-30.04.2014	- 0.6138	- 0.1461	0.03817	- 0.1295
p12	01.12.2013-31.05.2014	- 0.5784	- 0.0145	- 0.1759	- 0.1044
p13	01.01.2014-30.06.2014	- 0.5305	0.02467	- 0.1719	- 0.1163
p14	01.02.2014-31.07.2014	- 0.519	- 0.007676	- 0.1208	- 0.1762
p15	01.03.2014-31.08.2014	- 0.5716	0.07925	- 0.1163	- 0.2326
p16	01.04.2014-30.09.2014	- 0.3374	- 0.03484	- 0.2196	- 0.1188
p17	01.05.2014-31.10.2014	- 0.4628	- 0.07144	- 0.2362	0.08314
p18	01.06.2014-30.11.2014	- 0.5613	- 0.1287	- 0.084	0.01003
p19	01.07.2014-31.12.2014	- 0.6538	0.1007	- 0.28	0.09722
p20	01.08.2014-31.01.2015	- 0.5578	- 0.06039	- 0.3194	0.09849
p21	01.09.2014-28.02.2015	- 0.5611	- 0.1486	- 0.2603	0.1445
p22	01.10.2014-31.03.2015	- 0.5883	- 0.05023	- 0.1215	0.07154
p23	01.11.2014-30.04.2015	- 0.6574	0.06766	- 0.2213	- 0.1287
p24	01.12.2014-31.05.2015	- 0.5849	0.00772	- 0.1543	- 0.05627
p25	01.01.2015-30.06.2015	- 0.6217	0.09127	- 0.1769	- 0.329
p26	01.02.2015-31.07.2015	- 0.3658	- 0.01899	- 0.1669	- 0.3104
p27	01.03.2015-31.08.2015	- 0.4035	- 0.1095	0.02125	- 0.375
p28	01.04.2015-30.09.2015	- 0.1471	- 0.2715	- 0.213	- 0.1558
p29	01.05.2015-31.10.2015	- 0.1071	- 0.4804	- 0.3413	0.07676
p30	01.06.2015-30.11.2015	- 0.265	- 0.3232	- 0.3068	0.02056
p31	01.07.2015-31.12.2015	- 0.4625	- 0.1533	- 0.1594	- 0.008736
p32	01.08.2015-31.01.2016	- 0.595	- 0.1472	- 0.0541	- 0.02268
p33	01.09.2015-29.02.2016	- 0.5533	- 0.2135	- 0.07111	- 0.03003
p34	01.10.2015-31.03.2016	- 0.5988	- 0.125	- 0.0529	- 0.08865
p35	01.11.2015-30.04.2016	- 0.5602	- 0.03969	- 0.2063	- 0.134

Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink [63, 195].

Tabela 4.5. Zestawienie wartości współczynników wielomianów $B1(z)$ dla kolejnych modeli systemu RDN
Oznaczenia: p_i – i -ty okres identyfikacji, z^{-i} – i -ty operator przesunięcia czasowego.

Oznaczenie okresu danych do identyfikacji	Opis wartości elementów wielomianu $B1(z)$ stojących przy odpowiednich operatorach z^{-i} dla kolejnych okresów identyfikacji p_i				
p_i	Okres identyfikacji	z^{-1}	z^{-2}	z^{-3}	z^{-4}
p1	01.01.2013-30.06.2013	0.005455	0.01089	0.0006017	-0.006013
p2	01.02.2013-31.07.2013	0.005572	0.001121	0.0034	0.002929
p3	01.03.2013-31.08.2013	0.005025	-0.004956	0.001012	0.001206
p4	01.04.2013-30.09.2013	0.0008161	-0.0006004	-0.00000858	0.007244
p5	01.05.2013-31.10.2013	0.001582	- 0.006111	0.001007	0.005847
p6	01.06.2013-30.11.2013	-0.002599	- 0.001136	0.002666	0.004478
p7	01.07.2013-31.12.2013	0.008594	- 0.006689	0.001814	0.005702
p8	01.08.2013-31.01.2014	0.005944	- 0.01108	- 0.002147	- 0.006087
p9	01.09.2013-28.02.2014	0.008263	- 0.008909	- 0.002905	- 0.01278
p10	01.10.2013-31.03.2014	0.0005281	- 0.01174	0.002113	- 0.01329
p11	01.11.2013-30.04.2014	0.0008516	- 0.004367	- 0.01031	0.004978
p12	01.12.2013-31.05.2014	-0.006171	- 0.002097	0.008503	- 0.01409
p13	01.01.2014-30.06.2014	-0.00223	0.002043	0.007371	- 0.002545
p14	01.02.2014-31.07.2014	-0.002393	0.003117	0.003677	0.006103
p15	01.03.2014-31.08.2014	-0.002662	0.002162	0.0003665	0.005452
p16	01.04.2014-30.09.2014	0.00461	0.004675	- 0.001888	- 0.001657
p17	01.05.2014-31.10.2014	-0.009124	0.003083	0.0003077	0.00006578
p18	01.06.2014-30.11.2014	-0.01094	0.005096	0.000887	0.006396
p19	01.07.2014-31.12.2014	-0.01486	- 0.001821	0.002023	0.01029
p20	01.08.2014-31.01.2015	-0.009	- 0.004485	0.01131	0.01088
p21	01.09.2014-28.02.2015	-0.002215	- 0.00174	0.01208	0.01367
p22	01.10.2014-31.03.2015	0.01005	- 0.003868	- 0.0003333	0.0001342
p23	01.11.2014-30.04.2015	-0.006413	0.0001901	0.007854	0.001096
p24	01.12.2014-31.05.2015	-0.009362	0.007667	0.001022	- 0.006226
p25	01.01.2015-30.06.2015	-0.00425	0.006656	0.004926	0.001608
p26	01.02.2015-31.07.2015	-0.0084	- 0.000507	0.005878	0.005528
p27	01.03.2015-31.08.2015	-0.001345	0.004507	0.002137	0.001677
p28	01.04.2015-30.09.2015	0.001526	0.0024	- 0.001671	0.003377
p29	01.05.2015-31.10.2015	-0.003933	0.007045	- 0.00472	- 0.002683
p30	01.06.2015-30.11.2015	-0.003672	0.008857	- 0.005701	0.00306
p31	01.07.2015-31.12.2015	0.00523	0.009797	- 0.007371	- 0.0003131
p32	01.08.2015-31.01.2016	0.006782	0.0108	- 0.005087	0.007766
p33	01.09.2015-29.02.2016	0.004715	0.01171	0.004841	0.008003
p34	01.10.2015-31.03.2016	-0.007193	0.008944	0.006313	0.001716
p35	01.11.2015-30.04.2016	-0.01038	0.005976	0.009154	0.002155

Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink [63, 195].

W wyniku identyfikacji uzyskano 24 modele o 24 zmiennych wejściowych (wolumeny z poszczególnych godzin doby) oraz pojedyncze zmienne wyjściowe (średnie ceny w poszczególnych 24 godzinach doby). Łącznie wyodrębniono 35 okresów sześciomiesięcznego zakresu danych obejmującego 184 dni notowań na RDN, a identyfikację przeprowadzono z postępowaniem jednego miesiąca. A zatem uzyskano najpierw parametryczne modele dyskretnego typu liniowego (arx), które następnie przekształcono na ciągłe modele parametryczne (tharxp1).

Następnie model parametryczny ciągły tharxp1 został przekształcony na model ciągły liniowy w przestrzeni stanów ss, a zatem uzyskano ostatecznie macierze w przestrzeni stanów w postaci jak np. dla okresu p1:

$$A(p1) = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,5540 \\ 0,5000 & 0 & 0 & 0 & -1,7521 \\ 0 & 1,0000 & 0 & 0 & -1,7521 \\ 0 & 0 & 4,0000 & 0 & -3,6676 \\ 0 & 0 & 0 & 4,0000 & -2,8606 \end{bmatrix} \quad (4.15)$$


$$B(p1) = \begin{bmatrix} 0,0119 & 0,0259 & -0,0480 & 0,0134 & -0,0146 & 0,0039 & -0,0001 & 0,0091 & 0,0133 & 0,0108 & -0,0218 & -0,0159 \\ 0,0108 & -0,0172 & 0,0139 & 0,0020 & -0,0099 & 0,0103 & -0,0037 & -0,0021 & -0,0122 & 0,0089 & 0,0056 & -0,0012 \\ -0,0043 & 0,0071 & -0,0149 & 0,0079 & 0,0010 & 0,0001 & 0,0017 & 0,0016 & 0,0021 & 0,0079 & -0,0134 & -0,0002... \\ 0,0036 & -0,0073 & 0,0136 & -0,0055 & 0,0003 & -0,0012 & -0,0007 & -0,0045 & -0,0019 & 0,0010 & 0,0016 & 0,0063 \\ -0,0106 & 0,0141 & -0,0316 & 0,0177 & 0,0020 & 0,0019 & 0,0034 & 0,0053 & 0,0026 & 0,0139 & -0,236 & -0,0037 \\ 0,0266 & -0,0049 & -0,0176 & 0,0219 & -0,0083 & 0,0068 & 0,0196 & -0,0184 & -0,0043 & 0,0041 & 0,0139 & -0,0132 \\ -0,0099 & 0,0089 & 0,0001 & -0,0013 & -0,0094 & 0,0100 & -0,0031 & -0,0051 & 0,0128 & -0,0042 & 0,0077 & -0,0015 \\ ... & 0,0027 & 0,0030 & 0,0005 & 0,0034 & -0,0006 & -0,0037 & 0,0050 & -0,0024 & -0,0011 & -0,0008 & 0,0028 & -0,0032 \\ -0,0118 & 0,0035 & -0,0007 & 0,0023 & -0,0048 & 0,0071 & -0,0036 & -0,0013 & 0,0083 & -0,0008 & 0,0032 & 0,0008 \\ 0,0101 & 0,0045 & 0,0031 & 0,0024 & 0,0021 & -0,0118 & 0,0097 & -0,0023 & -0,0064 & -0,0018 & 0,0024 & -0,0054 \end{bmatrix} \quad (4.16)$$

$$C(p1) = [0 \ 0 \ 0 \ 0 \ 2] \quad (4.17)$$

$$D(p1) = 0. \quad (4.18)$$

Przebieg wartości średnioważonej wolumenem ceny sprzedanej energii elektrycznej odbiorcom na RDN [PLN/MWh] w godzinie 0–1 (y012013p1) dla okresu 1.01–30.06.2013 r. zamieszczono na rysunku 4.3. Łącznie otrzymano 35 modeli w przestrzeni stanów postaci jak model opisany macierzami (4.15)–(4.18) dotyczący zachowania się systemu RDN w okresie p1 (dla danych liczbowych od 1.01.2013 do 30.06.2013), stąd też istotne jest zwrócenie uwagi na zmiany elementów i struktury macierzy **A** odpowiadającej za stopień wewnętrznego zorganizowania systemu RDN oraz na zmiany elementów i struktury macierzy **B**

odpowiadającej za poziom sterowania systemem RDN, a także na macierz **C** odpowiadającą za powiązania z otoczeniem (macierz **D** posiadała w każdym badanym okresie wartości 0).



Rysunek 4.3. Przebieg wartości średnioważonej wolumenem ceny energii elektrycznej, która wystąpiła na RDN [PLN/MWh] w godzinie 0-1 w okresie p1 wynoszącym umownych 184 dni (1.01–30.06.2013r.)
Oznaczenia: Time, oś X – okres identyfikacji [dzień], oś Y – średnioważona wolumenem cena ee [PLN/MWh].
Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink oraz biblioteki System Identification Toolbox [63, 195, 208].


W celu otrzymania modelu ciągłego w przestrzeni stanów ss konwertowano ciągły model parametryczny arx za pomocą funkcji `th2ss()`, jak np. dla okresu p1 i otrzymano:

$$\begin{aligned} \frac{dx_1}{dt} = & -0,5540x_5 + 0,0119u_1 + 0,0259u_2 - 0,0480u_3 + 0,0134u_4 - 0,0146u_5 + \\ & 0,0039u_6 - 0,0001u_7 + 0,0091u_8 + 0,0133u_9 + 0,0108u_{10} - 0,0218u_{11} - 0,0159u_{12} + \\ & 0,0266u_{13} - 0,0049u_{14} - 0,0176u_{15} + 0,0219u_{16} - 0,0083u_{17} + 0,0068u_{18} + \\ & 0,0196u_{19} - 0,0184u_{20} - 0,0043u_{21} + 0,0041u_{22} + 0,0139u_{23} - 0,0132u_{24}, \\ \frac{dx_2}{dt} = & 0,5000x_1 - 1,7521x_5 + 0,0108u_1 - 0,0172u_2 + 0,0139u_3 + 0,0020u_4 - 0,0099u_5 + \\ & 0,0103u_6 - 0,0037u_7 - 0,0021u_8 - 0,0122u_9 + 0,0089u_{10} + 0,0056u_{11} - 0,0012u_{12} - \\ & 0,0099u_{13} + 0,0089u_{14} + 0,0001u_{15} - 0,0013u_{16} - 0,0094u_{17} + 0,0100u_{18} - 0,0031u_{19} - \\ & 0,0051u_{20} + 0,0128u_{21} - 0,0042u_{22} + 0,0077u_{23} - 0,0015u_{24}, \end{aligned} \quad (4.19)$$

$$\begin{aligned}
\frac{dx_3}{dt} &= 0,1000x_1 - 1,3873x_5 - 0,0043u_1 + 0,0071u_2 - 0,0149u_3 + 0,0079u_4 + 0,0010u_5 + \\
&\quad 0,0001u_6 + 0,0017u_7 + 0,0016u_8 + 0,0021u_9 + 0,0079u_{10} - 0,0134u_{11} + 0,0002u_{12} + \\
&\quad 0,0027u_{13} + 0,0030u_{14} + 0,0005u_{15} + 0,0034u_{16} - 0,0006u_{17} - 0,0037u_{18} + 0,0050u_{19} - \\
&\quad 0,0024u_{20} - 0,0011u_{21} - 0,0008u_{22} + 0,0028u_{23} - 0,0032u_{24}, \\
\frac{dx_4}{dt} &= 4,000x_3 - 3,6676x_5 + 0,0036u_1 - 0,0073u_2 + 0,0136u_3 - 0,0055u_4 + 0,0003u_5 - \\
&\quad 0,0012u_6 - 0,0007u_7 - 0,0045u_8 - 0,0019u_9 + 0,0010u_{10} + 0,0016u_{11} + 0,0063u_{12} - \\
&\quad 0,0118u_{13} + 0,0035u_{14} - 0,0007u_{15} + 0,0023u_{16} - 0,0048u_{17} + 0,0071u_{18} - 0,0036u_{19} - \\
&\quad 0,0013u_{20} + 0,0083u_{21} - 0,0008u_{22} + 0,0032u_{23} + 0,0008u_{24}, \\
\frac{dx_5}{dt} &= 4,000x_4 - 2,8606x_5 - 0,0106u_1 + 0,0141u_2 - 0,0316u_3 + 0,0177u_4 + 0,0020u_5 + \\
&\quad 0,0019u_6 + 0,0034u_7 + 0,0053u_8 + 0,0026u_9 + 0,0139u_{10} - 0,0236u_{11} - 0,0037u_{12} + \\
&\quad 0,0101u_{13} + 0,0045u_{14} + 0,0031u_{15} + 0,0024u_{16} + 0,0021u_{17} - 0,0118u_{18} + 0,0097u_{19} - \\
&\quad 0,0023u_{20} - 0,0064u_{21} - 0,0018u_{22} + 0,0024u_{23} - 0,0054u_{24},
\end{aligned}
\tag{4.19}$$

gdzie: $x_1, \dots, x_5$ – odpowiednie zmienne stanu.

W celu przeprowadzenia badań komparatystycznych i symulacyjnych zbudowano w Simulinku odpowiednie schematy blokowe na bazie poszczególnych modeli w przestrzeni stanów, takich jak schemat blokowy używany do porównywania modeli ciągłych w przestrzeni stanów (modele ss) z systemem rzeczywistym RDN pokazany dla okresu p7 na rysunku 4.4.



Rysunek 4.4. Przykład modelu ciągłego w przestrzeni stanów dla okresu pomiarowego p7 (od 1 lipca 2013 r. do 31 grudnia 2013 r.)

Oznaczenia: From Workspace – wprowadzanie danych z przestrzeni roboczej, Scope – wyświetlanie sygnału, State-Space – przestrzeń stanów, To Workspace – przekazywanie danych do przestrzeni roboczej, Add – sumator.

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Na gruncie teorii sterowania i systemów macierz A odpowiadająca za stopień wewnętrznego zorganizowania systemu RDN, wiąże wektor zmiennych stanu z pochodną

wektora zmiennych stanu [63]. Macierz **A** w okresie identyfikacji kroczącej dla 35 okresów posiadała dwie struktury, strukturę o wymiarze 5x5 oraz strukturę o wymiarze 4x4. Zmiana wymiaru macierzy **A** wiązała się też ze zmianą wartości elementów i tak wyróżniono m.in. następujące macierze **A** w umownych okresach rozwoju:

$$\mathbf{Ap1} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,5540 \\ 0,5000 & 0 & 0 & 0 & -1,7521 \\ 0 & 1,0000 & 0 & 0 & -1,3873 \\ 0 & 0 & 4,0000 & 0 & -3,6676 \\ 0 & 0 & 0 & 4,0000 & -2,8606 \end{bmatrix},$$

$$\mathbf{Ap2} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,2797 \\ 0,5000 & 0 & 0 & 0 & -1,0252 \\ 0 & 1,0000 & 0 & 0 & -1,4958 \\ 0 & 0 & 4,0000 & 0 & -2,0157 \\ 0 & 0 & 0 & 4,0000 & -3,2727 \end{bmatrix},$$

$$\mathbf{Ap16} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,5057 \\ 0,2500 & 0 & 0 & 0 & -1,4762 \\ 0 & 2,0000 & 0 & 0 & -2,2659 \\ 0 & 0 & 2,0000 & 0 & -2,5861 \\ 0 & 0 & 0 & 8,0000 & -4,6380 \end{bmatrix}, \quad (4.20)$$

$$\mathbf{Ap17} = \begin{bmatrix} 0 & 0 & 0 & -0,3650 \\ 0,5000 & 0 & 0 & -0,9066 \\ 0 & 2,0000 & 0 & -0,6369 \\ 0 & 0 & 4,0000 & -2,4872 \end{bmatrix},$$

$$\mathbf{Ap18} = \begin{bmatrix} 0 & 0 & 0 & -0,6239 \\ 0,5000 & 0 & 0 & -1,8589 \\ 0 & 2,0000 & 0 & -2,8149 \\ 0 & 0 & 4,0000 & -4,6021 \end{bmatrix},$$

$$\mathbf{Ap19} = \begin{bmatrix} 0 & 0 & 0 & -0,2747 \\ 0,5000 & 0 & 0 & -0,7153 \\ 0 & 2,0000 & 0 & -1,4383 \\ 0 & 0 & 4,0000 & -2,3307 \end{bmatrix},$$

$$\mathbf{Ap20} = \begin{bmatrix} 0 & 0 & 0 & -0,3392 \\ 0,2500 & 0 & 0 & -0,8070 \\ 0 & 2,0000 & 0 & -1,4815 \\ 0 & 0 & 4,0000 & -2,3178 \end{bmatrix},$$

$$\mathbf{Ap21} = \begin{bmatrix} 0 & 0 & 0 & -0,3268 \\ 0,5000 & 0 & 0 & -1,2904 \\ 0 & 1,0000 & 0 & -1,4913 \\ 0 & 0 & 4,0000 & -1,9342 \end{bmatrix},$$

$$\mathbf{Ap22} = \begin{bmatrix} 0 & 0 & 0 & -0,3980 \\ 0,5000 & 0 & 0 & -0,8319 \\ 0 & 2,0000 & 0 & -1,7686 \\ 0 & 0 & 4,0000 & -2,6376 \end{bmatrix}, \quad (4.20)$$

$$\mathbf{Ap23} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,2414 \\ 0,2500 & 0 & 0 & 0 & -1,8164 \\ 0 & 2,0000 & 0 & 0 & -2,0733 \\ 0 & 0 & 2,0000 & 0 & -3,9265 \\ 0 & 0 & 0 & 4,0000 & -3,1011 \end{bmatrix},$$

$$\mathbf{Ap28} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,4147 \\ 0,5000 & 0 & 0 & 0 & -2,2887 \\ 0 & 2,0000 & 1,0000 & 0 & -2,1859 \\ 0 & 0 & 4 & 0 & -3,6676 \\ 0 & 0 & 0 & 4,0000 & -2,4452 \end{bmatrix},$$

$$\mathbf{Ap29} = \begin{bmatrix} 0 & 0 & 0 & -0,3860 \\ 0,2500 & 0 & 0 & -1,3351 \\ 0 & 2,0000 & 0 & -1,8590 \\ 0 & 0 & 4,0000 & -2,5671 \end{bmatrix},$$

$$\mathbf{Ap30} = \begin{bmatrix} 0 & 0 & 0 & -0,2430 \\ 0,5000 & 0 & 0 & -1,8984 \\ 0 & 2,0000 & 0 & -2,1113 \\ 0 & 0 & 4,0000 & -3,8843 \end{bmatrix}, \quad (4.20)$$

$$\mathbf{Ap31} = \begin{bmatrix} 0 & 0 & 0 & 0 & -0,2378 \\ 0,2500 & 0 & 0 & 0 & -1,8966 \\ 0 & 2,0000 & 0 & 0 & -2,1137 \\ 0 & 0 & 2,0000 & 0 & -3,8883 \\ 0 & 0 & 0 & 4,0000 & -2,9390 \end{bmatrix}.$$

Na podstawie równań stanu (4.19) oraz wynikającego z nich schematu blokowego pokazanego na rysunku 4.5 można m.in. zauważyć, że pochodne wszystkich zmiennych stanu zależą od zmiennej stanu x_5 , ponadto pochodna zmiennej stanu x_2 oraz pochodna zmiennej stanu x_3 zależą od zmiennej stanu x_1 , a pochodna zmiennych stanu x_4 zależy od zmiennej stanu x_3 oraz pochodna zmiennej stanu x_5 zależy od zmiennej stanu x_4 . Z analizy zmian strukturalnych macierzy $\mathbf{A}$ i jej elementów niezerowych można ponadto zauważyć duży wpływ wszystkich zmiennych stanu na pochodne poszczególnych zmiennych stanu, co w tej pracy nie jest pokazane i wymaga przeprowadzenia odrębnych pogłębionych badań. Można też zauważyć na gruncie teorii sterowania i systemów, że macierz $\mathbf{B}$ odpowiadająca za poziom sterowania wskazuje wpływ wszystkich wielkości wejściowych na poszczególne zmienne stanu, przy czym wpływ ten jest od jednych wielkości wejściowych ujemny a od innych dodatni. Ze względu na to, że macierz $\mathbf{C}$ posiada tylko jeden element niezerowy (piąty), stąd równanie wyjścia było postaci:

$$y_1(t) = 2,0000 \cdot x_5(t). \quad (4.21)$$

Natomiast macierz $\mathbf{D}$ była macierzą o zerowych wartościach wszystkich jej elementów. Z przebiegu zmian wymiaru macierzy $\mathbf{A}$, $\mathbf{B}$ i $\mathbf{C}$ można wywnioskować, że w badanym okresie występowały zmiany strukturalne, a z przebiegu zmian wartości ich elementów można z kolei wywnioskować, że występowały zmiany parametryczne, stąd ważnym zagadnieniem jest uzyskanie katalogu modeli zmiennych stanu dla wszystkich 35 okresów wygenerowanych z postępowaniem jednego miesiąca.

Uzyskane wartości elementów:

- macierzy **A**, występujące w poszczególnych badanych okresach, zestawiono w tabeli 4.6,
- macierzy **B** w tabeli 4.7,
- macierzy **C** w tabeli 4.8.

Tabela 4.6. Zestawienie wybranych wartości elementów macierzy **A** odpowiadających za stopień wewnętrznego zorganizowania systemu RDN

Opis modelu		Wartości wybranych elementów macierzy A								
θ	Okres	a₂₁	a₃₂	a₄₃	a₅₄	a_{15/a14}	a_{25/a24}	a_{35/a34}	a_{45/a44}	a₅₅
p1	01.01.2013-30.06.2013	0.5000	1.000	4.000	4.000	-0.5540	-1.3873	-1.7521	-3.6676	-2.8676
p2	01.02.2013-31.07.2013	0.5000	2.000	2.000	8.000	-0.2797	-1.0252	-1.4958	-2.0157	-3.2727
p3	01.03.2013-31.08.2013	0.2500	2.0000	2.0000	8.0000	-0.2448	-1.0996	-1.5389	-2.1386	-3.5517
p4	01.04.2013-30.09.2013	0.5000	2.0000	2.0000	4.0000	-0.3395	-2.0844	-2.1985	-4.0978	-3.3050
p5	01.05.2013-31.10.2013	0.5000	2.0000	2.0000	4.0000	-0.3468	-2.1622	-2.2256	-4.2055	-3.5186
p6	01.06.2013-30.11.2013	0.5000	2.0000	0.2000	8.0000	-0.2911	-1.1024	-1.4506	-2.2901	-4.1016
p7	01.07.2013-31.12.2013	0.2500	2.5000	2.0000	4.0000	-0.4140	-1.2566	-1.9227	-3.3819	-2.3759
p8	01.08.2013-31.01.2014	0.1250	2.0000	2.0000	4.0000	0.1846	-1.4084	-0.9899	-3.2601	-1.6988
p9	01.09.2013-28.02.2014	0.2500	2.0000	2.0000	4.0000	-0.3694	-1.6132	-1.1822	-3.3317	-1.6709
p10	01.10.2013-31.03.2014	0.2500	2.0000	2.0000	4.0000	-0.3163	-1.3743	-1.0224	-3.1449	-1.2903
p11	01.11.2013-30.04.2014	0.5000	2.0000	2.0000	4.0000	-0.4147	-2.2887	-2.1859	-3.8134	-2.4452
p12	01.12.2013-31.05.2014	0.2500	2.0000	4.0000	X	-0.3860	-1.3351	-1.8590	-2.5671	X
p13	01.01.2014-30.06.2014	0.5000	2.0000	4.0000	X	-0.2430	-1.8984	-2.1113	-3.8843	X
p14	01.02.2014-31.07.2014	0.5000	2.0000	4.0000	8.0000	-0.3852	-1.4672	-1.9734	-4.2235	-7.5991
p15	01.03.2014-31.08.2014	0.5000	2.0000	2.0000	8.0000	-0.3851	-1.5451	-2.5042	-2.7603	-5.0615
p16	01.04.2014-30.09.2014	0.2500	2.0000	2.0000	8.0000	-0.5057	-1.4762	-2.2659	-2.5861	-4.6380
p17	01.05.2014-31.10.2014	0.2500	2.0000	4.0000	4.0000	-0.3099	-0.9250	-1.3556	-3.9836	-3.2402
p18	01.06.2014-30.11.2014	0.2500	2.0000	2.0000	4.0000	-0.2378	-1.8966	-2.1137	-3.8883	-2.9390
p19	01.07.2014-31.12.2014	0.5000	2.0000	4.0000	X	-0.2747	-0.7153	-1.4383	-2.3307	X
p20	01.08.2014-31.01.2015	0.2500	2.0000	4.0000	X	-0.3392	-0.8070	-1.4815	-2.3178	X
p21	01.09.2014-28.02.2015	0.5000	1.0000	4.0000	X	-0.3268	-1.2904	-1.4913	-1.9342	X
p22	01.10.2014-31.03.2015	0.5000	2.0000	4.0000	X	-0.3948	-0.8319	-1.7686	-2.6376	X
p23	01.11.2014-30.04.2015	0.2500	2.0000	2.0000	4.0000	-0.2414	-1.8164	-2.0733	-3.9265	-3.1011
p24	01.12.2014-31.05.2015	0.5000	2.0000	2.0000	8.0000	-0.3131	-1.2087	-1.6871	-2.3750	-4.2163
p25	01.01.2015-31.06.2015	0.1250	2.0000	2.0000	4.0000	0.1846	-1.4084	-0.9899	-3.2601	-1.6988
p26	01.02.2015-31.07.2015	0.2500	2.0000	2.0000	4.0000	-0.3694	-1.6132	-1.1822	-3.3317	-1.6709
p27	01.03.2015-31.08.2015	0.2500	2.0000	2.0000	4.0000	-0.3163	-1.3743	-1.0224	-3.1449	-1.2903
p28	01.04.2015-30.09.2015	0.5000	2.0000	2.0000	4.0000	-0.4147	-2.2887	-2.1859	-3.8134	-2.4452
p29	01.05.2015-31.10.2015	0.2500	2.0000	2.0000	4.0000	-0.3860	-1.3351	-1.8590	-1.8590	-2.5671
p30	01.06.2015-30.11.2015	0.5000	2.0000	4.0000	X	-0.2430	-1.8984	-2.1113	-3.8843	X
p31	01.07.2015-31.12.2015	0.5000	2.0000	4.0000	8.0000	-0.3852	-1.4672	-1.9734	-4.2235	-7.5991
p32	01.08.2015-31.01.2016	0.5000	2.0000	2.0000	8.0000	-0.3851	-1.5451	-2.5042	-2.7603	-5.0615
p33	01.09.2015-29.02.2016	0.2500	2.0000	2.0000	8.0000	-0.5057	-1.4762	-2.2659	-2.5861	-4.6380
p34	01.10.2015-31.03.2016	0.2500	2.0000	4.0000	4.0000	-0.3099	-0.9250	-1.3556	-3.9836	-3.2402
p35	01.11.2015-30.04.2016	0.2500	2.0000	2.0000	4.0000	0.2378	-1.8966	-2.1137	-3.8883	-2.9390

Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink [63, 195].

Tabela 4.7. Zestawienie wybranych wartości elementów macierzy **B** odpowiadających za poziom sterowania systemu RDN

Opis modelu		Wartości wybranych elementów macierzy B								
0	Okres	b₂₁	b₃₂	b₄₃	b₅₄	b₁₅	b₂₅	b₃₅	b₄₅	b₅₅
p1	01.01.2013-30.06.2013	-0.0108	0.0071	0.0136	0.0177	-0.0146	0.0119	0.0259	-0.0480	0.0134
p2	01.02.2013-31.07.2013	0.0003	-0.0070	0.0164	0.0902	0.0015	-0.0052	-0.0104	0.0024	-0.0215
p3	01.03.2013-31.08.2013	0.0004	-0.0090	0.0039	0.0392	-0.0068	-0.0019	-0.0055	0.0014	-0.0093
p4	01.04.2013-30.09.2013	-0.0058	0.0001	0.0022	0.0211	0.0098	0.0085	0.0037	-0.0024	-0.0016
p5	01.05.2013-31.10.2013	-0.0056	-0.0021	-0.0003	0.0098	0.0272	-0.0143	0.0284	-0.0244	0.0098
p6	01.06.2013-30.11.2013	-0.0087	-0.0053	-0.0044	0.0387	0.0118	0.0006	0.0011	-0.0900	-0.0044
p7	01.07.2013-31.12.2013	-0.0004	0.0040	0.0047	0.0057	0.0692	-0.0182	0.0089	-0.0076	0.0083
p8	01.08.2013-31.01.2014	0.0082	0.0290	0.0211	0.0378	0.0106	0.0170	-0.0082	0.0056	-0.0005
p9	01.09.2013-28.02.2014	0.0331	0.0544	0.0278	0.0850	-0.0151	0.0486	-0.0418	0.0245	-0.0492
p10	01.10.2013-31.03.2014	0.0180	-0.0569	0.0138	0.0729	-0.0347	0.0576	-0.0578	0.0361	-0.1330
p11	01.11.2013-30.04.2014	-0.0008	-0.0358	-0.0020	-0.0283	-0.0057	-0.0063	-0.0166	-0.0063	-0.0113
p12	01.12.2013-31.05.2014	0.0048	0.0582	0.0064	0.0189	-0.0130	0.0212	-0.0022	0.0166	-0.0064
p13	01.01.2014-30.06.2014	-0.0016	-0.0002	-0.0036	-0.0044	0.0224	0.0119	0.0022	0.0060	-0.0024
p14	01.02.2014-31.07.2014	0.0122	-0.0250	-0.0163	-0.0227	0.0314	0.0147	0.0083	-0.0043	0.0020
p15	01.03.2014-31.08.2014	0.0088	0.0101	0.0106	0.0094	0.0239	-0.0060	-0.0092	-0.0091	-0.0075
p16	01.04.2014-30.09.2014	-0.0043	0.0051	-0.0006	0.0124	0.0011	-0.0015	-0.0188	-0.0031	-0.0319
p17	01.05.2014-31.10.2014	-0.0065	0.0036	0.0287	X	0.0183	-0.0106	-0.0136	0.0113	X
p18	01.06.2014-30.11.2014	-0.0174	0.0019	0.0637	X	0.0099	-0.0064	-0.0062	0.0400	X
p19	01.07.2014-31.12.2014	-0.0205	-0.0140	-0.0406	X	0.0149	-0.0205	-0.0027	-0.0400	X
p20	01.08.2014-31.01.2015	-0.0105	-0.0163	-0.0764	X	0.0185	-0.0422	0.0141	-0.0783	X
p21	01.09.2014-28.02.2015	-0.0164	-0.0237	-0.0592	X	0.0202	-0.0525	0.0150	-0.0540	X
p22	01.10.2014-31.03.2015	0.0075	-0.0061	0.0173	X	0.0428	-0.0526	0.0431	-0.1503	X
p23	01.11.2014-30.04.2015	-0.0078	0.0033	-0.0069	0.0296	0.0037	-0.0363	0.0177	-0.0305	0.0183
p24	01.12.2014-31.05.2015	-0.0003	0.0286	-0.0157	-0.1034	0.0501	-0.0199	0.0412	-0.0239	0.0590
p25	01.01.2015-31.06.2015	-0.0027	0.0054	0.0038	0.0020	0.0258	0.0059	0.0104	-0.0012	0.0062
p26	01.02.2015-31.07.2015	-0.0081	-0.0004	0.0130	0.0095	0.0264	0.0012	-0.0045	-0.0032	-0.0047
p27	01.03.2015-31.08.2015	-0.0012	0.0160	0.0156	0.0043	0.0275	-0.0011	0.0120	-0.0037	0.0093
p28	01.04.2015-30.09.2015	-0.0007	0.0092	0.0056	-0.0122	0.0173	-0.0106	0.0122	-0.0059	0.0116
p29	01.05.2015-31.10.2015	0.0016	0.0200	0.0534	X	0.0180	-0.0053	0.0027	-0.0193	X
p30	01.06.2015-30.11.2015	0.0020	0.0192	0.0607	X	0.0164	0.0041	-0.0011	-0.0011	X
p31	01.07.2015-31.12.2015	0.0063	0.0146	-0.0221	0.0482	-0.0200	0.0202	-0.0043	0.0312	0.0182
p32	01.08.2015-31.01.2016	0.0007	0.0088	0.0108	0.0525	-0.0614	-0.0013	-0.0284	0.0010	-0.0469
p33	01.09.2015-29.02.2016	-0.0043	0.0051	-0.0006	0.0124	0.0011	-0.0015	-0.0188	-0.0031	-0.0319
p34	01.10.2015-31.03.2016	-0.0040	0.0174	0.0033	0.0368	-0.0343	0.0055	-0.0246	0.0030	-0.0424
p35	01.11.2015-30.04.2016	0.0107	0.0081	-0.0038	0.0015	-0.0711	-0.0091	-0.0556	0.0109	-0.0407

Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink [63, 195].


Tabela 4.8. Zestawienie wartości elementu c_{15} macierzy **C** odpowiadającego za sprzężenia systemu RDN z otoczeniem (dostawcami i odbiorcami energii elektrycznej, siła oddziaływania zmiennej stanu x_5 na jej pochodną

Opis modelu		
θ	Okres	c_{15}
p1	01.01.2013-30.06.2013	2,0000
p2	01.02.2013-31.07.2013	1,0000
p3	01.03.2013-31.08.2013	2,0000
p4	01.04.2013-30.09.2013	2,0000
p5	01.05.2013-31.10.2013	2,0000
p6	01.06.2013-30.11.2013	1,0000
p7	01.07.2013-31.12.2013	2,0000
p8	01.08.2013-31.01.2014	2,0000
p9	01.09.2013-28.02.2014	1,0000
p10	01.10.2013-31.03.2014	1,0000
p11	01.11.2013-30.04.2014	2,0000
p12	01.12.2013-31.05.2014	2,0000
p13	01.01.2014-30.06.2014	2,0000
p14	01.02.2014-31.07.2014	1,0000
p15	01.03.2014-31.08.2014	1,0000
p16	01.04.2014-30.09.2014	1,0000
p17	01.05.2014-31.10.2014	1,0000
p18	01.06.2014-30.11.2014	2,0000
p19	01.07.2014-31.12.2014	1,0000
p20	01.08.2014-31.01.2015	2,0000
p21	01.09.2014-28.02.2015	2,0000
p22	01.10.2014-31.03.2015	1,0000
p23	01.11.2014-30.04.2015	2,0000
p24	01.12.2014-31.05.2015	1,0000
p25	01.01.2015-31.06.2015	2,0000
p26	01.02.2015-31.07.2015	2,0000
p27	01.03.2015-31.08.2015	2,0000
p28	01.04.2015-30.09.2015	2,0000
p29	01.05.2015-31.10.2015	2,0000
p30	01.06.2015-30.11.2015	2,0000
p31	01.07.2015-31.12.2015	2,0000
p32	01.08.2015-31.01.2016	2,0000
p33	01.09.2015-29.02.2016	2,0000
p34	01.10.2015-31.03.2016	2,0000
p35	01.11.2015-30.04.2016	2,0000

Źródło: opracowanie własne z wykorzystaniem środowiska MATLAB i Simulink [63, 195].

Można zauważyć, że w badanych okresach umownych od okresu p1 (1.01.2013–30.06.2013) do okresu p35 (1.11.2015–30.04.2016) wystąpiło 6 zmian strukturalnych związanych ze zmianą stopnia wewnętrznego zorganizowania systemu (zmiany wymiaru macierzy **A**) oraz 6 zmian strukturalnych związanych ze zmianą poziomu sterowania (zmiany wymiaru macierzy **B**), to jest z okresu na okres p11/p12, p13/p14, p18/p19, p22/p23, p29/p30 oraz p30/p31 oraz w każdym okresie (p1-p35) zmiany parametryczne (zmiany wartości elementów macierzy **A** oraz macierzy **B**), przy czym zmiany stopnia wewnętrznego

zorganizowania systemu RDN oraz zmiany poziomu sterowania systemem RDN były ze sobą powiązane.



Rysunek 4.5. Schemat blokowy modelu zmiennych stanu systemu RDN dla 24 wielkości wejściowych dotyczących wolumenu energii elektrycznej sprzedanej w poszczególnych godzinach doby z średnioważoną wolumenem ceną energii elektrycznej uzyskaną w godzinie 0–1 dla okresów pomiarowych p_i , gdzie $i = 1-n$


Źródło: opracowanie własne w SIMULINK-u [63, 195].

Przebieg zmian wartości elementu a_{21} w badanych 35 okresach funkcjonowania systemu RDN pokazano na rysunku 4.6, przy czym można zauważyć m.in., że występowały zmiany

wartości ww. elementów macierzy wewnętrznej organizacji procesu (macierzy **A**) od wartości 0,125 (wartości minimalne), poprzez wartości 0,2500 (wartości pośrednie) do wartości 0,5000 (wartości maksymalne). Element a_{21} macierzy **A** wyraża intensywność wpływu zmiennej stanu x_1 na pochodną zmiennej stanu x_2 . Z kolei na rysunku 4.7 pokazano przebieg zmian wartości elementu a_{15} w 35 umownych okresach badania systemu RDN, przy czym wartość minimalna elementu a_{15} wynosiła -0,5440, a maksymalna 0,2378.


Element a_{15} macierzy **A** wyraża intensywność wpływu zmiennej stanu x_5 na pochodną zmiennej stanu x_1 . Dalej na rysunku 4.8 pokazano przebieg zmian wartości elementu a_{55} w 35 badanych okresach funkcjonowania systemu RDN, przy czym minimalna wartość elementu a_{55} wynosiła -7,5671, a wartość maksymalna -1,2903. Można zauważyć, że ten element nigdy nie miał wartości dodatnich i wyrażał intensywność wpływu zmiennej stanu x_5 na pochodną zmiennej stanu x_5 . Przebiegi wartości elementów a_{15} oraz a_{55} pokazują w sposób wizualny zmiany struktury (przerwy w przebiegu tych wartości widocznych na wykresach zmian). Dalej na kolejnych rysunkach pokazano przebiegi wartości wybranych elementów macierzy **B**, to jest na rysunku 4.9 – elementu b_{12} , na rysunku 4.10 – elementu b_{54} , a na rysunku 4.11 – elementu b_{15} . Wartość elementu b_{12} wyraża wpływ na pochodną zmiennej stanu x_1 wartości zmiennej sterującej u_2 , wartość elementu b_{54} – wpływ na pochodną zmiennej stanu x_5 wartości zmiennej sterującej u_4 , a wartość elementu b_{15} – wpływ na pochodną zmiennej stanu x_1 wartości zmiennej sterującej u_5 .

Natomiast bardzo ciekawy jest przebieg wartości elementu macierzy c_{15} macierzy **C** odpowiadającej za siłę powiązań systemu RDN (jego zmiennej stanu x_5) z otoczeniem (odbiorcami/kupcami energii elektrycznej). Interesującym przypadkiem jest również przebieg wartości elementu c_{15} macierzy **C** odpowiadającej za siłę powiązań systemu RDN (jego zmiennej stanu x_5) z otoczeniem (odbiorcami/kupcami energii elektrycznej). Przebieg wartości tego elementu pokazano na rysunku 4.12, która zmienia się z wartości 1,0000 na wartość 2,000 do okresu p25, po czym się stabilizuje na poziomie wartości 2,0000 i się dalej nie zmienia.

Rysunek 4.6. Zmiany elementu a_{21} macierzy A w 35 okresach badania systemu RDN

Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu a_{21} macierzy A .

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Rysunek 4.7. Zmiany elementu a_{15} macierzy A w 35 badania systemu RDN


Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu a_{15} macierzy A .

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Rysunek 4.8. Zmiany elementu a_{55} macierzy A w 35 badania systemu RDN


Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu a_{55} macierzy A .

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Rysunek 4.9. Zmiany elementu b_{21} macierzy $\mathbf{B}$ w 35 badania systemu RDN


Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu b_{21} macierzy $\mathbf{B}$.

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Rysunek 4.10. Zmiany elementu b_{54} macierzy $\mathbf{B}$ w 35 badania systemu RDN


Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu b_{54} macierzy $\mathbf{B}$.

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Rysunek 4.11. Zmiany elementu b_{15} macierzy $\mathbf{B}$ w 35 badania systemu RDN

Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze],
oś Y – zmiany elementu b_{15} macierzy $\mathbf{B}$.

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].



Rysunek 4.12. Zmiany elementu c_{15} macierzy C w 35 badania systemu RDN

Oznaczenia: oś X – czas długi (okresy kroczące po 184 dni z postępowaniem jednego miesiąca) [umowne półrocze], oś Y – zmiany elementu c_{15} macierzy C .

Źródło: opracowanie własne w MATLAB i Simulink przy użyciu SIT [63, 195].

Poszczególnym elementom macierzy A i B zatem nadano określoną interpretację związaną z interpretacją zmiennych stanu, przy czym interpretację zmiennych stanu wygodnie jest rozpocząć od równania wyjścia (4.21) [121, 212, 217].

Otóż zmienną wyjściową $y_1(t)$ w rozpatrywanym przykładzie jest średnioważona wolumenem cena uzyskana z tytułu dostarczenia i sprzedaży energii elektrycznej w godz. 0–1 w umownych 184 dniach wynikających z okresu identyfikacji modelu [PLN/MWh] i wówczas przy przyjęciu, że element c_{15} macierzy C (w rozważanym okresie p1 o wartości 2,0000) jest wyrażony w jednostkach [PLN/MWh²], wówczas zmienna stanu $x_5(t)$ może zostać zinterpretowana jako energia elektryczna dostarczona i sprzedana na RDN w godz. 0–1 w rozpatrywanym okresie notowań na RDN [MWh] (od 1.01.2013 r. do 30.06.2013 r.).

Na bazie zmiennej stanu $x_5(t)$ oraz przy wykorzystaniu równania stanu na wyznaczanie zmiennej stanu $x_1(t)$ (macierz A w zależności (4.19)) można zinterpretować zmienną stanu $x_1(t)$ jako moc wynikającą z dostarczonej i sprzedanej ee w godz. 0–1, przy zinterpretowaniu elementu a_{11} jako częstotliwości jej zmian w dniu sprzedaży [1/dzień]. Dalej na bazie zmiennej stanu $x_1(t)$ i przy wykorzystaniu równania stanu na wyznaczanie zmiennej stanu $x_2(t)$ oraz równania stanu na wyznaczanie zmiennej stanu $x_3(t)$ (macierz A w zależności (4.19)) można zinterpretować je odpowiednio jako zmienne stanu wyrażające energię elektryczną sprzedaną w ciągu doby.

Natomiast interpretacja zmiennej stanu $x_4(t)$ wynika z interpretacji zmiennej stanu $x_3(t)$ oraz z równania stanu na wyznaczanie pochodnej zmiennej stanu x_4 (macierz A w zależności (4.19)), która może zostać zinterpretowana jako energia elektryczna dostarczona na giełdę

i sprzedana w ciągu badanego okresu pomiarowego, czyli w ciągu 184 dni (od 1.01.2013 r. do 30.06.2013 r.) [112, 121, 212, 217].

Z teorii sterowania i systemów wynika m.in, że równowaga i stabilność są ze sobą związane i dotyczą tych samych charakterystyk zmian systemu w czasie długim [89, 137, 218, 224–225]. Różnica pojawia się wówczas, gdy dochodzi do ustalenia równowagi dynamicznej, która zmienia się w czasie w zależności od zmiany otoczenia (zmiany dostawców i odbiorców energii elektrycznej na RDN). Tutaj jednak, chociaż równowaga jest osiągana ze względu na stabilność systemu, to niemniej dodatkowo może być podtrzymywana przez sterowanie. W teorii sterowania i rozwoju systemów z reguły przyjmuje się, że identyfikatorami stabilności i miernikami jej poziomów są pierwiastki charakterystyczne macierzy wewnętrznej organizacji systemu **A**, która uwzględnia m.in. bieżące dostosowania w obrębie danej jednostki czasu (występowanie zer na głównej przekątnej w macierzy **A** oznacza, że w tych elementach nie występują samosprężenia).

Uwzględniając w równaniach stanu (4.6) wektor wartości własnych KRDN można otrzymać pierwiastki charakterystyczne jako wartości własne dla rozważanego przypadku okresu p1, trwającego od 1.01.2013 r. do 30.06.2013 r., które wynoszą odpowiednio [89, 136, 218]:

$$KRDN = \begin{bmatrix} -0,1911 \\ -1,1033 + 0,9403i \\ -1,1033 - 0,9403i \\ -0,2315 + 3,3142i \\ -0,2315 - 3,3142i \end{bmatrix}. \quad (4.22)$$

A zatem w badanym okresie p1 (w czasie długim trwającym pół roku, I półrocze 2013 r.) otrzymano jeden pierwiastek rzeczywisty o wartości ujemnej (leżący w lewej półpłaszczyźnie zmiennej zespolonej oraz dwie pary zespolonych parami sprzężonych pierwiastków o wartościach rzeczywistych ujemnych, których efekty dynamiczne są scalone, stąd do ich opisu wykorzystano informację o wartości modułów i argumentów liczb zespolonych. Ustalono, że amplitudy wynoszą odpowiednio dla pary:

pierwszej: $r1 = \pm 1,44966$, drugiej: $r2 = \pm 3,3223$,

i odpowiednio argumenty: $teta1 = 0,7058$, $teta2 = 1,5011$,

co wskazuje, że długość cyklu i częstotliwość wyniosły odpowiednio:

$t_1 = 8,9021$ i $f_1 = 1,1087$ oraz $t_2 = 4,1858$ i $f_2 = 2,3579$,

a więc pierwiastki zespolone dały pełny obraz oscylacji jako przejaw występowania procesów adaptacyjnych.

Możliwe jest uzyskanie modelu systemu RDN w postaci schematu zastępczego systemu rzeczywistego w procesie identyfikacji parametrycznej z wykorzystaniem danych liczbowych notowanych np. na Rynku Dnia Następnego TGE S.A. W procesie identyfikacji kroczącej z postępem jednego miesiąca uzyskano 35 modeli parametrycznych dyskretnych liniowych systemu RDN, które dalej konwertowano na 35 modeli parametrycznych ciągłych i w konsekwencji na 35 modeli ciągłych w przestrzeni stanów.

Dla wszystkich 35 modeli zbadano zmiany poszczególnych dziewięciu niezerowych elementów macierzy **A**, wybranych dziewięciu elementów macierzy **B** oraz jednego otrzymanego elementu macierzy **C**, zauważając interesujące prawidłowości występujące w systemie RDN.

Okazało się dalej, że na bazie otrzymanych modeli istnieje możliwość interpretacji uzyskanych wyników badań, m.in. zmiennych stanu oraz parametrów – elementów macierzy **A**, elementów macierzy **B** oraz elementu macierzy **C**, nie mówiąc już o możliwości przeprowadzenia dalszych badań, stosując chociażby z jednej strony metody analizy ekonomicznej opisane m.in. w książce J. Paski pt. *Ekonomika w elektroenergetyce* [154], czy też w książce W. Mielczarskiego pt. *Rynki energii elektrycznej. Wybrane aspekty techniczne i ekonomiczne* [130] oraz w książce pod redakcją S. Mynarskiego pt. *Analiza rynku. Systemy i mechanizmy* [137], a z drugiej strony metody teorii sterowania i systemów opisane m.in. w pracy T. Kaczorka (i innych) pt. *Podstawy teorii sterowania* [89], w książce S. Osowskiego pt. *Cyfrowe przetwarzanie sygnałów z zastosowaniem MATLABA* [151] oraz w pracach [212, 224] przy uwzględnieniu nadal aktualnej strategii zarządzania ryzykiem na giełdzie energii elektrycznej opisanej m.in. w pracy A. Werona i R. Werona pt. *Giełda energii elektrycznej – strategia zarządzania ryzykiem* [240].

4.4. Identyfikacja systemu RDN z wykorzystaniem danych z okresu od 1.01.2016 r. do 31.12.2019 r.

Przeprowadzono identyfikację systemu RDN dla danych rocznych pobranych z TGE S.A. z lat 2016–2019. Jako wynik identyfikacji otrzymano modele systemu RDN odpowiednio dla poszczególnych lat: 2016, 2017, 2018 i 2019. W każdym roku otrzymano po 24 modele parametryczne MISO typu: dyskretnego oraz ciągłego, a w ślad za tym 24 modele ciągłe w przestrzeni stanów.

Do szczegółowej analizy wykorzystano po 4 modele godzinowe, to jest dla godziny: 6, 12, 18 i 24.

A zatem dla godziny 6 roku 2019 otrzymano model parametryczny dyskretny w postaci:

$$A(z) \cdot y(t) = B_1(z) \cdot u_1(t) + B_2(z) \cdot u_2(t) + \dots + B_{24}(z) \cdot u_{24}(t) + e(t), \quad (4.23)$$

gdzie:

$$A(z) = 1 - 0.3777 \cdot z^{-1} + 0.1551 \cdot z^{-2} - 0.1395 \cdot z^{-3} - 0.1729 \cdot z^{-4} - 0.07633 \cdot z^{-5} - 0.0725 \cdot z^{-6},$$

$$B_1(z) = -0.01233 \cdot z^{-1} - 0.021 \cdot z^{-2} + 0.002389 \cdot z^{-3} - 0.003882 \cdot z^{-4} + 0.0452 \cdot z^{-5} - 0.0008132 \cdot z^{-6} - 0.01498 \cdot z^{-7} - 0.01678 \cdot z^{-8} - 0.002096 \cdot z^{-9} + 0.0196 \cdot z^{-10},$$

$$B_2(z) = 0.02169 \cdot z^{-1} + 0.02292 \cdot z^{-2} - 0.005696 \cdot z^{-3} + 0.01106 \cdot z^{-4} - 0.08478 \cdot z^{-5} - 0.002471 \cdot z^{-6} + 0.02813 \cdot z^{-7} + 0.04245 \cdot z^{-8} + 0.02165 \cdot z^{-9} - 0.03317 \cdot z^{-10},$$

.....

$$B_{24}(z) = -0.01645 \cdot z^{-1} - 0.000098 \cdot z^{-2} + 0.01285 \cdot z^{-3} + 0.009628 \cdot z^{-4} + 0.008773 \cdot z^{-5} - 0.000536 \cdot z^{-6} + 0.001467 \cdot z^{-7} - 0.001157 \cdot z^{-8} + 0.003415 \cdot z^{-9} + 0.01136 \cdot z^{-10},$$

Dokonując konwersji modelu parametrycznego dyskretnego na model parametryczny ciągły przy wykorzystaniu funkcji postaci:

$$\text{th6101h62019} = \text{d2c}(\text{arx6101h62019}, 'tustin') \quad (4.24)$$

otrzymano następujący model parametryczny ciągły dla godziny 6 roku 2019:

$$y(t) = [((B_1(s)/F_1(s)) \cdot u_1(t) + ((B_2(s)/F_2(s)) \cdot u_2(t) + \dots + ((B_{24}(s)/F_{24}(s)) \cdot u_{24}(t) + [C(s)/D(s)] \cdot e(t), \quad (4.25)$$

gdzie:

$$B_1(s) = -0.02731 \cdot s^{10} - 0.2861 \cdot s^9 + 2.816 \cdot s^8 - 9.212 \cdot s^7 + 49.11 \cdot s^6 \\ - 103.4 \cdot s^5 + 198.3 \cdot s^4 - 254.7 \cdot s^3 - 42.29 \cdot s^2 - 81.72 \cdot s \\ - 3.196,$$

$$B_2(s) = 0.03977 \cdot s^{10} + 0.501 \cdot s^9 - 6.2 \cdot s^8 + 18.33 \cdot s^7 - 90.71 \cdot s^6 + 193 \cdot s^5 \\ - 306.8 \cdot s^4 + 339.7 \cdot s^3 + 169 \cdot s^2 + 36.33 \cdot s + 14.83,$$

.....

$$B_{24}(s) = 0.006079 \cdot s^{10} + 0.03525 \cdot s^9 + 2.183 \cdot s^8 - 2.081 \cdot s^7 + 32.8 \cdot s^6 \\ - 58.96 \cdot s^5 + 74.968 \cdot s^4 - 211.2 \cdot s^3 + 19.52 \cdot s^2 - 68.22 \cdot s \\ + 19.93,$$

$$C(s) = s^6 + 12 \cdot s^5 + 60 \cdot s^4 + 160 \cdot s^3 + 240 \cdot s^2 + 192 \cdot s + 64,$$

$$D(s) = s^6 + 11.04 \cdot s^5 + 41.99 \cdot s^4 + 107.2 \cdot s^3 + 128.6 \cdot s^2 + 125.3 \cdot s + 13.46,$$

$$F_1(s) = s^{10} + 19.04 \cdot s^9 + 154.3 \cdot s^8 + 740 \cdot s^7 + 2363 \cdot s^6 + 5246 \cdot s^5 + 8203 \\ \cdot s^4 + 8943 \cdot s^3 + 6389 \cdot s^2 + 2435 \cdot s + 215.4,$$

$$F_2(s) = s^{10} + 19.04 \cdot s^9 + 154.3 \cdot s^8 + 740 \cdot s^7 + 2363 \cdot s^6 + 5246 \cdot s^5 + 8203 \\ \cdot s^4 + 8943 \cdot s^3 + 6389 \cdot s^2 + 2435 \cdot s + 215.4,$$

.....

$$F_{24}(s) = s^{10} + 19.04 \cdot s^9 + 154.3 \cdot s^8 + 740 \cdot s^7 + 2363 \cdot s^6 + 5246 \cdot s^5 + 8203 \cdot s^4 \\ + 8943 \cdot s^3 + 6389 \cdot s^2 + 2435 \cdot s + 215.4.$$

W wyniku konwersji modelu parametrycznego ciągłego na model w przestrzeni stanu ciągle z wykorzystaniem funkcji postaci:

$$[A \ B \ C \ D \ KRDN \ X0RDN]=th2ss(th6101h62019) \quad (4.26)$$

otrzymano następujący model dla godziny 6 roku 2019:

$$\begin{aligned}\frac{dx_1}{dt} = & -19,0379 x_1 - 9,6436 x_2 - 5,7815 x_3 - 4,6152 x_4 - 2,5617 x_5 - 2,0026 x_6 - 1,0917 x_7 \\ & - 0,7799 x_8 - 0,5945 x_9 - 0,2103 x_{10} + u_1,\end{aligned}$$

$$\frac{dx_2}{dt} = 16 x_1,$$

$$\frac{dx_3}{dt} = 8 x_2,$$

$$\frac{dx_4}{dt} = 4 x_3,$$

$$\frac{dx_5}{dt} = 4 x_4,$$

$$\frac{dx_6}{dt} = 2 x_5,$$

$$\frac{dx_7}{dt} = 2 x_6,$$

$$\frac{dx_8}{dt} = x_7,$$

$$\frac{dx_9}{dt} = 0.5 x_8,$$

$$\frac{dx_{10}}{dt} = 0.25 x_9,$$

$$\begin{aligned}\frac{dx_{11}}{dt} = & -19,0379 x_{11} - 9,6436 x_{12} - 5,7815 x_{13} - 4,6152 x_{14} - 2,5617 x_{15} - 2,0026 x_{16} \\ & - 1,0917 x_{17} - 0,7799 x_{18} - 0,5945 x_{19} - 0,2103 x_{20} + u_2,\end{aligned}$$

$$\frac{dx_{12}}{dt} = 16 x_{11},$$

$$\frac{dx_{13}}{dt} = 8 x_{12},$$

$$\frac{dx_{14}}{dt} = 4 x_{13},$$

$$\frac{dx_{15}}{dt} = 4 x_{14},$$

$$\frac{dx_{16}}{dt} = 2 x_{15},$$

$$\frac{dx_{17}}{dt} = 2 x_{16},$$

$$\frac{dx_{18}}{dt} = x_{17},$$

$$\frac{dx_{19}}{dt} = 0.5 x_{18},$$

$$\frac{dx_{20}}{dt} = 0.25 x_{19},$$

$$\dots\dots\dots(4.27)$$

$$\begin{aligned} \frac{dx_{231}}{dt} = & -19,0379 x_{231} - 9,6436 x_{232} - 5,7815 x_{233} - 4,6152 x_{234} - 2,5617 x_{235} - 2,0026 x_{236} \\ & - 1,0917 x_{237} - 0,7799 x_{238} - 0,5945 x_{239} - 0,2103 x_{240} + 0.5 u_{24}, \end{aligned}$$

$$\frac{dx_{232}}{dt} = 16 x_{231},$$

$$\frac{dx_{233}}{dt} = 8 x_{232},$$

$$\frac{dx_{234}}{dt} = 4 x_{233},$$

$$\frac{dx_{235}}{dt} = 4 x_{234},$$

$$\frac{dx_{236}}{dt} = 2 x_{235},$$

$$\frac{dx_{237}}{dt} = 2 x_{236},$$

$$\frac{dx_{238}}{dt} = x_{237},$$

$$\frac{dx_{239}}{dt} = 0.5 x_{238},$$

$$\frac{dx_{240}}{dt} = 0.25 x_{239},$$

$$\frac{dx_{241}}{dt} = -19,0379 x_{241} - 9,6436 x_{242} - 5,7815 x_{243} - 4,6152 x_{244} - 2,5617 x_{245} - 2,0026 x_{246}$$

$$\frac{dx_{242}}{dt} = 16 x_{241},$$

$$\frac{dx_{243}}{dt} = 8 x_{242},$$

$$\frac{dx_{244}}{dt} = 4 x_{243},$$

$$\frac{dx_{245}}{dt} = 4 x_{244},$$

$$\frac{dx_{246}}{dt} = 2 x_{245},$$

oraz dla godziny 6 roku 2019 równanie wyjścia przyjmuje postać:

$$y_6(t) = 0,2338 x_1(t) + 0,4394 x_2(t) + 0,08591 x_3(t) + \dots + 0,3949 x_{246}(t) - \\ + 0,0273 u_1(t) + 0,0397 u_2(t) + \dots + 0,0061 u_{24}(t), \quad (4.28)$$

gdzie:

$x_1(t), x_2(t), \dots, x_{246}(t)$ – odpowiednie zmienne stanu,

$u_1(t), u_2(t), \dots, u_{24}(t)$ – odpowiednie zmienne wejściowe.

W analogiczny sposób otrzymano modele parametryczne dyskretnie, modele parametryczne ciągłe oraz modele ciągłe w przestrzeni stanów dla godziny: 12, 18, 24, które zamieszczone są w Dodatku A.

Uzyskane w wyniku identyfikacji modele parametryczne wykorzystano dalej w rozdziałach 6 i 7, w badaniach dotyczących oceny dopasowania modelu do systemu oraz w badaniach efektywności, skuteczności i krzepkości systemu i modelu RDN.

5. METAIDENTYFIKACJA SYSTEMU RYNKU DNIA NASTĘPNEGO TGE S.A.

W literaturze przedmiotu z zakresu badania systemu RDN jak dotychczas brak jest modeli metaidentyfikacji, w tym modeli parametrycznych oraz modeli w przestrzeni stanów. Takie metamodele można uzyskać m.in. z wykorzystaniem teorii sterowania i systemów [89, 96, 130, 218, 224–225], a w szczególności z wykorzystaniem metaidentyfikacji systemu RDN lub z wykorzystaniem sztucznych sieci neuronowych (SSN) [102, 127, 131, 152, 194, 198, 218, 224, 249, 260, 262].

Proces metaidentyfikacji systemów w ogóle, w tym systemu RDN jest procesem złożonym, wymagającym wcześniejszego uzyskania wystarczającej liczby modeli systemu na drodze identyfikacji, których parametry są wykorzystywane do budowy bazy danych dla procesu metaidentyfikacji [125–126, 211, 218, 224–225].

W celu przeprowadzenia procesu metaidentyfikacji systemu RDN, wykorzystano przykład liczbowy oparty na danych notowanych na RDN w okresie od 1 stycznia 2013 r. do 30 kwietnia 2016 r. Na bazie eksperymentów badawczych stwierdzono, że identyfikacja może być w sposób wiarygodny przeprowadzona na zbiorze danych odnotowanych na RDN w okresie umownych 184 dni (sześciu miesięcy), a kolejne modele mogą być uzyskiwane z kolejnych danych liczbowych notowanych na RDN przyjmowanych z postępem jednego miesiąca. Umożliwiło to uzyskanie katalogu 35 dyskretnych modeli parametrycznych arx systemu RDN dla każdej godziny doby (modeli kroczących), przy przyjęciu, że wielkości dotyczące wolumenu energii elektrycznej (ee) w każdej godzinie doby są wejściami do systemu, a wielkości dotyczące średnioważonej wolumenem ceny są wyjściami z systemu [126–126, 211].

Następnie, wykorzystując parametry tego typu 35 modeli parametrycznych dyskretnych arx, przeprowadzono wtórną identyfikację (identyfikację modelu), którą nazwano metaidentyfikacją, gdyż w jej wyniku otrzymuje się modele modeli systemów (metamodeli) [218]. A zatem najpierw przeprowadzono identyfikację systemu RDN dla wszystkich 24 wielkości wejściowych i kolejnych wielkości wyjściowych, uzyskując w ten sposób 24 modele parametryczne dyskretne arx dla jednej próbki pomiarowej, to jest dla 184 dni. Eksperyment ten powtórzono 35 razy, a zatem łącznie uzyskano $35 \times 24 = 840$ modeli parametrycznych dyskretnych arx. Modele te dostarczyły danych do metaidentyfikacji w postaci współczynników wielomianów $B(z)$ związanych z wielkościami wejściowymi

(wolumenem ee) oraz w postaci współczynników wielomianów $A(z)$ związanych z wielkościami wyjściowymi (średnioważona wolumenem ceną ee). Metaidentyfikacji nauczono też Perceptronową SSN [125–126, 211].

Przeprowadzono proces metaidentyfikacji systemu RDN (proces identyfikacji modelu systemu RDN), w tym przygotowano dane liczbowe: współczynników wielomianów $B(z)$ związanych z wolumenem ee (wielkości wejściowe) oraz współczynników wielomianu $A(z)$ związanych ze średnioważoną wolumenem ceną ee (dla kolejnej godziny doby). Przeprowadzono eksperyment metaidentyfikacji odrębnie dla poszczególnych godzin doby z wykorzystaniem katalogu współczynników wielomianów wszystkich 35 uzyskanych modeli systemu RDN. Ostatecznie uzyskano 24 metamodele, to jest metamodele uzyskane odrębnie dla każdej godziny doby.

W eksperymencie przyjęto metodę identyfikacji arx [125–127, 131, 198, 214, 218] oraz dane liczbowe uzyskane na drodze identyfikacji systemu RDN przy przyjęciu 24 wielkości wejściowych oraz jednej wielkości wyjściowej (modele MISO). W wyniku przeprowadzonej identyfikacji z wykorzystaniem metody arx otrzymano 35 modeli parametrycznych dyskretnych, jak np. dla okresu pierwszego oznaczonego jako p1 dla danych notowanych na RDN z okresu od 1.01.2013 r. do 30.06.2013 r. dla wszystkich godzin doby w zakresie wolumenu dostarczonej i sprzedanej ee oraz dla godz. 1 dla średnioważonej wolumenem ceny ee (umownych 184 dni) w postaci przedstawioną zależnością (4.13).

Uzyskany model systemu RDN dla okresu p1 pokazany został na rysunku 4.3, którego dokładność w stosunku do systemu RDN wynosiła 87,8%. Przykłady wartości współczynników wielomianu $A(z)$ zamieszczono w tabeli 4.4, a wielomianu $B(z)$ w tabeli 4.5.

Wykorzystując wygenerowane współczynniki w 35 modelach dla każdej odrębnie godziny doby (24 wielomianów $B(z)$, to jest po 4 współczynniki w każdym z 24 modeli) otrzymano razem 96 wielkości wejściowych. Następnie wygenerowano w sposób losowy, z uzyskanych przedziałów zmienności odpowiednich współczynników wykorzystywanych w identyfikacji, w liczbie 560 par wartości wejściowo-wyjściowe.

Kolejno przeprowadzono metaidentyfikację i otrzymano cztery odrębne metamodele dla każdego współczynnika wielomianu $AM_i(z)$, jak np. dla godz. 0–1 i współczynnika przy operatorze z^{-1} , w postaci dyskretnego modelu arx748:

$$AM_1(z) a_1(\theta) = BM_{1,1}(z) b_1(\theta) + BM_{1,2}(z) b_2(\theta) + \dots + BM_{24,96}(z) b_{96}(\theta) + e(\theta), \quad (5.1)$$

gdzie:

$$AM_1(z) = 1 - 0.9557 z^{-1} + 0.166 z^{-2} + 0.04223 z^{-3} - 0.4683 z^{-4} + 0.7337 z^{-5} - 0.3706 z^{-6} - 0.2331 z^{-7},$$

$$BM_{1,1}(z) = 0,00001 z^{-8} + 0,00001 z^{-9} + 0,00001 z^{-10} + 0,00001 z^{-11},$$

$$BM_{1,2}(z) = 0,00001 z^{-8} + 0,00001 z^{-9} + 0,00001 z^{-10} + 0,00001 z^{-11},$$

.....

$$BM_{24,96}(z) = -2.88 z^{-8} + 3.923 z^{-9} - 0.8226 z^{-10} - 1.227 z^{-11},$$


na – stopień wielomianu $AM_1(z)$, $na=7$,

nb – stopień wielomianów $BM_j(z)$, $nb=4$,

nk – opóźnienie wyjścia w stosunku do wejścia, $nk=8$,

θ – czas długi [miesiąc].

Dokładność metamodelu do danych uzyskanych dla 35 modeli wyniosła 59.67% – rys. 5.1




Rysunek 5.1. Przebieg wartości współczynnika a_{11} wielomianu $AM_1(z)$ w metamodelu systemu RDN i modelu systemu RDN dla 560 próbek wejściowo-wyjściowych dotyczących okresu p1 w godzinie 0–1, to jest z okresu od 1.01 do 30.06.2013 r.

Oznaczenia: Time, Oś x – czas długi dotyczący okresu p1 (kolejne modele systemu RDN).

Źródło: opracowanie własne w środowisku MATLAB-a z wykorzystaniem SIT [63, 195].

Wykorzystując wygenerowane parametry 35 modeli systemu RDN nauczono także SSN metamodelu systemu RDN na przykładzie godziny 0–1 [152, 260, 262]. Przebieg krzywej uczenia zamieszczono na rysunku 5.2.

Sztuczna Sieć Neuronowa typu Perceptron dwuwarstwowy jako metamodel neuronalny systemu RDN typu MIMO (współczynniki dotyczące wejścia u_1 , współczynniki dotyczące wyjścia y_1) dla godz. 0–1 posiadała cztery wielkości wejściowe (współczynniki b_i) oraz cztery wielkości wyjściowe (współczynniki a_j).



Rysunek 5.2. Przebieg błędu uczenia MSE dla rozważanego metamodelu systemu RDN, to jest dla okresu p1

Oznaczenia: Oś x – epoki odpowiadające kolejnym modelom systemu RDN, oś y – wartość błędu MSE.

Źródło: opracowanie własne [63, 195].

Wielkościami wejściowymi do metamodelu systemu RDN były cztery współczynniki wielomianu $BM_1(z)$, stojące przy kolejnych operatorach z^{-i} , a wielkościami wyjściowymi były cztery współczynniki wielomianu $AM_1(z)$, stojące podobnie przy kolejnych operatorach z^{-i} .


W rozważanym przykładzie par trenujących było 35. SSN nauczyła się metamodelu systemu RDN po 8 epokach, a błąd MSE spadł znacząco, to jest od wartości 0.7555 do wartości 0.0255. Przyjęto, że SSN posiadała jedną warstwę ukrytą neuronów o czterech neuronach. Zarówno w warstwie ukrytej, jak też warstwie wyjściowej przyjęto jako funkcję aktywacji neuronów – funkcję tansig(). Wygenerowany metamodel neuronalny zamieszczono na rysunkach 5.3–5.5.



Rysunek 5.3. Metamodel neuronalny systemu RDN w środowisku MATLABA i Simulinka

Oznaczenia: Input 1 ($p\{1\}$) – wektor wejściowy do SSN, Neural Network – Sztuczna Sieć Neuronowa, $y\{1\}$ – wektor wyjściowy ze SSN.


Źródło: opracowanie własne w środowisku MATLAB z wykorzystaniem NNT [63, 195].



Rysunek 5.4. Model pierwszej warstwy neuronów w SSN jako metamodelu systemu RDN

Oznaczenia: weight – macierz wag postaci $IW\{1,1\}$, bias – wektor biasów postaci $b\{1\}$, netsum – blok sumowania, Delays 1 – opóźnienie sygnały wejściowego o jedną jednostkę czasu, tansig – funkcja aktywacji neuronu, $p\{1\}$ – macierz wielkości wejściowych do pierwszej warstwy neuronów, $a\{1\}$ – macierz wielkości wyjściowych z pierwszej warstwy neuronów.

Źródło: opracowanie własne w środowisku MATLAB z wykorzystaniem NNT [63, 195].




Rysunek 5.5. Model drugiej warstwy neuronów w SSN jako metamodelu systemu RDN

Oznaczenia analogiczne jak do rys. 4.16.

Źródło: opracowanie własne w środowisku MATLAB z wykorzystaniem NNT [63, 195].


Dla celów badań porównawczych zachowania się metamodelu neuralnego w stosunku do modelu systemu RDN zbudowano schemat blokowy jak na rysunku 5.6. Uzyskano wysoką dokładność metamodelu w odniesieniu do modelu systemu RDN, jak pokazano na rysunkach 5.7–5.10, mierzoną rozbieżnością w wielkościach wyjściowych z metamodeli w odniesieniu do danych parametrów odpowiedniego modelu systemu RDN.



Rysunek 5.6. Przykład schematu blokowego w Simulinku do badań porównawczych metamodelu neuralnego w postaci SSN z modelem systemu RDN

Źródło: opracowanie własne w środowisku MATLABA z wykorzystaniem Simulinka i NNT [63, 195].


Przykładowe wyniki przebiegów rozbieżności między sygnałami wyjściowymi z metamodelu i modelu systemu RDN pokazano na rysunkach 5.7–5.10.



Rysunek 5.7. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na pierwszym neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN

Oznaczenia: oś y – rozbieżność, oś x – epoki jako czas długi.


Źródło: opracowanie własne w środowisku MATLAB-a z wykorzystaniem Simulink-a i NNT [63, 195].



Rysunek 5.8. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na drugim neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN

Oznaczenia: oś y – rozbieżność, oś x – epoki jako czas długi.


Źródło: opracowanie własne w środowisku MATLAB-a z wykorzystaniem Simulink-a i NNT [63, 195].



Rysunek 5.9. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na trzecim neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN

Oznaczenia: oś y – rozbieżność, oś x – epoki jako czas długi.

Źródło: opracowanie własne w środowisku MATLAB-a z wykorzystaniem Simulink-a i NNT [63, 195].



Rysunek 5.10. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na czwartym neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN

Oznaczenia: oś y – rozbieżność, oś x – epoki jako czas długi.

Źródło: opracowanie własne w środowisku MATLAB-a z wykorzystaniem Simulink-a i NNT [63, 195].

Można zauważyć, że w zależności od modelu kroczącego rozbieżności w sygnałach wyjściowych między metamodeliem a danymi odpowiedniego modelu systemu RDN zmieniają się w zasadzie w przedziale od -0.2 do 0.2 .

Podsumowując, w celu przeprowadzenia identyfikacji systemu RDN na podstawie danych liczbowych notowanych na Rynku Dnia Następnego Towarowej Giełdy Energii S.A. w okresie od 1 stycznia 2013 r. do 30 kwietnia 2016 r., wyróżniono 24 zmienne wejściowe w odniesieniu do całkowitej wielkości wolumenu dostarczonej i sprzedanej energii elektrycznej wszystkich transakcji przeprowadzonych na sesji giełdowej w poszczególnych godzinach doby (zmienne wejściowe) [MWh] oraz wyróżniono pojedyncze wielkości wyjściowe związane z otrzymaną średnioważoną wolumenem ceną uzyskaną z tytułu dostarczenia i sprzedaży energii elektrycznej ze wszystkich transakcji na sesji giełdowej dla danej godziny doby [PLN/MWh]. W ten sposób uzyskano 24 modele o 24 zmiennych wyjściowych (wolumeny z poszczególnych godzin doby) oraz pojedyncze zmienne wyjściowe (średnioważone wolumenem ceny w poszczególnych 24 godzinach doby). Łącznie wyodrębniono 35 okresów sześciomiesięcznego zakresu danych, obejmującego umownych 184 dni notowań na RDN (modele kroczące), a identyfikację przeprowadzono z postępowaniem jednego miesiąca. W ten sposób uzyskano najpierw parametryczne modele dyskretne typu liniowego (arx), a na ich podstawie metamodel przy wykorzystaniu Perceptronowej Sztucznej Sieci Neuronowej. Ponadto pokazano wyniki uczenia na przykładzie danych otrzymanych dla godz. 0–1, to jest nauczono SSN metamodelu systemu RDN, to jest współczynników modelu systemu.

W poszczególnych modelach parametrycznych typu MISO wielkościami wejściowymi były wolumeny dostarczonej i sprzedanej ee w poszczególnych godzinach doby (po 24 wielkości wejściowe) a wielkościami wyjściowymi średnioważone wolumenem ceny uzyskane z tytułu sprzedanej ee w ww. godzinach doby. Poszczególne modele zostały wykorzystane do przeprowadzenia badań symulacyjnych, komparatystycznych oraz badania wrażliwości.

Opracowany w Simulinku schemat blokowy jest modelem obejmującym cztery modele parametryczne arx typu MISO wraz z subsystemami do badań symulacyjnych, komparatystycznych oraz do badania efektywności, skuteczności i krzepkości modelu do systemu RDN. Szczegółowy schemat blokowy wraz z zestawieniem wybranych bloków (będących w istocie odpowiednimi m-plikami języka Matlab) wykorzystanych w modelu parametrycznym arx systemu RDN, zamieszczony został w Dodatku B (rys. B.1).

Model ten w ogólnej swej postaci zawiera 17 subsystemów ośmiu następujących typów:


- separator wolumenu ee danych godzinowych systemu RDN (jeden subsystem),
- generator efektywności godzinowych systemu RDN (jeden subsystem),
- miernik przebiegu efektywności godzinowych systemu RDN (jeden subsystem),
- miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN (cztery subsystemy),
- separator ceny ee danych godzinowych systemu RDN (jeden subsystem),
- miernik błędu względnego efektywności pomiędzy modelem i systemem RDN (cztery subsystemy),
- generator wskaźników oceny jakości modelu do systemu RDN (efektywności, skuteczności, krzepkości itp.) (cztery subsystemy),
- model godzinowy systemu RDN (jeden subsystem).

Ponadto na model składają się między innymi bloki typu From Workspace służące do wprowadzania danych dotyczących wolumenu ee notowanych na RDN w odpowiednim roku oraz bloki typu To Workspace służące do wyprowadzania wyników do przestrzeni roboczej MATLAB-a.

Każdy z wyżej wymienionych subsystemów zbudowany jest z odpowiedniej liczby kolejnych odpowiednich subsystemów i innych towarzyszącym im elementów, tworząc model hierarchiczny systemu RDN.

Separator wolumenu ee danych godzinowych systemu RDN

Separator wolumenu ee danych godzinowych systemu RDN dokonuje wydzielenia z wektora danych wejściowych u242019 pojedynczych sygnałów godzinowych w celu ich wykorzystania w szczegółowych obliczeniach dotyczących wyznaczenia efektywności, skuteczności i krzepkości poszczególnych transakcji godzinowych. Model symulacyjny separatora wolumenu ee danych godzinowych systemu RDN został przedstawiony na rysunku 6.2. Zawiera on blok o nazwie Demux dokonujący separacji poszczególnych sygnałów wchodzących w skład wektora oraz jeden element wejściowy (in) i 24 elementy wyjściowe (out). W połączeniu pomiędzy blokiem in i Demux płynie sygnał wektorowy 24-elementowy w czasie 365 umownych dni, a w każdym z 24 połączeń pomiędzy Demux-em, a poszczególnymi elementami wyjściowymi (out) płyną sygnały jednoelementowe (skalary), także w czasie umownym 365 dni.




Rysunek 6.2. Separator wolumenu ee danych godzinowych systemu RDN

Oznaczenia jak w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Generator efektywności godzinowych systemu RDN

Generator efektywności godzinowych systemu RDN dokonuje wyznaczenia efektywności systemu w sensie opisanym w podrozdziale 2.6, to jest z wykorzystaniem bloku Divide opisanego w tabeli B.1 (Dodatek B), dokonującego dzielenia sygnału dotyczącego średnioważonej wolumenem ceny ee systemu RDN przez wolumen ee systemu RDN dla danej godziny. Następnie wyznaczane są efektywności systemu RDN w [%] z wykorzystaniem bloku Gain. Otrzymane efektywności są wyprowadzone z subsystemu za pomocą bloków out. Takich generatorów efektywności godzinowej jest 24.




Rysunek 6.3. Generator efektywności godzinowych systemu RDN

Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Miernik przebiegu efektywności godzinowych systemu RDN

Miernik przebiegu efektywności godzinowych systemu RDN dokonuje pomiaru odrębnie dla każdej godziny efektywności systemu RDN. Został on pokazany na rysunku 6.4. Jest to prosty subsystem zbudowany z 24 bloków Scope opisanych szczegółowo w tabeli B.1 (Dodatek B). Poszczególne wejścia, oznaczone jako in, pobierane są z subsystemu Generator efektywności godzinowych systemu RDN.




Rysunek 6.4. Miernik przebiegu efektywności godzinowych systemu RDN
Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN

Miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN z wykorzystaniem błędu bezwzględnego pomiędzy krzepkościami został przedstawiony na rysunku 6.5. Wykorzystuje on następujące bloki: In, Add, Abs, Divide, Gain i Out, opisane szczegółowo w tabeli B.1 (Dodatek B). W wyniku działania tego subsystemu otrzymuje się przebieg błędu względnego uzyskanego na bazie błędu bezwzględnego. W przypadku uwzględnienia rozbieżności pomiędzy krzepkością modelu i systemu, w miejsce błędu bezwzględnego otrzymuje się przebieg błędu względnego uzyskanego na bazie rozbieżności.




Rysunek 6.5. Miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN
Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Separator średniowanej wolumenem ceny ee danych godzinowych systemu RDN

Separator średniowanej wolumenem ceny ee danych godzinowych systemu RDN dokonuje wydzielenia z wektora danych wejściowych $y_{24 \times 2019}$ pojedynczych sygnałów godzinowych w celu ich wykorzystania w szczegółowych obliczeniach dotyczących wyznaczenia efektywności, skuteczności i krzepkości poszczególnych transakcji godzinowych. Model symulacyjny separatora średniowanej wolumenem ceny ee danych godzinowych systemu RDN został przedstawiony na rysunku 6.6. Zawiera on blok o nazwie Demux dokonujący separacji poszczególnych sygnałów wchodzących w skład wektora oraz jeden

element wejściowy (in) i 24 elementy wyjściowe (out). W połączeniu pomiędzy blokiem In i Demux płynie sygnał wektorowy 24-elementowy w czasie 365 umownych dni, a w każdym z 24 połączeń pomiędzy Demux-em, a poszczególnymi elementami wyjściowymi (out) płyną sygnały jednoelementowe (skalary), także w czasie umownym 365 dni.




Rysunek 6.6. Separator ceny ee danych godzinowych systemu RDN
Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Miernik błędu względnego efektywności pomiędzy modelem i systemem RDN

Miernik błędu względnego efektywności pomiędzy modelem i systemem RDN (rys. 6.7) został zbudowany z wykorzystaniem bloków: In, Add, Divide, Out. Subsystem ten dokonuje wyznaczenia błędu względnego, którego wizualizacja dokonywana jest za pomocą bloku Scope na zewnątrz subsystemu. Ponadto ten subsystem dokonuje zestawienia za pomocą bloku Mux obu sygnałów, wizualizowanych na jednym wykresie za pomocą bloku Scope na zewnątrz subsystemu.




Rysunek 6.7. Miernik błędu względnego efektywności pomiędzy modelem i systemem RDN
Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Generator wskaźników oceny jakości modelu do systemu RDN

Generator wskaźników oceny jakości modelu do systemu RDN wyznacza: błąd względny krzepkości modelu do systemu RDN, krzepkość modelu, efektywność modelu, komparatystykę krzepkości modelu do systemu, skuteczność modelu i krzepkość systemu, które są wysyłane za pomocą bloku ToWorkspace do przestrzeni roboczej MATLABa w celu wykorzystania wyników liczbowych w wyznaczaniu między innymi błędu MAPE. Subsystem ten został zbudowany z wykorzystaniem następujących bloków: In, Divide, Product, Gain, Subsystem wyznaczający błąd względny krzepkości pomiędzy modelem a systemem, Mux, Out, który pokazano na rysunku 6.8.


Subsystem wyznaczający błąd względny krzepkości pomiędzy modelem a systemem dokonuje wyznaczenia błędu procentowego (rys. 6.9). Został zbudowany z bloków: In, Add, Divide i Out.



Rysunek 6.8. Generator błędu względnego efektywności pomiędzy modelem i systemem RDN

Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].



Rysunek 6.9. Subsystem wyznaczający błąd względny krzepkości pomiędzy modelem a systemem RDN

Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Model godzinowy systemu RDN


Model godzinowy systemu RDN dokonuje wyznaczenia modeli systemu RDN dla każdej godziny doby (dla czytelności w subsystemie zamieszczono cztery wybrane godziny to jest: 6, 12, 18 i 24). Subsystem ten został zbudowany z wykorzystaniem następujących bloków: In, subsystem wyznaczający model systemu RDN, subsystem wyznaczający błąd względny modelu do systemu, Scope, ToWorkspace, Out (rys. 6.10).

Subsystem wyznaczający model systemu RDN zbudowany jest z następujących bloków: In, Idmodel, Gain, Custom Neural Network, Scope, ToWorkspace i Out (rys. 6.11). Podstawowym blokiem tego subsystemu jest Idmodel opisany funkcją:

$$y_{idmodelh62019} = idpoly(arx6101h62019), \quad (6.1)$$

którego argumentem jest model parametryczny z wejściem zawierającym 24 wielkości wejściowe dotyczące wolumenu dostarczonej i sprzedanej ee w poszczególnych godzinach doby w rozważanym przykładzie w 2019 r.


Otrzymano zbliżone wielkości wyjściowe z modelu do wielkości wyjściowych z systemu RDN. Rozbieżności pomiędzy tymi wielkościami wyznaczono za pomocą błędu względnego, którego model symulacyjny zamieszczono na rysunku 6.12. Szczegółowy opis rozważanego przypadku z godziny szóstej (h6) zawiera rozdział 7. Dalej podjęto próbę poprawienia otrzymanych wyników za pomocą Perceptronowej SSN (rys. 6.11), którą nauczono korygowania sygnału, co szczegółowo opisane jest w punkcie pt. Perceptronowa SSN jako korektor wielkości wyjściowych modelu systemu RDN [124].



Rysunek 6.10. Model godzinowy systemu RDN

Oznaczenia w tabeli B.1 (Dodatek B).


Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].



Rysunek 6.11. Subsystem wyznaczający model systemu RDN

Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].



Rysunek 6.12. Subsystem wyznaczający błąd względny modelu do systemu
Oznaczenia w tabeli B.1 (Dodatek B).

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].


Perceptronowa SSN jako korektor wielkości wyjściowych modelu systemu RDN

Perceptronową SSN uzyskano w wyniku uczenia sieci neuronowej na znormalizowanych wielkościach dotyczących średnioważonej wolumenem ceny ee w danej godzinie doby otrzymanej jako sygnał wyjściowy z subsystemu Idmodel (traktowany jako wejście do SSN) oraz średnioważonej wolumenem ceny ee w danej godzinie doby notowanej na RDN (traktowanej jako wyjście z SSN). Uzyskany w wyniku uczenia SSN błąd średniokwadratowy MSE został zamieszczony na rysunku 6.13, który dla zerowej epoki wynosił $1.70 \cdot 10^{-7}$, a po gwałtownym spadku uzyskał ustabilizowaną wartość już w epoce 9 wynoszącą $9.79 \cdot 10^{-13}$ (nie wystąpiło zjawisko przeuczenia). Uzyskany subsystem SSN składa się z dwóch warstw neuronów pokazanych jako subsystemy bloku SSN na rysunku 6.14, przy czym zawartość dla warstwy pierwszej z funkcją aktywacji neuronów `tansig()` pokazano na rysunku 6.15, a dla warstwy drugiej z funkcją aktywacji neuronów `purelin()` pokazano na rysunku 6.16 [124].


Model ten dotyczy Perceptronowej SSN złożonej z dwóch warstw neuronów z jednokierunkowym przepływem sygnałów od wejścia do wyjścia, z połączeniami wszystkich neuronów warstwy poprzedniej wszystkimi neuronami warstwy następnej. Na rysunkach 6.17 i 6.18 pokazano architekturę odpowiednio warstwy pierwszej neuronów **W1** i warstwy drugiej neuronów **W2**.

W wyniku uczenia SSN modelu korektora sygnału wychodzącego z Idmdel uzyskano wskaźnik regresji wynoszący $R = 0.82978$, a więc stosunkowo wysoki, świadczący o dobrym dopasowaniu korektora (rys. 6.19). Model po nauczaniu był następnie testowany, uzyskując


wskaźnik regresji $R = 0.83265$ oraz poddany walidacji ze wskaźnikiem regresji wynoszącym $R = 0.83678$.




Rysunek 6.13. Błąd średniokwadratowy MSE dopasowania SSN do modelu Idmodel
Oznaczenia: Train – błąd uczenia, Validation – błąd walidacji, Test – błąd testowania, Best – dopasowanie modelu neuralnego do danych rzeczywistych w piątej epoce, Epochs – epoki uczenia SSN.
Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].



Rysunek 6.14. Architektura SSN modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019
Oznaczenia: Layer 1 – warstwa 1 SSN, to jest warstwa ukryta neuronów, Layer 2 – warstwa 2 SSN, to jest warstwa wyjściowa neuronów, pozostałe oznaczenia dotyczą wejść i wyjść poszczególnych warstw neuronów.
Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].




Rysunek 6.15. Architektura SSN warstwy pierwszej modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019
Oznaczenia: IW{1,1} – macierz wag, b{1} – wektor biasów, tansig – blok funkcji aktywacji neuronów, pozostałe oznaczenia dotyczą wejść i wyjść poszczególnych warstw neuronów.
Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].



Rysunek 6.16. Architektura SSN warstwy drugiej modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019

Oznaczenia: $LW\{2,1\}$ – macierz wag, $b\{2\}$ – wektor biasów, purelin – blok funkcji aktywacji neuronów, pozostałe oznaczenia dotyczą wejść i wyjść poszczególnych warstw neuronów.


Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].



Rysunek 6.17. Architektura SSN warstwy pierwszej dla macierzy wag W_1 modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019

Oznaczenia: $IW\{1,1\}(i,:)$ – odpowiednie wagi macierzy wag W_1 , $i=1-12$. Pozostałe oznaczenia jak w tabeli 6.1.


Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].



Rysunek 6.18. Architektura SSN warstwy drugiej dla macierzy wag **W2** modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019

Oznaczenia: $IW\{2,1\}(1,:)$ – waga macierzy wag **W2**. Pozostałe oznaczenia jak w tabeli 6.1.

Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].



Rysunek 6.19. Wskaźnik regresji w procesie uczenia SSN modelu neuralnego dopasowania sygnału wyjściowego z Idmodel dla godziny 6 roku 2019 do danych rzeczywistych systemu RDN

Oznaczenia: Training – błąd uczenia, Validation – błąd walidacji, Test – błąd testowania, All – dopasowanie modelu neuralnego do danych rzeczywistych, oś x (Target) – cel uczenia, oś y (Output) – wyjście.

Źródło: opracowanie własne z wykorzystaniem Neural Network Toolbox-a [63, 195].

W wyniku uczenia otrzymano następujące wagi i biasy warstwy pierwszej dla godziny 6 roku 2019:

$$IW\{1,1\}(i,:) = [-13.9573; -13.9395; \dots; -14.0015; 14.0529], \quad (6.2)$$

$$\mathbf{B1} = [14.0409; 10.9558; \dots; -10.8863; 13.9459] \quad (6.3)$$

a zatem sumatory ważonych wejść neuronów warstwy ukrytej są następujące:

$$\begin{aligned} net_{11}^1 &= -13.9573 \cdot u_1 + 14.0409, \\ net_{12}^1 &= -13.9395 \cdot u_1 + 10.9558, \\ &\dots \\ net_{112}^1 &= 14.0529 \cdot u_1 + 13.9459. \end{aligned} \quad (6.4)$$

Analogicznie dla warstwy wyjściowej uzyskano następujące wagi i bias:

$$IW\{2,1\}(1,:) = [0.30678 \ -0.12441 \ \dots \ -0.024817 \ 0.20338], \quad (6.5)$$

$$\mathbf{B2} = [0.025585], \quad (6.6)$$

stąd też sumator ważonych wejść neuronów warstwy drugiej, to jest wyjściowej jest następujący:

$$net_1^2 = net_{11}^2 + net_{21}^2 + \dots + net_{101}^2 = 0.30678 \cdot u_1 - 0.12441 \cdot u_2 + \dots + 0.20338 \cdot u_{12} + 0.025585, \quad (6.7)$$

gdzie:

net_{ij}^k – sumator ważonych wejść pomiędzy i-tym wyjściem a j-tym neuronem k-tej warstwy,

bias ($\mathbf{B1}$, $\mathbf{B2}$) – wektory wag neuronów o stałej wartości wejścia odpowiednio dla warstwy 1 i warstwy 2 neuronów,

$IW\{1,1\}(i,:)$ – odpowiednie wagi macierzy wag $W1$, $i = 1-12$,

$IW\{2,1\}(1,:)$ – waga macierzy wag $W2$, $i = 1$.

Uwzględniając dla warstwy pierwszej funkcję aktywacji neuronów w postaci $tansig()$ oraz dla drugiej warstwy funkcję w postaci $purelin()$ otrzymuje się dalej:

$$tansig(net_{ij}^1) = \frac{2}{(1 + \exp(-2 \cdot net_{ij}^1))^{-1}}, \quad (6.8)$$

oraz

$$purelin(net_{ij}^2) = a \cdot net_{ij}^2, \quad (6.9)$$

gdzie:

a – współczynnik proporcjonalności, który w rozważanym przypadku wynosił 1.

Stąd dalej otrzymuje się dla warstwy ukrytej:

$$\begin{aligned} y_1^1 &= \text{tansig}(net_{11}^1) = \frac{2}{(1 + \exp(-2 * (-13.9573 \cdot u_1 + 14.0409)))^{-1}} \\ y_2^1 &= \text{tansig}(net_{12}^1) = \frac{2}{(1 + \exp(-2 * (-13.9395 \cdot u_1 + 10.9558)))^{-1}} \\ y_{12}^1 &= \text{tansig}(net_{112}^1) = \frac{2}{(1 + \exp(-2 * (14.0529 \cdot u_1 + 13.9459)))^{-1}} \end{aligned} \quad (6.10)$$

i odpowiednio dla warstwy wyjściowej:

$$y_{SSN} = y_1^2 = \text{purelin}(net_1^2) = 0.30678 \cdot u_1^2 - 0.12441 \cdot u_2^2 + \dots + 0.20338 \cdot u_{12}^2 + 0.025585. \quad (6.11)$$


A zatem model neuronalny w postaci Perceptronowej SSN nauczony korygowania błędu modelu identyfikacyjnego składa się z zależności (6.10), (6.11), przy czym wyjście z warstwy pierwszej jest wejściem do warstwy drugiej.

Model symulacyjny zamieszczony na rysunku A1 (Dodatek A) dotyczy zatem czterech godzinowych modeli parametrycznych dyskretnych arx skorygowanych za pomocą czterech sztucznych sieci neuronowych, który został wykorzystany w badaniach komparatystycznych oraz w badaniu wrażliwości modelu, a także w badaniu jakości modelu.

6.2. Badania komparatystyczne oraz badanie wrażliwości modelu

Badania komparatystyczne

Badania komparatystyczne modelu w stosunku do systemu RDN przeprowadzono dla każdej godziny doby, przy czym w rozprawie zamieszczono wyniki badań dla czterech przyjętych w podrozdziale 6.1, to jest dla umownych godzin: 6, 12, 18 i 24. Do porównania modelu w stosunku do systemu wykorzystano model symulacyjny rozbudowany o modele komparatystyczne o strukturze jak na rysunku 6.12. W każdym przypadku wyznaczono najpierw błąd bezwzględny lub rozbieżność pomiędzy wyjściem z modelu i wyjściem z systemu. Przebieg błędu względnego dla godziny 6 zamieszczono na rysunku 6.20, a dla pozostałych wyżej wymienionych godzin zamieszczono w Dodatku B (rys. B.1– B.3).



Rysunek 6.20. Przebiegi błędów względnego modelu w stosunku do systemu RDN dla godziny 6 roku 2019
Oznaczenia: oś x – czas długi (rok).

Źródło: opracowanie własne z wykorzystaniem środowiska Simulink [63, 195].

Wyznaczone błędy względne dla poszczególnych czterech godzin dla roku 2019 dla modelu identyfikacyjnego systemu RDN korygowanego za pomocą SSN kształtowały się w granicach od wartości 5.3898% do wartości 10.5419%. Uzyskane wyniki roczne, jak też wyniki dla losowo wybranego miesiąca (grudzień 2019 r.) oraz dla losowo wybranego tygodnia, w tym wyłącznie dla dni roboczych (pierwszy pełen tydzień grudnia) zamieszczono w tabeli 6.1.

Tabela 6.1. Zestawienie błędów względnych [%] dla wybranych okresów roku 2019 (rok 2019, miesiąc grudzień, tydzień drugi)

Wyszczególnienie	Cały rok 2019	Wybrane miesiące	Wybrane miesiące (tylko dni robocze)	Wybrane tygodnie	Wybrane tygodnie (tylko dni robocze)
Idmodel h6	5.4592	4.8593	4.8124	3.0139	2.8522
Idmodel h6 z korektą SSN	5.3898	3.4630	2.5209	0.7067	1.2561
Idmodel h12	11.2908	13.6850	13.9178	11.5474	11.4246
Idmodel h12 z korektą SSN	10.5419	18.4484	20.6271	20.8508	23.1990
Idmodel h18	11.7733	12.3978	12.4385	14.9105	18.8527
Idmodel h18 z korektą SSN	9.6771	8.2428	7.0387	9.6048	10.2660
Idmodel h24	6.1828	11.0222	11.7006	11.6091	12.1007
Idmodel h24 z korektą SSN	6.3913	11.1542	10.8337	8.9850	10.1781

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Ponadto wyznaczono błędy MAPE modelu systemu RDN dla godzin: 6, 12, 18, 24 roku 2019 oraz modelu systemu RDN skorygowanego za pomocą SSN. Błąd MAPE dla wybranych okresów roku 2019 zamieszczono w tabeli 6.2.

Tabela 6.2. Zestawienie błędów MAPE [%] dla wybranych okresów roku 2019 (rok 2019, miesiąc grudzień, tydzień drugi)

Wyszczególnienie	Cały rok 2019	Wybrane miesiące	Wybrane miesiące (tylko dni robocze)	Wybrane tygodnie	Wybrane tygodnie (tylko dni robocze)
Idmodel h6	5.46	6.57	6.15	3.01	2.85
Idmodel h6 z korektą SSN	5.39	6.81	6.51	3.77	4.58
Idmodel h12	11.50	13.07	14.33	11.24	13.91
Idmodel h12 z korektą SSN	9.55	12.21	12.49	12.81	14.48
Idmodel h18	11.85	8.30	8.60	3.65	3.53
Idmodel h18 z korektą SSN	9.92	11.86	11.99	5.98	5.77
Idmodel h24	6.94	7.89	7.93	8.80	8.89
Idmodel h24 z korektą SSN	6.31	11.07	11.55	5.99	5.57

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Badanie wrażliwości

Badania wrażliwości (eksperyment 4) modelu systemu RDN przeprowadzono na modelu systemu RDN dla godziny 6 roku 2019 dla umownych danych liczbowych dotyczących roku 2020. Zbadano zachowanie się modelu przy wprowadzeniu danych wejściowych dotyczących wolumenu dostarczonej i sprzedanej ee z roku 2020 przy założeniu, że pierwszych piętnaście wielkości wejściowych dotyczy warunków początkowych modelu (ze względu na opóźnienia występujące zarówno w wielomianach $A(z)$, jak i wielomianach $B(z)$). Otrzymano błąd MAPE, który dla wybranych okresów roku 2020 został zestawiony w tabeli 6.3.

Tabela 6.3. Zestawienie błędów MAPE dla wybranych okresów roku 2020 (rok 2020, miesiąc grudzień, tydzień drugi) [%]

Dla godziny 6	Cały rok 2020	Wybrane miesiące	Wybrane miesiące (tylko dni robocze)	Wybrane tygodnie	Wybrane tygodnie (tylko dni robocze)
Idmodel	32.00	7.00	6.70	10.05	4.58
Idmodel z korektą SSN	31.33	7.24	5.99	6.96	3.83

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

6.3. Wyniki badania efektywności, skuteczności i krzepkości modelu i systemu RDN

Wyznaczono także efektywność, skuteczność i krzepkość dotyczącą modelu i systemu na podstawie definicji zamieszczonych podrozdziale 6.1, z wykorzystaniem modelu symulacyjnego zamieszczonego na rysunku B.1 (Dodatek B). Uzyskano zarówno przebiegi poszczególnych wielkości dotyczących efektywności, skuteczności i krzepkości, jak też ich średnie wartości. Wyniki badań dotyczących przebiegów efektywności, skuteczności i krzepkości dla godziny 6 roku 2019 zestawiono w tabeli 6.4 oraz odpowiednio dla godzin: 12, 18, 24 w Dodatku C (tabele C.1–C.3), a odpowiadające im średnie wartości zamieszczono w tabeli 6.5.

Tabela 6.4. Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 6 roku 2019 dla modelu i systemu RDN




Tabela 6.4 cd.





Tabela 6.4 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Wyznaczono także błędy względne dotyczące efektywności, skuteczności i krzepkości modelu i systemu, których średnie wartości zamieszczono w tabeli 6.5, a przebiegi dla godziny 6 zamieszczono w tabeli 6.6 oraz dla godzin: 12, 18, 24 w Dodatku C (tabele C.4 – C.6).

Tabela 6.5. Zestawienie wartości oraz błędów względnych efektywności, skuteczności i krzepkości modelu i systemu dla godzin 6, 12, 18, 24 roku 2019

Wyszczególnienie	Efektywność realizacyjna systemu ²⁴	Efektywność realizacyjna modelu	Skuteczność modelu do systemu	Krzepkość systemu	Krzepkość modelu
Wartości wielkości dla h6	6.8069	6.8201	99.0309	6.8201	6.8629
Błąd względny dla h6	4.8071		5.3898	4.8679	
Wartości wielkości dla h12	7.9114	8.0090	97.3578	8.14749	8.6198
Błąd względny dla h12	9.6291		10.2842	13.2027	
Wartości wielkości dla h18	7.8703	7.5131	95.7859	7.5211	7.3531
Błąd względny dla h18	11.7241		12.4707	11.3745	
Wartości wielkości dla h24	7.2719	7.1941	99.4973	7.4010	7.3093
Błąd względny dla h24	6.0464		6.9568	6.6809	

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

²⁴ W podrozdziale wyróżnione zostały dwa pojęcia efektywności, to jest efektywność systemu oraz efektywność realizacyjną systemu, przy czym efektywność realizacyjna systemu odnosi się do pojęcia efektywności technologicznej a efektywność systemu do pojęcia efektywności ekonomicznej.

Tabela 6.6. Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 6 roku 2019 pomiędzy modelem i systemem RDN





Tabela 6.6 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

W celu wizualnej prezentacji przebiegów efektywności, skuteczności i krzepkości modelu i systemu RDN opracowano odpowiednie modele komparatystyczne, których wyniki zestawiono dla godziny 6 w tabeli 6.7, a dla godzin: 12, 18, 24 w odpowiednich tabelach C.7–C.9 (Dodatek C).

Tabela 6.7. Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 6 roku 2019 modelu i systemu RDN





Tabela 6.7 cd.



Źródło: opracowanie własne z wykorzystaniem MATLAB-a i Simulink-a [63, 195].

Wyznaczone błędy względne dla poszczególnych czterech godzin (6, 12, 18, 24) dla roku 2019 dla:

- efektywności modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 4.8071% dla godziny 6 do wartości 11.7241% dla godziny 18,
- skuteczności modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 5.3898% dla godziny 6 do wartości 12.4707% dla godziny 18,
- krzepkości modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 4.8679% dla godziny 6 do wartości 13.2027% dla godziny 12.

Korzystając z modelu symulacyjnego systemu RDN przeprowadzono badania symulacyjne i badania komparatystyczne dla danych z 2019 r. oraz badanie wrażliwości modelu systemu RDN dla roku 2019 z wykorzystaniem danych z 2020 r. Podsumowanie uzyskanych wyników oraz szczegółowe ich omówienie zamieszczono w rozdziale 7, dotyczącym badania i interpretacji oraz jakości modeli systemu RDN dla godzin: 6, 12, 18, 24.

7. BADANIE I INTERPRETACJA PARAMETRÓW ORAZ BADANIE JAKOŚCI MODELI

7.1. Interpretacja parametrów modeli

W ramach niniejszej rozprawy przeprowadzono identyfikację systemu Rynku Dnia Następnego funkcjonującego na Towarowej Giełdzie Energii S.A., z wykorzystaniem danych liczbowych z lat 2013–2020 dotyczących wolumenu dostarczonej i sprzedanej energii elektrycznej jako wielkości wejściowych oraz średnioważonej wolumenem ceny energii elektrycznej jako wielkości wyjściowych dla wszystkich 24 godzin doby. W wyniku identyfikacji otrzymano katalogi modeli parametrycznych systemu RDN, a więc współczynniki odpowiednich wielomianów. Do identyfikacji przyjęto zakresy danych, to jest:

- od 1 stycznia 2015 r. do 30 czerwca 2015 r. z okresem identyfikacji o długości 184 dni, na bazie których otrzymano po 24 modele parametryczne godzinowe, odpowiednio: dyskretne i ciągłe oraz 24 modele ciągłe w przestrzeni stanów, czyli łącznie 72 modele,
- od 1 stycznia 2013 r. do 30 kwietnia 2016 r. z okresem identyfikacji o długości 184 dni, na bazie których otrzymano po 24 katalogi modeli parametrycznych godzinowych, przy czym każdy katalog zawierał po 35 modeli zadanych w przyjętych okresach krocących z postępowaniem jednego miesiąca, to jest otrzymano łącznie 840 modeli dyskretnych i ciągłych oraz 840 modeli ciągłych w przestrzeni stanów,
- od 1 stycznia 2016 r. do 31.12.2019 r. z okresem identyfikacji o długości 365 dni, na bazie których w każdym z czterech lat, to jest dla roku: 2016, 2017, 2018, 2019 otrzymano po 24 modele parametryczne dyskretne oraz ciągłe, a w ślad za tym 24 modele ciągłe w przestrzeni stanów, czyli łącznie 288 modeli,
- od 1 stycznia 2020 r. do 31.12.2020 r. z okresem identyfikacji o długości 365 dni, na bazie których zbudowano model symulacyjny do badania wrażliwości 24 modeli parametrycznych dyskretnych oraz ciągłych, a w ślad za tym 24 modeli ciągłych w przestrzeni stanów, czyli łącznie do badania wrażliwości zbudowano 72 modele.

Ponadto na bazie modeli symulacyjnych zbudowano modele komparatystyczne do badania dokładności otrzymanych modeli oraz ich efektywności, skuteczności i krzepkości.

W przypadku danych wykorzystanych w identyfikacji w okresie od 1 stycznia 2015 r. do 30 czerwca 2015 r. otrzymano modele typu MISO (dla wszystkich wejść oraz pojedynczych

wyjąć odrębnych dla każdej godziny doby), które wykorzystano zwłaszcza na poziomie modeli zmiennych stanu do przeprowadzenia analizy systemu RDN ze zwróceniem szczególnej uwagi na poziom sterowania oraz na stopień wewnętrznej organizacji systemu. Do analizy wykorzystano macierz **A** oraz macierz **B** odpowiedzialne odpowiednio za wyżej wymienione własności systemu.

Z analizy struktury macierzy **A** występującej we wszystkich 24 godzinowych modelach systemu RDN wynika m.in., że o stopniu wewnętrznego zorganizowania systemu RDN w okresie I półrocza 2015 r. decydowały głównie cztery zmienne stanu oraz 7 elementów macierzy **A**, to jest a_{14} , a_{21} , a_{24} , a_{32} , a_{34} , a_{43} i a_{44} na 16 elementów występujących macierzy **A** (43,8%).

W celu zbadania natury zmiennych stanu ustalono najpierw na podstawie równania (4.6), że z macierzy **C** wynika, iż tylko zmienna stanu x_4 miała wpływ na wielkość wyjściową y_1 , czyli na średnioważoną wolumenem cenę uzyskaną z tytułu sprzedaży ee w poszczególnych godzinach doby.

Dalej zauważono w równaniu (4.6), że średnioważona wolumenem cena ee w kolejnej godzinie doby zależy jedynie od zmiennej stanu x_4 . Zatem zinterpretowano zmienną stanu x_4 jako moc [MW] wynikającą z ee dostarczonej i sprzedanej na RDN [MWh] w kolejnej godzinie doby przy założeniu, że element c_{14} macierzy **C** wyrażony jest w jednostce [PLN/(MWh x MW)], co można zinterpretować jako średnia jednostkowa wazona wolumenem cena ee w kolejnej godzinie doby (w rozważanym przykładzie w godzinie 0–1) przypadająca na jednostkę mocy związanej z ee wyprodukowaną i dostarczoną na RDN w ciągu dnia (w ciągu poszczególnych godzin całej doby).

Stąd też element c_{14} można zinterpretować jako szybkość zmiany jednostkowej ceny mocy w danej godzinie w odniesieniu do mocy dostarczonej i sprzedanej w ciągu całej doby. Ze względu na to, że zmienna stanu x_4 została zinterpretowana jako moc związana z ee dostarczoną i sprzedaną na RDN w ciągu kolejnych godzin doby, stąd też zinterpretowano kolejne zmienne stanu odpowiednio: x_1 jako ee dostarczona i sprzedana na RDN w ciągu kolejnych godzin doby [MWh], x_2 jako ee dostarczona i sprzedana na RDN w ciągu kolejnej godziny doby w okresie przez całą dobę [MWh x doba] oraz x_3 jako ee dostarczona i sprzedana na RDN w ciągu kolejnej godziny doby przez całą dobę oraz przez cały okres pomiarowy [MWh x doba x półrocze].

Na szczególną uwagę zasługuje zatem model zmiennych stanu, w tym oprócz możliwej istotnej interpretacji zmiennych stanu ważne jest również przeprowadzenie interpretacji elementów macierzy wewnętrznej organizacji systemu (macierzy **A**) oraz interpretacji macierzy elementów sterowania (macierzy **B**), a czasami także macierzy oddziaływania wewnętrznej organizacji systemu zarządzania jako systemu RDN na średnioważonej wolumenem cenę ee w każdej odrębnie godzinie doby (macierzy **C**) i sporadycznie macierz sprzężeń systemu RDN z otoczeniem (macierzy **D**), która w przeprowadzonych badaniach posiada elementy równe zero lub bliskie zera.

W przypadku macierzy wewnętrznej organizacji systemu sterowania RDN ustalono między innymi, że:

a₁₄ – wyraża stopień wpływu zmiennej stanu x_4 , to jest mocy związanej z ee sprzedaną w kolejnych godzinach doby na pochodną zmiennej stanu x_1 , to jest częstotliwość zmian mocy w kolejnych godzinach doby,

a₂₁ – wyraża stopień wpływu zmiennej stanu x_1 , to jest sprzedanej ee w kolejnych godzinach doby na pochodną zmiennej stanu x_2 , to jest moc związaną ze sprzedaną ee w kolejnych godzinach doby,

a₂₄ – wyraża stopień wpływu zmiennej stanu x_4 , to jest mocy związanej ze sprzedaną ee na pochodną zmiennej stanu x_2 , to jest moc związaną ze sprzedaną ee w kolejnych godzinach doby,

a₃₂ – wyraża stopień wpływu zmiennej stanu x_2 , to jest sprzedanej ee w kolejnych godzinach doby w odniesieniu do całej doby na pochodną zmiennej stanu x_3 to jest moc związaną ze sprzedaną ee,

a₃₄ – wyraża stopień wpływu sprzedaży ee w godz. 3–4 na uzyskiwanie średniej ceny ee w godz. 2–3,

a₄₃ – wyraża stopień wpływu sprzedaży ee w godz. 2–3 na uzyskiwanie średniej ceny ee w godz. 3–4,

a₄₄ – wyraża stopień wpływu sprzedaży ee w godz. 3–4 na uzyskiwanie średniej ceny ee w godz. 3–4.

Natomiast w przypadku macierzy sterowania systemem RDN ustalono między innymi, że:

b₁₁ – wyraża stopień wpływu sprzedaży wolumenu ee w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₁₇ – wyraża stopień wpływu sprzedaży wolumenu ee w godz. 6–7 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₁₁₃ – wyraża stopień wpływu sprzedaży ee w godz. 12–13 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₁₁₉ – wyraża stopień wpływu sprzedaży ee w godz. 18–19 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₂₁ – wyraża stopień wpływu sprzedaży ee w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₃₁ – wyraża stopień wpływu sprzedaży ee w godz. 0–1 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby,

b₄₁ – wyraża stopień wpływu sprzedaży ee w godz. 3–4 na stopień wewnętrznej organizacji systemu RDN w kolejnych godzinach doby.

W przypadku danych wykorzystanych w identyfikacji w okresie od 1 stycznia 2013 r. do 30 kwietnia 2016 r. otrzymano także modele parametryczne dyskretne arx systemu RDN dla okresów 184 umownych dni z postępem jednego miesiąca (dla wszystkich wejść oraz pojedynczych wyjść odrębnych dla każdej godziny doby), których parametry wykorzystano do metaidentyfikacji systemu RDN. Łącznie otrzymano 35 modeli typu MISO, a więc modeli parametrycznych dyskretnych dla każdej godziny doby, które konwertowano na modele parametryczne ciągłe, a te na modele ciągłe zmiennych stanu. W szczególności zbadano zmiany współczynników wielomianu $A1(z)$ oraz wielomianu $B1(z)$ dla wszystkich badanych okresów oraz wykorzystano je do otrzymania metamodelu parametrycznego dyskretnego, który konwertowano następnie na metamodel parametryczny ciągły, a ten na metamodel ciągły w przestrzeni stanów.

W przypadku badania zmian współczynników wielomianów występujących w modelu parametrycznym dyskretnym zauważono, że w badanych okresach umownych od okresu p_1 (1.01.2013–30.06.2013) do okresu p_{35} (1.11.2015–30.04.2016) wystąpiło 6 zmian

strukturalnych związanych ze zmianą stopnia wewnętrznego zorganizowania systemu (zmiany wymiaru macierzy **A**) oraz 6 zmian strukturalnych związanych ze zmianą poziomu sterowania (zmiany wymiaru macierzy **B**), to jest z okresu na okres p11/p12, p13/p14, p18/p19, p22/p23, p29/p30 oraz p30/p31 oraz w każdym okresie (p1–p35) zmiany parametryczne (zmiany wartości elementów macierzy **A** oraz macierzy **B**), przy czym zmiany stopnia wewnętrznego zorganizowania systemu RDN oraz zmiany poziomu sterowania systemem RDN były ze sobą powiązane.

W przebiegu zmian wartości elementu a_{21} w badanych 35 okresach funkcjonowania systemu RDN zauważono między innymi, że występowały zmiany wartości ww. elementów macierzy wewnętrznej organizacji procesu (macierzy **A**) od wartości 0,125 (wartości minimalne), poprzez wartości 0,2500 (wartości pośrednie) do wartości 0,5000 (wartości maksymalne). Element a_{21} macierzy **A** wyraża intensywność wpływu zmiennej stanu x_1 na pochodną zmiennej stanu x_2 . Odnotowano także przebieg zmian wartości elementu a_{15} w 35 umownych okresach badania systemu RDN, przy czym wartość minimalna elementu a_{15} wynosiła -0,5440, a maksymalna 0,2378. Warto między innymi zauważyć, że element a_{15} macierzy **A** wyraża intensywność wpływu zmiennej stanu x_5 na pochodną zmiennej stanu x_1 . Dalej pokazano przebieg zmian wartości elementu a_{55} w 35 badanych okresach funkcjonowania systemu RDN, przy czym minimalna wartość elementu a_{55} wynosiła -7,5671, a wartość maksymalna -1,2903. Zauważono, że ten element nigdy nie miał wartości dodatnich i wyrażał intensywność wpływu zmiennej stanu x_5 na pochodną zmiennej stanu x_5 . Przebiegi wartości elementów a_{15} oraz a_{55} zobrazowały zmiany struktury, która charakteryzowała się brakiem ciągłości w jej przebiegu. Dalej pokazano przebiegi wartości wybranych elementów macierzy **B**, to jest elementu b_{12} , elementu b_{54} oraz elementu b_{15} . Wartość elementu b_{12} wyraża wpływ na pochodną zmiennej stany x_1 wartości zmiennej sterującej u_2 , wartość elementu b_{54} – wpływ na pochodną zmiennej stany x_5 wartości zmiennej sterującej u_4 , a wartość elementu b_{15} – wpływ na pochodną zmiennej stanu x_1 wartości zmiennej sterującej u_5 .

Ponadto bardzo istotny był przebieg wartości elementu macierzy c_{15} macierzy **C** odpowiadającej za siłę powiązań systemu RDN (jego zmiennej stanu x_5) z otoczeniem (odbiorcami/kupcami energii elektrycznej). Interesującym przypadkiem jest również przebieg wartości elementu c_{15} macierzy **C** odpowiadającej za siłę powiązań systemu RDN (jego zmiennej stanu x_5) z otoczeniem (odbiorcami/kupcami energii elektrycznej). Przebieg wartości

tego elementu zmienił się z wartości 1,0000 na wartość 2,000 do okresu p25, po czym się ustabilizował na poziomie wartości 2,0000 i dalej nie zmienił się.

Interpretacja zmiennych stanu, jak też elementów macierzy organizacji wewnętrznej procesu oraz macierzy sterowania okazała się możliwa do przeprowadzenia w podobny sposób jak dla okresu od 1 stycznia 2015 r. do 30 czerwca 2015 r.

Okazało się dalej między innymi, że występująca w systemie RDN równowaga i stabilność jego funkcjonowania dotyczyły tych samych charakterystyk zmian systemu w czasie długim, to jest w 35 okresach. Różnica pojawiła się wówczas, gdy doszło do równowagi dynamicznej, która zmieniała się w czasie w zależności od zmiany otoczenia (zmiany dostawców i odbiorców energii elektrycznej na RDN). Tutaj jednak, chociaż równowaga jest osiągana ze względu na stabilność systemu, to niemniej dodatkowo może być podtrzymywana przez sterowanie. Identyfikatorami stabilności i miernikami jej poziomów są pierwiastki charakterystyczne macierzy wewnętrznej organizacji systemu **A**, która uwzględnia m.in. bieżące dostosowania w obrębie danej jednostki czasu (występowanie zer na głównej przekątnej w macierzy **A** oznacza, że w tych elementach nie występują samosprężenia).

7.2. Ocena jakości modelu i systemu

W przypadku danych wykorzystanych w identyfikacji od 1 stycznia 2016 r. do 31 grudnia 2019 r. otrzymano w wyniku identyfikacji po 24 modele systemu RDN typu dyskretnego oraz ciągłego, a w ślad za tym 24 modele ciągłe w przestrzeni stanów odpowiednio dla poszczególnych lat: 2016, 2017, 2018 i 2019. Do szczegółowej analizy wykorzystano po cztery modele dla każdego roku, to jest odpowiednio dla godzin: 6, 12, 18, 24, ustalając dla nich między innymi błędy względne, błędy MAPE oraz efektywność, skuteczność i krzepkość modeli i systemów RDN z wykorzystaniem odpowiednich modeli symulacyjnych i komparatystycznych. Błędy względne wynosiły odpowiednio od wartości 5.39% dla godziny 6 dla roku 2019 do wartości 10.54% dla godziny 12 roku 2019. Wyznaczono ponadto błędy dla wybranych miesięcy 2019 roku, które wyniosły odpowiednio od wartości 3.46% dla godziny 6 w grudniu 2019 r. dla skorygowanego modelu systemu RDN do wartości 13.69% dla godziny 12 w grudniu 2019 r. dla modelu systemu RDN. Wyznaczono także błędy dla wybranych tygodni (pierwszy pełny tydzień grudnia) 2019 roku, które wyniosły odpowiednio od wartości 0.71% dla godziny 6 w grudniu 2019 r. dla skorygowanego modelu systemu RDN

do wartości 14.91% dla godziny 12 w grudniu 2019 r. dla modelu systemu RDN. Przy uwzględnieniu tylko dni roboczych w miesiącu wahały się od wartości 2.5209% do wartości 13.92% oraz w tygodniu wahały się od wartości 1.26% do wartości 11.42%.

Błędy MAPE wynosiły odpowiednio od wartości 5.39% dla godziny 6 dla roku 2019 do wartości 9.55% dla godziny 12 roku 2019. Wyznaczono ponadto błędy dla wybranych miesięcy 2019 roku, które wyniosły odpowiednio od wartości 6.57% dla godziny 6 w grudniu 2019 r. dla modelu systemu RDN do wartości 12.21% dla godziny 12 w grudniu 2019 r. dla skorygowanego modelu systemu RDN. Wyznaczono także błędy dla wybranych tygodni (pierwszy pełny tydzień grudnia) 2019 roku, które wyniosły odpowiednio od wartości 3.01% dla godziny 6 w grudniu 2019 r. do wartości 11.24% dla godziny 12 w grudniu 2019 r. dla modelu systemu RDN. Przy uwzględnieniu tylko dni roboczych w miesiącu wahały się od wartości 6.15% do wartości 12.49% oraz w tygodniu wahały się od wartości 2.85% do wartości 13.91%.

Wyznaczone wartości efektywności systemu i modelu wahały się odpowiednio od 6.81% i 6.82% dla godziny 6 roku 2019 do 7.91% i 8.01% dla godziny 12 roku 2019, a wartości skuteczności modelu do systemu wahały się odpowiednio od 95.79% dla godziny 18 roku 2019 do 99.50% dla godziny 24 roku 2019 oraz wartości krzepkości systemu i modelu wahały się odpowiednio od 6.82% i 6.86% dla godziny 6 roku 2019 do 8.15% i 8.62% dla godziny 12 roku 2019.

Wyznaczone także błędy względne dla poszczególnych czterech godzin (6, 12, 18, 24) dla roku 2019 dla: efektywności modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 4.81% dla godziny 6 do wartości 11.72% dla godziny 18, skuteczności modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 5.39% dla godziny 6 do wartości 12.47% dla godziny 18, krzepkości modelu systemu RDN skorygowanego za pomocą SSN kształtowały się w granicach od wartości 4.87% dla godziny 6 do wartości 13.20% dla godziny 12.

7.3. Badanie efektywności w zależności od wolumenu ee

Zbadano ponadto efektywność w zależności od wolumenu ee dla godzin 6, 12, 18, 24 dla roku 2019. Uzyskane przebiegi zamieszczono w tabeli 7.1. Można zauważyć, że wraz ze wzrostem wolumenu dostarczonej i sprzedanej ee następował spadek efektywności modelu

systemu RDN, dla założonych wartości uzyskanej ceny z tytułu dostarczonej i sprzedanej ee oraz skuteczności modelu do systemu. Zestawienie efektywności w zależności od wolumenu ee dla godzin: 6, 12, 18, 24 roku 2019 pokazano na rysunku 7.1. Z analizy potęgowych linii trendu dla wyżej wymienionych czterech godzin wynika między innymi, że największy spadek efektywności wystąpił dla godziny 24, a najniższy dla godziny 6. Poszczególne linie trendu efektywności realizacyjnej wyrażone zostały następującymi zależnościami:

$$\begin{aligned}\Lambda_6 &= 373026 u_6^{-1,363}, \\ \Lambda_{12} &= 45265 u_{12}^{-1,069}, \\ \Lambda_{18} &= 167964 u_{18}^{-1,245}, \\ \Lambda_{24} &= 707966 u_{24}^{-1,451},\end{aligned}\tag{6.12}$$

z których wynika, że efektywność realizacyjna modelu systemu RDN jest odwrotnie proporcjonalna do wolumenu dostarczonej i sprzedanej ee dla założonych wartości uzyskanej ceny z tytułu dostarczonej i sprzedanej ee oraz skuteczności modelu do systemu.

Tabela 7.1. Efektywność w zależności od wolumenu ee dla godzin 6, 12, 18, 24 2019 r.




Tabela 7.1 cd.






Tabela 7.1 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].



Rysunek 7.1. Zestawienie efektywności w zależności od wolumenu ee dla godzin 6, 12, 18, 24 2019 r.
Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

7.4. Badanie skuteczności w zależności od wolumenu ee

Zbadano również skuteczność w funkcji wolumenu ee dla godzin: 6, 12, 18, 24 dla roku 2019. Uzyskane przebiegi zamieszczono w tabeli 7.3. Można zauważyć, że wraz ze wzrostem wolumenu dostarczonej i sprzedanej ee następował spadek skuteczności modelu systemu RDN dla założonych wartości minimalnej, średniej, maksymalnej uzyskanej ceny z tytułu dostarczonej i sprzedanej ee oraz wartości minimalnej, średniej, maksymalnej uzyskanej efektywności modelu systemu RDN. Poszczególne przebiegi skuteczności wyrażone zostały następującymi zależnościami zamieszczonymi w tabeli 7.2.

Tabela 7.2. Skuteczność w funkcji zasobów dla stałej średnioważonej wolumenem ceny ee i stałej efektywności realizacyjnej modelu systemu RDN

Warunki brzegowe	h6	h12	h18	h24
Cena minimalna i efektywność minimalna	$\Gamma_6 = 548187 u_6^{-1}$	$\Gamma_{12} = 521116 u_{12}^{-1}$	$\Gamma_{18} = 811955 u_{18}^{-1}$	$\Gamma_{24} = 512917 u_{24}^{-1}$
Cena średnia i efektywność średnia	$\Gamma_6 = 302666 u_6^{-1}$	$\Gamma_{12} = 325018 u_{12}^{-1}$	$\Gamma_{18} = 328702 u_{18}^{-1}$	$\Gamma_{24} = 276854 u_{24}^{-1}$
Cena maksymalna i efektywność maksymalna	$\Gamma_6 = 212195 u_6^{-1}$	$\Gamma_{12} = 312561 u_{12}^{-1}$	$\Gamma_{18} = 275419 u_{18}^{-1}$	$\Gamma_{24} = 202131 u_{24}^{-1}$

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Dla utrzymania 100% skuteczności modelu do systemu RDN z analizy otrzymanych wyników badań zestawionych w tabeli 6.18 wynika między innymi, że dla:

- minimalnej średnioważonej wolumenem ceny ee i minimalnej efektywności realizacyjnej wynoszących odpowiednio dla godziny:
 - 6 – 40.14 PLN/MWh i 0.732232174 PLN/MWh², wolumen wynosił 5481.87 MWh
 - 12 – 65.31 PLN/MWh i 1.253271555 PLN/MWh², wolumen wynosił 5211.16 MWh
 - 18 – 121.92 PLN/MWh i 1.50156118 PLN/MWh², wolumen wynosił 8119.55 MWh
 - 24 – 58.71 PLN/MWh i 1.144628741 PLN/MWh², wolumen wynosił 5129.17 MWh
- średniej średnioważonej wolumenem ceny ee i średniej efektywności realizacyjnej wynoszących odpowiednio dla godziny:

-
- 6 – 206.42 PLN/MWh i 6.82010399 PLN/MWh², wolumen wynosił 3026.66 MWh
- 12 – 260.31 PLN/MWh i 8.008959664 PLN/MWh², wolumen wynosił 3250.18 MWh
- 18 – 247.89 PLN/MWh i 7.54151414 PLN/MWh², wolumen wynosił 3287.02 MWh
- 24 – 199.17 PLN/MWh i 7.194131867 PLN/MWh², wolumen wynosił 2768.54 MWh
- maksymalnej średnioważonej wolumenem ceny ee i maksymalnej efektywności realizacyjnej wynoszących odpowiednio dla godziny:
- 6 – 287.93 PLN/MWh i 13.56912431 PLN/MWh², wolumen wynosił 2121.95 MWh
- 12 – 475.44 PLN/MWh i 15.21113484 PLN/MWh², wolumen wynosił 312561MWh
- 18 – 466.91 PLN/MWh i 16.95273783 PLN/MWh², wolumen wynosił 2754.19 MWh
- 24 – 273.84 PLN/MWh i 13.54763774 PLN/MWh², wolumen wynosił 2021.31 MWh

Z przeprowadzonej analizy wynika, że utrzymanie skuteczności modelu do systemu RDN o wartości zbliżonej do 100% dla średniej średnioważonej wolumenem ceny ee i średniej efektywności, wiąże się z koniecznością prognozowania wolumenu ee w granicach od 2768.54 MWh dla godziny 24 do około 3–3.3 tys. MWh dla pozostałych godzin, to jest 6, 12 i 18.

Natomiast utrzymanie skuteczności modelu do systemu RDN o wartości zbliżonej do 100% dla maksymalnej średnioważonej wolumenem ceny ee i maksymalnej efektywności, wiąże się z koniecznością prognozowania wolumenu ee w granicach od około 2–2.1 tys. MWh odpowiednio dla godziny 24 i 6 do około 2.7–3.1 tys. MWh dla odpowiednio godziny 18 i 12.

Z powyższej konstatacji wynika między innymi konieczność ustalania granic obrotu wolumenem ee na giełdzie w celu utrzymania stosunkowo wysokiej skuteczności modelu (każdy model uzyskany w wyniku identyfikacji może zostać dalej wykorzystany na określonym ściśle poziomie obrotu ee).

Tabela 7.3. Przebiegi skuteczność w funkcji zasobów, to jest wolumenu ee dla godzin 6, 12, 18, 24 2019 r. dla stałej średnioważonej wolumenu ceny ee i stałej efektywności realizacyjnej modelu systemu RDN





Tabela 7.3 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

7.5. Badanie skuteczności od średniowej wolumenem ceny ee

Dokonano również analizy skuteczności w zależności od średniowej wolumenem ceny ee odniesionej do wolumenu dla godzin: 6, 12, 18, 24 2019 r., z której wyniki zamieszczono w tabeli 7.4.

Tabela 7.4. Skuteczność w zależności od średniowej wolumenem ceny ee odniesionej do wolumenu dla godzin 6, 12, 18, 24 2019 r.





Tabela 7.4 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

W wyniku przeprowadzonych badań uzyskano skupienia punktów, na bazie których trudno jest określić linie trendu. Takie skupienia punktów mogą stanowić nowy kierunek badań i być dalej badane z wykorzystaniem metod analizy skupień, co nie było przedmiotem niniejszych badań.

Kluczowym zagadnieniem w zakresie badania efektywności modelu i systemu RDN oraz skuteczności modelu do systemu jest badanie krzepkości, którą zdefiniowano w podrozdziale 2.8 jako swoistą równowagę pomiędzy efektywnością i skutecznością systemu RDN wyrażoną iloczynem skuteczności modelu do systemu i efektywności modelu lub systemu.

7.6. Badanie krzepkości w zależności od wolumenu ee

Krzepkość zbadano w zależności od wolumenu ee dla godzin: 6, 12, 18, 24 dla roku 2019. Uzyskane przebiegi zamieszczono w tabeli 7.5. Można zauważyć, że wraz ze wzrostem wolumenu dostarczonej i sprzedanej ee następował spadek krzepkości modelu systemu RDN dla założonych wartości uzyskanej średnioważonej ceny wolumenem ee z tytułu dostarczonej i sprzedanej ee. Zestawienie krzepkości w zależności od wolumenu ee dla godzin: 6, 12, 18, 24 2019 r. pokazano na rysunku 7.2. Z analizy potęgowych linii trendu dla wyżej wymienionych czterech godzin wynika między innymi, że największy spadek krzepkości wystąpił dla godziny 24, a najniższy dla godziny 12. Poszczególne linie trendu krzepkości wyrażone zostały następującymi zależnościami:

$$\begin{aligned}\Xi_6 &= 297902 u_6^{-1,334}, \\ \Xi_{12} &= 50510 u_{12}^{-1,08}, \\ \Xi_{18} &= 137136 u_{18}^{-1,227}, \\ \Xi_{24} &= 1682143 u_{24}^{-1,559},\end{aligned}\tag{6.13}$$

z których wynika, że krzepkość modelu systemu RDN jest odwrotnie proporcjonalna do wolumenu dostarczonej i sprzedanej ee dla założonych wartości uzyskanej średnioważonej wolumenem ee ceny z tytułu dostarczonej i sprzedanej ee.

Tabela 7.5. Krzepkość w funkcji wolumenu dla godzin 6, 12, 18, 24 2019 r.






Tabela 7.5 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].



Rysunek 7.2. Zestawienie krzepkości w funkcji wolumenu ee dla godzin 6, 12, 18, 24 2019 r.

Oznaczenia: oś x – wolumen dostarczonej i sprzedanej ee w poszczególnych godzinach doby, oś y – krzepkość modelu systemu RDN dla poszczególnych godzin doby.

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

W wyniku przeprowadzonej analizy zależności pokazanych na rysunku 7.2 można zauważyć, że model systemu dla godziny 12 okazał się modelem najbardziej krzepkim a model dla godziny 24 okazał się modelem najmniej krzepkim.

Z przeprowadzonej analizy przebiegów krzepkości dla poszczególnych godzin zamieszczonych w tabeli 7.7 wynika, że utrzymanie stałej wartości krzepkości modelu systemu RDN (swoistej równowagi pomiędzy efektywnością i skutecznością systemu):

- dla godziny 6 na poziomie średnim w wysokości 6.42 wiąże się z koniecznością utrzymania poziomu wolumenu dostarczonej i sprzedanej ee w wysokości 3233.61 MWh (wartość średnia wolumenu dostarczonej i sprzedanej ee w 2019 r.), przy czym krzepkość zmieniała się od wartości minimalnej 1.29 do maksymalnej 8.23,
- dla godziny 12 na poziomie średnim w wysokości 7.71 wiąże się z koniecznością utrzymania poziomu wolumenu dostarczonej i sprzedanej ee w wysokości 3412.33 MWh (wartość średnia wolumenu dostarczonej i sprzedanej ee w 2019 r.), przy czym krzepkość zmieniała się od wartości minimalnej 1.94 do maksymalnej 12.64,
- dla godziny 18 na poziomie średnim w wysokości 7.76 wiąże się z koniecznością utrzymania poziomu wolumenu dostarczonej i sprzedanej ee w wysokości

3280.05 MWh (wartość średnia wolumenu dostarczonej i sprzedanej ee w 2019 r.), przy czym krzepkość zmieniała się od wartości minimalnej 5.02 do maksymalnej 13.10,

- dla godziny 24 na poziomie średnim w wysokości 6.87 wiąże się z koniecznością utrzymania poziomu wolumenu dostarczonej i sprzedanej ee w wysokości 2891.60 MWh (wartość średnia wolumenu dostarczonej i sprzedanej ee w 2019 r.), przy czym krzepkość zmieniała się od wartości minimalnej 2.03 do maksymalnej 9.24.

Otrzymane wyniki analizy zestawiono w tabelach 7.6 i 7.7.

Tabela 7.6. Krzepkość w funkcji zasobów, to jest wolumenu ee dla godzin 6, 12, 18, 24 2019 r. dla stałych minimalnej, maksymalnej oraz średniej średnioważonej wolumenem ceny ee modelu systemu RDN




Tabela 7.6 cd.





Tabela 7.6 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela 7.7. Zestawienie wyników analizy krzepkości modelu systemu RDN dla średniego wolumenu ee dla godzin 6, 12, 18, 24 2019 r.

Godzina	Krzepkość minimalna	Krzepkość średnia	Krzepkość maksymalna	Średni wolumen ee
h6	1.29	6.42	8.23	3233.61
h12	1.94	7.71	12.64	3412.33
h18	5.02	7.76	13.10	3280.05
h24	2.03	6.87	9.24	2891.60

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Najbardziej krzepkim modelem (o największej wartości iloczynu efektywności i skuteczności) okazał się model systemu RDN dla godziny 18, a najmniej krzepkim model dla godziny 6, co można zinterpretować, że dla godziny 18 występuje najwyższa z badanych swoista równowaga pomiędzy efektywnością i skutecznością modelu systemu RDN, która wynosi od 5.02 do 13.10 dla średniego wolumenu ee wynoszącego 3280.05 MWh.

PODSUMOWANIE, WNIOSKI I KIERUNKI DALSZYCH BADAŃ

Modelowaniem systemu Rynku Dnia Następnego zainteresowani są wszyscy uczestnicy Towarowej Giełdy Energii Elektrycznej, a więc zarówno dostawcy, odbiorcy (coraz częściej też prosumenci) jak również pośrednicy w handlu energią elektryczną, w tym TGE S.A. Jedną z grup metod modelowania jest modelowanie identyfikacyjne.

Ogólny cel rozprawy, którym było przeprowadzenie modelowania identyfikacyjnego i metaidentyfikacyjnego w kategoriach systemowych systemu RDN funkcjonującego na TGE S.A. został osiągnięty dzięki odpowiedniej realizacji następujących celów szczegółowych:

- 1) umiejscowienia systemu Rynku Dnia Następnego w ujęciu inżynierii systemów i nauk o zarządzaniu i jakości na tle problematyki badań dotyczącej systemu Rynku Energii Elektrycznej,
- 2) dokonania przeglądu metod modelowania identyfikacyjnego w ujęciu systemowym, w tym: opisu istoty identyfikacji, przeglądu możliwości uzyskiwania modeli systemów, przeglądu metod wykorzystywanych w modelowaniu systemów TGE S.A., opisu modelowania identyfikacyjnego systemu RDN, krytycznego przeglądu literatury przedmiotu w zakresie uzyskiwania wystarczająco dokładnych modeli systemu RDN,
- 3) opracowania metodyki badań identyfikacyjnych i metaidentyfikacyjnych systemu RDN, w tym opisu etapów procesu badawczego, ujęcia systemowego RDN jako systemu zarządzania oraz jego oceny w kategoriach efektywności, skuteczności i krzepkości,
- 4) przeprowadzenia identyfikacji i wygenerowania katalogu modeli parametrycznych dyskretnych i ciągłych systemu RDN oraz katalogu modeli ciągłych w przestrzeni stanów,
- 5) przeprowadzenia metaidentyfikacji i wygenerowania metamodeli parametrycznych dyskretnych i ciągłych systemu RDN oraz metamodeli ciągłych w przestrzeni stanów,
- 6) zbudowania modeli symulacyjnych i następnie przeprowadzenia z ich wykorzystaniem badań symulacyjnych, komparatystycznych oraz badania wrażliwości z punktu widzenia sformułowanych kryteriów dokładności modelu i systemu z uwzględnieniem błędów względnych oraz błędów MAPE, a także z punktu widzenia efektywności i krzepkości modelu i systemu oraz skuteczności modelu do systemu RDN,

- 7) przeprowadzenia interpretacji parametrów modeli oraz badania zmiany jakości modelu, w tym w zakresie przebiegów skuteczności, efektywności i krzepkości w funkcji zasobów jakim jest wolumen dostarczonej i sprzedanej na RDN energii elektrycznej w badanej godzinie doby,
- 8) sformułowania wniosków końcowych oraz dalszych kierunków badań.

A zatem w niniejszej rozprawie wykazano, że obie hipotezy zostały pozytywnie zweryfikowane, to jest:

- osiągnięto stosunkowo wysoką jakość modeli parametrycznych dyskretnych systemu RDN uzupełnionych modelami neuralnymi, uzyskanych w wyniku identyfikacji przeprowadzonej z wykorzystaniem inżynierii systemów, a w konsekwencji także modeli parametrycznych ciągłych oraz modeli ciągłych w przestrzeni stanu systemu RDN TGE S.A., przy czym szczegółowe badania przeprowadzone dla czterech charakterystycznych godzin roku 2019 (6, 12, 18, 24) wykazując, że wyznaczone błędy względne dla poszczególnych godzin kształtowały się w granicach od 5.39% do 10.54%, a więc uzyskane modele były o stosunkowo wysokiej dokładności w odniesieniu do systemów rzeczywistych RDN TGE S.A., jak dla przyjętego długiego horyzontu badań,
- uzyskano wystarczająco liczny katalog 35 modeli parametrycznych w układzie krocącym, który umożliwił przeprowadzenie metaidentyfikacji prowadzącej do uzyskania metamodeli parametrycznych oraz metamodeli neuronalnych systemu RDN, przy czym okazało się, że w zależności od modelu krocącego rozbieżności w wielkościach wyjściowych z metamodeli w odniesieniu do danych parametrów odpowiedniego modelu systemu RDN zmieniały się na przykład dla parametru a_1 (będącego wagą uzyskiwanej średnioważonej wolumenem ceny ee) w granicach od -0.2 do 0.2 – wartości wyrażone bezmianowo. Metaidentyfikację przeprowadzono na podstawie danych liczbowych notowanych na Rynku Dnia Następnego Towarowej Giełdy Energii S.A. w okresie od 1 stycznia 2013 r. do 30 kwietnia 2016 r., dla 24 zmiennych wejściowych w odniesieniu do całkowitej wielkości wolumenu dostarczonej i sprzedanej energii elektrycznej wszystkich transakcji przeprowadzonych na sesji giełdowej w poszczególnych godzinach doby (zmiennie wejściowe) [MWh] oraz dla pojedynczych wielkości wyjściowych związanych z otrzymaną

średnioważoną wolumenem ceną uzyskaną z tytułu dostarczenia i sprzedaży energii elektrycznej ze wszystkich transakcji na sesji giełdowej dla danej godziny doby [PLN/MWh]. W ten sposób uzyskano 24 modele o 24 zmiennych wejściowych (wolumeny z poszczególnych godzin doby) oraz pojedyncze zmienne wyjściowe (średnioważone wolumenem ceny w poszczególnych 24 godzinach doby).

Weryfikacja pozytywna sformułowanych hipotez wiązała się ponadto ze zbadaniem błędów względnych dotyczących wybranych czterech godzin roku 2019 (6, 12, 18, 24), przy czym zbadano także błędy względne dla grudnia 2019 roku, w tym dla dni roboczych grudnia oraz dla pierwszego pełnego tygodnia grudnia, a także dni roboczych tego tygodnia. W przypadku wybranego miesiąca błędy względne wynosiły od 3.46% dla godziny 6 do 13.69% dla godziny 12. W przypadku dni roboczych grudnia błędy te wynosiły od 2.52% dla godziny 6 do 13.92% dla godziny 12. Podobnie błędy względne dla pierwszego pełnego tygodnia grudnia wahały się od 0.71% dla godziny 6 do 14.91% dla godziny 18, przy uwzględnieniu tylko dni roboczych wynosiło od 1.26% dla godziny 6 do 11.42% dla godziny 12. Z analizy kształtowania się błędu względnego wynika, że w każdym przypadku najmniejszy błąd względny występował dla godziny 6, a największy dla godziny 12, z wyłączeniem przypadku pierwszego pełnego tygodnia, który był największy dla godziny 18.

Zbadano również błędy MAPE dla grudnia 2019 roku, w tym dla dni roboczych grudnia oraz dla pierwszego pełnego tygodnia grudnia, a także dla dni roboczych tego tygodnia. W przypadku wybranego miesiąca błędy MAPE wynosiły od 6.57% dla godziny 6 do 12.51% dla godziny 12. W przypadku dni roboczych grudnia błędy te wynosiły od 6.15% dla godziny 6 do 12.49% dla godziny 12. Podobnie błędy MAPE dla pierwszego pełnego tygodnia grudnia wahały się od 3.01% dla godziny 6 do 13.24% dla godziny 12, przy uwzględnieniu tylko dni roboczych wynosiło od 2.85% dla godziny 6 do 13.91% dla godziny 12. Z analizy kształtowania się błędu MAPE wynika, że w każdym przypadku najmniejszy błąd MAPE występował dla godziny 6, a największy dla godziny 12.

Na podkreślenie zasługuje fakt, że zarówno błędy względne jak też błędy MAPE dotyczyły dokładności dopasowania modelu do systemu, a nie dokładności uzyskiwanych prognoz za pomocą otrzymanych modeli. Niemniej w ramach badania wrażliwości modelu zbadano także dla danych dotyczących 2020 roku także błędy MAPE, uzyskując na przykład dla godziny 6: dla grudnia – 7.00%, dla dni roboczych grudnia – 5.99%, dla pierwszego

pełnego tygodnia grudnia – 6.96% oraz dla dni roboczych pierwszego pełnego tygodnia grudnia – 3.83%. Stosowanie SSN jako korektora modelu identyfikacyjnego w większości przypadków pozwalało na znaczną redukcję zarówno błędów względnych, jak i błędów MAPE, to znaczy udawało się tak nauczyć SSN, że uzyskiwana średnioważona wolumenem cena ee uzyskiwana z modelu zbliżała się bardziej do wartości średnioważonej wolumenem cen ee uzyskiwanej z systemu RDN. W uzyskanych badaniach potwierdzono, że znany w literaturze przedmiotu znaczny wpływ dni świątecznych na model systemu ma również zastosowanie w uzyskanych modelach dotyczących roku, miesiąca i tygodnia.

Z wyżej wymienionych względów, między innymi dużych rozbieżności pomiędzy błędami względnymi oraz pomiędzy błędami MAPE, tak w skali roku, miesiąca jak i tygodnia, zbadano ponadto efektywność, krzepkość modelu i systemu oraz skuteczność modelu do systemu RDN, uzyskując błędy względne efektywności realizacyjnej modelu do systemu od 4.81% dla godziny 6 do 11.72% dla godziny 18. Podobnie uzyskano błędy względne krzepkości od 4.87% dla godziny 6 do 13.20% dla godziny 12. Natomiast błędy względne skuteczności modelu do systemu RDN od 5.39% dla godziny 6 do 12.47% dla godziny 18.

Obie hipotezy rozprawy zostały zatem pozytywnie zweryfikowane:

- 1) z wykorzystaniem danych od 1 stycznia 2015 r. do 30 czerwca 2015 r. z okresem identyfikacji o długości 184 dni, uzyskując modele parametryczne dyskretne arx, modele parametryczne ciągłe th oraz modele ciągłe w przestrzeni stanów ss, z interpretacją parametrów poszczególnych modeli, aż do interpretacji zmiennych stanu,
- 2) z wykorzystaniem danych od 1 stycznia 2013 r. do 30 kwietnia 2016 r. z okresem identyfikacji o długości 184 dni, uzyskując metamodele dla celów określania modeli parametrycznych dyskretnych, modeli parametrycznych ciągłych oraz modeli ciągłych w przestrzeni stanu, a nie tylko uzyskiwania prognozy cen,
- 3) z wykorzystaniem danych od 1 stycznia 2016 r. do 31.12.2019 r. z okresem identyfikacji o długości 365 dni, uzyskując modele parametryczne dyskretne skorygowane modelami neuronalnymi, z wykorzystaniem których przeprowadzono szczegółowe badania błędów względnych, MAPE, efektywności i krzepkości modelu i systemu oraz skuteczności modelu do systemu RDN, a ponadto związane zagadnienie efektywności i skuteczności, uzyskując krzepkość systemu i modelu,

- 4) z wykorzystaniem danych modeli parametrycznych dyskretnych uzyskanych dla 2019 roku dla czterech godzin (6, 12, 18, 24) zbadano wrażliwość modelu w odniesieniu do danych z roku 2020, w celu uzyskania odpowiedzi na możliwość wykorzystania ich w prognozowaniu średnioważonych wolumenem cen ee,
- 5) z wykorzystaniem danych dotyczących 2019 r. wyznaczono rodziny charakterystyk krzepkości, skuteczności i efektywności modelu i systemu dla godzin: 6, 12, 18 i 24, uzyskując w szczególności bardzo ciekawe przebiegi krzepkości modelu w zależności od wielkości wolumenu dostarczonej i sprzedanej na RDN TGE S.A. ee.

Nie wyczerpano z pewnością wszystkich istotnych zagadnień dotyczących identyfikacji oraz metaidentyfikacji systemu RDN, w tym zwłaszcza w zakresie uzyskania modeli w badanym okresie tylko dla dni roboczych lub też tylko dla dni świątecznych. Z tych też względów dalsze badania dobrze byłoby, aby dotyczyły identyfikacji i badania tego typu modeli. W tym zakresie należy przeprowadzić identyfikację dla różnej liczby wielkości wejściowych i sprawdzić ich wpływ na występujące błędy pomiędzy modelem a systemem RDN. Ma to szczególne znaczenie w przypadku błędu MAPE.

Zasadniczym efektem wykorzystania przedstawionego w rozprawie autorskiego podejścia do modelowania identyfikacyjnego jest wysoka jakość modeli parametrycznych dyskretnych systemu RDN uzupełnionych modelami neuralnymi, uzyskanymi w wyniku identyfikacji przeprowadzonej z wykorzystaniem teorii i inżynierii systemów, a w konsekwencji także modeli parametrycznych ciągłych oraz modeli ciągłych w przestrzeni stanu systemu RDN TGE S.A. Łącznie uzyskano wystarczająco liczny katalog 35 modeli parametrycznych w układzie krocącym, który umożliwił przeprowadzenie metaidentyfikacji prowadzącej do uzyskania metamodelu parametrycznego oraz metamodelu neuronalnego systemu RDN.

Otrzymywane modele systemu RDN mogą służyć jako wiarygodne źródło danych w budowie bazy wiedzy dla potrzeb metaidentyfikacji, a nie wyłącznie wprost jako modele do prognozowania, planowania, czy też programowania przyszłych stanów systemu RDN jako elementu zarządzania, co jest aktualnie ważnym wyzwaniem z punktu widzenia wszystkich uczestników TGE S.A. Warto dodać, że dotychczas modele prognostyczne, modele planistyczne oraz modele programistyczne otrzymywane były w wyniku stosowania metod jednoscenariuszowych rozwoju systemu RDN TGE S.A. i wówczas na tej podstawie prowadzono badania w kierunku uzyskania nowych stanów systemu odpowiednio: prognoz, planów czy programów [1–6, 12, 20–22, 32–35]. W tym zakresie, zaproponowane podejście

polegające na zastosowaniu metod i modeli identyfikacyjnych wzmocnionych modelami neuralnymi, rozwija istniejący stan wiedzy z zakresu metamodelowania i modeli systemów RDN oraz instrumentarium ujmowanych w obszarze systemów zarządzania, wykorzystania inżynierii systemów i teorii sterowania [21–22, 26, 51, 83, 89, 96, 102, 120].

LITERATURA

- [1] Aggarwal S., Saini L. and Kumar A.: Electricity price forecasting in deregulated markets: A review and evaluation, *International Journal of Electrical Power & Energy Systems*, 31(1), 2009, pp. 13–22.
- [2] Ali J., Khan, R., Ahmad N., and Maqsood I.: Random Forests and Decision Trees, *IJCSI International Journal of Computer Science*, 9(5), 2012, pp. 272–278.
- [3] Amjady N.: Day ahead price forecasting of electricity markets by a new fuzzy neural network, *IEEE Trans. Power Syst.*, 21(2), 2006, pp. 887–896.
- [4] Amjady N. and Hemmati M.: Day-ahead price forecasting of electricity markets by a hybrid intelligent system, *European Transactions on Electric Power*, 19(1), 2009, pp. 89–102.
- [5] Amjady N. and Keynia F.: Day ahead price forecasting of electricity markets by a mixed data model and hybrid forecast method, *Int. J. Electric Power Energy Systems*, 30 (9), 2008, pp. 533–546.
- [6] Amjady N. and Keynia F.: Electricity market price spike analysis by a hybrid data model and feature selection technique, *Electric Power Systems Research*, 80(3), 2010, pp. 318–327.
- [7] Arlot S. and Celisse A.: A survey of cross-validation procedures for model selection, *Statistics. Surveys*, 4, 2010, pp. 40–79.
- [8] Bajpai P. and Singh S.: Bidding and gaming in electricity market: an overview and key issues, in *International conference on power systems*, Kathmandu, Nepal, 2004, pp. 571–576.
- [9] Barlow M.: A diffusion model for electricity prices, *Math Finance*, 12(4), 2002, pp. 287–298.
- [10] Barroso L., Cavalcanti T., Giesbertz P. and Purchala K.: Classification of electricity market models worldwide, [in:] *CIGRE Task Force C5.2.1.*, <http://raceadm3.nuca.ie.ufrj.br/BuscaRace/Docs/lanbarroso15.pdf> [dostęp: 23.02.2021 r.].
- [11] Bartodziej G., Tomaszewski M.: *Polityka energetyczna i bezpieczeństwo energetyczne, Energetyka i Środowisko*, Wydawnictwo Nowa Energia, Racibórz 2009, 335 s.
- [12] Bastian J., Zhu J., Banunarayanan V. and Mukerji R.: Forecasting energy prices in a competitive market, *IEEE Computer Application in Power*, 12, 1999, pp. 40–45.

-
- [13] Battiti R.: Using Mutual Information for Selecting Features in Supervised Neural Net Learning, *IEEE Transaction on Neural Networks*, 5(4), 1994, pp. 537–550.
- [14] Becker R., Hurn S. and Pavlov V.: Modelling Spikes in Electricity Prices, *The Economic Record*, 82(263), 2007, pp. 371–382.
- [15] Bełz G., Cyfert S., Czakon W., Dyduch W., Latusek-Jurczak D., Niemczyk J., Sopińska A., Szpitter A., Urbaniak M., Wiktor J.: *Subdyscypliny w naukach o zarządzaniu i jakości 2.0.*, 2019, http://www.knoiz.pan.pl/images/stories/pliki/pdf/Subdyscypliny_nauk_o_zarzadzaniu_i_jakosci.pdf, [dostęp: 14.01.2020 r.].
- [16] Bhattacharyya S.C. and Thanh L.T.: Short-term electric load forecasting using an artificial neural network: case of Northern Vietnam, *International Journal of Energy Research*, 28(5), 2003, pp. 463–472.
- [17] Bielewicz K.: *Smart metering. Inteligentny system pomiarowy*, PWN, Warszawa 2012, 278 s.
- [18] Bierbrauer S.T., Trück S. and Weron R.: Modeling electricity prices with regime-switching models, *Lecture Notes in Computer Science*, Springer, Berlin 2004, pp. 859–867.
- [19] Biuro Analiz i Rozwoju Rynku, Organizacja obrotu na Towarowej Giełdzie Energii, TGE S.A., Warszawa 2021, 45 s.
- [20] Biuro Analiz i Rozwoju Rynku, Rynek Dnia Następnego, TGE S.A., Warszawa 2021, 12 s.
- [21] Bojarski W. W.: *Podstawy analizy i inżynierii systemów*, PWN, Warszawa 1984, 454 s.
- [22] Bojarski W. W.: *Przykładowe zastosowania analizy i inżynierii systemów*, PWN, Warszawa 1984, 124 s.
- [23] Box G. E. P., Jenkins G. M.: *Analiza szeregów czasowych. Prognozowanie i sterowanie*. PWN, Warszawa 1983, 574 s.
- [24] Brown Do Coutto Filho M., Cesar Stacchini de Souza J.: Forecasting-Aided State Estimation – Part I: Panorama, *IEEE Transactions on Power Systems*, Vol. 24, No. 4, Nov. 2009, pp. 1667–1677.
- [25] Brown Do Coutto Filho M., Cesar Stacchini de Souza J., Sergio Freund R.: Forecasting-Aided State Estimation – Part II: Implementation, *IEEE Transactions on Power Systems*, Vol. 24, No. 4, Nov. 2009, pp. 1678–1685.
- [26] Bubnicki Z.: *Identyfikacja obiektów sterowania*, PWN, Warszawa 1974, 360 s.
-

-
- [27] Calmarza M. and de la Fuente J.I.: New forecasting method for the residual demand curves using lime series (ARIMA) models, [in:] Proceedings of the International Conference on Probabilistic Methods Applied to Electric Power Systems, Naples 2002.
- [28] Carrion M., Philpott A. B., Conejo A. J. and Arroyo J. M.: A stochastic programming approach to electric energy procurement for large consumers, IEEE Transaction on Power Systems, 22(2), 2007, pp. 744–754.
- [29] Cartea A. and Figueroa M.: Pricing in electricity markets: A mean reverting jump diffusion model with seasonality, Applied Mathematical Finance, 12(4), 2005, pp. 313–335.
- [30] Castillo E., Conejo A.J., Prunela R.E., Solares C., and Menendez J.M.: m-k Robust Observability in State Estimation. IEEE Transactions on Power Systems, Vol. 23, No. 2, May 2008, pp.296–305.
- [31] Catalão J.P.S., Mariano S.J.P.S., Mendes V.M.F. and Ferreira L.A.F.M.: Short-term electricity prices forecasting in a competitive market: A neural network approach, Electric Power Systems Research, 77, 2007, pp. 1297–1304.
- [32] Catalão J.P.S., Pousinho H.M.I. and Mendes V.M.F.: An artificial neural network approach for short-term wind power forecasting in Portugal, [in:] 15th International Conference on Intelligent System Applications to Power Systems, 2009, pp.1–5.
- [33] Cavallaro F.: Electric load analysis using an artificial neural network, International Journal of Energy Research, 29, 2005, pp. 377–392.
- [34] Chandarasupsang T., Galloway S., Burt G., McDonald J. and Siewierski T.: Bidding behaviour and electricity market simulation, European Transactions on Electrical Power, 17, 2007, pp. 333–346.
- [35] Chen Y., Luh P.B., Guan C., Zhao Y., Michel L.D., Coolbeth M.A., Friedland P.B. and Rourke S.J.: Short-term Load Forecasting: Similar Day-based Wavelet Neural Networks, IEEE Transaction on Power Systems, 25(1), 2010, pp. 322–330.
- [36] Chochowski A., Obstawski P.: Model parametryczny baterii kolektorów słonecznych, Wydawnictwo SGGW, Inżynieria Rolnicza 14/2005, ss. 55–64.
- [37] 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.
- [38] Conejo A.J., Contreras J., Espínola R. and Plazas M.A.: Forecasting electricity prices for a day-ahead pool-based electricity energy market, *International Journal of Forecasting*, 21(3), 2005, pp. 435–462.
- [39] Conejo A.J., Plazas M.A., Espinola R. and Molina, A.B.: Day-ahead electricity price forecasting using the wavelet transform and ARIMA models, *IEEE Transactions on Power Systems*, 20, 2005, pp. 1035–1042.
- [40] Contreras J., Espínola R., Nogales F.J. and Conejo A.J.: ARIMA models to predict next-day electricity prices, *IEEE Transactions on Power Systems*, 18(3), 2003, pp. 1014–1020.
- [41] Dash S.K., Dash K.P.: Short-term mixed electricity demand and price forecasting using adaptive autoregressive moving average and functional link neural network, *Journal of Modern Power Systems and Clean Energy*, No. 7(5)/2019, pp. 1241–1255.
- [42] Dehghani M., Nikravesh S.K.Y.: State-Space Model Parameter Identification In Large-Scale Power Systems. *IEEE Transactions on Power Systems*, Vol. 23, No. 3, Aug. 2008, pp. 1449–1457.
- [43] 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, 2011.
- [44] Duraiski R.G., Trierweiler J.O., Secchi A.R.: DTS Optimization: A New Algorithm for Multi-objective Problems Based on the Goal Attainment Method, *EngOpt 2008 – International Conference on Engineering Optimization*, Rio de Janeiro, Brazil, 01–05 June 2008, pp. 1–13.
- [45] Dyrektywa Parlamentu Europejskiego i Rady 2009/72/WE, z dnia 13 lipca 2009 r. dotycząca wspólnych zasad rynku wewnętrznego energii elektrycznej i uchylająca dyrektywę 2003/54/WE, Dz.U.UE L 211/55.
- [46] Dyrektywa Parlamentu Europejskiego i Rady 2009/73/WE z dnia 13 lipca 2009 r. dotycząca wspólnych zasad rynku wewnętrznego gazu ziemnego i uchylająca dyrektywę 2003/55/WE, Dz.U.UE L 211/94.
- [47] Dziekoński K., Jurczuk A.: Rola narzędzi informatycznych w zarządzaniu procesowym, Część 3 [w:] *Instrumenty zarządzania współczesnym przedsiębiorstwem*, [pod red. nauk.] Kowalczewskiego W. i Nazarko J., Difin, Warszawa 2006.

-
- [48] Ejdyś J., Halicka K., Godlewska J.: Prognozowanie cen energii elektrycznej na giełdzie energii, Wydawnictwo Politechniki Śląskiej, Zeszyty Naukowe. Organizacja i Zarządzanie, 2015, z. 77, ss. 53–61.
- [49] Encyklopedia Zarządzania, <https://mfiles.pl>, [dostęp: 17.06.2022 r.].
- [50] Engle, R.F.: Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation, *Econometrica*, 50, 1987, pp. 987–1007.
- [51] Eykhoff P.: Identyfikacja w układach dynamicznych, PWN, Warszawa 1980, 683 s.
- [52] Epexspot, www.epexspot.com, [dostęp: lata 2021–22].
- [53] Gabryelczyk R., Jurczuk A.: Does Experience Matter? Factors Affecting the Understandability of the Business Process Modelling Notation, “*Procedia Engineering*” 2017, nr 182, s. 198–205.
- [54] Gan M., Chen L., Zhang C. Y. and Peng H.: A Self-Organizing State Space Type Microstructure Model for Financial Asset Allocation, in *IEEE Access*, Vol. 4, 2016, pp. 8035–8043.
- [55] Gao F., Cao X. and Papalexopoulos A.: Forecasting power market clearing price and quantity using a neural network method, in *Proc. IEEE Power Engineering Society Summer Meeting*, 4, 2000, pp. 2183–2188.
- [56] Garcia R.C., Contreras J., van Akkeren M. and Garcia J.B.C.: A GARCH forecasting model to predict day-ahead electricity prices, *IEEE Transactions on Power Systems*, 20(2), 2005, pp. 867–874.
- [57] Gasparski W., Kieżun W. [pod red.]: Krytyczna teoria organizacji. Elementy filozofii i praktyki zarządzania, MT Biznes, Warszawa 2020, 462 s.
- [58] Georgilakis, P.S.: Market clearing price forecasting in deregulated electricity markets using adaptively trained neural networks, *Lecture notes in artificial intelligence LNAI 3955*. Berlin, Heidelberg: Springer-Verlag, 2006, pp. 56–66.
- [59] Gomółka Z.: Cybernetyka w zarządzaniu. Modelowanie cybernetyczne. Sterowanie systemami, AW Placed, 2000, 128 s.
- [60] Grudzewski W., Hejduk I. [pod red.]: Projektowanie systemów zarządzania, Difin, Warszawa 2000, 560 s.
- [61] Grudzewski W. [pod red.]: Identyfikacja procesów w zarządzaniu. Ekonomiczne modele wymiarowe, Warszawa 1984, 121 s.
-

-
- [62] Guan X., Pepyne D. and Ho Y.C.: Gaming and price spikes in electric power markets, IEEE Trans. Power Syst., 16, 2001, pp. 402–408.
- [63] Guide for MATLAB, Guide for Simulink, Guide for System Identification Toolbox, Guide for Control System Toolbox, Guide for Neural Network Toolbox. The MathWorks®. Getting Started Guide, 2021b.
- [64] Gutkowski W.: Komputerowe metody optymalizacji konstrukcji, IPPT PAN, Warszawa 1994.
- [65] Guzik B., Appenzell D., Jurek W.: Prognozowanie i symulacja, Wydawnictwo AE, Poznań 2007, 286 s.
- [66] Halicka K.: Skuteczność prognozowania w zarządzaniu transakcjami na giełdzie energii elektrycznej. Rozprawa doktorska pod kierunkiem prof. dr hab. inż. J. Nazarko, UW, Warszawa 2006, 207 s.
- [67] Halicka K., Winkowski C.: Wykorzystanie metod wygładzania wykładniczego do prognozowania kursu sprzedaży EUR, Economics and Management – 2/2013, ss. 70–80.
- [68] Halilcevic S. S., Gubina F., Gubina A.F.: Prediction of Power System Security Levels. IEEE Transactions on Power Systems, Vol. 24, No. 1, Feb. 2009, pp. 368–377.
- [69] Haykin S.: Neural Networks: A Comprehensive Foundation, Englewood Cliffs, NJ. Prentice-Hall, 2005, 823 p.
- [70] He Y.G. and Bo L.: Price forecasting based on PSO train BP neural network, [in]: Power and Energy Engineering Conference, 2009, pp. 1–4.
- [71] Hippert H.S., Pedreira C.E. and Souza R.C.: Neural Networks for Short-Term Load Forecasting: A Review and Evaluation, IEEE Transaction on Power Systems, 16(1), 2001, pp. 44–55.
- [72] Hirsch G.: Pricing of hourly exercisable electricity swing options using different price processes, Journal of Energy Markets, 2(2), 2009, pp. 3–46.
- [73] Huang D., Zareipour H., Rosehart W.D. and Amjady, N.: Data mining for electricity price classification and the application to demand-side management, IEEE Transaction on Smart Grid, 3(2), 2012, pp. 808–817.
- [74] Hunter G.: Metalogika, PWN, Warszawa 1982, 219 s.
- [75] Huston McCulloch J.: On Heteroskedasticity, Econometrica, No 53 (2), 483 p.
-

-
- [76] Jablonska M.: Analysis of outliers in electricity spot market price with example of New England and New Zealand markets, Master's Thesis Lappeenranta University of Technology, Finland, 2008.
- [77] Jablonska M., Nampala H. and Kauranne T.: The multiple-mean-reversion jump-diffusion model for Nordic electricity spot prices, *The journal of energy market*, 4(2), 2011, pp 3–25.
- [78] Jablonska M., Viljainen S., Partanen J. and Kauranne T.: The impact of emissions trading on electricity spot market price behavior, *International Journal of Energy Sector Management*, 6(3), 2012, pp. 343–364.
- [79] Jajuga K.: Statystyczna analiza wielowymiarowa, PWN, Warszawa 1993, 277 s.
- [80] Janczak A.: Techniki identyfikacji procesów, www.issi.uz.zgora.pl/didactic/janczak [dostęp: 02.02.2019 r.].
- [81] Jiang L.L., Hu G.: Day-Ahead Price Forecasting for Electricity Market using Long-Short Term Memory Recurent Neural Network. 2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV), Singapore, Nov. 19–21, IEEE Digital Library, pp. 949–954, 2018.
- [82] Jurczuk A.: Reaktywne podejście do analizy przyczyn niespójności procesów biznesowych, „Przegląd Organizacji”, 2016, nr 3, ss. 42–48.
- [83] Jurczuk A.: Wieloaspektowa identyfikacja i typologia źródeł niespójności procesów biznesowych, Oficyna Wydawnicza Politechniki Białostockiej, Białystok 2019, 309 s.
- [84] Jurczuk A.: Identification and Tracking of Process Inconsistencies in Manufacturing Enterprises, [w:] 8th International Conference on Engineering, Project, and Product Management (EPPM 2017). Lecture Notes in Mechanical Engineering, S. Sahin (red.), Springer, Cham, 2018, s. 129–138.
- [85] Jurczuk A.: Wieloaspektowe podejście do klasyfikacji źródeł niespójności procesów biznesowych, *Przegląd Organizacji*, 2017, nr 4, s. 40–47.
- [86] Jurczuk A., Gabryelczyk R.: Cele doskonalenia przedsiębiorstw w kontekście dojrzałości procesowej, *Zeszyty Naukowe Politechniki Śląskiej „Organizacja i Zarządzanie”*, 2015, t. 83, nr 1941, s. 245–254.
- [87] Kacejko P.: Analiza systemu elektroenergetycznego w ujęciu obiekowym, *PN PW, Elektryka*, z. 104/1998.
-

-
- [88] Kachniewski M., Weremowicz E.: Giełda, [w:] Encyklopedia PWN, <https://encyklopedia.pwn.pl/haslo/gielda;3905361.html> [dostęp: 06.05.2022 r.].
- [89] Kaczorek T., Dzieliński A., Dąbrowski W., Łopatka R.: Podstawy teorii sterowania, PWN WNT, Warszawa 2021, 498 s.
- [90] Karandikar R.G., Deshpande N.R., Khaparde S.A. and Kulkarni S.V.: Modelling Volatility Clustering in Electricity Price Return Series for Forecasting Value at Risk, European Transactions on Electrical Power, 19, 2009, pp. 15–38.
- [91] Kasprzyk S., i inni: Najważniejsze zagadnienia dotyczące funkcjonowania sektora elektroenergetycznego w Polsce („Raport siedmiu”), Warszawa 2008, 45 s.
- [92] Keles D., Genoese M., Most D. and Fichtner W.: Comparison of extended mean-reversion and time series models for electricity spot price simulation considering negative prices, Energy Economics, 34, 2012, pp. 1012–1032.
- [93] Kisielnicki J.: Zarządzanie, PWE, Wyd. II, Warszawa 2014, 356 s.
- [94] Knosala R. [pod red.]: Inżynieria zarządzania. Cyfryzacja produkcji. Aktualności badawcze 1, PWE, Warszawa 2019, 1024 s.
- [95] Kohzadi N., Boyd M.S. Kermanshahi B. and Kaastra I.: A comparison of artificial neural network and time series models for forecasting commodity prices, Neurocomputing, 10 (2), 1996, pp.169–181.
- [96] Konieczny J.: Inżynieria systemów działania, WNT, Warszawa 1983, 386 s.
- [97] Kononiuk A., Nazarko J.: Scenariusze w antycypowaniu i kształtowaniu przyszłości, Wolters Kluwer, Warszawa 2014, 220 s.
- [98] Kowal W.: Skuteczność i efektywność – zróżnicowane aspekty interpretacji, Kwartalnik Naukowy pt. Organizacja i Kierowanie, Nr 4(157), SGH, Warszawa 2013, ss. 12–23.
- [99] Kowalczewski W., Nazarko J. [red.]: Instrumenty zarządzania współczesnym przedsiębiorstwem, Difin, Warszawa 2006, 216 s.
- [100] Koźmiński A., Jemielniak D.: Zarządzanie od podstaw. Podręcznik akademicki, Wydawnictwa Akademickie i Profesjonalne, Warszawa 2008, 493 s.
- [101] Krawiec F., Krawiec S.: Marketing w elektroenergetyce, Difin, Warszawa 2017, 242 s.
- [102] Królikowski A., Horla D.: Identyfikacja obiektów sterowania. Metody dyskretne parametryczne, Wydawnictwo Politechniki Poznańskiej, Poznań 2010, 124 s.
-

-
- [103] Kulczycki J.: Optymalizacja struktur sieci elektroenergetycznych, WNT Warszawa, 1990, 191 s.
- [104] Kwak N. and Choi C.-H.: Input Feature Selection for Classification Problems, *IEEE Trans. Neural Networks*, 13(1), 2002, pp. 143–159.
- [105] Kwater T., Krutys. P.: The Simulations of Sequential of Estimator for Objects with a Serial Structure, *Information Systems in Management*, Vol. 5(3)/2016, pp. 347–357.
- [106] Kwiatkowski M.: Proces formułowania strategii rozwoju firmy obrotu energią elektryczną, SGH, 2006, 187 s.
- [107] Lari-Lavassani A., Sadeghi A.A. and Ware A.: Mean reverting models for energy option pricing, 2001, <http://math.ucalgary.ca/sites/finance.math.ucalgary.ca/files/u22/LavassaniSadeghiWare2001.pdf>. [dostęp: 20.05.2020 r.].
- [108] Liao G.C.: A novel particle swarm optimization approach combined with fuzzy neural networks for short-term load forecasting, in: *IEEE Power Engineering Society General Meeting*, 2007.
- [109] Lora A.T., Santos Jesus R., Santos Jose R., Exposito A.G. and Ramos J.L.M.: A comparison of two techniques for next-day electricity price forecasting, *Lecture notes in computer science*, Berlin, Heidelberg: Springer Verlag, 2002, pp. 384–390.
- [110] Lu X., Dong Z.Y. and Li X.: Electricity Market Price Spike Forecast with Data Mining Techniques, *Electric Power Systems Research*, 73(1), 2005, pp.19–29.
- [111] Lucia, J. and Schwartz, E.: Electricity prices and power derivatives: Evidence from the Nordic Power Exchange, UC Los Angeles: Finance, 2000, <http://www.escholarship.org/uc/item/12w8v7jj> [dostęp: 14.06.2019 r.]
- [112] Malko J.: Planowanie systemów elektroenergetycznych, PWN, Warszawa 1976, 188 s.
- [113] Malko J.: Wybrane zagadnienia prognozowania w elektroenergetyce, OW Politechniki Wrocławskiej, 1995, 84 s.
- [114] Malko J., Otręba L., Skorupski W.: Identyfikacja modelu autoregresji-średniej ruchomej krótkoterminowej predykcji procesu zapotrzebowania mocy, *Archiwum Energetyki*, Nr 1–2 1990, ss. 101–108.
- [115] Malko J.: Aktualne problemy prognozowania na potrzeby sektora energii elektrycznej, *Przegląd Elektrotechniczny*, Nr 9/2006, ss. 2–9.
- [116] Malko J., Wilczyński A.: Rynki energii, działania marketingowe, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2006, 265 s.
-

-
- [117] Mandal, P., Senjyu, T. and Funabashi, T.: Neural networks approach to forecast several hour ahead electricity prices and loads in deregulated market, *Energy Conversion and Management*, 47, 2006, pp. 2128–2142.
- [118] Mandal P., Haque A.U., Meng J., Srivastava A.K., Martinez R.: A Novel Hybrid Approach Using Wavelet, Firefly Algorithm, and Fuzzy ARTMAP for Day-Ahead Electricity Price Forecasting, *IEEE Transactions on Power Systems*, Vol. 28, No. 2, pp. 1041–1051, May 2013.
- [119] Mandal P., Senjyu, T., Urasaki, N., Funabashi, T. and Srivastava, A.K.: A novel approach to forecast electricity price for PJM using neural network and similar days method, *IEEE Transactions on Power System*, 22(4), 2007, pp. 2058–2065.
- [120] Mańczak K.: *Komputerowa identyfikacja obiektów dynamicznych*, PWN, Warszawa 1983, 432 s.
- [121] Marłęga R.: Comparative Study of the Identification Methods of the Management System of the Day-Ahead Market of Polish Energy Market SA, *Studia Informatica. System and information technology*, 2021, Nr 1–2 (25), pp. 67–86.
- [122] Marłęga R.: State-space model and implementation Polish Power Exchange in MATLAB and Simulink environments, *Information Systems in Management*, 2017, Vol. 6 (4), pp. 294–308.
- [123] Marłęga R.: Model and simulation of electric power exchange development in terms of control and system theory, 2016 *Electric Power Networks (EPNet)*, 2016, pp. 1–4.
- [124] Marłęga R.: Correction of the parametric model of the Day-Ahead Market system using the Artificial Neural Network, *Studia Informatica. System and information technology*, 2022, Nr 1 (26), pp. 89–109.
- [125] Marłęga R., Tchórzewski J.: Identification modeling of Polish electric power exchange, *Information Systems in Management*, 2016, Volume 5, Issue 2, ss. 195–204.
- [126] Marłęga R., Tchórzewski J.: Metaidentification of the Day-Ahead market system of the Polish Electric Power Exchange in terms of control and systems theory, *Współczesne Problemy Zarządzania, ZN WITZ WSISiZ*, Nr 1/2021, ss. 21–42.
- [127] McGraw G.A., Gustafson C.L., Girls J.T.: Conditions for the equivalence of ARMAX and ARX Systems, *IEEE Transactions on Automatic Control*. Vol. 38, Issue 4, 1993, pp. 632–636.
-

-
- [128] Meng K., Dong Z., Wang H. and Wang Y.: Comparisons of Machine Learning Methods for Electricity Regional Reference Price Forecasting, *Lecture Notes in Computer Science*, 2009, pp. 827–835.
- [129] Merayo D., Rodriguez-Prieto A., Camacho A.M.: Comparative analysis of artificial intelligence techniques for material selection applied to manufacturing in Industry 4.0, *Procedia Manufacturing* no. 41, pp. 42–49, 2019.
- [130] Mielczarski W.: Rynki energii elektrycznej. Wybrane aspekty techniczne i ekonomiczne, ARE S.A., Warszawa 2000, 321 s.
- [131] Monden Y., Yamada M., Arimoto S.: Fast algorithm for Identification of an ARX model and its order determination. *Acoustics, IEEE Transactions on Speech and Signal Processing*, Vol. 30, No. 3, 1982, pp. 390–399.
- [132] Mori H. and Awata A.: Data Mining of Electricity Price Forecasting with Regression Tree and Normalized Radial Basis Function Network, [in:] *IEEE International Conference on Systems, Man and Cybernetics (SMC2007)*, 2007, pp. 3743–3748.
- [133] Möst D. and Keles D.: A survey of stochastic modelling approaches for liberalized electricity markets, *European Journal of Operational Research*, 207(2), 2010, pp. 543–556.
- [134] Mróz M.: Czym jest efektywność a czym skuteczność działań, 2020, [online]: https://pl.linkedin.com/in/mi%C5%82osz-mr%C3%B3z-9408a322?trk=author_mini-profile_title.
- [135] Mtunya, A.: Modeling electricity spot price time series using colored noise forces, Master's Thesis, University of Dar es Salaam, Tanzania, 2010.
- [136] Mynarski S.: Analiza danych: makromechanizmy, Wydawnictwo Akademii Ekonomicznej, Kraków 2000, 99 s.
- [137] Mynarski S. [pod red.]: Analiza rynku. Systemy i mechanizmy, AE, Kraków 1993, 178 s.
- [138] Mynarski S.: Elementy teorii systemów i cybernetyki. PWN, Warszawa 1979, 186 s.
- [139] Naeem, M.: A comparison of electricity spot prices simulation using ARMA/GARCH and mean reverting models, Master's Thesis, Lappeenranta University of Technology, Finland, 2009, p. 59.
-

-
- [140] Nasr G.E., Badr E.A. and Younes M.R.: Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches, *International Journal of Energy Research*, 26(1), 2001, pp. 67–78.
- [141] Nazarko J.: Estymacja stanów pracy elektroenergetycznych sieci rozdzielczych. *Rozprawy Naukowe Nr 9*, Wydawnictwo Politechniki Białostockiej, Białystok 1991, 122 s.
- [142] Nazarko J., Chodakowska E., Halicka K., Kononiuk A.: Prognozowanie cen energii elektrycznej na Towarowej Giełdzie Energii SA z wykorzystaniem modeli ARIMA [w:] L. Kiełtyka, J. Nazarko (red.), *Technologie informatyczne i prognozowanie w zarządzaniu, Wybrane zagadnienia*, Wydawnictwo Politechniki Białostockiej, Białystok 2005.
- [143] Nazarko J., Rybaczuk M., Jurczuk A.: Wpływ poziomu zakłóceń losowych na możliwość identyfikacji modeli ARIMA dla niestacjonarnych szeregów czasowych, *Prace Naukowe Akademii Ekonomicznej we Wrocławiu. Taksonomia*, Tom 13/2006, Wydanie: 1126 *Klasyfikacja i analiza danych – teoria i zastosowania*, ss. 175–185.
- [144] Nazarko J., Rybaczuk M., Jurczuk A.: Wpływ poziomu zakłóceń losowych na możliwość identyfikacji modeli ARIMA, *Prace Naukowe Akademii Ekonomicznej we Wrocławiu*, Nr 1076/2005, Wydawnictwo Akademii Ekonomicznej im. Oskara Langego we Wrocławiu, ss. 238–247.
- [145] Napieralski A., Poźniak T.: Nowe trendy w elektroenergetyce, *Elektronika*, Nr 4/98, 1998, ss. 3–15.
- [146] Nelson M., Hill T., Remus W. and O'Connor M.: Time series forecasting using neural networks: should the data be deseasonalized first?, *Journal of Forecasting*, 18(5), 1999, pp. 359–367.
- [147] Niedziółka D.: *Rynek energii w Polsce*, Difin, Warszawa 2010, 172 s.
- [148] Niu L., Zhao J. and Liu M.: Application of relevance vector regression model based on sparse Bayesian learning to long-term electricity demand forecasting, [in]: *IEEE International Conference on Mechatronics and Automation*, Changchun, China, 2009, pp. 2363–2367.
- [149] Nord Pool AS, www.nordpoolgroup.com, [dostęp: lata 2021–22].
-

-
- [150] Nogales F.J., Contreras J., Conejo A.J. and Espínola R.: Forecasting next-day electricity prices by time series models, *IEEE Transactions on Power Systems*, 17, 2002, pp. 342–348.
- [151] Osowski S.: *Cyfrowe przetwarzanie sygnałów z zastosowaniem MATLABA*, OW PW, Warszawa 2016, 407 s.
- [152] Osowski S.: *Sieci neuronowe do przetwarzania informacji*, OW PW, Warszawa 2013, 422 s.
- [153] Pamuła A.: Czynniki zmiany roli z pasywnej w aktywną i zaangażowania odbiorcy w nowe rozwiązania rynku energii, [w:] *Energetyka Prosumencka. Pierwsza próba konsolidacji* [pod red.] Popczyk J., Kucęba R. i inni., Sekcja Wydawnictw Wydziału Zarządzania PCz, Częstochowa 2014, ss. 100–109.
- [154] Paska J.: *Ekonomika w elektroenergetyce*, OW PW, Warszawa 2007, 248 s.
- [155] Paoletti S., Roll J., Garulli A. and A. Vicino A.: On the Input-Output Representation of Piecewise Affine State Space Models, in *IEEE Transactions on Automatic Control*, Vol. 55, No. 1/2010, pp. 60–73.
- [156] Peng H., Long F. and Ding C.: Feature selection based on mutual information: Criteria of max-dependency, max-relevance and min-redundancy, *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 27(8), 2005, pp. 1226–1238.
- [157] Plazas M. A., Conejo A. J., and Prieto F. J.: Multimarket optimal bid-ding for a power producer, *IEEE Transactions on Power Systems*, 20(4), 2005, pp. 2041–2050.
- [158] *Polityka energetyczna Polski do 2025 roku*. Ministerstwo Gospodarki. Zespół do Spraw Polityki Energetycznej, Warszawa 2005, s. 56.
- [159] *Polityka energetyczna Polski do 2030 roku*, Ministerstwo Gospodarki, Załącznik do uchwały nr 202/2009 Rady Ministrów z dnia 10 listopada 2009 r., 122 s.
- [160] *Polskie Sieci Elektroenergetyczne S.A.*, www.pse.pl [dostęp: 15.06.2021 r.].
- [161] Popczyk J.: Innowacyjność technologiczna – najbardziej pożądana droga rozwojowa energetyki w Polsce. Zeszyty BRE _ CASE. *Energetyka – polityka – ekonomia*, Nr 91/2007, s. 52.
- [162] Popczyk J.: *Energetyka rozproszona. Od dominacji energetyki w gospodarce do zrównoważonego rozwoju, od paliw kopalnych do energii odnawialnej i efektywności energetycznej*, Polski Klub Ekologiczny Okręg Mazowiecki, Warszawa 2011, 194 s.
-

-
- [163] Popławski T.: Rozmyty model prognozowania cen energii na Towarowej Giełdzie Energii, *Przegląd Elektrotechniczny* 82 (9), 2006, ss. 41–43.
- [164] Popławski T., Dąsal K.: Model harmonicznym w prognozowaniu giełdowych cen energii elektrycznej, *Przegląd Elektrotechniczny* 82(9), 2006, ss. 38–40.
- [165] Popławski T., Weźgowiec M.: Krótkoterminowe prognozy cen na Towarowej Giełdzie Energii z wykorzystaniem modelu trendu pełzającego, *Przegląd Elektrotechniczny*, R. 91, Nr 12/2015, ss. 267–270.
- [166] Prachniak L.: Rola TGE w organizacji Rynku Praw Majątkowych, Rynki prowadzone przez TGE, nowe produkty, www.tge.pl [dostęp: 23.05.2021 r.], 17s.
- [167] Prawo energetyczne, Ustawa z dn.10 kwietnia 1997, Dz.U. Nr 54 z dn. 4 czerwca 1997 (ze zm.), 251 s.
- [168] Raczkowski K., Solarz J.K.: Nauki ekonomiczne wobec wojny gospodarczej na płaszczyźnie finansowej, [w:] *Współczesna wojna handlowo-gospodarcza*, [pod red.] Płaczek J., Difin, Warszawa 2015, ss.111–136.
- [169] Ram S. S., Veeravalli V. V. and Nedlic A.: Distributed and Recursive Parameter Estimation in Parametrized Linear State-Space Models, in *IEEE Transactions on Automatic Control*, Vol. 55, No. 2/2010, pp. 488–492.
- [170] Rambharat B.R., Brockwell A.E. and Seppi D.J.: A threshold autoregressive model for wholesale electricity prices, *Journal of the Royal Statistical Society Series C*, 54(2), 2005, pp. 287–300.
- [171] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2021, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 106 s.
- [172] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2020, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 94 s.
- [173] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2019, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 90 s.
- [174] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2018, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 85 s.
- [175] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2017, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 67 s.
- [176] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2016, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 101 s.
-

-
- [177] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2015, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 102 s.
- [178] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2014, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 92 s.
- [179] Raport Krajowy Prezesa Urzędu Regulacji Energetyki 2013, URE, www.ure.gov.pl, [dostęp: 06.10.2021 r.], 78 s.
- [180] Robinson T.A.: Electricity pool prices: a case study in nonlinear time-series modeling, *Applied Economics*, 32(5), 2000, pp. 527–532.
- [181] Reis A.J.R. and Alves da Silva A.P.: Feature extraction via multiresolution analysis for short-term load forecasting, *IEEE Trans Power Systems*, 2005, pp.189–198.
- [182] Rocznik Statystyczny, Główny Urząd Statystyczny, Warszawa 1947–2021.
- [183] Rosé C., Lavie A.: Balancing Robustness and Efficiency in Unification-Augmented Context-Free Parsers for Large Practical Applications, [in:] *Robustness in Language and Speech Technology*, [eds.: Junqua J-C., van Noord G.], Springer Science+Business Media B.V. 2001, pp. 239–269.
- [184] Rozporządzenie Parlamentu Europejskiego i Rady (UE) Nr 1227/2011 z dnia 25 października 2011 r. w sprawie integralności i przejrzystości hurtowego rynku energii (tekst mający znaczenie dla EOG), *Dziennik Urzędowy Unii Europejskiej* L 326 z dnia 8 grudnia 2011 r., 16 s.
- [185] Rodriguez C.P. and Anders G.J.: Energy price forecasting in the Ontario competitive power system market, *IEEE Transactions on Power Systems*, 19(3), 2004, pp. 366–374.
- [186] Ruciński D.: The Influence of the Artificial Neural Network type on the quality of learning on the Day-Ahead Market model at Polish Power Exchange joint-stock company, *Studia Informatica. Systems and Information Technology*, No. 1-2 (23)2019, pp. 77–93.
- [187] Ruciński D.: Neural modeling of electricity prices quoted on the Day-Ahead Market of TGE S.A. shaped by environmental and economic factors, *Studia Informatica. Systems and Information Technology*, No. 1-2 (24)2020, pp. 25–36.
- [188] Ruciński D.: The impact of the size of the training set on the predictive abilities of neural models on the example of the Day-Ahead Market System of TGE S.A., *Studia Informatica. Systems and Information Technology*, No. 1(26)2022, pp. 5–24.
-

-
- [189] Rynek Energii Elektrycznej i Gazu w Polsce, stan na 31.03.2021 r., Raport TOE, Towarzystwo Obrotu Energią, Warszawa 2021, 80 s.
- [190] Sadeh J., Mashhadi H.R. and Latifi M.A.: A risk-based approach for bidding strategy in an electricity pay-as-bid auction, *European Transactions on Electrical Power*, Nr 19(1), 2009, pp. 39–55.
- [191] Sarkka S. and Hartikainen J.: On Gaussian Optimal Smoothing of Non-Linear State Space Models, in *IEEE Transactions on Automatic Control*, Vol. 55, No. 8/2010, pp. 1938–1941.
- [192] Shafie-khah M., Moghaddam M.P. and Sheikh-El-Eslami M.K.: Price forecasting of day-ahead electricity markets using a hybrid forecast method, *Energy Convers. Management*, 52(5), 2011, pp. 2165–2169.
- [193] Sienkiewicz P.: *Teoria efektywności systemów*, Wydawnictwo Ossolineum, Wrocław 1987, 80 s.
- [194] Sienkiewicz P.: *Inżynieria systemów kierowania*, PWE, Warszawa 1988, 262 s.
- [195] Simulink® Getting Started Guide. The MathWorks, Inc. 3 Apple Hill Drive Natick, MA 01760-2098, 1990–2021b.
- [196] Sobierajski M., Wikosz K.: *Sieci elektroenergetyczne a rynki energii elektrycznej. Problemy i perspektywy*, *Prace Naukowe Instytutu Energoelektryki Politechniki Wrocławskiej, OW Politechniki Wrocławskiej*, 2000, ss. 31–40.
- [197] Söderström T., Stoica P.: *Identyfikacja systemów*, WNT, Warszawa 1997, 670 s.
- [198] Söderstrom T., Fan H., Carsson B., Bigi S.: Least squares parameter estimation of continuous-time ARX models from discrete-time data. *IEEE Transactions on Automatic Control*, Vol. 42, 1997, pp. 659–673.
- [199] Sprawozdanie Prezesa Urzędu Regulacji Energetyki 2021, URE, www.ure.gov.pl, [dostęp: 01.08.2022 r.], 378 s.
- [200] Staniszewski R.: *Sterowanie procesem eksploatacji*, WNT, Warszawa 1990, 475 s.
- [201] *Statystyka Elektroenergetyki Polskiej*, Agencja Rynku Energii, Warszawa, lata 2003–2021.
- [202] Swanson N.R. and White H.A.: Model selection approach to real-time macroeconomic forecasting using linear models and artificial neural networks, *The Review of Economics and Statistics*, MIT Press, 79(4), 1997, pp. 540–550.
-

-
- [203] Szkuta B.R., Sanabria L.A. and Dillon T.S.: Electricity price short-term forecasting using artificial neural networks, *IEEE Transaction Power Systems*, 14(3), 1999, pp. 851–857.
- [204] Tan Z., Zhang J., Wang J., and Xu J.: Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models, *Applied Energy*, 87(11), 2010, pp. 3606–3610.
- [205] Taylor J.: Wstęp do analizy błędu pomiarowego, Wydawnictwo Naukowe PWN, 2021, 382 s.
- [206] Taylor J.W., de Menezes L.M. and McSharry P.E.: A comparison of univariate methods for forecasting electricity demand up to a day ahead, *International Journal of Forecasting*, 22, 2006, pp. 1–16.
- [207] Tchórzewski J., Marłęga R.: The Day-Ahead Market System Simulation Model in the MATLAB and Simulink Environment, 2021 Progress in Applied Electrical Engineering (PAEE), 2021, pp. 1–8.
- [208] Tchórzewski J., Marłęga R.: Interpretation of State Variables of the Control Model of the Polish Power Exchange System Based on the Day-Ahead Market Data, 2021 Progress in Applied Electrical Engineering (PAEE), 2021, pp. 1–8.
- [209] Tchórzewski J., Marłęga R.: Metaidentification of the Modern Polish Power Exchange Control System, 2019 Modern Electric Power Systems (MEPS), 2019, pp. 1–5.
- [210] Tchórzewski J., Marłęga R.: The Management System of the Polish Electricity Exchange from the Viewpoint of the Control and Systems Theory, 2019 16th International Conference on the European Energy Market (EEM), 2019, pp. 1–5.
- [211] Tchórzewski J., Marłęga R.: Development of the Polish Power Exchange as a Management System in Terms of Control Theory and Systems Engineering, 2018 15th International Conference on the European Energy Market (EEM), 2018, pp. 1–5.
- [212] Tchórzewski J., Marłęga R.: Modeling and simulation of the control- and the systems-inspired of the Polish Electricity Exchange, 2017 Progress in Applied Electrical Engineering (PAEE), 2017, pp. 1–6.
- [213] Tchórzewski J., Marłęga R.: Systemowy algorytm ewolucyjny do poprawy modelu Towarowej Giełdy Energii Elektrycznej. Część 1, Istota i możliwości algorytmu,
-

- Poznan University of Technology Academic Journals. Electrical Engineering, 2017, tom 90, ss. 277–287.
- [214] Tchórzewski J., Marłęga R.: Identification of the polish power exchange based on the data related to the day-ahead market, 2016 Electric Power Networks (EPNet), 2016, pp. 1–6.
- [215] Tchórzewski J., Marłęga R.: Model parametryczny bezpieczeństwa rozwoju Towarowej Giełdy Energii Elektrycznej i jego implementacja w środowisku MATLABA i Simulinka, Przedsiębiorczość i Zarządzanie, 2015, ss. 323–334.
- [216] Tchórzewski J.: Metody sztucznej inteligencji i informatyki kwantowej w ujęciu teorii sterowania i systemów, Wydawnictwo Uniwersytetu Przyrodniczo-Humanistycznego w Siedlcach, Siedlce 2021, 344 s.
- [217] Tchórzewski J.: Capabilities of MATLAB and Simulink Related to Modelling of Polish Power Exchange. Information System in Management, Tom 5, No 3/2016, ss. 424–435.
- [218] Tchórzewski J.: Rozwój systemu elektroenergetycznego w ujęciu teorii sterowania i systemów, OW Politechniki Wrocławskiej, Wrocław 2013, 190 s.
- [219] Tchórzewski J.: Dynamiczny model rozwoju polskiej giełdy energii elektrycznej na przykładzie danych z lat 2002–2007, Rynek Energii, Nr II(IV), 2009, ss. 128–133.
- [220] Tchórzewski J., Chyży E.: Statyczne modele rozwoju polskiej giełdy energii elektrycznej na przykładzie danych z lat 2002–2007, Rynek Energii, Nr II(IV), 2009, ss. 134–139.
- [221] Tchórzewski J.: Model of Control System Development on Example the System of Electricity Market, Polish Journal of Environmental Studies, Vol. 16, No 4B, 2007, pp. 179–183.
- [222] Tchórzewski J.: Systemowy algorytm ewolucyjny w modelowaniu rozwoju rynku energii elektrycznej, Inżynieria Wiedzy i Systemy Ekspertowe [pod red.:] Bubnickiego Z. i Grzecha A., OW Politechniki Wrocławskiej, 2003, ss. 231–238.
- [223] Tchórzewski J.: Wielki system elektroenergetyczny w warunkach zmian strukturalno-parametrycznych własności. Prognozowanie w Elektroenergetyce, Konferencje 38, Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2000, ss. 239–246
- [224] Tchórzewski J.: Cybernetyka życia i rozwoju systemów, Wydawnictwo Wyższej Szkoły Rolniczo-Pedagogicznej w Siedlcach, Seria Monografie, 1992, 408 s.

-
- [225] Tchórzewski J.: Inżynieria rozwoju systemów, Wydawnictwo Wyższej Szkoły Rolniczo-Pedagogicznej w Siedlcach, Seria Monografie, 1990, 279 s.
- [226] Tchórzewski J., Ruciński D.: Modeling and simulation inspired by quantum methods of the Polish Electricity Stock Exchange, Progress in Applied Electrical Engineering, Kościelisko, 2017, pp. 1–6.
- [227] Thomas M.C. and Joy A.T.: Elements of Information Theory, John Wiley & Sons, Inc., 1991, pp.12–23.
- [228] Toczyłowski E.: Efektywność ekonomiczna mechanizmów rynkowych i regulacyjnych w energetyce, Rynek Energii, II(I), 2008, ss. 1–22.
- [229] Towarowa Giełda Energii S.A., www.tge.pl, [dostęp: lata 2006–2022].
- [230] Tseng F.M., Yu H.C. and Tzeng G.H.: Combining neural network model with seasonal time series ARIMA model, Technological Forecasting and Social Change, 2002, pp. 71–87.
- [231] Tserakh U. and Trusz M.: GARCH(1,1) models with stable residuals, Studia Informatica. System and information technology, 22, 1–2, 2019, pp. 47–57.
- [232] Qin P., Yang Z. J. and R. Nishii R.: Predictive control for dual-rate systems based on lifted state-space model identified by N4SID method, Proceedings of the 48th IEEE Conference on Decision and Control (CDC) held jointly with 2009 28th Chinese Control Conference, Shanghai, pp. 7369–7374.
- [233] Urząd Regulacji Energetyki, www.ure.gov.pl [dostęp: 18.06.2022 r.].
- [234] Vahidinasab V., Jadid S. and Kazemi A.: Day-ahead price forecasting in restructured power systems using artificial neural networks, Electric Power Systems Research, 78(8), 2008, pp. 1332–1342.
- [235] Voronin S.: Price Spike Forecasting in a competitive day-ahead energy market, Acta Universitatis, Lappeenrantaensis 530, 2013, 181 p.
- [236] Voronin, S., Partanen, J. and Kauranne, T., A hybrid electricity price forecasting model for the Nordic electricity spot market, International Transactions on Electrical Energy Systems. Published online, DOI: 10.1002/etep.1734, 2013.
- [237] Voronin S. and Partanen J.: Forecasting electricity price and demand using a hybrid approach based on wavelet transform, ARIMA and neural networks, International Journal of Energy Research, Published online, DOI: 10.1002/er.3067, 2013.
-

-
- [238] Wang A. and Ramsay B.: A neural network based estimator for electricity spot pricing with particular reference to weekend and public holidays, *Neurocomputing*, 23, 1998, pp. 47–57.
- [239] Weather Underground, Historical Weather, Accessed 1 May 2013, [at:] <http://www.wunderground.com> [dostęp: 24.02.2019 r.].
- [240] Weron A., Weron R.: *Giełda energii elektrycznej – strategia zarządzania ryzykiem*, CIRE, Wrocław 2000, 284 s.
- [241] Weron, R.: *Modeling and forecasting electricity loads and prices: A statistical approach*, Wiley Finance Series, Wiley 2006, 396 s.
- [242] Weron R.: *Modeling and Forecasting Loads and Prices in Deregulated Electricity Markets*, Agencja Rynku Energii, Warszawa 2006, 199 s.
- [243] Weron R.: Electricity price forecasting: A review of the state-of-the-art with a look into the future, *International Journal of Forecasting* 30(4), 2014, pp. 1030–1081.
- [244] Weron R., Misiorek A.: *Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models*, MPRA Paper, No. 10428, Monachium 2008, 23 s.
- [245] Willis H.: *Spatial Electric Load Forecasting*, Second edition, Revised and Expanded, Marcel Dekker, Inc., 2002, pp. 124–128.
- [246] Wnukowska B.: *Metodyka analizy i prognozowania potrzeb energetycznych odbiorców przemysłowych na rynku energii*, Prace Naukowe Instytutu Energoelektryki Politechniki Wrocławskiej, Seria: Monografie Nr 30 (95), OW Politechniki Wrocławskiej, 2005, 210 s.
- [247] Wolak F.A.: *Market design and price behavior in restructured electricity markets*, Power, 1997, pp. 79–133.
- [248] Wu L. and Shahidehpour M.: A hybrid model for day-ahead price forecasting, *IEEE Transaction on Power Systems*, 25(3), 2010, pp. 1519–1530.
- [249] Xiang Li X., Chen H., Gao S.: Electric power system load forecast model based on State Space time-varying parameter theory, *International Conference on Power System Technology*, POWERCOM, China 2010, pp. 1–4.
- [250] Yamin H.Y., Shahidehpour S.M. and Li Z.: Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets, *Electrical Power Energy Systems*, 2004, pp. 571–581.
-

-
- [251] Yun Z., Quan Z., Caixin S., Shaolan, L., Yuming L., and Yang S.: RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment, *IEEE Transaction on Power Systems*, 23 (3), 2008, pp. 853–858.
- [252] Zareipour H., Canizares C.A. and Bhattacharya K.: Economic impact of electricity market price forecasting errors: a demand – side analysis, *IEEE Transaction on Power Systems*, 25, 2010, pp. 254–262.
- [253] Zerka M.: *Mechanizmy rynkowe w elektroenergetyce: zagadnienia wybrane*, Instytut Doskonalenia Wiedzy o Rynku, Warszawa 2001.
- [254] Zhang G.P.: Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50, 2003, pp. 159–175.
- [255] Zhang G.P. and Qi M.: Neural network forecasting for seasonal and trend time series, *European Journal of Operational Research*, 160, 2005, pp. 501–514.
- [256] Zhao J.H., Dong Z.Y., Li X. and Wong K.P.: A framework for electricity price spike analysis with advanced data mining methods, *IEEE Transaction on Power Systems*, 22(1), 2007, pp. 376–385.
- [257] Zhao J.H., Dong Z.Y. and Li, X.: Electricity market price spike forecasting and decision making, *IET Generation, Transmission & Distribution*, 1(4), 2007, pp. 647–654.
- [258] Zhou N., Trudnowski D. J., Pierre J. W., and Mittelstadt W. A.: Electromechanical Mode Online Estimation Using Regularized Robust RLS Methods, *IEEE Transactions on Power Systems*, Vol. 23, No 4, Nov 2008, pp. 1670–1680.
- [259] Zieliński J.S. [i inni]: *Inteligentne systemy w zarządzaniu. Teoria i praktyka*, WN PWN, Warszawa 2000, 350 s.
- [260] Zimmer A., Englot A.: *Identyfikacja obiektów i sygnałów. Teoria i praktyka dla użytkowników MATLABA*, Politechnika Krakowska, 2005, 239 s.
- [261] Żak S. H.: On state-space models for systems described by partial differential equations, *The 23rd IEEE Conference on Decision and Control*, Las Vegas, Nevada, USA 1984, pp. 571–576.
- [262] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe. Podstawy teorii i zastosowania*, PWN, Warszawa 1996, 374 s.
-

WYKAZ RYSUNKÓW

Rysunek 1.1.	Wolumen energii bilansującej nieplanowanej, ale odebranej z rynku bilansującego oraz przebieg cen rozliczeniowych niezbilansowania dla poszczególnych miesięcy 2020 r.	20
Rysunek 1.2.	Średniodobowe ceny energii elektrycznej w transakcjach SPOT mierzone indeksem IRDN24 [zł/MWh] oraz wolumen obrotu energią elektryczną na RDN (bez kontraktów blokowych) [MWh] w poszczególnych miesiącach lat 2018–2020	22
Rysunek 1.3.	Sposoby notowania przeprowadzane na RDN.....	22
Rysunek 2.1.	Sytuacja systemowa modelowania RDN: analitycznego (matematycznego), identyfikacyjnego (eksperymentalnego) oraz neuralnego (projektowego).....	32
Rysunek 2.2.	Schemat blokowy modelu parametrycznego w postaci ogólnej.....	34
Rysunek 2.3.	Schemat blokowy modelu parametrycznego ARX.....	35
Rysunek 2.4.	Umieszczenie systemu RDN w kategoriach inżynierii systemów w otoczeniu bliższym (dostawców i odbiorców ee)	37
Rysunek 2.5.	Ilustracja procesu modelowania i metamodelowania systemu RDN TGE S.A.....	38
Rysunek 2.6.	Ilustracja rysunkowa systemu RDN na TGE S.A.....	39
Rysunek 3.1.	Schemat procesu badawczego.....	51
Rysunek 3.2.	Schemat procesu identyfikacji i metaidentyfikacji systemu RDN TGE S.A....	60
Rysunek 3.3.	Sytuacja systemowa wyróżnienia obszaru badań systemu RDN TGE S.A....	61
Rysunek 3.4.	Wybrane rodzaje modeli systemu Rynku Dnia Następnego na Towarowej Giełdzie Energii S.A. w ujęciu inżynierii systemów.....	64
Rysunek 3.5.	Efektywność jako relacja pomiędzy skutecznością oraz zasobami systemu....	69
Rysunek 4.1.	Przebieg wartości wielkości wyjściowej y_{012015} (jako strumienia decyzyjnego DF, średnioważonej wolumenem ceny jednostkowej ee z modelu i z systemu RDN dla 184 dni pomiarowych (próbek do identyfikacji zawierających wartości 24 wielkości wejściowych dotyczących wolumenu ee dostarczonej i sprzedanej na RDN TGE S.A. oraz dla wielkości wyjściowej dotyczącej średnioważonej wolumenem ceny uzyskanej za sprzedaną ee w godzinie 0–1 w okresie 01 trwającym od 1.01 do 30.06.2015 r.....	75
Rysunek 4.2.	Schemat blokowy procesu identyfikacji parametrycznej arx systemu RDN....	86
Rysunek 4.3.	Przebieg wartości średnioważonej wolumenem ceny energii elektrycznej, która wystąpiła na RDN [PLN/MWh] w godzinie 0-1 w okresie p1 wynoszącym umownych 184 dni (1.01–30.06.2013r.)	90
Rysunek 4.4.	Przykład modelu ciągłego w przestrzeni stanów dla okresu pomiarowego p7 (od 1 lipca 2013 r. do 31 grudnia 2013 r.).....	91

Rysunek 4.5. Schemat blokowy modelu zmiennych stanu systemu RDN dla 24 wielkości wejściowych dotyczących wolumenu energii elektrycznej sprzedanej w poszczególnych godzinach doby z średnioważoną wolumenem ceną energii elektrycznej uzyskaną w godzinie 0-1 dla okresów pomiarowych p_i , gdzie $i=1-n$	98
Rysunek 4.6. Zmiany elementu a_{21} macierzy A w 35 okresach badania systemu RDN.....	100
Rysunek 4.7. Zmiany elementu a_{15} macierzy A w 35 badania systemu RDN.....	100
Rysunek 4.8. Zmiany elementu a_{55} macierzy A w 35 badania systemu RDN.....	100
Rysunek 4.9. Zmiany elementu b_{21} macierzy B w 35 badania systemu RDN.....	101
Rysunek 4.10. Zmiany elementu b_{54} macierzy B w 35 badania systemu RDN.....	101
Rysunek 4.11. Zmiany elementu b_{15} macierzy B w 35 badania systemu RDN.....	101
Rysunek 4.12. Zmiany elementu c_{15} macierzy C w 35 badania systemu RDN.....	102
Rysunek 5.1. Przebieg wartości współczynnika a_{11} wielomianu $AM_1(z)$ w metamodelu systemu RDN i modelu systemu RDN dla 560 próbek wejściowo-wyjściowych dotyczących okresu p_1 w godzinie 0–1, to jest z okresu od 1.01 do 30.06.2013 r.	112
Rysunek 5.2. Przebieg błędu uczenia MSE dla rozważanego metamodelu systemu RDN, to jest dla okresu p_1	113
Rysunek 5.3. Metamodel neuronalny systemu RDN w środowisku MATLABA i Simulinka.....	113
Rysunek 5.4. Model pierwszej warstwy neuronów w SSN jako metamodelu systemu RDN	114
Rysunek 5.5. Model drugiej warstwy neuronów w SSN jako metamodelu systemu RDN	114
Rysunek 5.6. Przykład schematu blokowego w Simulinku do badań porównawczych metamodelu neuralnego w postaci SSN z modelem systemu RDN.....	115
Rysunek 5.7. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na pierwszym neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN.....	115
Rysunek 5.8. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na drugim neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN.....	116
Rysunek 5.9. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na trzecim neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN.....	116
Rysunek 5.10. Przebieg rozbieżności pomiędzy sygnałem wyjściowym na czwartym neuronie z drugiej warstwy neuronów metamodelu a analogicznym sygnałem wyjściowym z modelu systemu RDN.....	116

Rysunek 6.1. Przykład godzinowego rozkładu zapotrzebowania na ee dla dwóch dni miesiąca grudnia 2019 r.	118
Rysunek 6.2. Separator wolumenu ee danych godzinowych systemu RDN.....	120
Rysunek 6.3. Generator efektywności godzinowych systemu RDN.....	122
Rysunek 6.4. Miernik przebiegu efektywności godzinowych systemu RDN.....	123
Rysunek 6.5. Miernik błędu względnego krzepkości pomiędzy modelem i systemem RDN.....	124
Rysunek 6.6. Separator ceny ee danych godzinowych systemu RDN	125
Rysunek 6.7. Miernik błędu względnego efektywności pomiędzy modelem i systemem RDN	126
Rysunek 6.8. Generator błędu względnego efektywności pomiędzy modelem i systemem RDN.....	127
Rysunek 6.9. Subsystem wyznaczający błąd względny krzepkości pomiędzy modelem a systemem RDN.....	127
Rysunek 6.10. Model godzinowy systemu RDN	129
Rysunek 6.11. Subsystem wyznaczający model systemu RDN	129
Rysunek 6.12. Subsystem wyznaczający błąd względny modelu do systemu.....	130
Rysunek 6.13. Błąd średniokwadratowy MSE dopasowania SSN do modelu Idmodel.....	131
Rysunek 6.14. Architektura SSN modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019	131
Rysunek 6.15. Architektura SSN warstwy pierwszej modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019	131
Rysunek 6.16. Architektura SSN warstwy drugiej modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019	132
Rysunek 6.17. Architektura SSN warstwy pierwszej dla macierzy wag W1 modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019	132
Rysunek 6.18. Architektura SSN warstwy drugiej dla macierzy wag W2 modelu neuralnego korektora wyjścia z Idmodel dla godziny 6 roku 2019	133
Rysunek 6.19. Wskaźnik regresji w procesie uczenia SSN modelu neuralnego dopasowania sygnału wyjściowego z Idmodel dla godziny 6 roku 2019 do danych rzeczywistych systemu RDN	133
Rysunek 6.20. Przebiegi błędu względnego modelu w stosunku do systemu RDN dla godziny 6 roku 2019.....	136
Rysunek 7.1. Zestawienie efektywności w zależności od wolumenu ee dla godzin 6, 12, 18, 24 2019 r.	155

Rysunek 7.2. Zestawienie krzepkości w funkcji wolumenu ee dla godzin 6, 12, 18, 24 2019 r.....	165
Rysunek B.1. Model symulacyjny systemu RDN dla godzin 6, 12, 18 24 w 2019 r.....	217
Rysunek C.1. Przebiegi błędu względnego modelu w stosunku do systemu RDN dla godziny 12 2019 r.....	221
Rysunek C.2. Przebiegi błędu względnego modelu w stosunku do systemu RDN dla godziny 18 2019 r.....	221
Rysunek C.3. Przebiegi błędu względnego modelu w stosunku do systemu RDN dla godziny 24 2019 r.....	222

WYKAZ TABEL

Tabela 1.1	Liczba odbiorców, wolumen, wartość oraz średnie ceny energii elektrycznej stosowane do odbiorcy końcowego w zależności od kryterium zużycia dla roku 2020.....	21
Tabela 2.1.	Studium porównawcze wybranych metod/modeli systemu Rynku Dnia Następnego	47
Tabela 3.1.	Cele i zadania badawcze.....	53
Tabela 4.1.	Stopień dopasowania uzyskanych modeli do danych rzeczywistych za pomocą wybranych metod identyfikacji dla godziny 6 roku 2019.....	74
Tabela 4.2.	Przebiegi zmian elementów macierzy A w ciągu doby dla danych RDN TGE S.A. z pierwszego półrocza 2015 r.	78
Tabela 4.3.	Przebiegi zmian elementów macierzy B w ciągu doby dla danych RDN TGE S.A. i półrocza 2015 r.....	80
Tabela 4.4.	Zestawienie wartości współczynników wielomianu $A_1(z)$ dla kolejnych modeli systemu RDN.....	87
Tabela 4.5.	Zestawienie wartości współczynników wielomianów $B_1(z)$ dla kolejnych modeli systemu RDN.....	88
Tabela 4.6.	Zestawienie wybranych wartości elementów macierzy A odpowiadających za stopień wewnętrznego zorganizowania systemu RDN.....	95
Tabela 4.7.	Zestawienie wybranych wartości elementów macierzy B odpowiadających za poziom sterowania systemu RDN.....	96
Tabela 4.8.	Zestawienie wartości elementu c_{15} macierzy C odpowiadającego za sprzężenia systemu RDN z otoczeniem (dostawcami i odbiorcami energii elektrycznej, siła oddziaływania zmiennej stanu x_5 na jej pochodną.....	97
Tabela 6.1.	Zestawienie błędów względnych [%] dla wybranych okresów roku 2019 (rok 2019, miesiąc grudzień, tydzień drugi).....	136
Tabela 6.2.	Zestawienie błędów MAPE [%] dla wybranych okresów roku 2019 (rok 2019, miesiąc grudzień, tydzień drugi).....	137
Tabela 6.3.	Zestawienie błędów MAPE dla wybranych okresów roku 2020 (rok 2020, miesiąc grudzień, tydzień drugi) [%]	137
Tabela 6.4.	Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 6 roku 2019 dla modelu i systemu RDN.....	138
Tabela 6.5.	Zestawienie wartości oraz błędów względnych efektywności, skuteczności i krzepkości modelu i systemu dla godzin 6, 12, 18, 24 roku 2019.....	141
Tabela 6.6.	Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 6 roku 2019 pomiędzy modelem i systemem RDN	142
Tabela 6.7.	Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 6 roku 2019 modelu i systemu RDN	143

Tabela 7.1.	Efektywność w zależności od wolumenu ee dla godzin 6, 12, 18, 24 2019 r.	153
Tabela 7.2.	Skuteczność w funkcji zasobów dla stałej średnioważonej wolumenem ceny ee i stałej efektywności realizacyjnej modelu systemu RDN.....	156
Tabela 7.3.	Przebiegi skuteczność w funkcji zasobów, to jest wolumenu ee dla godzin 6, 12, 18, 24 2019 r. dla stałej średnioważonej wolumenem ceny ee i stałej efektywności realizacyjnej modelu systemu RDN.....	158
Tabela 7.4	Skuteczność w zależności od średnioważonej wolumenem ceny ee odniesionej do wolumenu dla godzin 6, 12, 18, 24 2019 r.	160
Tabela 7.5.	Krzepkość w funkcji wolumenu dla godzin 6, 12, 18, 24 2019 r.....	163
Tabela 7.6.	Krzepkość w funkcji zasobów, to jest wolumenu ee dla godzin 6, 12, 18, 24 2019 r. dla stałej minimalnej, maksymalnej oraz średniej średnioważonej wolumenem ceny ee modelu systemu RDN.....	166
Tabela 7.7.	Zestawienie wyników analizy krzepkości modelu systemu RDN dla średniego wolumenu ee dla godzin 6, 12, 18, 24 2019 r.....	168
Tabela B.1.	Zestawienie wybranych bloków wykorzystanych w modelu parametrycznym arx systemu RDN.....	218
Tabela C.1.	Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 12 roku 2019 dla modelu i systemu RDN.....	222
Tabela C.2.	Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 18 roku 2019 dla modelu i systemu RDN.....	225
Tabela C.3.	Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 24 roku 2019 dla modelu i systemu RDN.....	227
Tabela C.4.	Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 12 roku 2019 pomiędzy modelem i systemem RDN	230
Tabela C.5.	Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 18 roku 2019 pomiędzy modelem i systemem RDN.....	231
Tabela C.6.	Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 24 roku 2019 pomiędzy modelem i systemem RDN.....	233
Tabela C.7.	Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 12 roku 2019 modelu i systemu RDN.....	234
Tabela C.8.	Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 18 roku 2019 modelu i systemu RDN.....	236
Tabela C.9.	Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 24 roku 2019 modelu i systemu RDN.....	237

DODATEK A

Modele systemu Rynku Dnia Następnego

Dla godziny 12 roku 2019 otrzymano model parametryczny dyskretny w postaci:

$$A(z) \cdot y_{12}(t) = B_1(z) \cdot u_1(t) + B_2(z) \cdot u_2(t) + \dots + B_{24}(z) \cdot u_{24}(t) + e(t), \quad (A.1)$$

gdzie:

$$A(z) = 1 - 0.7265 \cdot z^{-1} + 0.6700 \cdot z^{-2} - 0.3250 \cdot z^{-3} - 0.0862 \cdot z^{-4} + \\ 0.0011 \cdot z^{-5} - 0.1366 \cdot z^{-6},$$

$$B_1(z) = 0.0181 \cdot z^{-2} + 0.0779 \cdot z^{-3} + 0.0676 \cdot z^{-4} + 0.0266 \cdot z^{-5} + 0.0921 \cdot z^{-6} \\ - 0.0347 \cdot z^{-7} + 0.0866 \cdot z^{-8} - 0.0924 \cdot z^{-9} + 0.0721 \cdot z^{-10} \\ - 0.0389 \cdot z^{-11} + 0.0181 \cdot z^{-12} - 0.0222 \cdot z^{-13} + 0.0178 \cdot z^{-14},$$

$$B_2(z) = -0.0002 \cdot z^{-2} + 0.0844 \cdot z^{-3} - 0.0476 \cdot z^{-4} - 0.0048 \cdot z^{-5} - 0.0474 \\ \cdot z^{-6} + 0.0199 \cdot z^{-7} - 0.0124 \cdot z^{-8} + 0.0183 \cdot z^{-9} - 0.0350 \cdot z^{-10} \\ + 0.0461 \cdot z^{-11} + 0.0061 \cdot z^{-12} + 0.0964 \cdot z^{-13} - 0.0992 \cdot z^{-14},$$

.....

$$B_{24}(z) = -0.0103 \cdot z^{-2} + 0.004 \cdot z^{-3} + 0.0005 \cdot z^{-4} + 0.0005 \cdot z^{-5} + 0.0374 \cdot z^{-6} \\ - 0.0288 \cdot z^{-7} + 0.0258 \cdot z^{-8} - 0.0562 \cdot z^{-9} + 0.0474 \cdot z^{-10} + 0.0018 \\ \cdot z^{-11} + 0.0147 \cdot z^{-12} - 0.0144 \cdot z^{-13} - 0.0073 \cdot z^{-14},$$

Dokonując konwersji modelu parametrycznego dyskretnego na model parametryczny ciągły przy wykorzystaniu funkcji postaci:

$$\text{th6132h122019} = \text{d2c}(\text{arx6132h122019}, 'tustin') \quad (A.2)$$

otrzymano następujący model parametryczny ciągły dla godziny 12 roku 2019:

$$y_{12}(t) = [((B_1(s)/F_1(s)) \cdot u_1(t) + ((B_2(s)/F_2(s)) \cdot u_2(t) + \dots + ((B_{24}(s)/F_{24}(s)) \cdot \\ u_{24}(t) + [C(s)/D(s)] \cdot e(t), \quad (A.3)$$

gdzie:

$$B_1(s) = -0.2450 \cdot s^{13} + 0.0668 \cdot s^{12} - 12.6900 \cdot s^{11} + 0.2316 \cdot s^{10} - 166.5 \cdot s^9 \\ + 356.2 \cdot s^8 - 570.1 \cdot s^7 + 2018 \cdot s^6 - 1158 \cdot s^5 + 1130 \cdot s^4 - 2109 \\ \cdot s^3 + 53.58 \cdot s^2 + 487.5 \cdot s + 436.3,$$

$$B_2(s) = 0.1985 \cdot s^{13} - 1.304 \cdot s^{12} + 27.48 \cdot s^{11} - 119.4 \cdot s^{10} + 632.6 \cdot s^9 - 2027 \cdot s^8 + 4383 \cdot s^7 - 8796 \cdot s^6 + 1.034e04 \cdot s^5 - 7800 \cdot s^4 + 7293 \cdot s^3 + 233.1 \cdot s^2 + 431.4 \cdot s + 80.98,$$

.....

$$B_{24}(s) = -0.0788 \cdot s^{13} + 0.5148 \cdot s^{12} + 0.4375 \cdot s^{11} + 6.816 \cdot s^{10} + 28.07 \cdot s^9 - 33.94 \cdot s^8 + 284.7 \cdot s^7 - 862.9 \cdot s^6 + 1333 \cdot s^5 - 2566 \cdot s^4 + 594.3 \cdot s^3 - 701.3 \cdot s^2 + 80.19 \cdot s + 63.9,$$

$$C(s) = s^6 + 12 \cdot s^5 + 60 \cdot s^4 + 160 \cdot s^3 + 240 \cdot s^2 + 192 \cdot s + 64,$$

$$D(s) = s^6 + 9.003 \cdot s^5 + 24.05 \cdot s^4 + 63.13 \cdot s^3 + 62.23 \cdot s^2 + 69.47 \cdot s + 10.17,$$

$$F_1(s) = s^{13} + 23 \cdot s^{12} + 234.1 \cdot s^{11} + 1436 \cdot s^{10} + 6047 \cdot s^9 + 1.869e04 \cdot s^8 + 4.385e04 \cdot s^7 + 7.908e04 \cdot s^6 + 1.095e05 \cdot s^5 + 1.149e05 \cdot s^4 + 8.834e04 \cdot s^3 + 4.592e04 \cdot s^2 + 1.345e04 \cdot s + 1301,$$

$$F_2(s) = s^{13} + 23 \cdot s^{12} + 234.1 \cdot s^{11} + 1436 \cdot s^{10} + 6047 \cdot s^9 + 1.869e04 \cdot s^8 + 4.385e04 \cdot s^7 + 7.908e04 \cdot s^6 + 1.095e05 \cdot s^5 + 1.149e05 \cdot s^4 + 8.834e04 \cdot s^3 + 4.592e04 \cdot s^2 + 1.345e04 \cdot s + 1301,$$

.....

$$F_{24}(s) = s^{13} + 23 \cdot s^{12} + 234.1 \cdot s^{11} + 1436 \cdot s^{10} + 6047 \cdot s^9 + 1.869e04 \cdot s^8 + 4.385e04 \cdot s^7 + 7.908e04 \cdot s^6 + 1.095e05 \cdot s^5 + 1.149e05 \cdot s^4 + 8.834e04 \cdot s^3 + 4.592e04 \cdot s^2 + 1.345e04 \cdot s + 1301.$$

W wyniku konwersji modelu parametrycznego ciągłego na model w przestrzeni stanu ciągle z wykorzystaniem funkcji postaci:

$$[A \ B \ C \ D \ KRDN \ X0RDN]=th2ss(th6132h122019)$$

otrzymano następujący model dla godziny 12 roku 2019:

$$\begin{aligned} \frac{dx_1}{dt} = & -23,0030 x_1 - 7,3155 x_2 - 5,6099 x_3 - 2,9528 x_4 - 2,2817 x_5 - 1,3383 x_6 - 1,2066 x_7 \\ & - 0,8355 x_8 - 0,8768 x_9 - 0,6739 x_{10} - 0,3503 x_{11} - 0,2052 x_{12} - 0,1589 x_{13} \\ & + 4 u_1, \end{aligned}$$

$$\frac{dx_2}{dt} = 32 x_1,$$

$$\frac{dx_3}{dt} = 8 x_2,$$

$$\frac{dx_4}{dt} = 8 x_3,$$

$$\frac{dx_5}{dt} = 4 x_4,$$

$$\frac{dx_6}{dt} = 4 x_5,$$

$$\frac{dx_7}{dt} = 2 x_6,$$

$$\frac{dx_8}{dt} = 2 x_7,$$

$$\frac{dx_9}{dt} = x_8,$$

$$\frac{dx_{10}}{dt} = x_9,$$

$$\frac{dx_{11}}{dt} = x_{10},$$

$$\frac{dx_{12}}{dt} = 0,5 x_{11},$$

$$\frac{dx_{13}}{dt} = 0,125 x_{12},$$

$$\begin{aligned} \frac{dx_{14}}{dt} = & -23,0030 x_{14} - 7,3155 x_{15} - 5,6099 x_{16} - 2,9528 x_{17} - 2,2817 x_{18} - 1,3383 x_{19} \\ & - 1,2066 x_{20} - 0,8355 x_{21} - 0,8768 x_{22} - 0,6739 x_{23} - 0,3503 x_{24} - 0,2052 x_{25} \\ & - 0,1589 x_{26} + 4 u_2, \end{aligned}$$

$$\frac{dx_{15}}{dt} = 32 x_{14},$$

$$\frac{dx_{16}}{dt} = 8 x_{15},$$

$$\frac{dx_{17}}{dt} = 8 x_{16},$$

$$\frac{dx_{18}}{dt} = 4 x_{17},$$

$$\frac{dx_{19}}{dt} = 4 x_{18},$$

$$\frac{dx_{20}}{dt} = 2 x_{19},$$

$$\frac{dx_{21}}{dt} = 2 x_{20},$$

$$\frac{dx_{22}}{dt} = x_{21},$$

$$\frac{dx_{23}}{dt} = x_{22},$$

$$\frac{dx_{24}}{dt} = x_{23},$$

$$\frac{dx_{25}}{dt} = 0.5 x_{24},$$

$$\frac{dx_{26}}{dt} = 0,125 x_{25},$$

$$\dots\dots\dots (A.4)$$

$$\begin{aligned} \frac{dx_{300}}{dt} = & -23,0030 x_{300} - 7,3155 x_{301} - 5,6099 x_{302} - 2,9528 x_{303} - 2,2817 x_{304} - 1,3383 x_{305} \\ & - 1,2066 x_{306} - 0,8355 x_{307} - 0,8768 x_{308} - 0,6740 x_{309} - 0,35033 x_{310} \\ & - 0,2052 x_{311} - 0,1589 x_{312} + 2 u_{24}, \end{aligned}$$

$$\frac{dx_{301}}{dt} = 32 x_{300},$$

$$\frac{dx_{302}}{dt} = 8 x_{301},$$

$$\frac{dx_{303}}{dt} = 8 x_{302},$$

$$\frac{dx_{304}}{dt} = 4 x_{303},$$

$$\frac{dx_{305}}{dt} = 4 x_{304},$$

$$\frac{dx_{306}}{dt} = 2 x_{305},$$

$$\frac{dx_{307}}{dt} = 2 x_{306},$$

$$\frac{dx_{308}}{dt} = x_{307},$$

$$\frac{dx_{309}}{dt} = x_{308},$$

$$\frac{dx_{310}}{dt} = x_{309},$$

$$\frac{dx_{311}}{dt} = 0.5 x_{310},$$

$$\frac{dx_{312}}{dt} = 0,125 x_{311},$$

$$\frac{dx_{313}}{dt} = -9,0030 x_{313} - 3,0067 x_{314} - 1,9727 x_{315} - 0,9724 x_{316} - 1,0854 x_{317} - 0,3177 x_{318},$$

$$\frac{dx_{314}}{dt} = 8 x_{313},$$

$$\frac{dx_{315}}{dt} = 4 x_{314},$$

$$\frac{dx_{316}}{dt} = 2 x_{315},$$

$$\frac{dx_{317}}{dt} = x_{316}$$

$$\frac{dx_{318}}{dt} = 0,5 x_{317}$$

oraz dla godziny 12 roku 2019 równanie wyjścia przyjmuje postać:

$$y_{12}(t) = 1,4253 x_1(t) + 0,3489 x_2(t) + 0,3438 x_3(t) + \dots + 0,4206 x_{318}(t) - \\ + 0,2450 u_1(t) + 0,1985 u_2(t) + \dots - 0,0788 u_{24}(t), \quad (\text{A.5})$$

gdzie:

$x_1(t), x_2(t), \dots, x_{318}(t)$ – odpowiednie zmienne stanu,

$u_1(t), u_2(t), \dots, u_{24}(t)$ – odpowiednie zmienne wejściowe.

Dla godziny 18 roku 2019 otrzymano model parametryczny dyskretny w postaci:

$$A(z) \cdot y_{18}(t) = B_1(z) \cdot u_1(t) + B_2(z) \cdot u_2(t) + \dots + B_{24}(z) \cdot u_{24}(t) + e(t), \quad (\text{A.6})$$

gdzie:

$$A(z) = 1 - 0.4424 \cdot z^{-1} - 0.0211 \cdot z^{-2} + 0.1844 \cdot z^{-3} - 0.1027 \cdot z^{-4} + 0.1191 \cdot z^{-5} - 0.1753 \cdot z^{-6} - 0.2558 \cdot z^{-7} - 0.0173 \cdot z^{-8} + 0.0162 \cdot z^{-9} - 0.0748 \cdot z^{-10} - 0.0138 \cdot z^{-11},$$

$$B_1(z) = -0.0050 \cdot z^{-1} - 0.0206 \cdot z^{-2} - 0.0221 \cdot z^{-3} + 0.0034 \cdot z^{-4} + 0.0181 \cdot z^{-5} + 0.0079 \cdot z^{-6} + 0.0069 \cdot z^{-7} - 0.0214 \cdot z^{-8} + 0.0391 \cdot z^{-9} + 0.0086 \cdot z^{-10} + 0.0099 \cdot z^{-11} + 0.0075 \cdot z^{-12},$$

$$B_2(z) = 0.0436 \cdot z^{-1} + 0.0138 \cdot z^{-2} + 0.0296 \cdot z^{-3} - 0.0023 \cdot z^{-4} - 0.0348 \cdot z^{-5} - 0.0246 \cdot z^{-6} + 0.0139 \cdot z^{-7} + 0.0293 \cdot z^{-8} - 0.0295 \cdot z^{-9} - 0.0154 \cdot z^{-10} - 0.0208 \cdot z^{-11} + 0.0084 \cdot z^{-12},$$

.....

$$B_{24}(z) = -0.0044 \cdot z^{-1} - 0.0285 \cdot z^{-2} + 0.0165 \cdot z^{-3} + 0.0074 \cdot z^{-4} + 0.0093 \cdot z^{-5} + 0.0115 \cdot z^{-6} + 0.0026 \cdot z^{-7} - 0.0095 \cdot z^{-8} + 0.0180 \cdot z^{-9} - 0.0090 \cdot z^{-10} - 0.0044 \cdot z^{-11} - 0.0090 \cdot z^{-12},$$

Dokonując konwersji modelu parametrycznego dyskretnego na model parametryczny ciągły przy wykorzystaniu funkcji postaci:

$$\text{th11121h182019}=\text{d2c}(\text{arx11121h182019},\text{'tustin'}) \quad (\text{A.7})$$

otrzymano następujący model parametryczny ciągły dla godziny 18 roku 2019:

$$y_{18}(t) = [((B_1(s)/F_1(s)) \cdot u_1(t) + ((B_2(s)/F_2(s)) \cdot u_2(t) + \dots + ((B_{24}(s)/F_{24}(s)) \cdot u_{24}(t) + [C(s)/D(s)] \cdot e(t), \quad (\text{A.8})$$

gdzie:

$$B_1(s) = -0.0613 \cdot s^{12} + 0.5383 \cdot s^{11} - 0.8807 \cdot s^{10} - 9.941 \cdot s^9 + 55.61 \cdot s^8 - 153.8 \cdot s^7 + 464.8 \cdot s^6 - 494.4 \cdot s^5 + 1132 \cdot s^4 - 2545 \cdot s^3 + 427 \cdot s^2 - 1468 \cdot s + 132.1,$$

$$B_2(s) = 0.0071 \cdot s^{12} - 1.787 \cdot s^{11} - 1.502 \cdot s^{10} - 63.78 \cdot s^9 - 5.83 \cdot s^8 - 437.1 \cdot s^7 + 582.1 \cdot s^6 - 367.8 \cdot s^5 + 1774 \cdot s^4 + 3783 \cdot s^3 + 1842 \cdot s^2 + 1856 \cdot s + 46.28,$$

.....

$$B_{24}(s) = -0.0747 \cdot s^{12} + 0.0294 \cdot s^{11} - 6.504 \cdot s^{10} + 8.564 \cdot s^9 - 40.25 \cdot s^8 + 257.3 \cdot s^7 - 350.9 \cdot s^6 + 1077 \cdot s^5 - 1828 \cdot s^4 + 479.8 \cdot s^3 - 1703 \cdot s^2 + 50.94 \cdot s + 2.693,$$

$$C(s) = s^{11} + 22 \cdot s^{10} + 220 \cdot s^9 + 1320 \cdot s^8 + 5280 \cdot s^7 + 14784 \cdot s^6 + 29568 \cdot s^5 + 42240 \cdot s^4 + 42240 \cdot s^3 + 28160 \cdot s^2 + 11264 \cdot s + 2048,$$

$$D(s) = s^{11} + 27.2 \cdot s^{10} + 271 \cdot s^9 + 1646 \cdot s^8 + 5889 \cdot s^7 + 1.52e04 \cdot s^6 + 2.92e04 \cdot s^5 + 3.54e04 \cdot s^4 + 3.446e04 \cdot s^3 + 1.936e04 \cdot s^2 + 9559 \cdot s + 442.9,$$

$$F_1(s) = s^{12} + 29.2 \cdot s^{11} + 325.4 \cdot s^{10} + 2188 \cdot s^9 + 9180 \cdot s^8 + 2.698e04 \cdot s^7 + 5.96e04 \cdot s^6 + 9.381e04 \cdot s^5 + 1.053e05 \cdot s^4 + 8.829e04 \cdot s^3 + 4.828e04 \cdot s^2 + 1.956e04 \cdot s + 885.9,$$

$$F_2(s) = s^{12} + 29.2 \cdot s^{11} + 325.4 \cdot s^{10} + 2188 \cdot s^9 + 9180 \cdot s^8 + 2.698e04 \cdot s^7 + 5.96e04 \cdot s^6 + 9.381e04 \cdot s^5 + 1.053e05 \cdot s^4 + 8.829e04 \cdot s^3 + 4.828e04 \cdot s^2 + 1.956e04 \cdot s + 885.9,$$

.....

$$F_{24}(s) = s^{12} + 29.2 \cdot s^{11} + 325.4 \cdot s^{10} + 2188 \cdot s^9 + 9180 \cdot s^8 + 2.698e04 \cdot s^7 + 5.96e04 \cdot s^6 + 9.381e04 \cdot s^5 + 1.053e05 \cdot s^4 + 8.829e04 \cdot s^3 + 4.828e04 \cdot s^2 + 1.956e04 \cdot s + 885.9.$$

W wyniku konwersji modelu parametrycznego ciągłego na model w przestrzeni stanu ciągły z wykorzystaniem funkcji postaci:

$$[A18 \ B18 \ C18 \ D18 \ KRDN18 \ X0RDN18] = \text{th2ss}(\text{th11121h182019})$$

otrzymano następujący model dla godziny 18 roku 2019:

$$\begin{aligned}\frac{dx_1}{dt} = & -29,1977 x_1 - 10,1689 x_2 - 8,5451 x_3 - 4,4824 x_4 - 3,2930 x_5 - 1,8188 x_6 - 1,4314 x_7 \\ & - 0,8031 x_8 - 0,6736 x_9 - 0,3684 x_{10} - 0,2985 x_{11} - 0,1081 x_{12} + 2 u_1,\end{aligned}$$

$$\frac{dx_2}{dt} = 32 x_1,$$

$$\frac{dx_3}{dt} = 8 x_2,$$

$$\frac{dx_4}{dt} = 8 x_3,$$

$$\frac{dx_5}{dt} = 4 x_4,$$

$$\frac{dx_6}{dt} = 4 x_5,$$

$$\frac{dx_7}{dt} = 2 x_6,$$

$$\frac{dx_8}{dt} = 2 x_7,$$

$$\frac{dx_9}{dt} = x_8,$$

$$\frac{dx_{10}}{dt} = x_9,$$

$$\frac{dx_{11}}{dt} = 0.5 x_{10},$$

$$\frac{dx_{12}}{dt} = 0.125 x_{11},$$

$$\begin{aligned}\frac{dx_{13}}{dt} = & 29,1977 x_{13} - 10,1689 x_{14} - 8,5451 x_{15} - 4,4824 x_{16} - 3,2930 x_{17} - 1,8188 x_{18} \\ & - 1,4314 x_{19} - 0,8031 x_{20} - 0,6736 x_{21} - 0,3684 x_{22} - 0,2985 x_{23} - 0,1081 x_{24} \\ & + 2 u_2,\end{aligned}$$

$$\frac{dx_{14}}{dt} = 32 x_{13},$$

$$\frac{dx_{15}}{dt} = 8 x_{14},$$

$$\frac{dx_{16}}{dt} = 8 x_{15},$$

$$\frac{dx_{17}}{dt} = 4 x_{16},$$

$$\frac{dx_{18}}{dt} = 4 x_{17},$$

$$\frac{dx_{19}}{dt} = 2 x_{18},$$

$$\frac{dx_{20}}{dt} = 2 x_{19},$$

$$\frac{dx_{21}}{dt} = x_{20},$$

$$\frac{dx_{22}}{dt} = x_{21},$$

$$\frac{dx_{23}}{dt} = 0.5 x_{22},$$

$$\frac{dx_{24}}{dt} = 0.125 x_{23},$$

..... (A.9)

$$\begin{aligned} \frac{dx_{277}}{dt} = & 29,1977 x_{277} - 10,1689 x_{278} - 8,5451 x_{279} - 4,4824 x_{280} - 3,2930 x_{281} - 1,8188 x_{282} \\ & - 1,4314 x_{283} - 0,8031 x_{284} - 0,6736 x_{285} - 0,3684 x_{286} - 0,2985 x_{287} \\ & - 0,1081 x_{288} + 2 u_{24}, \end{aligned}$$

$$\frac{dx_{278}}{dt} = 32 x_{277},$$

$$\frac{dx_{279}}{dt} = 8 x_{278},$$

$$\frac{dx_{280}}{dt} = 8 x_{279},$$

$$\frac{dx_{281}}{dt} = 4 x_{280},$$

$$\frac{dx_{282}}{dt} = 4 x_{281},$$

$$\frac{dx_{283}}{dt} = 2 x_{282},$$

$$\frac{dx_{284}}{dt} = 2 x_{283},$$

$$\frac{dx_{285}}{dt} = x_{284},$$

$$\frac{dx_{286}}{dt} = x_{285},$$

$$\frac{dx_{287}}{dt} = 0.5 x_{286},$$

$$\frac{dx_{288}}{dt} = 0.125 x_{287},$$

$$\begin{aligned} \frac{dx_{289}}{dt} = & 29,1977 x_{289} - 10,1689 x_{290} - 8,5451 x_{291} - 4,4824 x_{292} - 3,2930 x_{293} - 1,8188 x_{294} \\ & - 1,4314 x_{295} - 0,8031 x_{296} - 0,6736 x_{297} - 0,3684 x_{298} - 0,2985 x_{299}, \end{aligned}$$

$$\frac{dx_{290}}{dt} = 32 x_{289},$$

$$\frac{dx_{291}}{dt} = 8 x_{290},$$

$$\frac{dx_{292}}{dt} = 8 x_{291},$$

$$\frac{dx_{293}}{dt} = 4 x_{292},$$

$$\frac{dx_{294}}{dt} = 2 x_{293},$$

$$\frac{dx_{295}}{dt} = 2 x_{294},$$

$$\frac{dx_{296}}{dt} = x_{295},$$

$$\frac{dx_{297}}{dt} = x_{296},$$

$$\frac{dx_{298}}{dt} = 0.5 x_{297},$$

$$\frac{dx_{299}}{dt} = 0.125 x_{298},$$

oraz dla godziny 18 roku 2019 równanie wyjścia przyjmuje postać:

$$y_{18}(t) = 1,16396 x_1(t) + 0,2979 x_2(t) + 0,2425 x_3(t) + \dots + 0,1959 x_{299}(t) - 0,0613 u_1(t) + 0,0071 u_2(t) + \dots - 0,0747 u_{24}(t), \quad (\text{A.10})$$

gdzie:

$x_1(t), x_2(t), \dots, x_{299}(t)$ – odpowiednie zmienne stanu,

$u_1(t), u_2(t), \dots, u_{24}(t)$ – odpowiednie zmienne wejściowe.

Dla godziny 24 roku 2019 otrzymano model parametryczny dyskretny w postaci:

$$A(z) \cdot y_{24}(t) = B_1(z) \cdot u_1(t) + B_2(z) \cdot u_2(t) + \dots + B_{24}(z) \cdot u_{24}(t) + e(t), \quad (\text{A.11})$$

gdzie:

$$A(z) = 1 - 0.4924 \cdot z^{-1} + 0.2662 \cdot z^{-2} - 0.1694 \cdot z^{-3},$$

$$B_1(z) = 0.0037 \cdot z^{-1} + 0.0028 \cdot z^{-2} - 0.0034 \cdot z^{-3} + 0.0177 \cdot z^{-4} + 0.0090 \cdot z^{-5} - 0.0076 \cdot z^{-6} - 0.0006 \cdot z^{-7} + 0.0069 \cdot z^{-8} + 0.0150 \cdot z^{-9} - 0.0027 \cdot z^{-10} - 0.0028 \cdot z^{-11} + 0.0211 \cdot z^{-12},$$

$$B_2(z) = 0.0321 \cdot z^{-1} - 0.0179 \cdot z^{-2} + 0.0179 \cdot z^{-3} - 0.0006 \cdot z^{-4} - 0.0077 \cdot z^{-5} + 0.0114 \cdot z^{-6} + 0.0070 \cdot z^{-7} + 0.0309 \cdot z^{-8} - 0.0233 \cdot z^{-9} + 0.0147 \cdot z^{-10} + 0.0426 \cdot z^{-11} - 0.0028 \cdot z^{-12},$$

$$B_{24}(z) = 0.0010 \cdot z^{-1} - 0.0036 \cdot z^{-2} + 0.0049 \cdot z^{-3} + 0.0103 \cdot z^{-4} + 0.0003 \cdot z^{-5} + 0.0084 \cdot z^{-6} + 0.0147 \cdot z^{-7} + 0.0020 \cdot z^{-8} + 0.0034 \cdot z^{-9} - 0.0063 \cdot z^{-10} + 0.0037 \cdot z^{-11} - 0.0056 \cdot z^{-12},$$

Dokonując konwersji modelu parametrycznego dyskretnego na model parametryczny ciągły przy wykorzystaniu funkcji postaci:

$$\text{th3121h0242019} = \text{d2c}(\text{arx3121h0242019}, 'tustin') \quad (\text{A.12})$$

otrzymano następujący model parametryczny ciągły dla godziny 24 roku 2019:

$$y(t) = [((B_1(s)/F_1(s)) \cdot u_1(t) + ((B_2(s)/F_2(s)) \cdot u_2(t) + \dots + ((B_{24}(s)/F_{24}(s)) \cdot u_{24}(t) + [C(s)/D(s)] \cdot e(t), \quad (\text{A.13})$$

gdzie:

$$B_1(s) = 0.0089 \cdot s^{12} - 0.146 \cdot s^{11} + 2.791 \cdot s^{10} - 21.34 \cdot s^9 - 118.3 \cdot s^8 - 309.3 \cdot s^7 + 675.7 \cdot s^6 - 1008 \cdot s^5 + 1302 \cdot s^4 - 1053 \cdot s^3 + 869.5 \cdot s^2 - 203.9 \cdot s + 125.7,$$

$$B_2(s) = -0.0171 \cdot s^{12} - 0.4825 \cdot s^{11} - 7.269 \cdot s^{10} + 2.604 \cdot s^9 - 118.3 \cdot s^8 + 111.7 \cdot s^7 - 57.59 \cdot s^6 + 26.05 \cdot s^5 + 1417 \cdot s^4 - 327.9 \cdot s^3 + 1565 \cdot s^2 - 256.3 \cdot s + 221.5,$$

.....

$$B_{24}(s) = -0.0119 \cdot s^{12} + 0.1755 \cdot s^{11} - 1.867 \cdot s^{10} + 5.8 \cdot s^9 - 30.11 \cdot s^8 + 84.35 \cdot s^7 - 138.9 \cdot s^6 + 245.4 \cdot s^5 - 319.1 \cdot s^4 + 291 \cdot s^3 - 218.3 \cdot s^2 + 79.7 \cdot s + 70.52,$$

,

$$C(s) = s^3 + 6 \cdot s^2 + 12 \cdot s + 8,$$

$$D(s) = s^3 + 2.82 \cdot s^2 + 5.705 \cdot s + 2.508,$$

$$F_1(s) = s^{12} + 20.82 \cdot s^{11} + 200.5 \cdot s^{10} + 1183 \cdot s^9 + 4777 \cdot s^8 + 1.391e04 \cdot s^7 + 2.993e04 \cdot s^6 + 4.782e04 \cdot s^5 + 5.608e04 \cdot s^4 + 4.678e04 \cdot s^3 + 2.615e04 \cdot s^2 + 8700 \cdot s + 1284,$$

$$F_2(s) = s^{12} + 20.82 \cdot s^{11} + 200.5 \cdot s^{10} + 1183 \cdot s^9 + 4777 \cdot s^8 + 1.391e04 \cdot s^7 + 2.993e04 \cdot s^6 + 4.782e04 \cdot s^5 + 5.608e04 \cdot s^4 + 4.678e04 \cdot s^3 + 2.615e04 \cdot s^2 + 8700 \cdot s + 1284,$$

.....

$$F_{24}(s) = s^{12} + 20.82 \cdot s^{11} + 200.5 \cdot s^{10} + 1183 \cdot s^9 + 4777 \cdot s^8 + 1.391e04 \cdot s^7 + 2.993e04 \cdot s^6 + 4.782e04 \cdot s^5 + 5.608e04 \cdot s^4 + 4.678e04 \cdot s^3 + 2.615e04 \cdot s^2 + 8700 \cdot s + 1284.$$

.

W wyniku konwersji modelu parametrycznego ciągłego na model w przestrzeni stanu ciągły z wykorzystaniem funkcji postaci:

$$[A \ B \ C \ D \ KRDN \ X0RDN]=th2ss(th3121h0242019)$$

otrzymano następujący model dla godziny 24 roku 2019:

$$\begin{aligned}\frac{dx_1}{dt} = & -20,8197 x_1 - 6,2643 x_2 - 4,6220 x_3 - 4,6655 x_4 - 3,3963 x_5 - 1,8267 x_6 - 1,4595 x_7 \\ & - 0,8557 x_8 - 0,7138 x_9 - 0,3989 x_{10} - 0,2655 x_{11} - 0,1568 x_{12} + u_1,\end{aligned}$$

$$\frac{dx_2}{dt} = 32 x_1,$$

$$\frac{dx_3}{dt} = 8 x_2,$$

$$\frac{dx_4}{dt} = 4 x_3,$$

$$\frac{dx_5}{dt} = 4 x_4,$$

$$\frac{dx_6}{dt} = 4 x_5,$$

$$\frac{dx_7}{dt} = 2 x_6,$$

$$\frac{dx_8}{dt} = 2 x_7,$$

$$\frac{dx_9}{dt} = x_8,$$

$$\frac{dx_{10}}{dt} = x_9,$$

$$\frac{dx_{11}}{dt} = 0.5 x_{10},$$

$$\frac{dx_{12}}{dt} = 0.25 x_{11},$$

$$\begin{aligned}\frac{dx_{13}}{dt} = & -20,8197 x_{13} - 6,2643 x_{14} - 4,6220 x_{15} - 4,6655 x_{16} - 3,3963 x_{17} - 1,8267 x_{18} \\ & - 1,4595 x_{19} - 0,8557 x_{20} - 0,7138 x_{21} - 0,3989 x_{22} - 0,2655 x_{23} - 0,1568 x_{24} \\ & + u_2,\end{aligned}$$

$$\frac{dx_{14}}{dt} = 32 x_{13},$$

$$\frac{dx_{15}}{dt} = 8 x_{14},$$

$$\frac{dx_{16}}{dt} = 4 x_{15},$$

$$\frac{dx_{17}}{dt} = 4 x_{16},$$

$$\frac{dx_{18}}{dt} = 4 x_{17},$$

$$\frac{dx_{19}}{dt} = 2 x_{18},$$

$$\frac{dx_{20}}{dt} = 2 x_{19},$$

$$\frac{dx_{21}}{dt} = x_{20},$$

$$\frac{dx_{22}}{dt} = x_{21},$$

$$\frac{dx_{23}}{dt} = 0.5 x_{22},$$

$$\frac{dx_{24}}{dt} = 0.25 x_{23},$$

$$\dots\dots\dots (A.14)$$

$$\begin{aligned} \frac{dx_{277}}{dt} = & -20,8197 x_{277} - 6,2643 x_{278} - 4,6220 x_{279} - 4,6655 x_{280} - 3,3963 x_{281} - 1,8267 x_{282} \\ & - 1,4595 x_{283} - 0,8557 x_{284} - 0,7138 x_{285} - 0,3989 x_{286} - 0,2655 x_{287} \\ & - 0,1568 x_{288} + u_{24}, \end{aligned}$$

$$\frac{dx_{278}}{dt} = 32 x_{277},$$

$$\frac{dx_{279}}{dt} = 8 x_{278},$$

$$\frac{dx_{280}}{dt} = 4 x_{279},$$

$$\frac{dx_{281}}{dt} = 4 x_{280},$$

$$\frac{dx_{282}}{dt} = 4 x_{281},$$

$$\frac{dx_{283}}{dt} = 2 x_{282},$$

$$\frac{dx_{284}}{dt} = 2 x_{283},$$

$$\frac{dx_{285}}{dt} = x_{284},$$

$$\frac{dx_{286}}{dt} = x_{285},$$

$$\frac{dx_{287}}{dt} = 0.5 x_{286},$$

$$\frac{dx_{288}}{dt} = 0.25 x_{287},$$

$$\frac{dx_{289}}{dt} = -11,0379 x_{289} - 5,2493 x_{290} - 3,3492 x_{291}$$

$$\frac{dx_{290}}{dt} = 4 x_{289},$$

$$\frac{dx_{291}}{dt} = x_{290},$$

oraz dla godziny 24 roku 2019 równanie wyjścia przyjmuje postać:

$$y_{24}(t) = -0,3323 x_1(t) + 0,0312 x_2(t) - 0,1247 x_3(t) + \dots + 0,6865 x_{291}(t) - \\ + 0,0089 u_1(t) - 0,0171 u_2(t) + \dots - 0,0119 u_{24}(t), \quad (\text{A.15})$$


gdzie:

$x_1(t), x_2(t), \dots, x_{291}(t)$ – odpowiednie zmienne stanu,

$u_1(t), u_2(t), \dots, u_{24}(t)$ – odpowiednie zmienne wejściowe.

DODATEK B

Model symulacyjny Rynku Dnia Następnego



Rysunek B.1. Model symulacyjny systemu RDN dla godzin 6, 12, 18 24 w 2019 r.

Oznaczenia w tekście.

Źródło: opracowanie własne z wykorzystaniem Simulink-a [63, 195].

Tabela B.1. Zestawienie wybranych bloków wykorzystanych w modelu parametrycznym arx systemu RDN





	From Workspace – Odczytuje wartości danych określone w timeseries, macierzach lub innych formach z obszaru roboczego MATLAB, obszaru roboczego modelu lub obszaru roboczego maski. Format timeseries MATLAB może być użyty dla dowolnego typu danych. Aby wczytać dane dla sygnału magistrali, używamy struktury MATLAB, która pasuje do hierarchii magistrali i określamy przedziały czasowe dla każdego sygnału. W przypadku formatów macierzy każdy wiersz macierzy ma znacznik czasu w pierwszej kolumnie i wektor zawierający odpowiednią próbkę danych w kolejnej kolumnie (kolumnach). W przypadku formatu struktury używamy następującego zapisu: <code>var.time = [TimeValues]</code> <code>var.signals.values = [DataValues]</code> <code>var.signals.dimensions = [DimValues]</code>, np. <code>[tpp365 u242019]</code>, gdzie: <code>tpp365</code> – wektor sterujący pobieraniem danych, <code>u242019</code> – macierz wartości wielkości wejściowych dla danych dotyczących wolumenu sprzedanej ee w poszczególnych godzinach doby w 2019 r.
	To Workspace – wprowadza sygnał i zapisuje dane sygnału do przestrzeni roboczej MATLABA. Podczas symulacji blok zapisuje dane w buforze wewnętrznym. Po zakończeniu symulacji lub pauzie dane te są zapisywane w obszarze roboczym. Dane nie są dostępne, dopóki symulacja nie zostanie zatrzymana lub wstrzymana. Opis bloku np. <code>ToWbwemdosh6</code> – nazwa danych wyjściowych przekazanych do przestrzeni roboczej MATLABA, w tym przypadku dotyczących błędu względnego pomiędzy modelem i systemem RDN dla godziny 6 w 2019 r.
	Demux – wyodrębnia składowe wejściowego sygnału wektorowego i wysyła oddzielne sygnały. Porty sygnału wyjściowego są uporządkowane od góry do dołu. Na wejściu - akceptuje sygnał wektorowy nonbus. Wyodrębnia i wyprowadza sygnały z rzeczywistych lub zespolonych wartości dowolnego nonbus typu danych obsługiwane przez Simulink. Na wyjściu – Sygnały wyjściowe wyodrębnione z wejściowego sygnału wektorowego nonbus z rzeczywistymi lub złożonymi wartościami dowolnego typu danych obsługiwane przez Simulink. W rozważanym przykładzie sygnałem wejściowym do bloku jest macierz zawierająca 24 wielkości dotyczące sygnału wejściowego <code>u</code> (wolumen sprzedanej ee), a sygnałami wyjściowymi poszczególne wolumeny ee dla każdej godziny doby.
	Mux – blok łączy wiele wejść skalarnych w pojedyncze wyjście wektorowe, przy czym sygnał wejściowy może być sygnałem wektorowym. Wszystkie sygnały wejściowe muszą być tego samego typu danych i typu numerycznego. Elementy wyjściowego sygnału wektorowego przyjmują kolejność od góry do dołu lub od lewej do prawej. W rozważanym przykładzie blok ten został wykorzystany do połączenia sygnału dotyczącego krzepkości modelu z sygnałem dotyczącym krzepkości systemu RDN dla godziny 6 2019 r., aby istniała możliwość przebiegu obu sygnałów na jednym wykresie.

Tabela B.1 cd.














	Gain – w rozważanym przypadku blok ten jest wykorzystany jako człon proporcjonalny, to jest opisujący wartości liczbowe występujące w modelu (np. dane wykorzystywane do przeskalowania sygnału wejściowego zgodnie z wartością będącą jego parametrem), tutaj: stała wartość 100. Sygnał wejściowy oraz parametr bloku (wzmocnienie) może być skalar, wektorem lub macierzą. Użytkownik określa wartość wzmocnienia jako wartość parametru Gain. Parametr wzmocnienia umożliwia określenie stopnia wzmocnienia lub osłabienia sygnału. Wzmocnienie jest konwertowane z wartości double na dane określone w masce bloku w trybie offline za pomocą funkcji round-to-nearest (zaokrąglenia) i saturation (przepełnienia). Wejście i wzmocnienie są następnie mnożone, a wynik jest konwertowany na wyjściowy typ danych przy użyciu określonych trybów zaokrąglania i przepełnienia.
	Math Function – blok funkcji matematycznych wykonujący przypisane za pomocą parametrów typowe funkcje matematyczne. W rozważanym przypadku blok ten został wykorzystany w korektorze sygnału wyjściowego z modelu neuralnego jako funkcja matematyczna podnoszenia do potęgi przy zadanym parametrze v.
	Product – blok funkcji mnożenia i dzielenia sygnałów skalarnych i sygnałów innych niż skalare o tych samych wymiarach lub mnożenia i odwracania macierzy. W rozważanym w rozprawie modelu blok ten został wykorzystany do wyznaczania krzepkości modelu oraz krzepkości systemu (w prezentowanym przykładzie krzepkość modelu jest wyznaczana dla godziny 12 2019 r.).
	Constant – generuje rzeczywistą lub złożoną wartość stałą. Wyjściem może być sygnał skalarny, wektorowy lub macierzowy. Wyjście bloku ma takie same wymiary i elementy jak sygnały wejściowe, w rozważanym przypadku były to stałe wartości.
	Abs – generuje wartość bezwzględną wyjścia. W modelowanych w rozprawie przypadkach blok został wykorzystany do uzyskania wartości bezwzględnej rozbieżności pomiędzy dwoma sygnałami.
	Divide – dzieli wartości sygnału wprowadzone do licznika (oznaczenie x) przez wartości sygnału wprowadzone do mianownika (oznaczenie: ÷). Wyjście z bloku jest sygnałem będącym wynikiem dzielenia jako obiekt numerictype T. Licznik i mianownik muszą mieć te same wymiary. W rozważanym przypadku blok został wykorzystany do wyznaczania efektywności systemu RDN.
	Transport Delay – opóźnia wejście o określoną jednostkę czasu, np. o jednostkę opóźnienia wynikająca z operatora przesunięcia czasowego z^{-1} występującego w modelu parametrycznym arx. Na początku symulacji blok wyprowadza parametr wyjścia początkowego, dopóki czas symulacji nie przekroczy parametru opóźnienia czasowego z^{-1}, po czym następuje generowanie opóźnienia wejścia. W przypadku sygnałów dyskretnych na wyjściu występuje w wymaganym czasie odpowiednia wartość. W rozważanych w pracy modelach blok ten został wykorzystany w modelu idpoly jako subsystemie.

Tabela B.1 cd.


 Skuteczność modelu6	Scope – wyświetla przebiegi sygnałów generowane podczas symulacji. W rozważanym przypadku sygnałem wyświetlanym jest skuteczności modelu systemu RDN dla godziny 6 w 2019 r.
 Add1	Sum – umożliwia wykonanie operacji dodawanie i/lub odejmowanie sygnałów wprowadzanych do bloku. Liczba i rodzaj wejść są parametrami bloku, jak też typ kształtu bloku. W rozważanym przypadku blok został wykorzystany do wyznaczenia błędu bezwzględnego pomiędzy efektywnością systemu i efektywnością modelu.
	Idpoly – funkcja idpoly(arx6101h62019) jest implementacją modelu parametrycznego dyskretnego arx6101h62019 w Simulinku. Wymaga aby jej argument był przechowywany w Workspace. Argument funkcji będący w istocie modelem systemu RDN musi być między innymi obiektem typu idpoly, tak jak w rozważanym przypadku dla godziny 6 2019 r. Funkcja ta realizowana jest w Simulinku za pomocą bloku, który obsługuje w ogólnym ujęciu modele także z czasem ciągłym lub też bez opóźnień wejścia-wyjścia. Stany początkowe muszą być wektorem o długości równej rzędowi modelu. W przypadku rozważanego modelu idpoly warunki początkowe wynoszą zero.
	NNET – blok symulujący działanie Sztucznej Sieci Neuronowej nauczonej korygowania sygnału wyjściowego z modelu parametrycznego dyskretnego arx. W rozważanym przykładzie modelem tym jest arx6101h62019, to jest model systemu RDN dla godziny 6 2019 r. Blok ten przyjmuje parametry SSN zaprojektowanej i zaimplementowanej za pomocą NNT.
	Subsystem – Bwymdoysh6 jest subsystemem zawierającym model do wyznaczania błędu bezwzględnego i błędu względu pomiędzy modelem parametrycznym arx oraz systemem RDN dla godziny 6 2019 r.
	Inport – łączy wejściowe do subsystemu z otoczenia systemu (najczęściej z systemu nadrzędnego). Są one automatycznie numerowane w kolejności od najwyższego poziomu zaczynając od wejścia 1. Można portowi przypisać czas próbkowania jako szybkość pobierania sygnału z otoczenia do systemu. Wartość -1 powoduje, że blok dziedziczy swój czas próbkowania z bloku, który nim steruje.
	Outport – łączy wyjściowe z subsystemu do otoczenia systemu (najczęściej do systemu nadrzędnego). Są one automatycznie numerowane w kolejności od najwyższego poziomu zaczynając od wejścia 1. Można portowi przypisać czas próbkowania jako szybkość wysyłania sygnału z systemu do otoczenia.
	Łącze zaczeppowe – łączy rozdzielające dopływający sygnał skalarny lub wektorowy na dwa identyczne sygnały (tzw. zaczepp).

Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

DODATEK C

Wyniki badania jakości modeli systemu Rynku Dnia Następnego


Błędy względne



Rysunek C.1. Przebiegi błędów względnego modelu w stosunku do systemu RDN dla godziny 12 2019 r.

Oznaczenia: oś x – czas długi (rok).


Źródło: opracowanie własne z wykorzystaniem środowiska Simulink [63, 195].



Rysunek C.2. Przebiegi błędów względnego modelu w stosunku do systemu RDN dla godziny 18 2019 r.

Oznaczenia: oś x – czas długi (rok).

Źródło: opracowanie własne z wykorzystaniem środowiska Simulink [63, 195].



Rysunek C.3. Przebiegi błędu względnego modelu w stosunku do systemu RDN dla godziny 24 2019 r.

Oznaczenia: oś x – czas długi (rok).

Źródło: opracowanie własne z wykorzystaniem środowiska Simulink [63, 195].

Efektywność, skuteczność i krzepkość systemu i modelu RDN

Tabela C.1. Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 12 roku 2019 dla modelu i systemu RDN




Tabela C.1 cd.





Tabela C.1 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.2. Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 18 roku 2019 dla modelu i systemu RDN




Tabela C.2 cd.





Tabela C.2 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.3. Przebiegi efektywności, skuteczności i krzepkości modelu i systemu dla godziny 24 roku 2019 dla modelu i systemu RDN




Tabela C. 3 cd.





Tabela C.3 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.4. Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 12 roku 2019 pomiędzy modelem i systemem RDN





Tabela C. 4 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.5. Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 18 roku 2019 pomiędzy modelem i systemem RDN





Tabela C.5 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.6. Przebiegi błędów względnych efektywności, skuteczności i krzepkości dla godziny 24 roku 2019 pomiędzy modelem i systemem RDN





Tabela C.6 cd.



Źródło: opracowanie własne z wykorzystaniem MATLABA i Simulinka [63, 195].

Tabela C.7. Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 12 roku 2019 modelu i systemu RDN





Tabela C.7 cd.



Źródło: opracowanie własne z wykorzystaniem MATLAB-a i Simulink-a [63, 195].

Tabela C.8. Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 18 roku 2019 modelu i systemu RDN





Tabela C.8 cd.



Źródło: opracowanie własne z wykorzystaniem MATLAB-a i Simulink-a [63, 195].

Tabela C.9. Komparatystyka przebiegów efektywności, skuteczności i krzepkości dla godziny 24 roku 2019 modelu i systemu RDN





Tabela C.9 cd.



Źródło: opracowanie własne z wykorzystaniem MATLAB-a i Simulink-a [63, 195].