

AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii
Biomedycznej

KATEDRA ENERGOGOELEKTRONIKI I AUTOMATYKI SYSTEMÓW
PRZETWARZANIA ENERGII



ROZPRAWA DOKTORSKA

Mateusz Dutka

**Prognozowanie generacji energii
elektrycznej z odnawialnych źródeł
energii przy wykorzystaniu metod
sztucznej inteligencji**

PROMOTOR:

prof. dr hab. inż. Zbigniew HANZELKA

PROMOTOR POMOCNICZY:

dr inż. Bogusław ŚWIĄTEK

Kraków 2020

Składam serdeczne podziękowania

Panu profesorowi Zbigniewowi Hanzelce
za pomoc merytoryczną oraz cenne wskazówki,
za życzliwość i nieustanną motywację do realizacji założonych celów,
za zaszczyt współpracy.

Panu dr inż. Bogusławowi Świątkowi
za trud opieki, liczne dyskusje naukowe oraz pomoc
bez której trudno byłoby sobie wyobrazić powstanie tej rozprawy.

Zespołowi Jakości Energii Elektrycznej dziękuję za życzliwość oraz pomocne wskazówki.

Składam podziękowania dla dr Evangelos Rikos oraz dr Anastasios Tasos Kyritsis
za udostępnienie danych oraz aparatury badawczej Laboratorium CRES
wykorzystanej do powstania niniejszej pracy.

Dziękuję wszystkim,
którzy przyczynili się do powstania tej pracy.

Pracę tę dedykuję
mojej żonie Agnieszce
oraz córkom Julii i Laurze.
Za nieustanne wsparcie, źródło radości
i wspólnie spędzone chwile.

STRESZCZENIE

Pracę poświęcono prognozowaniu generacji energii elektrycznej z odnawialnych źródeł przy wykorzystaniu metod sztucznej inteligencji. Dokonano przeglądu metod prognostycznych, ze szczególnym uwzględnieniem tych, które mogłyby być alternatywą do zaproponowanych sieci neuronowych. Największą uwagę zwrócono na elektrownie wiatrowe oraz fotowoltaiczne charakteryzujące się znaczną zmiennością produkcji zależną od warunków meteorologicznych.

Ze względu na specyfikę pracy, zróżnicowanie pod względem technicznym oraz lokalizacyjnym do analizy wybrano cztery elektrownie wiatrowe oraz dwie fotowoltaiczne. Dane dla elektrowni fotowoltaicznej PV2 pozyskane zostały przez autora pracy podczas wizyty w Centre for Renewable Energy Sources and Saving (CRES) na obszarze Attyki w Grecji w ramach projektu ERIGrid - European Research Infrastructure supporting Smart Grid. Wykorzystując zgromadzone dane zbadano wpływ czynników pogodowych na ilość produkowanej energii. Poza prędkością wiatru i natężeniem promieniowania słonecznego analizie poddano również dodatkowe czynniki wpływu takie jak: temperatura, ciśnienie oraz kierunek wiatru. Na tej podstawie wytypowano najkorzystniejsze struktury danych wejściowych do modeli prognostycznych.

Zaproponowano i przetestowano zróżnicowane struktury sieci neuronowych, w celu wyboru najkorzystniejszego wariantu niezależnie dla każdego obiektu. Zaproponowane modele prognostyczne charakteryzują się prostotą budowy, krótkim procesem uczenia i adaptacji sieci dla elektrowni różniących się między sobą pod względem mocy zainstalowanej, lokalizacji oraz technicznym. Wybrane modele testowano na zarejestrowanych danych pochodzących z badanych obiektów. W pracy użyto długookresowe dane pomiarowe dla okresu ponad 1 roku, dzięki czemu możliwe było uwzględnienie zmienności warunków pogodowych charakterystycznych dla poszczególnych pór roku. Dzięki automatyzacji procesu modele wielokrotnie uczono wyznaczając wagi połączeń pozwalające na minimalizację średniego absolutnego błędu prognozy. Zaproponowane w pracy modele porównano z alternatywnymi rozwijanymi przez dwie zewnętrzne jednostki specjalizujące się w prognozowaniu.

Dane pochodzące z numerycznych prognoz pogody stanowiące podstawowe źródło informacji dla modeli prognostycznych generacji energii elektrycznej z OZE zazwyczaj obciążone są błędem oraz niedokładnością wynikającą z ograniczonej rozdzielczości siatki prognostycznej. Zaproponowano metodę zwiększenia tej dokładności tak, aby odpowiada-

ły rzeczywistym warunkom występującym w najbliższym otoczeniu elektrowni. W tym celu zgromadzono oraz zweryfikowano prognozy pogody NWP pochodzących z dwóch różnych portali i sześciu punktów zlokalizowanych w pewnej odległości od elektrowni. W pracy zbadano działanie zaproponowanej metody wielopunktowej korekty numerycznych prognoz pogody pozwalającej zwiększyć dokładność predykcji mocy elektrowni.

ABSTRACT

The work describes the possibility of forecasting electricity generation from renewable sources using artificial intelligence methods. The paper reviews forecasting methods that could be an alternative to proposed neural networks. Particular attention was paid to wind farms and photovoltaic plants, which are characterized by significant production variability depending on meteorological conditions. Due to the specificity of the work, technical and location differentiation four wind farms and two photovoltaic farms were selected for the analysis. Data for the PV2 photovoltaic power plant was obtained by the author of the study during a visit to the Center for Renewable Energy Sources and Saving (CRESES) in the Attica area in Greece as part of the ERIGrid project - European Research Infrastructure supporting Smart Grid. Using the collected data, the influence of weather factors on the amount of energy produced was investigated. Apart from wind speed and solar radiation intensity, additional influencing factors such as temperature, pressure and wind direction were also analyzed. As a result of the research, the most favorable input data structures for forecasting models were selected.

Various structures of neural networks were proposed and tested in order to select the most favorable variant independently for each object. The proposed forecasting models are characterized by simple construction, a short learning process and network adaptation for power plants that differ in terms of installed capacity, location and technical. Selected models were tested on registered data from the tested objects. The study uses long-term measurement data for a period of more than 1 year, thanks to which it was possible to take into account the variability of weather conditions characteristic for individual seasons. Thanks to the automation of the process, the models have been repeatedly taught by determining the connection weights allowing to minimize the average absolute forecast error. The models proposed in the study were compared with alternative ones developed by two external research institute specializing in forecasting.

Data from numerical weather forecasts constituting the basic source of information for forecasting models of electricity generation from renewable energy sources are usually affected by an error and inaccuracy resulting from the limited resolution of the forecast grid. A method of increasing this accuracy has been proposed to match the actual conditions in the immediate vicinity of the power plant. Numerical weather forecasts from six points and two different portals were collected and verified. The work investigates the operation of the proposed method of multi-point correction of numerical weather

forecasts, allowing to increase the accuracy of power plant power prediction.

Spis treści

| | |
|---|-----------|
| Wykaz ważniejszych oznaczeń i symboli | 10 |
| 1 Wprowadzenie | 12 |
| 1.1 Cele pracy | 16 |
| 1.2 Teza pracy | 16 |
| 1.3 Cele szczegółowe pracy | 16 |
| 1.4 Metoda badawcza | 17 |
| 1.5 Struktura pracy | 18 |
| 2 Prognozowanie produkcji energii w elektrowniach wiatrowych i fotowoltaicznych - analiza literatury | 21 |
| 2.1 Wprowadzenie | 21 |
| 2.2 Źródło danych do modeli | 25 |
| 2.3 Przykładowe modele prognostyczne dedykowane dla elektrowni wiatrowych | 26 |
| 2.3.1 Model WPPT | 26 |
| 2.3.2 Model FUGS | 28 |
| 2.3.3 Sieć wektorów nośnych (SVM) | 29 |
| 2.3.4 Modele hybrydowe | 31 |
| 2.4 Modele prognostyczne dedykowane do elektrowni fotowoltaicznych | 32 |
| 2.4.1 Model Historical Similar Mining | 33 |
| 2.4.2 Modele Sieci Neuronowych | 34 |
| 3 Prezentacja analizowanych obiektów - elektrownie wiatrowe oraz fotowoltaiczne | 39 |
| 3.1 Elektrownie wiatrowe | 41 |
| 3.1.1 Kinytyka wiatru | 42 |
| 3.1.2 Strefy energetyczne w Polsce | 44 |
| 3.1.3 Elektrownia wiatrowa FW1 | 47 |
| 3.1.4 Elektrownia wiatrowa FW2 | 53 |
| 3.1.5 Elektrownia wiatrowa FW3 | 59 |
| 3.1.6 Elektrownia wiatrowa FW4 | 65 |
| 3.2 Badanie wpływu czynników zewnętrznych na pracę elektrowni wiatrowej | 72 |
| 3.2.1 Wpływ temperatury otoczenia na pracę elektrowni | 73 |

| | | |
|----------|--|------------|
| 3.2.2 | Wpływ ciśnienia atmosferycznego na pracę elektrowni | 76 |
| 3.2.3 | Wpływ kierunku wiatru na pracę elektrowni wiatrowej | 77 |
| 3.3 | Elektrownia fotowoltaiczna | 79 |
| 3.3.1 | Elektrownia fotowoltaiczna PV1 | 83 |
| 3.3.2 | Elektrownia fotowoltaiczna PV2 | 95 |
| 3.4 | Badanie wpływu czynników zewnętrznych na pracę elektrowni fotowoltaicznej | 103 |
| 4 | Modele prognostyczne dedykowane OZE oparte o sztuczną inteligencję | 107 |
| 4.1 | Jednokierunkowe sieci neuronowe | 107 |
| 4.1.1 | Modele sieci neuronowej | 107 |
| 4.1.2 | Uczenie sieci neuronowej i budowa modelu prognostycznego | 111 |
| 4.2 | Narzędzia do oceny jakości modeli prognostycznych | 111 |
| 4.2.1 | Mierniki bezwzględne | 112 |
| 4.2.2 | Mierniki względne | 113 |
| 4.2.3 | Współczynniki oraz szacunkowe błędy przyszłe | 114 |
| 4.3 | Czynniki wpływające na prognozowanie produkcji energii | 116 |
| 4.3.1 | Elektrownie wiatrowe | 116 |
| 4.3.2 | Elektrownie fotowoltaiczne | 117 |
| 4.3.3 | Efekt uśredniania | 118 |
| 4.4 | Prognozowanie z wykorzystaniem sieci neuronowych | 119 |
| 4.4.1 | Prognozowanie produkcji energii elektrowni wiatrowej | 120 |
| 4.4.2 | Prognozowanie produkcji energii elektrowni fotowoltaicznej | 134 |
| 4.5 | Podsumowanie | 137 |
| 5 | Analiza porównawcza modeli prognostycznych rozwijanych przez jednostki zewnętrzne | 139 |
| 5.1 | Metoda Rozkładu Kanonicznego Wektora Zmiennych Losowych (MRK) | 139 |
| 5.1.1 | Opis modelu MRK | 140 |
| 5.1.2 | Analiza dokładności i wiarygodności prognoz | 144 |
| 5.2 | Metoda adaptacyjnej krzywej mocy (AKM) | 147 |
| 5.2.1 | Opis modelu AKM | 147 |
| 5.2.2 | Analiza dokładności i wiarygodności prognoz | 149 |

| | | |
|----------|--|------------|
| 5.3 | Porównanie dokładności prognoz generowanych przez modele oparte o SNN, AKM i MRK | 152 |
| 5.3.1 | Elektrownia wiatrowa FW1 | 152 |
| 5.3.2 | Elektrownia wiatrowa FW2 | 156 |
| 5.3.3 | Elektrownia wiatrowa FW3 | 160 |
| 5.4 | Podsumowanie | 163 |
| 6 | Wielopunktowa korekta prognoz produkcji energii elektrowni wiatrowej | 167 |
| 6.1 | Wielopunktowa korekta prognoz pogody | 167 |
| 6.1.1 | Wybór struktury sieci neuronowej | 168 |
| 6.1.2 | Wybór struktury danych wejściowych | 171 |
| 6.2 | Prognozowanie produkcji energii z wykorzystaniem wielopunktowej korekty prognoz pogody | 173 |
| 7 | Podsumowanie | 179 |
| 7.1 | Opis wykonanych prac i oryginalnych osiągnięć naukowych | 179 |
| 7.2 | Wnioski końcowe | 180 |
| | Bibliografia | 183 |

Wykaz ważniejszych oznaczeń i symboli

- AE - (*Absolute Error*) błąd bezwzględny
- AKM - Adaptacyjna Krzywa Mocy
- ANN - (*Artificial Neural Networks*) sztuczne sieci neuronowe
- ARIMA - (*Autoregressive Integrated Moving Average*) autoregresyjny zintegrowany model średniej ruchomej
- ARMA - (*Autoregressive Moving Average*) model autoregresyjny i średniej ruchomej
- CRES - (*Centre for Renewable Energy Sources and Saving*) - nazwa własna Centrum Odnawialnych Źródeł Energii w Grecji
- CNN - (*Convolutional Neural Network*) konwolucyjne sieci neuronowe
- FFNN - (*Feed-forward Neural Network*) jednokierunkowa sieć neuronowa
- IAE - (*Integrated Absolute Error*) błąd całkowity
- IMGW - Instytut Meteorologii i Gospodarki Wodnej
- KSE - Krajowy System Elektroenergetyczny
- LS - (*Least Squares*) metoda najmniejszych kwadratów
- LS-SVM - (*Least-squares support-vector machines*) metoda średniokwadratowej maszyny wektorów nośnych
- LSTM - (*Long Short-Term Memory Neural Network*) rekurencyjna sieć neuronowa z pamięcią
- MAE - (*Mean Absolute Error*) średni absolutny błąd
- MAPE - (*Mean Absolute Percentage Error*) średni absolutny błąd procentowy
- ME - (*Mean Error*) średni błąd
- MLP - (*Multilayer Perceptron*) perceptron wielowarstwowy
- MPE - (*Mean Percentage Error*) średni błąd procentowy
- MPP - (*Maximum Power Point*) punkt mocy maksymalnej
- MRK - Metoda Rozkładu Kanonicznego Wektora Zmiennych Losowych
- MSE - (*mean squared error*) błąd średni kwadratowy
- NMAPE - (*Normalized Mean Absolute Error*) znormalizowany średni absolutny błąd procentowy
- NRMSE - (*Normalized Root Mean Square Error*) znormalizowany pierwiastek błędu średniokwadratowego

- NWP - (*Numerical Weather Prediction*) numeryczna prognoza pogody
- OZE - Odnawialne Źródła Energii
- PSE - Polskie Sieci Elektroenergetyczne
- PTPiREE - Polskie Towarzystwo Przesyłu i Rozdziału Energii Elektrycznej
- PV - (*Photovoltaic*) fotowoltaika
- RBFFN - (*Radial Basis Function Neural Network*) sieć neuronowa radialna
- RE - (*Relative Error*) błąd względny
- RMSE - (*Root Mean Squared Error*) pierwiastek błędu średniokwadratowego
- RNN - (*Recurrent Neural Network*) rekurencyjna sieć neuronowa
- SCADA - (*Supervisory Control And Data Acquisition*) system nadzoru i pozyskiwania danych
- SSA - (*Salp Swarm Algorithm*) algorytm optymalizacji roju punktów
- SVM - (*Support vector machine*) sieć wektorów nośnych
- URE - Urząd Regulacji Energetyki
- WPPT - (*Wind Power Prediction Tool*) system prognozowania produkcji energii elektrowni wiatrowych
- WU - (*Weather Underground*) - nazwa własna - portal pogodowy

1 Wprowadzenie

Odnawialne źródła energii (OZE) to niekopalne źródła, których zasoby odnawiają się w krótkim okresie czasu. Zgodnie z ustawą [1] należą do nich wiatr, promieniowanie słoneczne, energia aerothermalna, energia geothermalna, energia hydrothermalna, hydroenergia, energia fal, prądów i pływów morskich, energia otrzymywana z biomasy, biogazu, biogazu rolniczego oraz z biopłynów. Kontynent europejski dzięki różnorodności pod względem warunków geologicznych, klimatycznych i hydrologicznych pozwala na wykorzystanie zróżnicowanych zasobów, a tym samym pozwala na stworzenie zbilansowanego systemu zaopatrzenia w energię bazującego na energii pochodzącej z OZE. Energetyka odnawialna jest aktualnie jedną z prężniej rozwijanych dziedzin energetyki w Polsce i na Świecie. Jak szacuje Bloomberg New Energy Finance [2] do roku 2050 połowa energii będzie produkowana z wiatru lub słońca. Stanie się to dzięki obniżeniu kosztów budowy elektrowni PV nawet o 71%. Z raportu wynika, że koszt energii z wiatru może obniżyć się o 58%. Nie bez znaczenia będzie też rozwój technologii magazynowania energii. Pakiet klimatyczny 3x20 zobowiązuje Polskę do uzyskania 15% udziału OZE w ogólnym zużyciu energii do 2020 roku [3].

W ostatnich latach w Polsce widoczny jest znaczny wzrost sumarycznej mocy zainstalowanej w elektrowniach wykorzystujących odnawialne źródła energii. Według danych URE [4] w połowie 2018 r. moc zainstalowana w siłowniach wiatrowych wynosiła 5,856 [GW] (1199 instalacji wiatrowych), w elektrowniach fotowoltaicznych 110,563 [MW] (602 instalacji fotowoltaicznych). Na koniec 2019 r. jak wynika z raportu [5] nastąpił wzrost mocy zainstalowanej zwłaszcza elektrowni fotowoltaicznych 478 [MW] i nieco mniejszy wiatrowych 5,917 [GW].

Projekt Polityki energetycznej Polski do 2040 r. [6] wskazuje na dalszy wzrost udziału OZE w końcowym zużyciu energii brutto do poziomu co najmniej 23% (w roku 2030). Od 2025 r. wdrożona ma zostać dodatkowo energetyka wiatrowa na morzu osiągając odpowiednio ok. 5,9 GW (w 2030 r.) oraz 8-11 GW (w 2040 r.). Obecnie OZE zaspokajają około 16% zapotrzebowania na energię (wzrost o 2,5% w porównaniu z rokiem 2018) [5][7]. Głównymi odnawialnymi źródłami energii są: wiatr, biomasa (w tym współspalanie biomasy), energia słoneczna, hydroenergetyka, biogaz, geotermia.

Energia słoneczna jest coraz częściej wykorzystywanym odnawialnym źródłem energii na świecie i w Polsce. Powyższe zestawienie nie uwzględnia mikroinstalacji PV, których

moc zainstalowana na koniec 2019 osiągnęła około 990,5 [MW]. Moc zainstalowanych ogniw fotowoltaicznych łącznie szacowana jest na około 1468,5 MW, co stanowi 16% udziału elektrowni fotowoltaicznych w polskim „miksie” OZE [5]. W pierwszym kwartale 2020 na świecie odnotowano wzrost mocy zainstalowanej elektrowni PV o ponad 100 GW w porównaniu z rokiem 2019 [8].

Elektrownie słoneczne pozwalają zaspokoić około 3% światowego zapotrzebowania na energię elektryczną [9]. Dodatkowo współczynnik ten w najbliższych latach może się zwiększać, ponieważ panele fotowoltaiczne charakteryzują się znaczną trwałością i rosnącą wydajnością energetyczną. Producenci deklarują zachowanie parametrów elektrycznych ogniw nawet do 25 lat.

Raport PTPiREE z maja 2020 [5] prognozuje dalszy wzrost udziału OZE w wytwarzaniu energii elektrycznej. W roku 2030 szacuje się około 32%, a w 2040 nawet 40% udziału elektrowni wykorzystujących OZE w ogólnym polskim „miksie” energetycznym. Zwiększenie wolumenu produkcji ma dotyczyć głównie elektrowni wiatrowych oraz fotowoltaicznych.

Elektrownie wiatrowe można podzielić ze względu na:

- moc (mikro - do 50 kW, małe - 50-500 kW oraz duże - powyżej 0,5 MW) [1],
- lokalizację (lądowe i morskie),
- oś obrotu wirnika (poziomą i pionową).

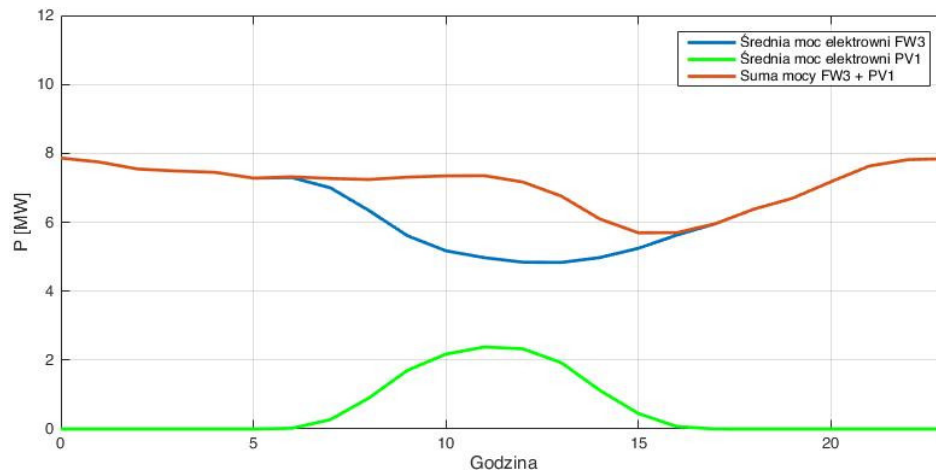
Energia pochodząca z mikro elektrowni wiatrowych magazynowana jest w bateriach, a następnie wykorzystywana do zasilania łodzi, przyczep kempingowych, oświetlenia dróg i ostrzegawczej sygnalizacji drogowej. Większe elektrownie produkują energię, która konsumowana jest lokalnie w gospodarstwach domowych, przedsiębiorstwach lub przekazywana bezpośrednio do sieci. Liczba farm wiatrowych oraz ich moc zainstalowana jest z roku na rok coraz większa, budowane są nowe farmy, a także modernizowane są już istniejące instalacje oraz turbiny. Dzięki tym zmianom energetyka wiatrowa staje się ważnym źródłem energii odnawialnej wielu państw, które chcąc uniezależnić się od paliw kopalnych dywersyfikują w ten sposób swój mix energetyczny.

Zgodnie z ustawą [1] o odnawialnych źródłach energii układ hybrydowy definiuje się jako ”instalację odnawialnego źródła energii, wytwarzającą energię elektryczną albo energię elektryczną i ciepło, w której w procesie wytwarzania energii elektrycznej lub ciepła są wykorzystywane nośniki energii wytwarzane oddzielnie z odnawialnych źródeł energii, z możliwością wykorzystania paliwa pomocniczego, i ze źródeł energii innych niż odna-

wialne, pracujące na wspólny kolektor oraz zużywane wspólnie w tej jednostce wytwórczej do wytworzenia energii elektrycznej lub ciepła”. Elektrownie wiatrowe oraz fotowoltaiczne mogą częściowo kompensować swoją zmienność produkcji energii ponieważ bazują na różnych nośnikach odnawialnej energii. Połączenie takich obiektów w układ hybrydowy pozwala na zmniejszenie zmienności wielkości produkcji w porównaniu do poszczególnych obiektów rozpatrywanych niezależnie.

Rysunek 1.1 przedstawia średnią godzinową moc elektrowni wiatrowej FW3¹ oraz elektrowni fotowoltaicznej PV1² przeskalowaną 180 razy, tak aby uzyskać proporcjonalny do FW3 poziom mocy. Zestawienie wykonano na podstawie uśrednionych danych z okresu dwóch lat i miesięcy listopad-luty. Zestawienie ma na celu przedstawienie możliwości kompensacji zmienności produkcji energii przez elektrownie bazujące na różnych OZE.

Na rysunku 1.1 można zaobserwować komplementarność źródeł. Spadek średniej mo-



Rysunek 1.1: Średnia moc elektrowni wiatrowej FW3 i fotowoltaicznej PV1 (listopad-luty)

cy elektrowni wiatrowej zwłaszcza w godzinach około południa uzupełniany jest przez produkcję z elektrowni fotowoltaicznej, co umożliwia częściowe zmniejszenie zmienności mocy.

Zasoby takie jak wiatr, promieniowanie słoneczne, opady, fale morskie silnie zależne są od panujących warunków meteorologicznych. Ciągły wzrost ilości energii pochodzącej z OZE w ogólnym bilansie wymusza na producentach energii oraz zarządcy Krajowego Systemu Energetycznego (Polskie Sieci Elektroenergetyczne – PSE), gromadzenie co-

¹FW3 - elektrownia wiatrowa o mocy zainstalowanej 30 MW zlokalizowana w południowej części województwa łódzkiego - szerszy opis obiektu znajduje się w rozdziale 3.1.5

²PV1 - elektrownia fotowoltaiczna o mocy zainstalowanej 60 kWp zlokalizowana w południowej części polski - szerszy opis obiektu znajduje się w rozdziale 3.3.1

raz dokładniejszych danych nt. aktualnej i prognozowanej produkcji energii pochodzącej z tych źródeł. Można wyróżnić dwa główne czynniki wymuszające potrzebę prognozowania:

- bilansowanie systemu elektroenergetycznego - konieczność precyzyjniejszego szacowania energii produkowanej i konsumowanej,
- rynek energii i rynek kontraktów z wyprzedzeniem 24h, który nakłada potrzebę prognozowania produkcji energii przez ich wytwórców. Oferty następnie przedkładane są na rynku bilansowym.

Niepewność wynikająca z zależności produkcji energii wiatrowej i fotowoltaicznej od czynników atmosferycznych, wymusza zapewnienie „gorącej rezerwy mocy”, a tym samym zwiększa koszty produkcji energii za które płacą wszyscy użytkownicy sieci.

Rozwiązaniem tej sytuacji może okazać się zastosowanie zasobników energii, które są naturalnym narzędziem ograniczania tych fluktuacji [10].

Ze względu na różne technologie stosowane do magazynowania energii można wyróżnić następujące zasobniki [11]:

- Termiczne
 - termoelektryczne,
 - przemiany fazowe,
- Chemiczne
 - wodór,
 - paliwa syntetyczne, metanol,
 - elektrochemiczne,
 - * akumulatory,
 - * akumulatory wysokotemperaturowe,
 - * ogniwa paliwowe,
- Mechaniczne
 - elektrownie szczytowo-pompowe,
 - magazyny na sprężone powietrze,
 - kinetyczne zasobniki energii,
- Elektryczne
 - kondensatory,
 - superkondensatory,
 - magazyny nadprzewodnikowe.

Wirtualne agregowanie rozproszonych odnawialnych źródeł, jest alternatywnym sposobem ograniczania niepewności dostaw i zakresu zmienności energii oraz pozwala na bilansowanie handlowe zarządzanych obiektów. Do realizacji tego celu niezbędne są narzędzia prognozujące wielkość produkcji energii elektrycznej z elektrowni wykorzystującej OZE.

1.1 Cele pracy

Celem pracy jest opracowanie i zbadanie metod prognostycznych generacji energii elektrycznej z odnawialnych źródeł energii przy wykorzystaniu metod sztucznej inteligencji. W szczególności zaproponowane modele dedykowane są do predykcji krótkoterminowej dla elektrowni wiatrowych oraz fotowoltaicznych.

1.2 Teza pracy

Możliwe jest zbudowanie systemu pozwalającego na skuteczne prognozowanie generacji energii elektrycznej z odnawialnych źródeł przy wykorzystaniu metod sztucznej inteligencji z perspektywą czasu 24h, dla średniego błędu prognozy nie przekraczającego 20% mocy zainstalowanej oraz prostej i uniwersalnej strukturze umożliwiającej szybkie prognozowanie dla dużej liczby elektrowni, wspierającego techniczne zarządzanie energią na potrzeby zapewnienia ciągłości dostaw energii elektrycznej.

1.3 Cele szczegółowe pracy

- Analiza pracy elektrowni wykorzystujących OZE w celu zbadania czynników wpływających na ilość produkowanej energii. Na przykładzie 4 elektrowni wiatrowych oraz dwóch fotowoltaicznych zaproponowano po 16 struktur danych wejściowych do modelu, a następnie zweryfikowano ich wpływ na zmianę dokładności wykonanych prognoz.
- Opracowanie i przetestowanie modeli pozwalających na predykcję generacji energii elektrycznej elektrowni wykorzystujących promieniowanie słoneczne oraz wiatr. W wyniku przeprowadzonych badań, zaproponowano i przetestowano po 18 różnych struktur sieci neuronowych, w celu wyboru najkorzystniejszego wariantu.
- Zaproponowanie modeli charakteryzujących się prostą budową, krótkim procesem uczenia i adaptacji. Wybrane modele przetestowano na rzeczywistych zarejestro-

wanych danych pochodzących z obiektów zlokalizowanych w kraju oraz poza nim, zróżnicowanych pod względem lokalizacyjnym oraz technicznym.

- Porównanie zaproponowanych w pracy modeli z alternatywnymi modelami rozwijanymi przez dwie zewnętrzne jednostki badawcze takie jak Politechnika Częstochowska oraz PSE Innowacje.
- Zaproponowanie sposobów korekty i poprawy numerycznych prognoz pogody na potrzeby prognozowania produkcji energii. Na podstawie przeprowadzonych testów zaproponowano oraz zweryfikowano modele sieci neuronowych różniące się pod względem struktury oraz zbioru danych wejściowych. W przeprowadzonej analizie wykorzystano dane pochodzące z różnych portali pogodowych.

Zaproponowane w pracy modele bazują na metodzie sztucznej inteligencji, a w szczególności sieciach neuronowych.

1.4 Metoda badawcza

Prognozowanie produkcji energii może być wykorzystywane w wielu aspektach związanych z pracą elektrowni bazującej na odnawialnych źródłach energii. Energia pierwotna pochodząca z OZE podlega ciągłym fluktuacjom. Najczęściej jest to proces zmieniający się w horyzoncie kilku – kilkudziesięciu minut [12]. W zależności od okresu na jaki przygotowywane są prognozy, można wyróżnić:

- *Prognozy ultrakrótkoterminowe* - prognoza 5-60 min - wykonywana jest na potrzeby podejmowania bieżących decyzji związanych z działaniem elektrowni, regulacją wytwarzanej i/lub magazynowanej energii.
- *Prognozy krótkoterminowe*, podzielono na dwa okresy:
 - Prognoza 1–6 h - przeznaczona do kontroli bieżącego stanu produkcji, korekty zobowiązań produkcyjnych na następną godzinę.
 - Prognoza jednodniowa/kilkudniowa - wspierająca proces planowania wielkości produkcji, przygotowywania harmonogramu pracy elektrowni, a także umożliwiająca proces szacowania generowanej energii w celu sprzedaży na rynku energii.
- *Prognozy długoterminowe* - wykonywane na potrzeby przygotowania analiz opłacalności oraz rentowności inwestycji.

Możliwość wykonywania prognoz o wybranym horyzoncie czasowym zależy silnie od dostępnych danych wejściowych służących do jej opracowywania. W pracy ze względu na zgromadzony zbiór danych zaproponowano modele dedykowane do prognoz krótkoterminowych z horyzontem od kilku do kilkudziesięciu godzin. Zostały wykonane oraz przetestowane dedykowane modele dla łącznie 6 elektrowni (4 wiatrowe, 2 fotowoltaiczne).

Obiekty wybierano w taki sposób, aby wnioski oraz wyniki analiz pozwoliły na zaproponowanie uniwersalnego modelu charakteryzującego się skalowalnością do innych elektrowni zlokalizowanych w kraju.

Główne kryteria uwzględniane podczas selekcji obiektów to:

- liczba i moc jednostkowa turbin/paneli
- lokalizacja
- typ generatorów/przekładni
- wysokość do osi piasty
- powierzchnia obrotowa wirnika.

Wybrane obiekty zostały szczegółowo opisane w Rozdziale 3.

W pracy zaproponowano wykorzystanie neuronowych modeli dedykowanych do krótkoterminowego prognozowania generacji z niestabilnych odnawialnych źródeł energii (OZE) - elektrowni wiatrowych i fotowoltaicznych. Praca obejmuje projektowanie oraz wykonanie modeli dedykowanych dla tych elektrowni. Ich działanie zweryfikowano, przy użyciu narzędzi prognostycznych rozwijanych przez dwa zewnętrzne ośrodki badawcze - Politechnikę Częstochowską oraz PSE Innowacje. Celem porównania była walidacja modeli zaproponowanych w niniejszej pracy przez alternatywne narzędzia wykorzystujące do prognozowania metody inne niż sztuczna inteligencja. Analiza rzeczywistych danych elektrycznych elektrowni wiatrowych oraz fotowoltaicznych potwierdziła sezonową zależność wielkości produkcji. Dlatego na potrzeby testowania i weryfikacji modeli sieci neuronowych przyjęto minimalną liczbę danych obejmujących co najmniej jeden rok.

1.5 Struktura pracy

Rozprawę podzielono na 6 rozdziałów.

Rozdział 1 - Wprowadzenie

W rozdziale zamieszczono podstawowe informacje dotyczące motywacji jakie towarzyszyły autorowi podczas wyboru oraz budowy modeli prognostycznych dedykowanych

dla elektrowni wiatrowych i fotowoltaicznych. Sformułowano cele szczegółowe pracy oraz zamieszczono tezę i opis metody badawczej.

Rozdział 2 - Prognozowania produkcji energii w elektrowniach wiatrowych i fotowoltaicznych - stan wiedzy

Autor skoncentrował się głównie na metodach, które mogły by być alternatywą do zaproponowanych sieci neuronowych. Zwłaszcza grupa modeli statystycznych bazująca na dużych zbiorach danych. W tym rozdziale opisano stan wiedzy w zakresie wybranych metod przeznaczonych do prognozowania produkcji energii w elektrowniach wiatrowych i fotowoltaicznych.

Rozdział 3 - Prezentacja analizowanych obiektów - elektrownie wiatrowe oraz fotowoltaiczne

W tej części pracy przedstawiono opis elektrowni wybranych do dalszej analizy. Łącznie wybrano 5 obiektów zlokalizowanych na terenie Polski oraz jeden na terenie Grecji. Analizie poddano wpływ czynników meteorologicznych na pracę elektrowni wiatrowej oraz fotowoltaicznej.

Rozdział 4 - Modele prognostyczne dedykowane OZE oparte o sztuczną inteligencję

W Rozdziale 4 wykonano analizę porównawczą różnych autorskich modeli przeznaczonych dla elektrowni wiatrowych i fotowoltaicznych na potrzeby prognozowania krótkoterminowego. Rozdział zawiera opis narzędzi do oceny jakości modeli prognostycznych oraz dobór struktury sieci i danych wejściowych. Wykonano analizę porównawczą zaproponowanych modeli oraz wybrano do dalszej analizy te z nich, które generowały najlepsze prognozy.

Rozdział 5 - Analiza porównawcza modeli prognostycznych rozwijanych przez jednostki zewnętrzne

Przeprowadzono analizę porównawczą prognoz dla trzech modeli:

- modelu opracowanego przez autora niniejszej pracy (opisanego w Rozdziale 4),
- modelu opracowanego przez zespół Politechniki Częstochowskiej (Rozkład Kanoniczny Wektora Zmiennych Losowych - MRK) [13] [14],
- modelu wykorzystywanego przez PSE (Adaptacyjna Krzywa Mocy - AKM) [15].

Zaproponowano kryteria weryfikacji poprawności ich działania. Celem była walidacja

zaproprowanych modeli przy pomocy narzędzi rozwijanych przez dwa ośrodki wiodące w zakresie prognozowania.

Rozdział 6 - Wielopunktowa korekta prognoz generacji energii elektrowni wiatrowej

W Rozdziale 6 zaproponowano oraz opisano metodę poprawy jakości prognoz przy pomocy wielopunktowej korekty prognozy. Podano analizie wybrane struktury danych wejściowych oraz sieci neuronowych. Zaproponowano algorytm poprawy dokładności numerycznych prognoz pogody (NWP) pochodzących z różnych portali prognostycznych. Wykonano modele prognozy produkcji energii elektrowni wiatrowej bazujące na wielopunktowych prognozach. Wybrano 4 sieci neuronowe charakteryzujące się najmniejszym błędem MAE oraz MAPE. Poddano analizie wyniki prognoz generowanych przez te modele.

Podsumowanie

W tej części zawarto opis wykonanych prac oraz oryginalnych osiągnięć autora. Opisano w skrócie aplikację, której autor pracy był współautorem. Przygotowana aplikacja prognostyczna dedykowana dla przedsiębiorstw działających na rynku energii została wdrożona w komercyjnej firmie.

2 Prognozowanie produkcji energii w elektrowniach wiatrowych i fotowoltaicznych - analiza literatury

2.1 Wprowadzenie

Światowi oraz europejscy operatorzy systemów przesyłowych i dystrybucyjnych stoją przed coraz większym problemem zbilansowania podaży i popytu energii. Jest to związane ze zwiększeniem udziału elektrowni wykorzystujących OZE w ogólnym miksie energetycznym. Wraz z rozwojem OZE konieczny jest rozwój narzędzi wspierających operatorów w zakresie sprawnego zarządzania siecią. Tymi narzędziami są m. in. modele prognostyczne produkcji energii z elektrowni wykorzystujących odnawialne źródła energii. Aktualnie widoczny jest szybki rozwój tematyki związanej z prognozowaniem wielkości produkcji energii zwłaszcza elektrowniach wiatrowych i fotowoltaicznych. Jest to zagadnienie aktywnie rozwijane przez jednostki badawcze z całego świata. Świadczyć o tym mogą pojawiające się bardzo liczne artykuły w znaczących oficynach wydawniczych IEEE Transaction, Springer oraz Elsevier [16–31]. W dalszej części pracy omówiono wybrane modele stosujące odmienne metody prognostyczne.

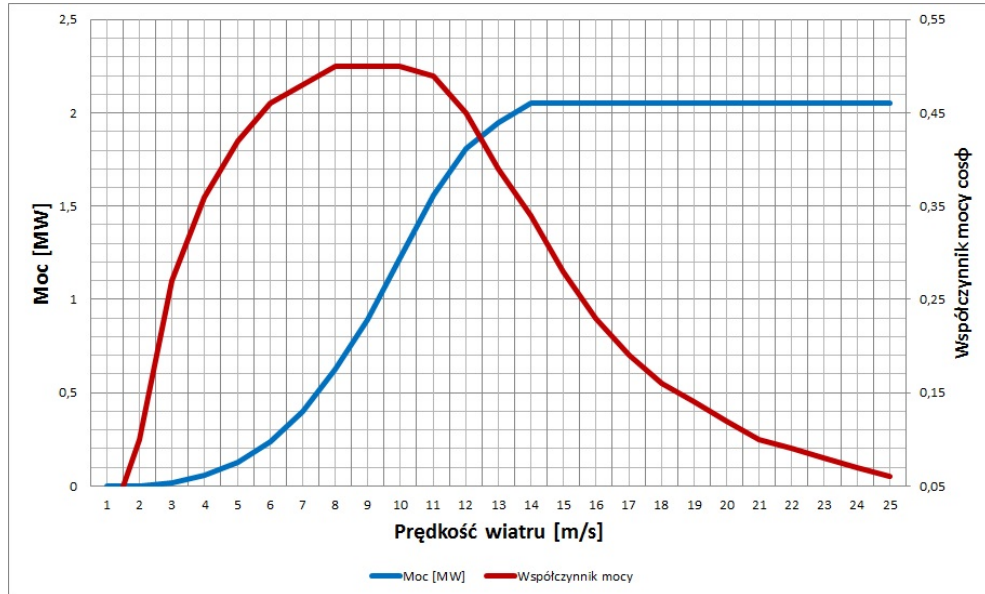
Podział modeli prognostycznych [24]:

- Modele fizyczne [32–34]
- Modele statystyczne
 - bazujące na zbiorach danych
 - * modele naiwne (persistence metod) [35]
 - * modele prognostyczne Grey’a [36]
 - * modele bazujące na filtrach Kalmana [37]
 - * modele ARMA (Autoregressive moving average model) [38]
 - * modele ARIMA (Autoregressive integrated moving average model) [35][39][40]
 - bazujące na ”sztucznej inteligencji”
 - * sztuczne sieci neuronowe [41–44]
 - * maszyny wektorowe[45]
 - * analiza falkowa (Wavelet analysis)[46]
 - * logika rozmyta (Fuzzy-Logic)[44]
- Modele hybrydowe (będące kombinacją powyższych typów modeli)[42][44][46]


Autorzy artykułów proponują różne metody prognostyczne oraz sposoby zwiększenia ich dokładności. Często spotykane są narzędzia wykorzystujące sztuczne sieci neuronowe. Rozwiązania te posiadają wielu zwolenników, ale również i krytyków którzy zarzucają tej metodzie, że operuje pojęciami rozmytymi, jej wyniki są niejednoznaczne i nieprecyzyjne, nie nadają się do obliczeń wieloetapowych (tj. gdy wynik pierwszego etapu jest informacją do wnioskowania w kolejnym etapie) [47]. Wszystkie osoby tak twierdzące w istocie mają rację. Jednak już wiele lat temu George Box brytyjski statystyk zajmujący się tematyką kontroli jakości, analizą szeregów czasowych oraz wnioskowaniem Bayesowskim zauważył i zatytułował jeden z rozdziałów swojego artykułu [48] „All models are wrong, but some are useful”. Box w artykule podkreśla, że bardzo trudnym zadaniem jest odwzorowanie rzeczywistości za pomocą prostego modelu. Modele liniowe są dobrze znane i opisane przez matematyków, niestety rzadko właściwie odzwierciedlają rzeczywistość. Problemy nieliniowe bardziej zbliżone do rzeczywistości są trudniejsze do zdefiniowania i rozwiązania. W takich przypadkach z pomocą przychodzą metody oparte o sztuczną inteligencję, które w prawdzie nie są w stanie podać dokładnego, precyzyjnego rozwiązania jednak dzięki odpowiedniemu zdefiniowaniu cech rozpoznawanego obiektu potrafią znaleźć zależności łączące dane zjawisko i podać ze znaczną dokładnością rozwiązanie problemu. Ta argumentacja przekonała autora i była powodem wyboru tej metody do prognozowania mocy w elektrowniach opartych na OZE. Sztuczna sieć neuronowa dzięki prostocie budowy oraz łatwości modyfikacji dobrze sprawdza się w sytuacjach gdy:

- zależności analityczne opisujące zjawiska są nieznane lub ręczne kodowanie reguły jest zbyt skomplikowane, jak na przykład rozpoznawanie wzorców, twarzy, mowy itp.
- reguły związane z rozważanym problemem stale się zmieniają, na przykład: algorytmy wykrywania oszustw, anomalii w danych z czujnika itp.
- zmienia się rodzaj i forma danych przez co program wymaga dostosowania. Na przykład: prognozowanie popytu na energię elektryczną, prognozowanie trendów zakupowych itp.

W prognozowaniu produkcji energii w elektrowniach wiatrowych oraz fotowoltaicznych można spotkać się z wszystkimi wyżej opisanymi trudnościami. Na rysunku 2.1 przedstawiono przykładową charakterystykę mocy turbiny wiatrowej wykonaną na podstawie dokumentacji producenta [49]. Dla porównania na rysunku 2.2 zaprezentowano krzywą mocy tej samej turbiny sporządzoną na podstawie rzeczywistych danych historycznych.



Rysunek 2.1: Teoretyczna charakterystyka mocy (kolor niebieski) i współczynnika mocy (kolor czerwony) pojedynczej turbiny wiatrowej E70 (źródło: opracowanie własne na podstawie [49])




Rysunek 2.2: Rzeczywista (kolor niebieski) oraz teoretyczna (kolor czerwony) charakterystyka mocy dla turbiny wiatrowej E70 - elektrownia wiatrowa FW3 (źródło: opracowanie własne na podstawie [49])

Porównując przebiegi na rysunkach 2.1 oraz 2.2 można zauważyć następujące różnice:

- rzeczywista charakterystyka mocy zawiera się w obszarze wokół teoretycznej charakterystyki podanej przez producenta. Jest to spowodowane pracą turbiny w zmiennych warunkach meteorologicznych innych niż te przyjęte podczas wyznaczania teoretycznej charakterystyki mocy,
- na rzeczywistej charakterystyce mocy występuje zbiór punktów dla prędkości wiatru od 4 [m/s] do 17 [m/s] dla których moc $P=0$. Może to być spowodowane mechanicznym lub programowym wyłączeniem turbiny na przykład w czasie jej serwisu lub wymiany elementów eksploatacyjnych turbiny.

Rysunek 2.3 przedstawia przykładową zależność mocy od promieniowania słonecznego dla elektrowni fotowoltaicznej PV1.



Rysunek 2.3: Rzeczywista (kolor niebieski) oraz aproksymowana (kolor czerwony) zależność mocy od natężenia promieniowania słonecznego dla elektrowni fotowoltaicznej PV1 opisanej w rozdziale "3.2 Elektrownia fotowoltaiczna"

Rzeczywista zależność mocy od natężenia promieniowania słonecznego jest charakterystyką nieliniową, co można zaobserwować na rysunku 2.3. Widoczna jest znaczna zmienność mocy czynnej P dla tych samych wartości promieniowania słonecznego. Świadczy to o tym, że wielkość produkcji nie jest zależna wyłącznie od nasłonecznienia.

Wielkość produkcji energii w elektrowniach wiatrowych i fotowoltaicznych zależy od wielu czynników zarówno związanych z "mechaniką" źródeł, wytwarzaniem i przetwarzaniem energii jak i warunkami pogodowymi silnie zmiennymi i w małym stopniu zależnymi od człowieka. Wraz z upływem czasu zmieniają się również parametry elektrowni na skutek procesu starzenia urządzeń, zmniejszenie sprawności, zabrudzenie paneli fotowoltaicznych co wpływa na wielkość produkcji energii przez elektrownię. Rozwój technologii pozwala na wyposażanie turbin wiatrowych oraz elektrowni fotowoltaicznych w urządzenia pomiarowe oraz sterujące charakteryzujące się większą funkcjonalnością. Pozwala to na uzyskanie nowych coraz precyzyjniejszych danych. Większe powierzchnie dyskowe serwerów obsługujących systemy SCADA umożliwią zwiększenie częstotliwości próbkowania danych. Wszystkie te czynniki pozwalają na uzyskanie w przyszłości precyzyjniejszych prognoz. Wprowadzenie do modeli sieci neuronowych sygnałów z tych urządzeń nie wymaga dużych nakładów pracy. Dzięki temu możliwe jest w krótkim czasie oraz przy niskich nakładach pieniężnych udoskonalenie modelu, poprzez interpretację zjawisk, które wcześniej były niemożliwe do zidentyfikowania. Jakość prognoz generacji energii jest silnie zależna od dokładności numerycznych prognoz pogody oraz zdolności np. sieci neuronowych do ich korygowania.

Modeli prognostycznych dedykowanych do szacowania wartości mocy/prędkości wiatru oraz ich modyfikacji jest dużo. W pracy nie uwzględniono modeli komercyjnych, ponieważ dostępna dokumentacja na ich temat jest bardzo ograniczona. Autor wybrał te modele, które są związane z rozwijanymi sieciami neuronowymi lub mogą z nimi tworzyć hybrydowe modyfikacje potencjalnie pozwalające uzyskać lepsze wyniki.

2.2 Źródło danych do modeli

Atmosfera ziemską może być traktowana jak układ zmieniający się dynamicznie, opisany nieliniowymi cząstkowymi równaniami różniczkowymi. Metody numeryczne pozwalają na uzyskanie rozwiązań przybliżonych w skończonej liczbie węzłów [50]. Węzły siatki są to punkty lokalizacyjne, w których wykonywane są obliczenia. Pozioma odległość pomiędzy sąsiednimi węzłami nazywana jest rozdzielczością modelu. Numeryczna prognoza pogody (NWP - Numerical Weather Prediction) jest to ocena stanu atmosfery w przyszłości na podstawie znajomości warunków początkowych oraz sił działających na powietrze. NWP oparta jest na rozwiązaniu równań ruchu powietrza przy pomocy dyskretyzacji i wykorzystaniu do obliczeń komputerów [51]. Prawidłowe prognozowanie pogody wiąże

się również z przeprowadzeniem obliczeń dla wyższych poziomów atmosfery (zwłaszcza procesy zachodzące w warstwie granicznej). Wysokość tej warstwy może się zmieniać od kilkuset metrów do kilku kilometrów, zależnie od warunków meteorologicznych. Liczba uwzględnianych poziomów oraz ich rozkład w pionie opisuje pionową rozdzielczość modelu.

Modele dla numerycznych prognoz pogody można podzielić na:

- globalne,
- regionalne,
- lokalne,

Modele te charakteryzują się określoną rozdzielczością siatki prognostycznej. Na potrzeby prognozowania wielkości produkcji, najlepsza jest prognoza o wysokiej rozdzielczości. Powoduje to zmniejszenie kroku siatki i prowadzi do wzrostu liczby punktów dla których generowane są prognozy meteorologiczne. Wiąże się to jednocześnie z koniecznością zapewnienia większych możliwości obliczeniowych komputera.

2.3 Przykładowe modele prognostyczne dedykowane dla elektrowni wiatrowych

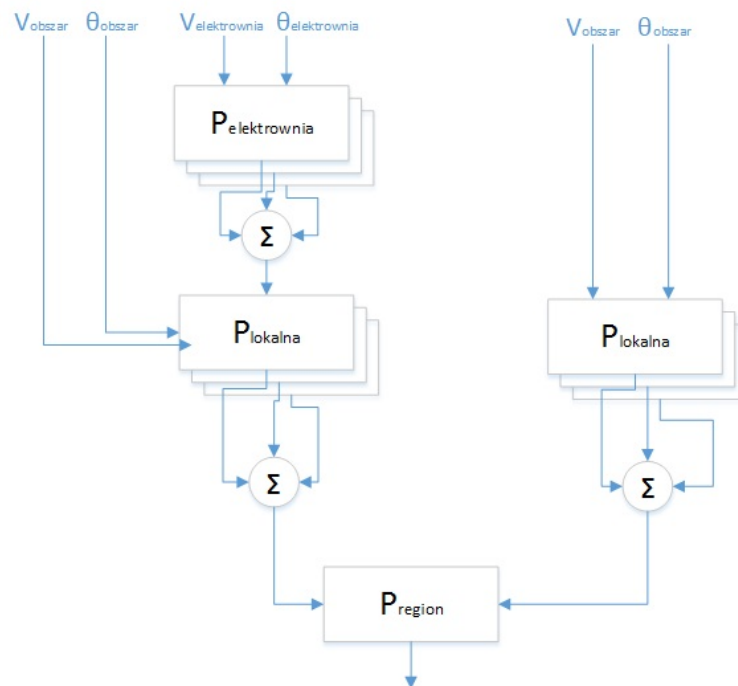
Takie modele prognostyczne rozwijane są od wielu lat. Przykładami mogą być modele WPPT, FUGS oraz inne poniżej opisane. Zostały one wybrane ze względu na różne podejście do procesu przetwarzania danych oraz prognozowania. Autorzy prac zaproponowali autorskie metody prognostyczne bazujące na indywidualnych zbiorach danych wejściowych oraz weryfikacyjnych.

2.3.1 Model WPPT

Działanie modelu WPPT (ang. Wind Power Prediction Tool) opisano w pracy [52]. Jest to system prognozowania produkcji energii pochodzącej z wiatru pozwalający na oszacowanie wielkości produkcji dla elektrowni zlokalizowanych na morzu i lądzie. Model pozwala na prognozowanie energii z horyzontem czasowym do 48 godzin z rozdzielczością 30 min. Do prognozowania wykorzystuje numeryczne prognozy pogody oraz na bieżąco aktualizowane dane pomiarowe z farmy wiatrowej, co pozwala na ciągłą aktualizację nieliniowego modelu.

Na rysunku 2.4 zaprezentowano zasadę działania modelu WPPT, który można podzielić na dwie części:

- W pierwszej model prognozuje generowaną moc dla poszczególnych turbin, na podstawie aktualizowanych danych historycznych oraz danych dotyczących prognozowanej pogody (dla każdej turbiny niezależnie). W kolejnym kroku prognozy mocy z poszczególnych turbin są sumowane dla jednej lub grupy elektrowni otrzymując w efekcie moc dla całego obszaru.



Rysunek 2.4: Schemat działania modelu WPPT (źródło: opracowanie własne na podstawie [52])

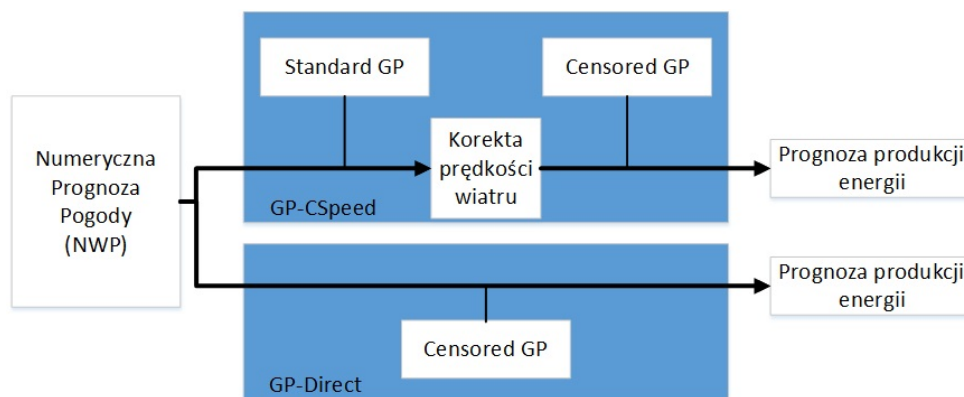
- W drugiej części model prognozuje wielkość produkcji energii elektrycznej farmy na podstawie zagregowanych danych z poszczególnych siłowni wiatrowych oraz numerycznej prognozy pogody. Model prognozuje wielkość energii dla całej elektrowni, w przeciwieństwie do pierwszej części, gdzie prognozy generowane były dla każdej turbiny oddzielnie. Uśrednione dane charakteryzują się większą "gładkością" prognozy. Podejście takie jest również zasadne, jeśli model wykorzystuje numeryczne prognozy pogody o małej gęstości siatki, co uniemożliwia wykonanie prognozy dla poszczególnych turbin wiatrowych.

Szacowana wielkość produkcji energii dla danego regionu wyznaczana jest na podstawie średniej ważonej z obu gałęzi modelu (Rysunek 2.4).

Modele prognostyczne bazujące na metodach statystycznych takich jak ARMA, ARX i Box-Jenkins [52] są wykorzystywane do krótkoterminowej prognozy mocy do kilku godzin w przód. Zgodnie z pracą [53] dane wejściowe do modelu powinny zostać pogrupowane zależnie od pory roku.

2.3.2 Model FUGS

Przykład działania modelu FUGS (ang. Forecasting Using Gaussian Processes) zaprezentowano w pracy [22]. Jest to model krótkoterminowego (1h-24h) prognozowania produkcji energii pochodzącej z wiatru. Rysunek 2.5 przedstawia system składający się z dwóch modeli GP-CSpeed oraz GP-Direct (nazwy modeli zaproponowane przez autorów). Pierwszy *GP-Direct* budowany jest na danych pochodzących bezpośrednio z numerycznych prognoz pogody (bez wykonywania ich dodatkowej korekty). W drugim o nazwie *GP-CSpeed* w pierwszej kolejności wykonywana jest korekta danych wejściowych, a następnie model budowany jest na bazie już skorygowanych wartości. Korekta prędkości wiatru polega na odfiltrowaniu *Standard GP* z danych wykraczających poza dopuszczalne limity. W obu przypadkach wykorzystano ten sam model prognostyczny. Jak podają autorzy, takie podejście pozwala na poprawę szacowania siły wiatru, która ma istotny wpływ na wielkość produkcji energii.



Rysunek 2.5: Zasada działania modelu Forecasting Using Gaussian Processes (źródło: opracowanie własne na podstawie [22])

Raz dziennie generowana jest numeryczna prognoza pogody NWP. W zaproponowanej metodzie prognozy generowane są dla każdej godziny niezależnie przy pomocy indywidualnego modelu prognostycznego. W przypadku prognoz 24 h koniecznej jest przygotowanie 24 modeli. W celu poprawy dokładności prognoz w modelach uwzględniono historyczne dane z maksymalnie 4 godzin poprzedzających predykcję. Zastosowano

również korekcję danych z modelu NWP przygotowując dodatkowo modele A1 (horyzont prognozy 1-4h) i A2 (horyzont prognozy 5-24 h) dla prędkości wiatru większych od przyjętego arbitralnie progu zależnego od zbioru danych.

2.3.3 Sieć wektorów nośnych (SVM)

Sieci SVM (z ang. support vector machine) pozwalają na rozwiązywanie zadań związanych z klasyfikacją i aproksymacją. *W przypadku zadania klasyfikacji maksymalizuje się margines separacji między dwoma klasami, przypisanymi danym (x_i, d_i) , przy zachowaniu jak najmniejszego błędu klasyfikacji na danych uczących. Zadanie aproksymacji zwane również regresją rozwiązuje się w tych sieciach przez sprowadzenie problemu uczenia do zadania analogicznego do klasyfikacji [54].*

Przykładem wykorzystania sieci wektorów nośnych może być model, zaproponowany w pracy [23]. Opracowany model SVM to skuteczne statystyczne narzędzie pozwalające rozwiązywać wiele-parametrowe nieliniowe problemy. SVM to maszyny uczące się, oparte na wektorach podtrzymujących. Metoda ta ma szerokie zastosowanie w wielu zagadnieniach związanych z uczeniem, na przykład problem klasyfikacji, estymacji funkcji gęstości, wyznaczania funkcji regresji lub prognozowania wartości szeregów czasowych [55]. Model regresyjny SVM wykorzystany do prognozowania produkcji energii w elektrowniach wiatrowych można opisać wzorem:

$$y_{output} = \sum_{i=1}^M w_i K(x_{input}, x_i) + w_0 + \epsilon \quad (2.1)$$

gdzie:

- y_{output} - prognozowana zmienna,
- w_i - i-ty współczynnik wagowy,
- $K(\cdot)$ - funkcja jądra (Gausa),
- x_{input} - wektor danych wejściowych,
- x_i - wektor danych wejściowych dla i. danej uczącej,
- w_0 - współczynnik korekcyjny,
- ϵ - parametr rezydualny.

Zasada działania opiera się na podziale przestrzeni decyzyjnej na odseparowane linią lub płaszczyzną klasy. W przestrzeni danych Ω znajdują się wektory danych x stanowiące

próbkę uczącą D , należące do dwóch klas [56].

$$D = \left\{ (x_i, c_i) \mid x_i \in R^p, c_i \in \{1, -1\} \right\}_{i=1}^N \quad (2.2)$$

Następnie poszukiwany jest klasyfikator umożliwiający podział całej przestrzeni Ω na dwa rozłączne obszary odpowiadające klasom $\{1, -1\}$. Znalezienie granicy decyzyjnej między klasami umożliwi również klasyfikację nowych obiektów x .

Dwie klasy są liniowo separowalne, gdy istnieje hiperpłaszczyzna H o postaci $g(x)$:


$$g(x) = w^T x + b \quad (2.3)$$

przyjmująca wartości:

$$y = \begin{cases} g(x_i) > 0 & x_i \in 1 \\ g(x_i) < 0 & x_i \in -1 \end{cases}$$

Działanie metody można przedstawić na rysunku 2.6. Znajdują się na nim trzy proste H_1, H_2, H_3 oraz dwa zbiory punktów. Jak można zauważyć prosta:

- H_3 nie umożliwia podziału danych na klasy.
- H_1 umożliwia podział danych jednak z bardzo małym marginesem.
- H_2 separuje dane z maksymalnym marginesem.



Rysunek 2.6: Zasada działania modelu SVM (źródło: opracowanie własne na podstawie [57])

Zaprezentowana metoda umożliwia uogólnienie zadania do problemów nieliniowych oraz do płaszczyzn wielowymiarowych.

Istotną zaletą sieci SVM w porównaniu do sieci neuronowych MLP (Multilayer Perceptron) jest sprowadzenie problemu do zadania charakteryzującego się zazwyczaj występowaniem pojedynczego minimum funkcji celu. Wadą tego typu rozwiązań jest zależność wyników od przyjętych wartości parametrów stałych, takich jak szerokość funkcji gaussowskiej σ , współczynnika γ dla jądra wielomianowego, wartości parametru regularizacyjnego C czy tolerancję ε [54].

2.3.4 Modele hybrydowe

Przykład praktycznego zastosowania hybrydowego modelu prognostycznego opisano w artykule [16]. Artykuł przedstawia model dedykowany do predykcji produkcji energii z czternastu farm wiatrowych zlokalizowanych w Turcji. Zaproponowany model hybrydowy będący połączeniem sieci neuronowych oraz maszyn wektorowych został porównany z innymi modelami opartymi wyłącznie o sieć neuronową lub maszyny wektorowe. Połączenie modeli pozwoliło na poprawę jakości prognoz. W celu poprawy dokładności predykcji wykorzystano metodę klasteryzacji dla wyboru najlepszych danych wejściowych (prognoz). Zaproponowany model wykonano na potrzeby Tureckiego Systemu Energetycznego.

Model opisany w pracy [16] umożliwia generowanie prognoz dla dużej liczby elektrowni wiatrowych zróżnicowanych pod względem geograficznej lokalizacji jak i zainstalowanej mocy.

Najważniejsze cechy modelu hybrydowego Statistical Hybrid Wind Power Forecast Technique (SHWIP) to:

- zdolność do prognozowania dla dużej liczby elektrowni wiatrowych zlokalizowanych na zróżnicowanym terenie, obejmującym dużą liczbę farm wiatrowych,
- możliwość wykonania prognoz krótkoterminowych do 48 h,
- numeryczne prognozy pobierane są z następujących serwisów pogodowych:
 1. Global Forecast System (GFS),
 2. European Centre for Medium Range Weather Forecasts (ECMWF),
 3. Turkish Met Office (DMI),
- model przygotowano na podstawie rocznych danych będących zbiorem uczącym, a następnie zaplanowano ciągłą korektę modelu co 1 miesiąc,

- prognozy dla danego punktu wyznaczane są za pomocą regresji liniowej (uśrednienie) dostępnych punktów NWP,
- model wykorzystuje metodę klastryzacji k-średnich na potrzeby wyznaczenia prognozy jak najdokładniejszej dla danej turbiny.

W artykule [16] sieć neuronową ANN (Artificial Neural Networks) uczono za pomocą danych historycznych obejmujących jeden rok. W modelu uwzględniono prędkość oraz kierunek wiatru jako parametry warunkujące wielkość produkcji energii. Autorzy [16] zaproponowali sieć neuronową składającą się z jednej warstwy ukrytej, ponieważ dodanie kolejnych nie poprawiało rezultatów. W warstwie ukrytej znajdowało się od 15 do 25 neuronów w zależności od farmy wiatrowej dla której wykonywano prognozy. Z obserwacji autorów [16] wynika, że najgorsze jakościowo prognozy wystąpiły dla elektrowni zlokalizowanej na szorstkim terenie. Istotną zaletą zaproponowanego modelu SHWIP jest generowanie prognoz z mniejszym błędem, zwłaszcza jeśli modele uczone są przy użyciu małych zbiorów danych. W przyszłości autorzy planują połączyć model fizyczny, ANN, SVM i SHWIP w jeden w celu poprawy jakości prognoz. Nieco inne połączenie modeli zaproponowano w artykule [46]. W modelu hybrydowym przy pomocy transformaty falkowej (IEWT - improved empirical wavelet transform) dane zostały podzielone na 4 przedziały, a następnie przetworzone przez sieć wektorów nośnych wykorzystującą metodę najmniejszych kwadratów do znalezienia jej parametrów (LS-SVM Least-squares support-vector machines). Metoda najmniejszych kwadratów LS (ang. Least Squares), jest narzędziem pozwalającym minimalizować błąd średniokwadratowy podczas wyznaczania regresji liniowej lub estymacji parametrów modeli nieliniowych [54]. Jednocześnie w celu osiągnięcia precyzyjniejszych prognoz zastosowano algorytm BSA (Bird Swarm Algorithm) [58]. Inspiracją do jego powstania była obserwacja zachowania ptaków. Zapewnia lepszą dokładność optymalizacji i niezawodność.

Zastosowanie BSA zostało wykorzystane do wyboru parametrów sieci LS-SVM, co jak podają autorzy znacznie zmniejszyło złożoność obliczeń i poprawiło dokładność.

2.4 Modele prognostyczne dedykowane do elektrowni fotowoltaicznych

Wielkość produkcji w elektrowniach fotowoltaicznych jest zależna od tych samych czynników pogodowych jak w przypadku elektrowni wiatrowych jednak ich istotność jest inna. Dlatego modele dedykowane do elektrowni fotowoltaicznej nieco różnią się od wymienio-

nych w poprzednim podrozdziale. W kolejnych rozdziałach zaprezentowano przykładowe modele przeznaczone do predykcji produkcji energii elektrycznej z elektrowni fotowoltaicznej. Podobnie jak dla modeli dedykowanych do elektrowni wiatrowych, również w tym przypadku opisano jedynie wybrane modele związane z sieciami neuronowymi lub te pozwalające na budowę struktur hybrydowych.

2.4.1 Model Historical Similar Mining


Model HISIMI (Historical Similar Mining) zaproponowano w pracy [31]. Model bazuje na historycznych i prognozowanych danych pogodowych (numeryczne prognozy pogody NWP) oraz zmierzonych danych elektrycznych z paneli fotowoltaicznych (pochodzących z systemu SCADA). SCADA (ang. Supervisory Control And Data Acquisition) umożliwia zbieranie bieżących danych (np. pomiarów), wizualizację, sterowanie procesem, archiwizację danych, informuje o przekroczeniu wybranych parametrów. Wejściami do modelu są dwie wartości każdego parametru (np. promieniowania słoneczne, temperatura) dla chwili $t-1$ oraz t w celu poprawy jakości prognozy produkcji energii. Zmienna t jest wyrażona w godzinach. W obliczeniach uwzględniane są godzinowe wartości nasłonecznienia oraz mocy elektrowni fotowoltaicznej (w chwili t oraz $t-1$). Wielkość bazy danych zależy w dużym stopniu od liczby rejestrowanych zmiennych pogodowych oraz tych związanych z krótkoterminową prognozą produkcji energii w elektrowniach fotowoltaicznych.

Mechanism Based on Data Mining (MDM)

Wykorzystywany mechanizm MDM pozwala na określenie zależności pomiędzy badanymi strumieniami danych. Model przeszukuje i porównuje dane historyczne pochodzące z NWP (natężenie promieniowania, temperatura itp.) z aktualnie występującymi, a następnie wyznacza na tej podstawie wagi. Dzięki nim możliwe jest wybranie jedynie tych danych historycznych, które są istotne dla rozwiązania bieżącego problemu. W tym celu metoda MDM wykorzystuje funkcję gęstości rozkładu normalnego ze średnią μ (wartością centralną) i odchyleniem standardowym σ (równoważnie: wariancją σ^2), która jest przykładem funkcji Gaussa oraz dana jest wzorem:

$$\phi_{\mu,\sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(\frac{-(x - \mu)^2}{2\sigma^2}\right) \quad (2.4)$$

Na rysunku 2.7 przedstawiono przykładową funkcję gęstości rozkładu normalnego.



Rysunek 2.7: Przykładowa funkcja gęstości rozkładu normalnego [31]

Wartości centralne μ funkcji Gaussa odpowiadają bieżącym wartościom, wartość odchylenia σ może zostać wyznaczony podczas poprawy dokładności prognoz. Parametry funkcji Gaussa μ oraz σ są wyznaczane przy wykorzystaniu wartości sąsiadujących lub historycznych (na zasadzie podobieństwa).

Model HISIMI (HIstorical SIMilar Mining) [31] bazuje na rachunku prawdopodobieństwa, który jest wyznaczany na podstawie danych historycznych. Na podstawie tego zbioru (zawierającego znaczną liczbę przypadków - korelacji pomiędzy danymi zmierzonymi i prognozowymi NWP) tworzona jest funkcja dyskretnego rozkładu prawdopodobieństwa. Do optymalizacji struktury danych wejściowych wykorzystywany jest algorytm genetyczny (genetic algorithm – GA). W procesie tym następuje wybór istotnych czynników pogodowych dostępnych w bazie danych. W tym celu wszystkie dane wejściowe są normalizowane w zakresie od 0 do 1. Pozwala to na zastosowanie dla nich tego samego zakresu w odchyleniu standardowym. HISIMI prognozując produkcję energii z elektrowni fotowoltaicznej bazuje jedynie na zbiorze danych (jest modelem statystycznym), dlatego podobnie jak inne tego typu rozwiązania posiada zdolność do łatwej aktualizacji bazy danych oraz adaptacji.

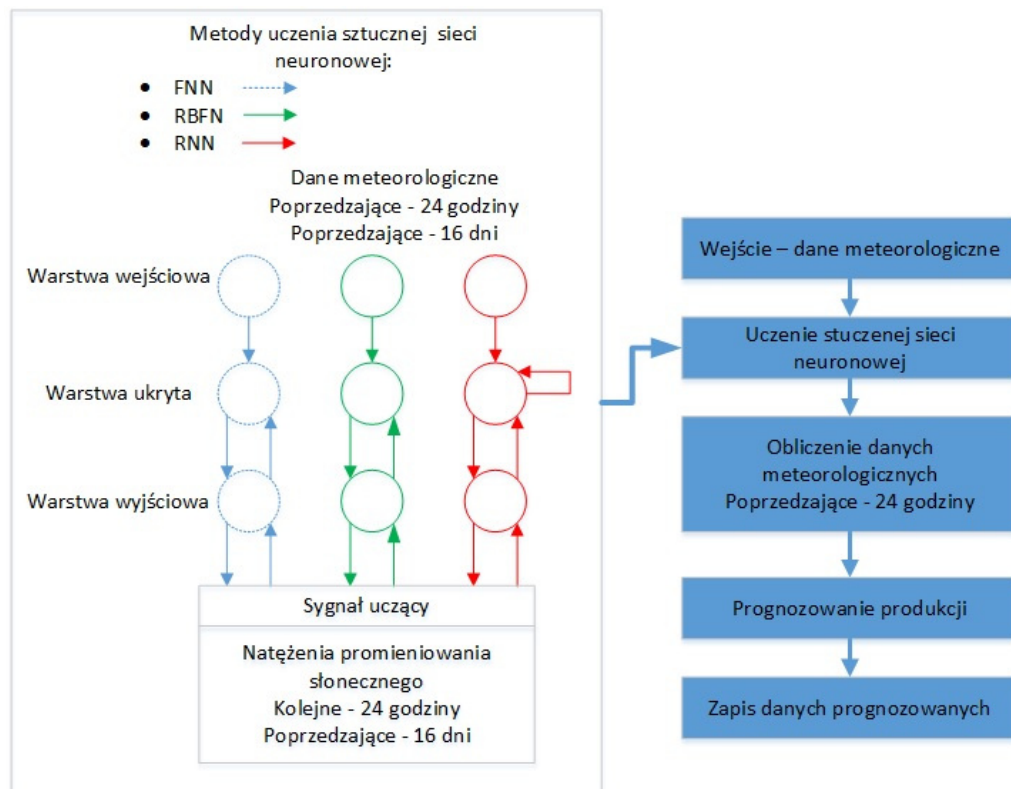
2.4.2 Modele Sieci Neuronowych

Działanie przykładowego modelu prognostycznego wykorzystującego sztuczne sieci neuronowe opisano w pracy [59]. Zbiór uczący zawiera dane pogodowe oraz elektryczne (ilość produkowanej energii elektrycznej). Na wejście modelu wprowadzono dane pomiarowe oraz prognozowane. Dane prognostyczne GPV pochodzą z japońskiego odpowiednika Instytutu Meteorologii i Gospodarki Wodnej (Numerical Prediction Division of Japan Me-

teorological Agency). Do modelu wprowadzano prognozowane dane z horyzontem czasowym 24 godzinnym i rozdzielczością 1 godzinną, takie jak: nasłonecznienie, temperatura, ciśnienie atmosferyczne, wilgotność, zachmurzenie, prędkość wiatru i opady deszczu. Jak podają autorzy, ze względu na trudność normalizacji danych prędkości wiatru i opadów deszczu, ostatecznie nie uwzględniono ich jako informacje wejściowe do modelu.

W pracy zaproponowano wykorzystanie trzech różnych typów sieci neuronowych:

- FFNN (ang. Feed-forward Neural Network)
- RBFN (ang. Radial Basis Function Neural Network)
- RNN (ang. Recurrent Neural Network)



Rysunek 2.8: Algorytm uczenia sieci neuronowej (źródło: opracowanie własne na podstawie [59])

Algorytm uczenia powyższych modeli polega na wykorzystaniu 16 dniowych zbiorów danych uczących meteorologicznych i elektrycznych. W pracy [59] podkreślono silny wpływ sezonowości na nasłonecznienie, co przekłada się na dodatkową trudność w procesie uczenia oraz wymusza konieczność wykorzystania większego zbioru uczącego.

Moc elektrowni obliczana jest z wzoru [59]:

$$P_s = \eta SI(1 - 0,005(t_o + 25)) \quad (2.5)$$

gdzie:

η - sprawność paneli fotowoltaicznych [%]

S - powierzchnia paneli fotowoltaicznych [m²],

I - natężenie promieniowania słonecznego (wartość wyjściowa z ANN) [kW/m²],

t_o - temperatura powietrza [°C].

W tabli 2.1 zaprezentowano strukturę danych wejściowych wprowadzonych do modelu. Tabela 2.2 przedstawia strukturę sieci neuronowej zaproponowaną w artykule [59].

Tabela 2.1: Dane wejściowe do modelu [59]

| Wejścia (wartości zmierzone) | |
|----------------------------------|---|
| x_1 | Nasłonecznienie dla okresu 1-24 godziny |
| x_2 | Temperatura dla okresu 1-24 godziny |
| Wejścia (wartości przeliczone) | |
| x_3 | Nasłonecznienie paneli dla okresu 1-24 godziny |
| x_4 | Nasłonecznienia paneli, dane prognozowane dla okresu 1-24 godziny |
| Wejścia (Prognozy z systemu GPV) | |
| $x_5 - x_8$ | Wilgotność, dane prognozowane dla okresu 1-24 godziny |
| Wyjście (wartości zmierzone) | |
| T_1 | Nasłonecznienie, dane prognozowane dla okresu 1-24 godziny |
| T_2 | Temperatura, dane prognozowane dla okresu 1-24 godziny |

Tabela 2.2: Parametry sieci neuronowej [59]

| | |
|---------------------------------------|-------|
| Liczba neuronów wejściowych | 8 |
| Liczba neuronów w warstwie ukrytej | 16 |
| Liczba neuronów w warstwie wyjściowej | 2 |
| Efektywność uczenia | 0.001 |
| Współczynnik momentum | 0.25 |
| Czas uczenia | 1000 |

Wykorzystanie powyższych modeli sieci neuronowych do obliczeń prognozowanej produkcji energii nie wymaga rozbudowanych wzorów oraz tworzenia skomplikowanych mo-

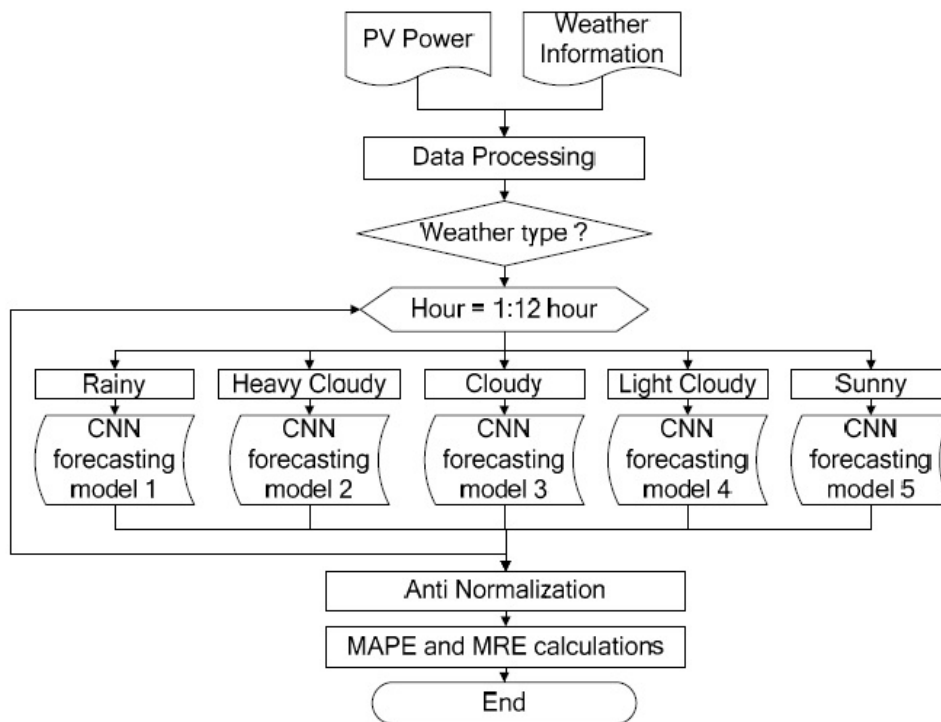
deli matematycznych. W celu przeprowadzenie predykcji wystarczy dostarczyć prognozowane dane meteorologiczne. Model RBFN został wybrany ze względu na prostą budowę oraz skalowalność. Model RNN jest do narzędzie dobrze sprawdzające się w obliczeniach bazujących na szeregach czasowych. Wykazano, że modele RBFN i RNN pozwalają na uzyskanie lepszych dokładności prognoz niż w przypadku modelu FFNN. Jak zauważono w [59] w krótkim okresie czasu możliwe jest prognozowanie produkcji energii bazujące jedynie na danych meteorologicznych.

Nieco inne podejście do prognozowania zaproponowano w artykule [60]. Publikacja opisuje modele krótkoterminowej predykcji mocy z wykorzystaniem konwolucyjnych sieci neuronowych CNN oraz kombinacji metod SVM-SSA, LSTM-SSA oraz CNN-SSA. Zaproponowane modele bazują na danych generowanych przez model klasyfikacji CNN, inaczej niż na przykład w [61–63], gdzie natężenie promieniowania słonecznego jest ważnym parametrem wejściowym. Autorzy zaproponowali natomiast podział warunków pogodowych na pięć kategorii: deszczowo, mocne zachmurzenie, zachmurzenie, lekkie zachmurzenie i słonecznie. Informacja ta posłużyła jako dodatkowa zmienna wejściowa do zaproponowanych modeli prognozy mocy. Do zbioru danych wejściowych wytypowano następujące parametry:

- średnia moc,
- odchylenie standardowe mocy,
- moc maksymalna,
- maksymalna temperatura,
- minimalna temperatura,
- ilość opadów,
- warunki pogodowe,
- godzina

Dla każdej kategorii pogodowej zbudowano również niezależny model prognostyczny CNN-SSA jak na rysunku 2.9.

Ocenę dokładności prognoz wykonano z użyciem dwóch wskaźników: MAPE (4.18) oraz NMAPE(4.19), dla elektrowni o mocy 500 kWp zlokalizowanej na Tajwanie.



Rysunek 2.9: Proces prognozowania z wykorzystaniem klasyfikacji typu pogody [60]

3 Prezentacja analizowanych obiektów - elektrownie wiatrowe oraz fotowoltaiczne

Zwiększenie dokładności prognoz generacji energii elektrycznej elektrowni bazującej na OZE wymaga wykonania analizy specyfiki pracy oraz wpływu czynników pogodowych na wolumen produkcji.

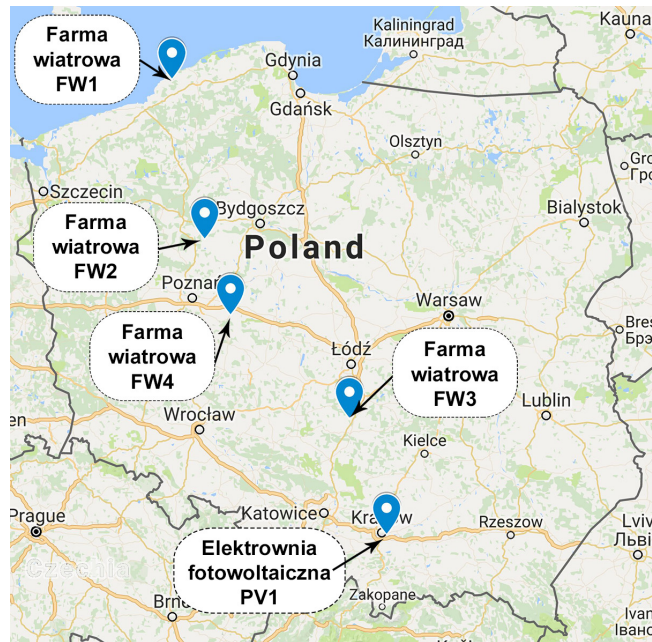
Na podstawie danych uzyskanych z 4 elektrowni wiatrowych oraz dwóch fotowoltaicznych poddano analizie czynniki mające wpływ na wielkość produkcji energii oraz badano z jaką siłą na nią wpływają. Do analizy wybrano jedynie te dane, które można dla danego obiektu monitorować i które mogą być potencjalnie istotne podczas wykonywania prognoz. W opisie poszczególnych obiektów występują niejednorodności ze względu na różny zbiór rejestrowanych wielkości oraz dostępnych informacji. Zgromadzona baza danych oraz przeprowadzona na jej podstawie analiza ma w przyszłości uprościć proces przygotowania modeli prognostycznych dla nowych obiektów.

W przypadku zaproponowanych metod prognozowania bazujących na sztucznej inteligencji dane pochodzące z elektrowni dostarczają informacji o kluczowych czynnikach wpływających na jej pracę.

Na rysunkach 3.1-3.2 przedstawiono lokalizację rozważanych elektrowni na tle mapy Grecji oraz Polski.



Rysunek 3.1: Lokalizacja elektrowni fotowoltaicznej PV2 - półwysep bałkański - Grecja [źródło: opracowanie własne na podstawie Google Maps]

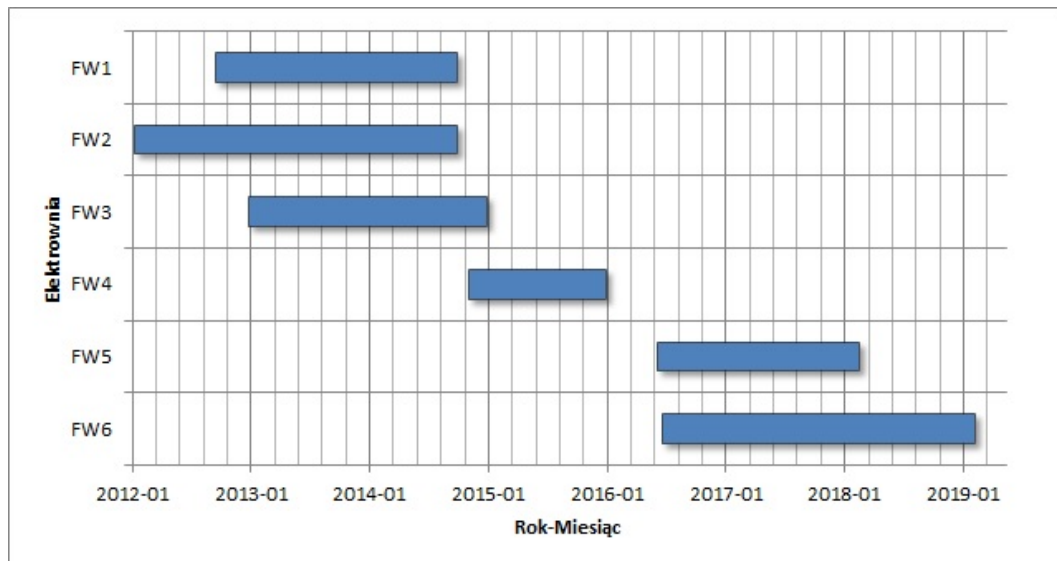


Rysunek 3.2: Lokalizacja analizowanych obiektów na mapie Polski

Dane pochodzą z następujących obiektów:

1. Elektrownia wiatrowa nr 1 (FW1), położona w centralnym obszarze wybrzeża Morza Bałtyckiego Polski o łącznej mocy zainstalowanej turbozespołów wiatrowych 20 [MW],
2. Elektrownia wiatrowa nr 2 (FW2), położona w północno-zachodniej części kraju o łącznej mocy zainstalowanej turbozespołów 120 [MW],
3. Elektrownia wiatrowa nr 3 (FW3), położona w południowo-centralnej części kraju o łącznej mocy zainstalowanej turbozespołów 30 [MW],
4. Elektrownia wiatrowa nr 4 (FW4), położona w zachodnio-centralnej części kraju o łącznej mocy zainstalowanej 1 [MW]. Składa się z jednej turbiny, przez co lokalna zmienność wiatru bezpośrednio wpływa na zmiany mocy jednostki wytwórczej. Taką sytuacją utrudnia proces prognozowania i dlatego postanowiono uwzględnić ją również w pracy.
5. Elektrownia fotowoltaiczna nr 5 (PV1), położona w południowej części kraju o łącznej mocy zainstalowanej paneli fotowoltaicznych 60 [kW].
6. Elektrownia fotowoltaiczna nr 6 (PV2), położona w środkowej części Grecji na obszarze Attyki o łącznej mocy zainstalowanej paneli fotowoltaicznych 22,11 [kW].

W celu wykonania analizy pracy przedstawionych powyżej elektrowni zgromadzono zbiory danych z okresów zamieszczonych na rysunku 3.3. Najmniejszy zbiór danych zawiera informację z 365 dni, największy z 994 dni.



Rysunek 3.3: Wykres przedstawiający okresy dla których zgromadzono dane dla poszczególnych analizowanych obiektów

Na potrzeby pracy zgromadzono informacje z nieco różniących się od siebie okresów. Można wyróżnić przedział czasu od 01.01.2013 r. do 01.10.2014 r., w którym dane z elektrowni wiatrowych FW1-FW3 się pokrywają.

W tabli 3.1 zamieszczono zestawienie charakterystycznych parametrów technicznych elektrowni wiatrowych FW1-FW4.

3.1 Elektrownie wiatrowe

Istotnym czynnikiem podczas planowania budowy elektrowni wiatrowej jest miejsce jej lokalizacji. Od tego, gdzie obiekt zostanie wybudowany zależą średnie roczne warunki wietrzne. Elektrownie budowane są wewnątrz lądu, na wybrzeżach oraz morzach. Wiatr jest wynikiem nierównomiernego nagrzewania się lądu i mórz, biegunów oraz równika. Prowadzi to do powstania różnic ciśnień między tymi strefami cieplnymi i do przemieszczania się mas powietrza.

Tabela 3.1: Zestawienie charakterystycznych parametrów elektrowni wiatrowych

| | | Elektrownia wiatrowa | | | |
|---|------------|-----------------------------------|------------|---------------|-----------------------------------|
| | | FW1 | FW2 | FW3 | FW4 |
| Liczba turbin | | 8 | 60 | 15 | 1 |
| Producent | | Nordex | Gamesa | Enercon | NEG Micon |
| Model | | N100/2500 | G90 DA 2,0 | E70-E4 | NM-60 |
| Moc turbiny [MW] | | 2,5 | 2 | 2 | 1 |
| Prędkość wiatru [m/s] | Startowa | 3 | 3 | 2,5 | 3 |
| | Nominalna | 12 | 13 | 12,7 | 16 |
| | Maksymalna | 20 | 21 | 25 | 20 |
| | Graniczna | 52,5 | 49 | 34 | 60 |
| Wysokość do osi piasty [m] | | 100 | 100 | 85 | 70 |
| Powierzchnia obrotowa wirnika [m ²] | | 7854 | 6362 | 3959 | 2827 |
| Rodzaj generatora | | Asynchroniczny podwójnie zasilany | | Synchroniczny | Asynchroniczny podwójnie zasilany |
| Przekładnia | | Planetarna | Planetarna | Brak | Planetarna |

3.1.1 Kinetyka wiatru

Moc pozyskiwana z elektrowni wiatrowej zależy od różnych czynników [64]. Obrót śmigła w elektrowni wiatrowej o poziomej osi obrotu wirnika, jest wynikiem przetwarzania energii kinetycznej poruszającego się powietrza przepływającego przez powierzchnię A w czasie t . Zależność tę możemy zapisać jako:

$$E = \frac{1}{2}mV_w^2 = \frac{1}{2}AV_w t \rho V_w^2 = \frac{1}{2}At\rho V_w^3 \quad (3.1)$$

gdzie:

m - masa powietrza [kg]

V_w - prędkość wiatru [m/s],

ρ - gęstość powietrza [kg/m³],

A - powierzchnia zataczana przez łopaty turbiny [m²],

$AV_w t$ - objętość powietrza przepływającego przez powierzchnię A .

Jedynie część energii wiatru jaka przepływa przez powierzchnię omiataną wirnikiem turbozespołu może zostać przez niego odzyskana. Moc pojedynczej turbiny wiatrowej określona jest zależnością:

$$P_t = \frac{1}{2} A \rho V_w^3 \eta_{el} \eta_m c_p \quad (3.2)$$

gdzie:

P_t - moc turbiny [W],

c_p - współczynnik wykorzystania energii wiatru (współczynnik Betza),

η_{el} - sprawność elektryczna (generatora, przetworników, transformatorów itd.),

η_m - sprawność mechaniczna (przekładni, wirnika, urządzeń pomocniczych).

Jak wynika z (3.2) czynnikiem, który ma największy wpływ na generowaną moc jest prędkość wiatru. Jednocześnie jest to parametr charakteryzujący się znaczną stochastycznością. Producenci podają charakterystykę mocy turbiny w funkcji V_w w postaci tabelarycznej lub graficznej. Jest ona wyznaczana dla zadanej sprawności mechanicznej i określonej gęstości powietrza. W rzeczywistości parametry te są zmienne w czasie (sprawność mechaniczna - w dłuższym kilku letnim przedziale czasu, gęstości powietrza - w krótszym kilkunasto/kilkudziesięciu minutowym okresie).

Gęstość powietrza wilgotnego można wyznaczyć ze wzoru [65]:

$$\rho = \frac{p_d}{R_d \cdot T} + \frac{p_v}{R_v \cdot T} = \frac{p_d \cdot M_d + p_v \cdot M_v}{R \cdot T} \quad (3.3)$$

gdzie:

ρ - gęstość powietrza wilgotnego [kg/m³],

p_d - ciśnienie cząstkowe suchego powietrza [Pa],

R_d - stała gazowa suchego powietrza 287,058 J/(kg · K),

T - temperatura [K],

p_v - ciśnienie cząstkowe pary wodnej [Pa],

R_v - stała gazowa pary wodnej - 461,495 [J/kg · K],

M_d - masa molowa suchego powietrza - 0.028964 [kg/mol],

M_v - masa molowa pary wodnej - 0.018016 [kg/mol],

R - uniwersalna stała gazowa - 8,314 [J/(K · mol)].

Ciśnienie pary wodnej można obliczyć na podstawie ciśnienia pary nasyconej i wilgotności względnej:

$$p_v = \phi \cdot p_{sat} = \phi \cdot 6,1078 \cdot 10^{\frac{7,5T}{T+237,3}} \quad (3.4)$$

gdzie:

ϕ - wilgotność względna [%]

p_{sat} - ciśnienie pary nasyconej

Ciśnienie powietrza wilgotnego p tj. ciśnienie barometryczne wg prawa Daltona:

$$p = p_v + p_d \quad (3.5)$$

W uproszczeniu przyjmuje się, że temperatura wraz ze wzrostem wysokości h zmniejsza się o $L=0,0065$ [K/m], natomiast zmianę ciśnienia można obliczyć ze wzoru:

$$p = p_0 \left(1 - \frac{Lh}{T_o} \right)^{\frac{gM}{RL}} \quad (3.6)$$

gdzie:

p_0 - ciśnienie atmosferyczne na poziomie odniesienia [hPa],

T_o - temperatura na poziomie odniesienia [$^{\circ}C$],

g - przyspieszenie ziemskie $9,80665$ [m/s²].

Jak wynika z powyższych wzorów wzrost temperatury oraz wilgotności powoduje zmniejszenie gęstości powietrza, a tym samym zmniejszenie P_t . W praktyce wykorzystanie samej charakterystyki mocy (zależnej wyłącznie od prędkości wiatru) do predykcji może okazać się niewystarczające.

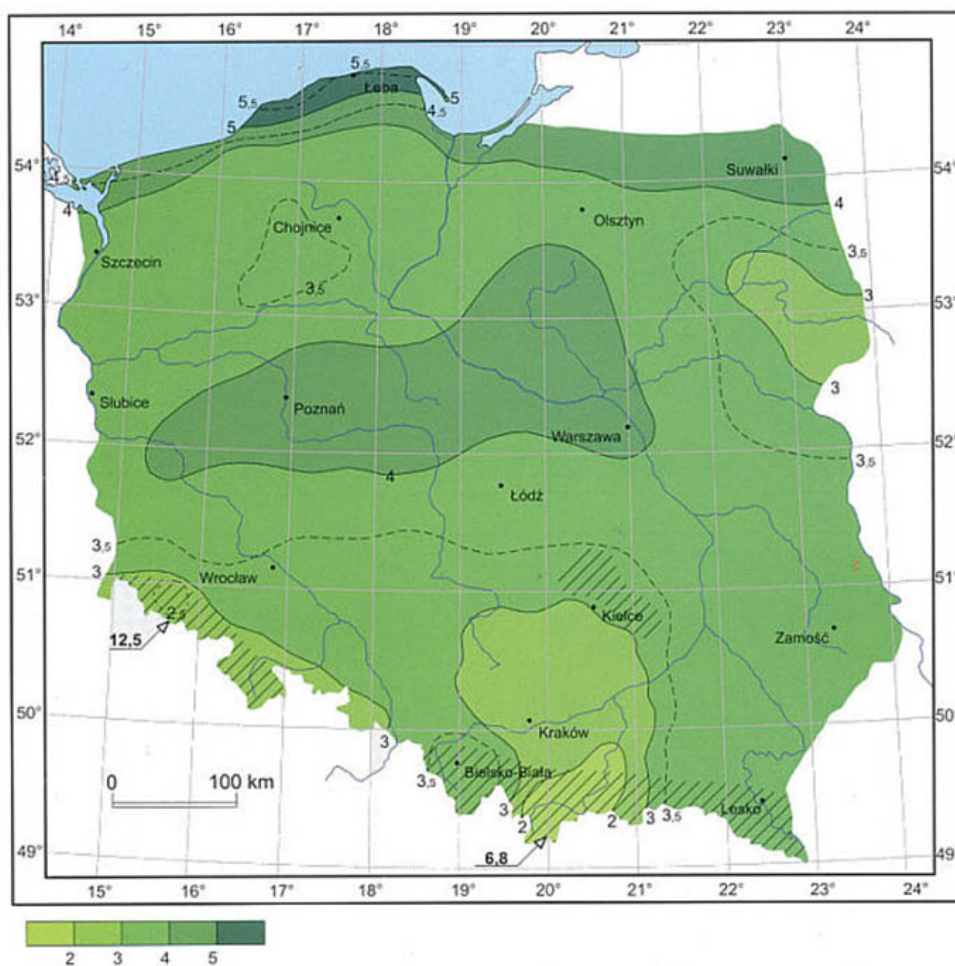
3.1.2 Strefy energetyczne w Polsce

Strefy energetyczne są to obszary na terenie których występuje określony potencjał wykorzystania energii wietrznej. Każdej strefie przypisano kategorię oraz średnie wielkości energii wiatru w kWh/m²/rok. W tabeli 3.2 wyróżniono sześć stref energetycznych i przyporządkowano do nich zasoby energii na wysokości 10 i 30 m. Dane zostały opracowane przez prof. Halinę Lorenc z IMGW na podstawie pomiarów wykonanych w latach 1971-2000. Należy pamiętać, że wysokość na jakiej zainstalowana jest piasta turbiny wiatrowej to około 70-100 m, dlatego możliwa do odzyskania energia jest jeszcze większa. Na rysunku 3.4 przedstawiono średnie prędkości wiatru na wysokości 10 m.n.p.g. w terenie otwartym o klasie aerodynamicznej szorstkości terenu³ 0-1 określające warunki wietrzne na terenie Polski.

³Aerodynamiczna szorstkość terenu - jest to współczynnik zależny od rodzaju powierzchni, stopnia zabudowania i ukształtowania terenu mających wpływ na prędkość wiatru. Przykładowo przeszkody takie jak budynki, słupy energetyczne wprowadzają zawirowania powietrza i ujemnie wpływają na przepływ wiatru. Zdefiniowano 9 klas szorstkości w przedziale 0-4, gdzie 0 - to powierzchnia wody / 4 - bardzo duże miasta z wysokimi budynkami i drapaczami chmur [67].

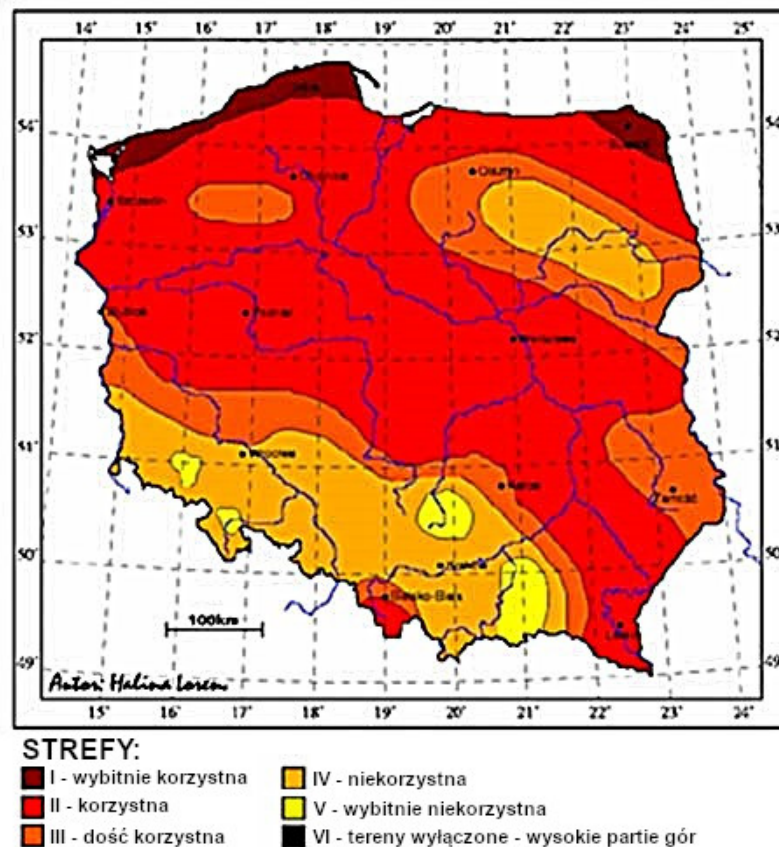
Tabela 3.2: Zasoby energii wiatru w poszczególnych strefach energetycznych [66]

| Nr i nazwa strefy | Energia wiatru na wys. 10 m [kWh/rok z 1 m ²] | Energia wiatru na wys. 30 m [kWh/rok z 1 m ²] |
|---------------------------|--|--|
| I - bardzo korzystna | > 1000 | > 1500 |
| II - korzystna | 750-1000 | 1000-1500 |
| III - dość korzystna | 500-750 | 750-1000 |
| IV - nie korzystna | 250-500 | 500-750 |
| V - bardzo nie korzystna | < 250 | < 500 |
| VI - szczytowe partie gór | tereny wyłączone | tereny wyłączone |



Rysunek 3.4: Warunki wietrzne w Polsce – średnie 10 minutowe prędkości wiatru [m/s] [66]

Zasoby energetyczne wiatru są jednym z ważniejszych czynników decydujących o miejscu lokalizacji elektrowni wiatrowej w początkowej fazie projektu. Mapę Polski podzieloną na strefy przydatności⁴ przedstawia rysunek 3.5 [68]. Jest ona przydatna podczas wykonywania wstępnej oceny opłacalności budowy elektrowni wiatrowej w danym regionie Polski.



Rysunek 3.5: Energetyczne zasoby wiatru w Polsce z podziałem na strefy przydatności [66]

W dalszych rozdziałach zostanie rozważona oddzielnie specyfika pracy poszczególnych elektrowni z uwzględnieniem indywidualnych charakterystycznych cech wyróżnionych dla tych obiektów.

⁴Strefa przydatności / strefa energetyczna wiatru - jest to obszar dla którego określone zostały zasoby energetyczne wiatru na podstawie długookresowych danych pomiarowych. W pracy [68] wykorzystany został podział obszaru Polski na strefy przydatności zaproponowany przez prof. Halinę Lorenc z IMGW. Wyróżniono 5 stref (ze względu na możliwość pozyskania energii z wiatru): Tabela 3.2. Mapa podlega modyfikacji, jak podaje [69] poprzednia wersja była mniej korzystna. Dla przykładu strefa II z korzystnej została zmodyfikowana na bardzo korzystną.

3.1.3 Elektrownia wiatrowa FW1

Na rysunku 3.6 przedstawiono pierwszą z rozważanych elektrownię wiatrową zlokalizowaną w pasie nadmorskim Polski (Rysunek 3.2).



Rysunek 3.6: Elektrownia wiatrowa FW1 [70]

Charakterystyczne parametry obiektu zostały zestawione w Tabeli 3.1. Na potrzeby analizy pracy elektrowni wykorzystano zarejestrowane historyczne dane z okresu od 18.09.2012 r. do 01.10.2014 r. (Rysunek 3.3). Czas uśredniania danych wynosił 15 min. Zamieszczone w dalszej części pracy wykresy oraz charakterystyki prezentujące pracę elektrowni FW1 zostały opracowane na podstawie tych danych. Pomimo, iż elektrownia wiatrowa wyposażona jest łącznie w 8 turbin to średnia liczba pracujących jednostek w badanym okresie ponad dwóch lat wynosiła 6,465 (wartość została wyznaczona na podstawie informacji przekazanej przez operatora elektrowni).

Średnie roczne wartości prędkości i kierunku wiatru, temperatury, ciśnienia atmosferycznego (zaprezentowane w Tabeli 3.3) oraz wartości minimalne i maksymalne tylko częściowo odzwierciedlają zmienność tych parametrów występującą w miejscu lokalizacji poszczególnych turbin i w bliskim otoczeniu farmy. Mały poziom średniej mocy czynnej FW1 jest wynikiem małych prędkości wiatru wiejących na wysokości piasty. Średnie procentowe wykorzystanie elektrowni wiatrowej⁵ w analizowanym okresie (Rysunek 3.3) wyniosło 26%. Zgodnie z deklaracją producenta turbina dla średniej prędkości wiatru 6-6,5 [m/s] powinna generować 472-608 [kW]. Na rysunku 3.7 zaprezentowano charakterystykę mocy zainstalowanych turbin dla znamionowych warunków pracy⁶. Średni punkt

⁵Średnie procentowe wykorzystanie elektrowni wiatrowej [%] - rozumiane jako iloraz liczby rejestracji dla których moc elektrowni była większa od 0 [kW] do liczby wszystkich rejestracji.

⁶Znamionowe warunki pracy turbiny - warunki pogodowe dla których gęstość przemieszczającego się powietrza wynosi 1,225 kg/m³, przy średniej prędkości wiatru mierzonej na wysokości piasty.

pracy znajduje się w miejscu przecięcia charakterystyki mocy z czerwoną przerywaną linią, a poniżej znajduje się histogram rozkładu częstości wystąpienia prędkości wiatru dla elektrowni FW1.

Tabela 3.3: Zestawienie szacowanych oraz zmierzonych minimalnych, średnich, maksymalnych wartości parametrów charakterystycznych dla elektrowni FW1


| | Elektrownia FW1 | | | |
|--------------------------------------|----------------------|----------------------|--------|-------|
| | Wartości szacunkowe* | Wartości zmierzone** | | |
| | | Min. | Śr. | Max. |
| Liczba turbin*** | 8 | 0 | 6,46 | 8 |
| Prędkość wiatru**** [m/s] | 5-6 (10 m.n.p.g.) | 0 | 6,25 | 26,9 |
| Temperatura otoczenia**** [°C] | 8-9 | 0 | 11,93 | 37 |
| Ciśnienie atmosferyczne**** [hPa] | 1013,25 | 979 | 1012,8 | 1035 |
| Moc czynna [MW] | 20 | 0 | 5,2 | 19,71 |

* - wartości deklarowane przez producenta, średnie dla lokalizacji elektrowni lub odczytane z Rysunku 3.4

** - wartości wyznaczone na podstawie zgromadzonych danych dla analizowanego okresu (Rysunek 3.3)

*** - zainstalowana / pracująca

**** - pomiar wykonany na wysokości gondoli przez stację pogodową zainstalowaną w jednej z turbin elektrowni

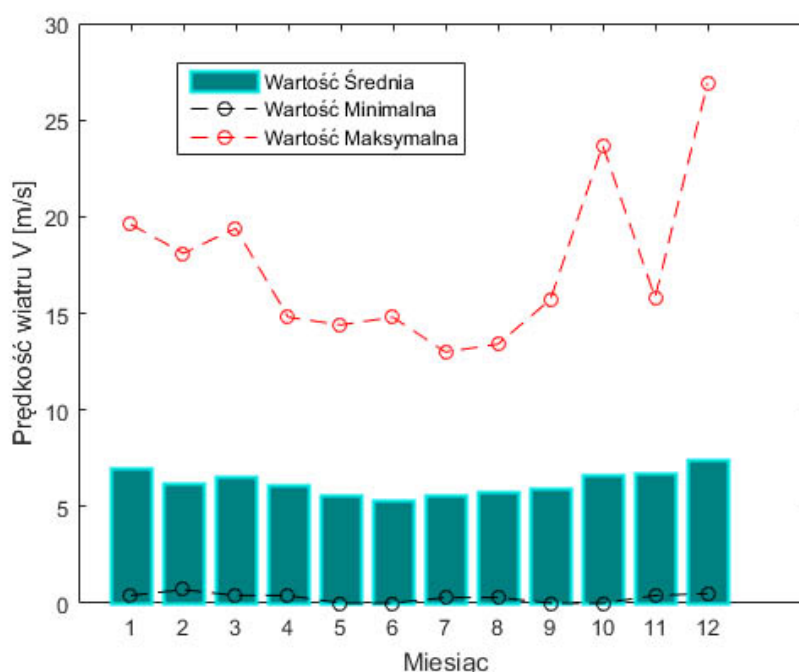


Rysunek 3.7: Charakterystyka mocy turbiny N100/2500 z zaznaczonym średnim punktem pracy⁷ oraz histogram prędkości wiatru elektrowni FW1 (źródło: opracowanie własne na podstawie [71])

⁷Średni punkt pracy - jest to punkt na charakterystyce mocy elektrowni wiatrowej, odpowiadający średniej prędkości wiatru wyznaczonej na podstawie posiadanego zbioru danych.

Jak wynika z rysunku 3.7 średni punkt pracy turbiny, odpowiadający średniej prędkości wiatru znajduje się w miejscu, gdzie charakterystyka posiada dużą pochodną (nie-wielkie zmiany prędkości wiatru wywołują znaczną zmianę mocy). To sprawia, że opracowywanie trafnych prognoz dla tego typu obiektów jest jeszcze trudniejsze.

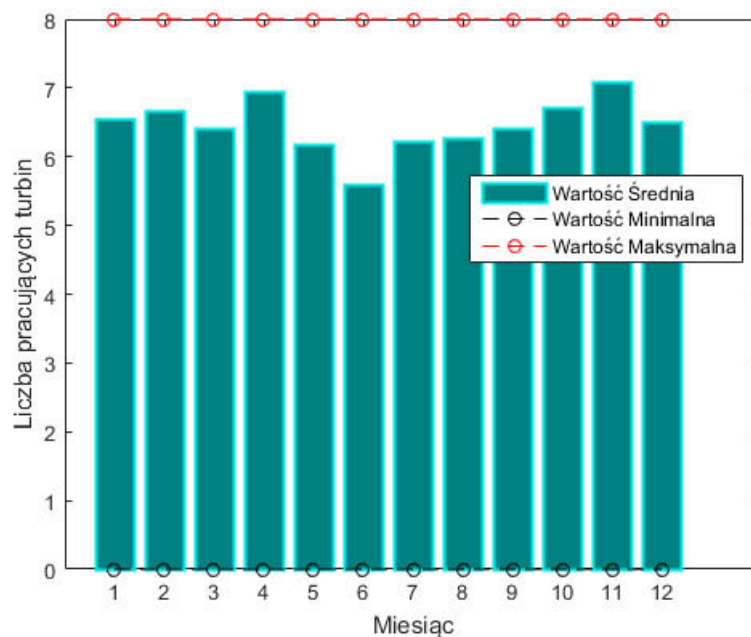
Średnia prędkość wiatru w zależności od miesiąca wahała się w granicach 5,33-7,47 [m/s]. Największe i najmniejsze wartości zarejestrowano odpowiednio w grudniu ($\sim 7,47$ [m/s]) oraz czerwcu ($\sim 5,33$ [m/s]). Zmienność tę w zależności od miesiąca przedstawiono na rysunku 3.8.



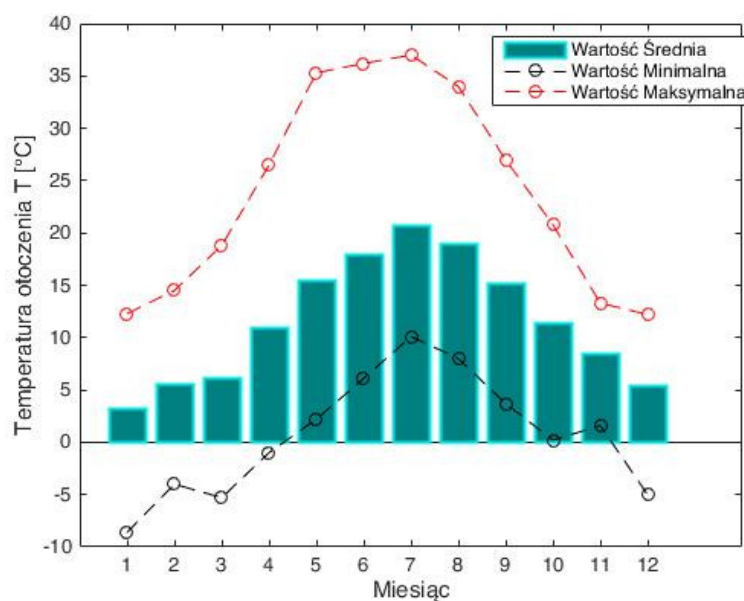
Rysunek 3.8: Minimalna, średnia, maksymalna prędkość wiatru dla elektrowni FW1 w poszczególnych miesiącach analizowanego okresu

Ze względu na zbyt małą prędkość wiatru (poniżej progu załączenia turbiny) (Rysunek 3.8) oraz nierównomierny rozkład wiejących wiatrów - nie wszystkie jednostki w tym samym czasie pracowały. Na rysunku 3.9 zamieszczono miesięczną zmienność średniej liczby pracujących turbin. Jak można zauważyć średnio najmniej turbin pracowało w czerwcu (5,5), najwięcej w listopadzie (7).

Z punktu widzenia pracy elektrowni wiatrowej dodatkowymi parametrami, które mają wpływ na wielkość produkcji energii są temperatura oraz ciśnienie. Charakterystyki przedstawiające ich miesięczną zmienność zaprezentowano na rysunkach 3.10-3.11.



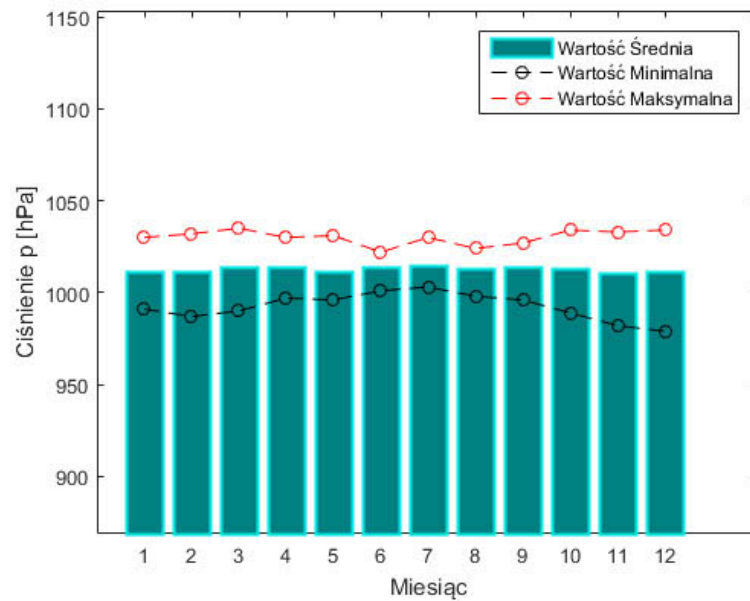
Rysunek 3.9: Minimalna, średnia, maksymalna liczba pracujących turbin elektrowni FW1 w poszczególnych miesiącach analizowanego okresu



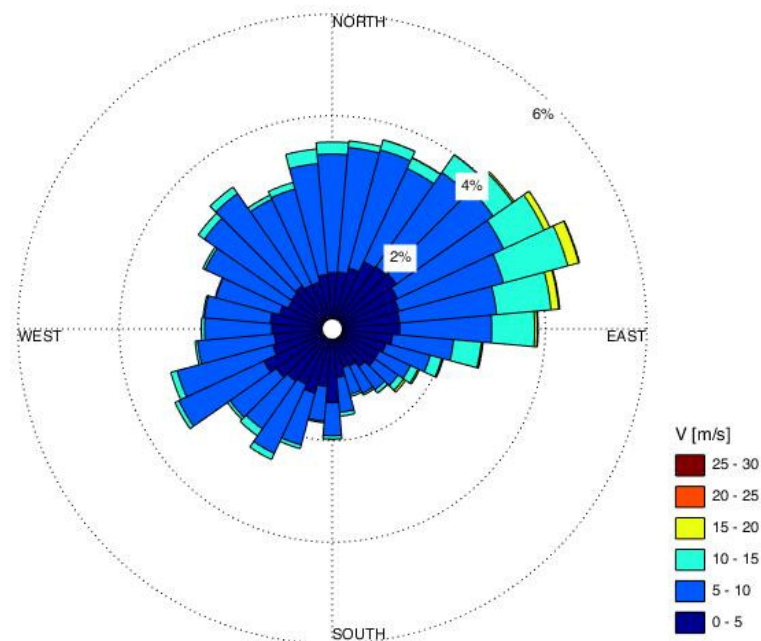
Rysunek 3.10: Minimalna, średnia, maksymalna temperatura otoczenia elektrowni FW1 w poszczególnych miesiącach analizowanego okresu

W przypadku temperatury widoczne są znaczne zmiany sezonowe. Najniższe średnie wartości występowały w styczniu ($\sim 4,32$ [°C]), najwyższe w lipcu ($\sim 20,70$ [°C]). Uzupełnieniem analizy pracy farmy wiatrowej jest wykres kierunku i prędkości wiatru (tzw. róża wiatrów), którą zaprezentowano na rysunku 3.12. Jak widać dominujące prędkości wiatru zawarte są w dwóch przedziałach 0-5 oraz 5-10 [m/s] oraz dla kierunków północno-wschodniego i zachodniego.

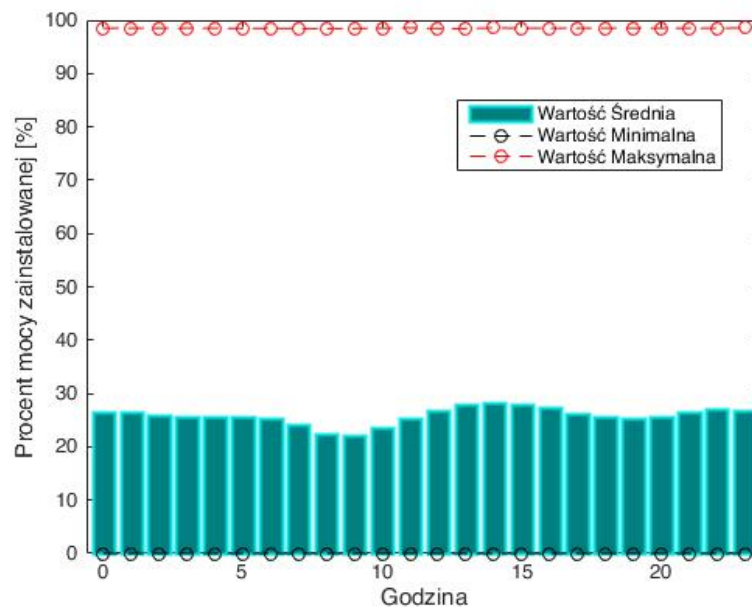
Istotnym parametrem elektrycznym z punktu widzenia pracy elektrowni wiatrowej jest średnia generowana moc. Jest ona przydatna podczas bilansowania energii oraz profilowania jej zużycia. Rysunki 3.13 - 3.15 przedstawiają zmienność produkcji w zależności od godziny, dnia tygodnia oraz miesiąca. Prezentowany na nich procent mocy czynnej zainstalowanej jest to średnia obliczona na podstawie danych 15 minutowych dla elektrowni FW1 w okresie ponad dwóch lat (Rysunek 3.3).



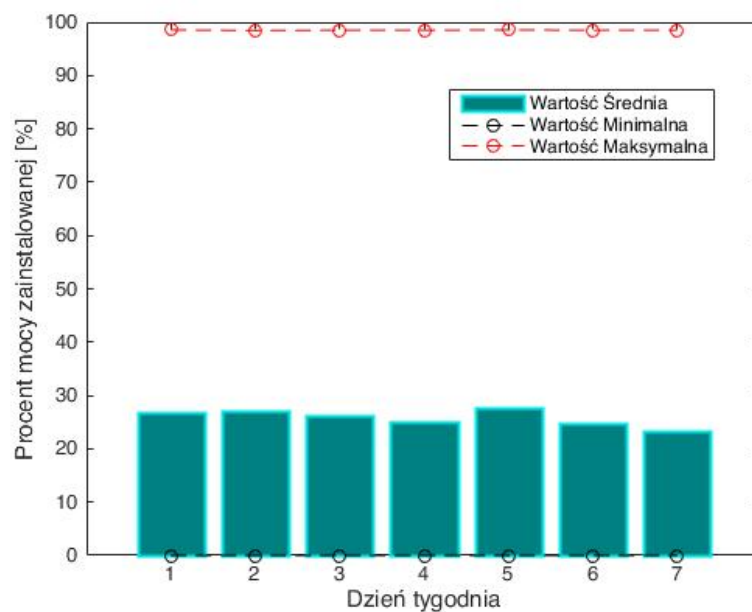
Rysunek 3.11: Minimalne, średnie, maksymalne ciśnienie atmosferyczne elektrowni FW1 w poszczególnych miesiącach analizowanego okresu



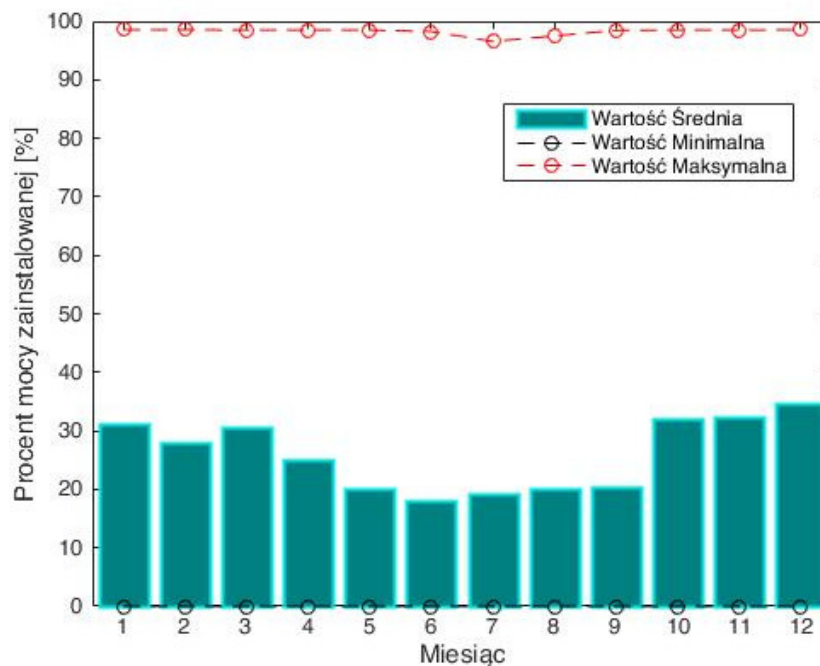
Rysunek 3.12: Róża wiatrów elektrowni FW1



Rysunek 3.13: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych godzinach analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.14: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych dniach tygodnia analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.15: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych miesiącach analizowanego okresu (w % mocy zainstalowanej)

Jak wynika z rysunków 3.13-3.15 w elektrowni FW1 występuje znaczna zmienność minimalnych oraz maksymalnych wartości mocy (prawie w pełnym zakresie mocy zainstalowanej) - niezależnie od analizowanego okresu godziny, dnia czy miesiąca. Najmniejszą oraz największą średnią moc zarejestrowano odpowiednio w czerwcu (3,64 MW) oraz grudniu (6,93 MW).

3.1.4 Elektrownia wiatrowa FW2

Elektrownia wiatrowa przedstawiona na rysunku 3.16 zlokalizowana jest w północno-zachodniej części kraju (Rysunek 3.2). Składa się z dwóch obszarów w których zainstalowano 11 oraz 49 turbin (łącznie 60). Pozostałe charakterystyczne parametry techniczne zestawiono w Tabeli 3.1. Elektrownia FW2 została wybrana do analizy ponieważ jest obiektem o znacznej liczbie turbin i mocy zainstalowanej (jak na warunki Polskie) oraz zlokalizowana jest na dużym obszarze. Ma to wpływ na różną prędkość wiatru przecinającego powierzchnię zataczaną przez łopaty poszczególnych turbin, a tym samym ich generowaną moc.

Analiza pracy elektrowni wiatrowej wykonana została na podstawie zarejestrowanych danych z okresu od 12.01.2012 r. do 01.10.2014 r. Czas uśredniania danych wynosił 15 min.



Rysunek 3.16: Elektrownia wiatrowa FW2 [72]

Wykresy oraz charakterystyki prezentowane w dalszej części tekstu zostały opracowane dla tego okresu.

Elektrownia wyposażona jest łącznie w 60 turbin, jednak średnia liczba pracujących jednostek wytwórczych w badanym okresie blisko trzech lat wynosiła 49,75 (Rysunek 3.18). Jest to spowodowane zbyt małymi średnimi prędkościami wiatru (poniżej progu załączenia turbiny) oraz nierównomiernym rozkładem prędkości wiatru wiejącego wewnątrz farmy. Z rysunku 3.18 wynika, że najmniej turbin pracowało w miesiącu sierpniu (średnio 44) oraz miesiącu czerwcu (średnio 44,8). Najwięcej jednostek pracowało w styczniu (52 turbiny). Pozostałe dane opisujące parametry pracy obiektu zestawiono w Tabeli 3.4.

Tabela 3.4: Zestawienie szacowanych oraz zmierzonych minimalnych, średnich, maksymalnych wartości parametrów charakterystycznych dla elektrowni FW2

| | Elektrownia FW2 | | | |
|---------------------------|-----------------------|----------------------|-------|--------|
| | Wartości szacunkowe* | Wartości zmierzone** | | |
| | | Min. | Śr. | Max. |
| Liczba turbin*** | 60 | 0 | 49,75 | 60 |
| Moc [MW] | 120 | 0 | 28,03 | 118,66 |
| Prędkość wiatru**** [m/s] | 5,0-6,0 (10 m.n.p.g.) | 0 | 5,64 | 20,30 |


* - wartości deklarowane przez producenta, średnie dla lokalizacji elektrowni lub odczytane z Rysunku 3.4

** - wartości wyznaczone na podstawie zgromadzonych danych dla analizowanego okresu (Rysunek 3.3)

*** - zainstalowana / pracująca

**** - pomiar wykonany na wysokości gondoli przez stację pogodową zainstalowaną w jednej z turbin elektrowni

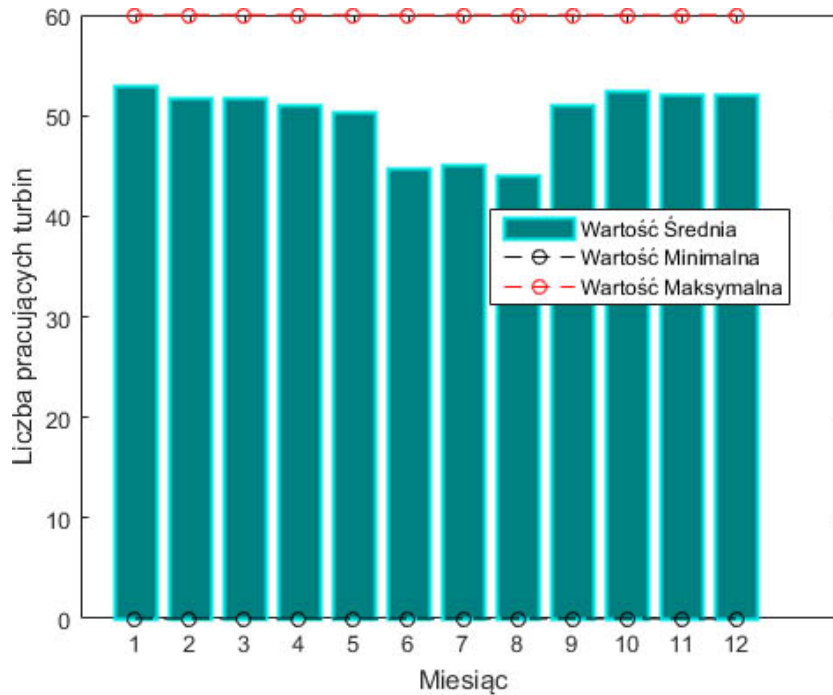
Średnie procentowe wykorzystanie elektrowni wiatrowej FW2 jest na niższym poziomie w porównaniu z FW1 i wynosi około 23,36% (dla okresu prawie trzech lat). Niski poziom mógł być spowodowany gorszymi warunkami lokalizacyjnymi lub parametrami turbiny. Pomimo zastosowania generatora o mniejszej mocy, wymaga on większej niż w przypadku FW1 prędkości wiatru, aby osiągnąć moc znamionową. Na rysunku 3.17 przedstawiono deklarowaną przez producenta charakterystykę mocy dla znamionowych warunków pracy turbiny. Przez większość czasu elektrownia pracuje w dolnej oraz środkowej części charakterystyki mocy (Rysunek 3.17), co bezpośrednio przekłada się na wielkość produkcji. Nawet niewielkie zmiany prędkości wiatru wpływają na znaczne zmiany wielkości generowanej mocy.



Rysunek 3.17: Charakterystyka mocy turbiny G90 z zaznaczonym średnim punktem pracy oraz histogram prędkości wiatru elektrowni FW2 [źródło: opracowano własne na podstawie [73]].

Analiza pracy elektrowni FW2 została wykonana na podstawie danych takich jak: liczba jednostek pracujących, moc turbiny oraz prędkość wiatru rejestrowanych jako średnie 15 minutowe wartości.

Średnie prędkości wiatru w poszczególnych miesiącach zmieniały się w granicach 4,72-6,54 m/s (rys. 3.19). Największe i najmniejsze średnie prędkości wiatru zarejestrowano odpowiednio w grudniu (~6,54 m/s) oraz sierpniu (~4,72 m/s). Dla tego obiektu nie rejestrowano danych takich jak temperatura, ciśnienie oraz kierunek wiatru.

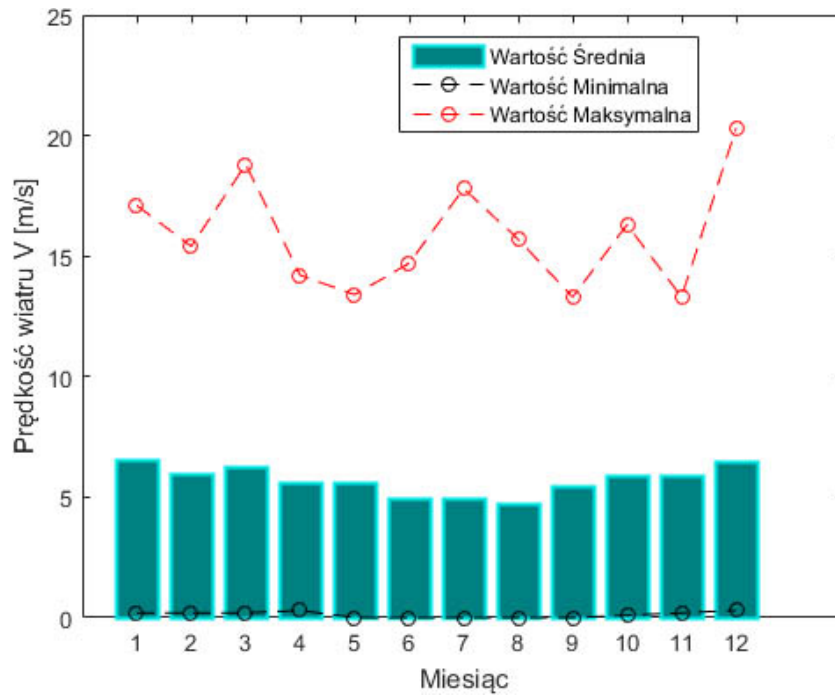


Rysunek 3.18: Minimalna, średnia, maksymalna liczba pracujących turbin elektrowni FW2 w poszczególnych miesiącach analizowanego okresu

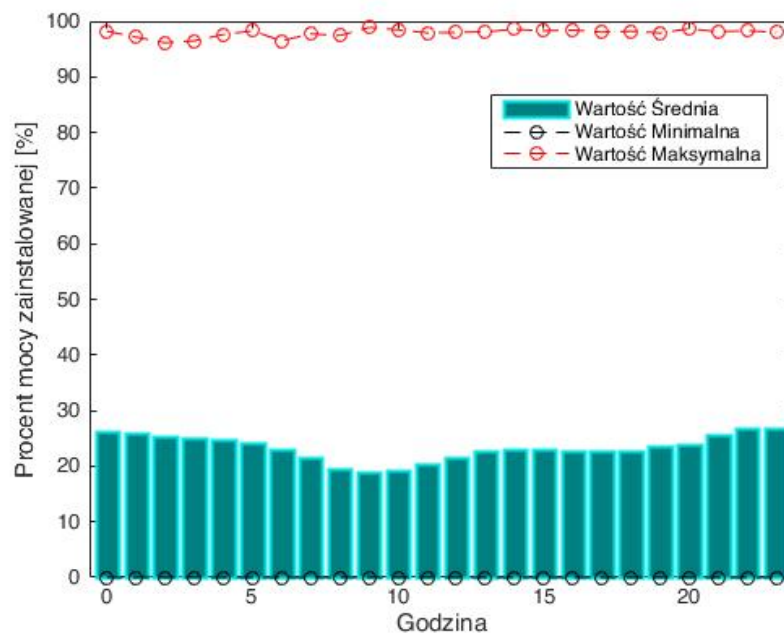
Ze względu na stochastyczny charakter generacji efektywne bilansowanie energii oraz profilowanie jej zużycia nie jest zadaniem trywialnym, co można zaobserwować na rysunkach 3.17-3.22. Przedstawiono na nich zmienność mocy w zależności od godziny, dnia tygodnia oraz miesiąca.

Na rysunku 3.22 przedstawiono średnią miesięczną procentową zmienność mocy czynnej zainstalowanej elektrowni FW2. Elektrownia ta charakteryzuje się znacznym jak na polskie warunki wolumenem produkcji energii w porównaniu do innych elektrowni wiatrowych. Rysunki 3.20-3.22 potwierdzają dużą zmienność ilości produkcji wahającą się od wartości bliskich zero do 120 MW. Im większa liczba pracujących turbin tym efektywne ich bilansowanie staje się coraz trudniejsze, ponieważ są one rozproszone zazwyczaj na znacznym obszarze o zróżnicowanych warunkach pogodowych.

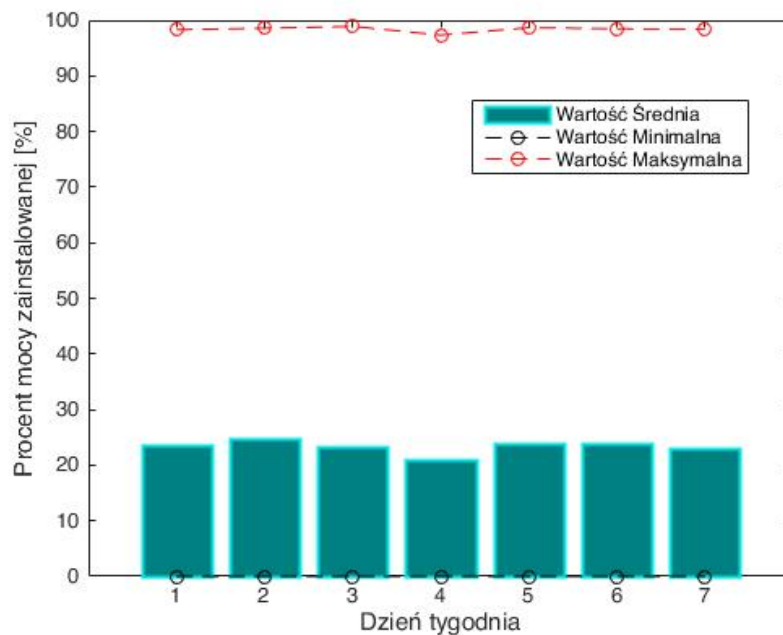
Na rysunku 3.20 widoczne jest zmniejszenie średniej mocy elektrowni w godzinach porannych 8-9 do poziomu 22-23 MW. Podobne zjawisko zaobserwowano dla elektrowni FW1 (rysunek 3.13)



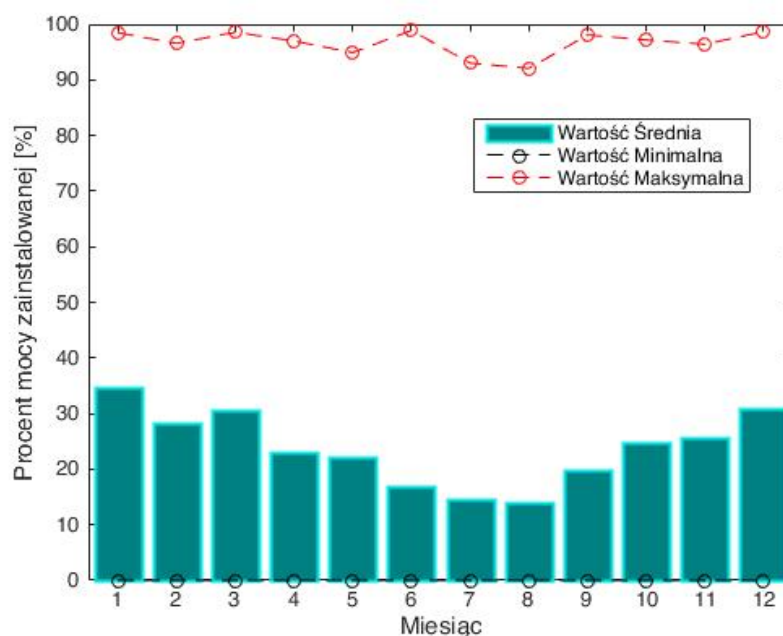
Rysunek 3.19: Minimalna/średnia/maksymalna miesięczna prędkość wiatru dla elektrowni FW2



Rysunek 3.20: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW2 w poszczególnych godzinach analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.21: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW2 w poszczególnych dniach tygodnia analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.22: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW2 w poszczególnych miesiącach analizowanego okresu (w % mocy zainstalowanej)

3.1.5 Elektrownia wiatrowa FW3

Trzecia elektrownia wiatrowa FW3 (Rysunek 3.23) o mocy zainstalowanej 30 MW (15 x 2MW) zlokalizowana jest w południowej części województwa łódzkiego (Rysunek 3.2). Składa się z turbin firmy Enercon GmbH typu E70 – E4 [49]. Elektrownia wiatrowa FW3 jest średnią co do wielkości elektrownią zarówno pod względem liczby turbin jak i mocy. Obiekt został wytypowany ze względu na dostęp zarówno do danych uśrednionych dla całej farmy, jak również z poszczególnych turbin, co umożliwiło analizę specyfiki działania oraz nierównomiernego rozkładu prędkości i kierunku wiatru wewnątrz elektrowni.



Rysunek 3.23: Farma wiatrowa FW3 [źródło:pgeeo.pl]

Elektrownia wybudowana została na wzniesieniu o powierzchni około 270 ha. Wysokość względna wierzchołki góry wynosi ok. 150–170 m (350 – 470 m npm). Wiatraki oddalone są od siebie o około 450 m.

Piasta generatora zainstalowana została na wysokości 85 m. Średnica wirnika wynosi 71 m, a powierzchnia obrotowa jest równa 3959 m². Rozruchowa oraz maksymalna prędkość wiatru to odpowiednio 2,5 oraz 25,0 m/s, moc nominalną turbina osiąga przy 12,7 m/s. Generator pierścieniowy i wirnik tworzą w turbinie typu E-70 jedną jednostkę. Dzięki połączeniu kołnierzowemu piasta wirnika obraca się z tą samą prędkością co wał generatora. Zastosowanie konstrukcji bezprzekładniowej wyeliminowało szybko obracające się elementy i spowodowało ograniczenie strat energii pomiędzy wirnikiem i generatorem, emisji hałasu, mechanicznego zużycia oraz strat oleju. Łopaty wirnika zaprojektowano do pracy ze zmiennym nachyleniem łopat i zmienną prędkością. Analiza pracy farmy wiatrowej wykonana została na podstawie zgromadzonych danych pomiarowych dotyczących prędkości wiatru, całkowitej mocy generowanej, liczby pracujących turbin z okresu

od 01.01.2013 r. do 31.01.2015 r. Dla okresu od 01.02.2014 r. do 31.01.2015 r. uzyskano dodatkową informację dot. temperatury zewnętrznej mierzonej przez stację pogodową zainstalowaną na każdej turbinie. Czas uśredniania danych wynosił 10 min. W Tabeli 3.5 zestawiono dane opisujące parametry pracy obiektu.

Tabela 3.5: Zestawienie szacowanych oraz zmierzonych minimalnych, średnich, maksymalnych wartości parametrów charakterystycznych dla elektrowni FW3

| | Elektrownia FW3 | | | |
|---------------------------|----------------------|----------------------|------|-------|
| | Wartości szacunkowe* | Wartości zmierzone** | | |
| | | Min. | Śr. | Max. |
| Liczba turbin*** | 15 | 0 | 9,6 | 15 |
| Prędkość wiatru**** [m/s] | 3-4 (10 m.n.p.g.) | 0 | 6,13 | 21,39 |
| Temperatura**** [°C] | 8-9 | -11,93 | 9,48 | 32,13 |
| Moc [MW] | 30 | 0 | 6,53 | 30,89 |


* - wartości deklarowane przez producenta, średnie dla lokalizacji elektrowni lub odczytane z Rysunku 3.4

** - wartości wyznaczone na podstawie zgromadzonych danych dla analizowanego okresu (Rysunek 3.3)

*** - zainstalowana / pracująca

**** - pomiar wykonany na wysokości gondoli przez stację pogodową zainstalowaną w jednej z turbin elektrowni


Elektrownia wyposażona jest łącznie w 15 turbin natomiast średnia liczba pracujących jednostek wytwórczych w badanym okresie dwóch lat wynosiła 9,6. Na rysunku 3.24 zamieszczono miesięczną zmienność średniej liczby pracujących turbin.



Rysunek 3.24: Minimalna, średnia, maksymalna liczba pracujących turbin elektrowni FW3 w poszczególnych miesiącach analizowanego okresu

Najmniejsza ich liczba pracowała w miesiącu styczniu oraz czerwcu, było ich odpowiednio 7,4/7,7. Najwięcej jednostek pracowało w grudniu (średnio ponad 12).

Ze względu na lokalizację elektrowni na wzniesieniu, średnia prędkość wiatru w przypadku tego obiektu jest nieco większa niż wynika to z Mapy Wietrzności [66] dla danego obszaru (Tabela 3.5). Średnie procentowe wykorzystania elektrowni wiatrowej w badanym okresie wynosiło 22%. W przypadku tego obiektu, dość istotne jest rozmieszczenie turbin. Pomimo dość znacznego obszaru wieże zlokalizowane są blisko siebie co może wpływać na wzajemne oddziaływanie (efekt "zasłaniania się" turbin). Turbina dla prędkości wiatru w pobliżu wartości średniej zmierzonej 6,0-7,0 [m/s] zgodnie z deklaracją producenta powinna generować 240-400 [kW]. Na podstawie karty katalogowej producenta [49] przedstawiono charakterystykę mocy turbiny (Rysunek 3.25).




Rysunek 3.25: Charakterystyka mocy turbiny E70 z zaznaczonym średnim punktem pracy oraz histogram prędkości wiatru elektrowni FW3 [źródło: opracowano na podstawie [49]]


Średnio roczne wartości prędkości i kierunku wiatru oraz temperatury nie odzwierciedlają rzeczywistej zmienności tych parametrów w poszczególnych porach roku. Zmienność średnich prędkości wiatru w zależności od miesiąca przedstawiono na rysunku 3.26.

Największe i najmniejsze średnie prędkości wiatru zarejestrowano odpowiednio w grudniu ($\sim 8,54$ [m/s]) oraz czerwcu ($\sim 4,78$ [m/s]).

Z punktu widzenia pracy farmy wiatrowej dodatkowym parametrem jaki ma wpływ na wielkość produkcji jest temperatura otoczenia. Charakterystykę przedstawiającą jej miesięczną zmienność zaprezentowano na Rysunku 3.27. Widoczne są znaczne sezonowe zmiany, najniższe średnie temperatury występowały w styczniu (~ 0 [°C]), najwyższe w sierpniu ($\sim 18,43$ [°C]).




Rysunek 3.26: Minimalna/średnia/maksymalna miesięczna prędkość wiatru dla elektrowni FW3




Rysunek 3.27: Minimalna, średnia, maksymalna temperatura otoczenia elektrowni FW3 w poszczególnych miesiącach analizowanego okresu

Do pełnej analizy pracy farmy wiatrowej niezbędny jest wykres kierunku i prędkości wiatru (tzw. róża wiatrów), którą zamieszczono na rysunku 3.28. Na obszarze elektrowni dominują prędkości wiatru w przedziale 2-8 [m/s]. Również w przypadku tego obiektu przez większość czasu turbiny pracują ze znaczną zmiennością mocy (Rysunek 3.25).


Na rysunku 3.31 przedstawiono średnią miesięczną zmienność mocy generowanej (w procentach mocy zainstalowanej). Na rysunkach 3.29-3.31 przedstawiono zmienność mocy w zależności od godziny, dnia tygodnia oraz miesiąca.




Rysunek 3.28: Róża wiatrów elektrowni FW3



Rysunek 3.29: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW3 w poszczególnych godzinach analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.30: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW3 w poszczególnych dniach tygodnia analizowanego okresu (w % mocy zainstalowanej)




Rysunek 3.31: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW3 w poszczególnych miesiącach analizowanego okresu (w % mocy zainstalowanej)

3.1.6 Elektrownia wiatrowa FW4

Elektrownia przedstawiona na rysunku 3.32 składa się z jednej turbiny wiatrowej NEG Micon NM-60⁸ o mocy zainstalowanej 1 MW. Turbina zlokalizowana jest w centralnej części województwa wielkopolskiego.

Powodem wyboru tego obiektu była znaczna zmienność wielkości produkcji uzależniona od lokalnych warunków pogodowych. Z punktu widzenia prognozowania ten typ obiektów jest najtrudniejszym do predykcji. W przypadku pojedynczej turbiny nie zachodzi efekt uśredniania produkcji, który występuje dla elektrowni wiatrowych zawierających wiele turbin niekiedy znacznie oddalonych od siebie i jednocześnie pracujących w różnych warunkach wietrznych.



Rysunek 3.32: Elektrownia wiatrowa FW4 [74]

Zastosowanie w turbinie technologii zmiennej prędkości pozwoliło na uzyskanie wysokiej sprawności aerodynamicznej⁹ dla szerokiego zakresu prędkości wiatru [76]. Zainstalowana turbina firmy NEG Micon NM 60/1000 posiada regulację momentu obrotowego,

⁸Od 2004 roku turbiny wiatrowe NEG Micon produkowane są pod logiem firmy Vestas.


⁹Sprawność aerodynamiczna - sprawność konwersji energii wiatru na energię mechaniczną. Zależy od kąta ustawienia łopat wirnika turboszespołu wiatrowego θ oraz od wyróżnika szybkobieżności λ . Wyróżnik szybkobieżności λ wyrażony jest jako stosunek prędkości obwodowej końca łopatki wirnika do prędkości strumienia swobodnie przepływającego powietrza [75]

a tym samym mocy generowanej przez asynchroniczny generator trójfazowy o podwójnym zasilaniu 1000/250 kW.

Analiza pracy elektrowni wykonana została na podstawie zgromadzonych historycznych danych dotyczących prędkości wiatru i mocy pochodzących z systemu SCADA turbiny z okresu od 01.01.2015 r. do 31.12.2016 r. oraz danych pochodzących z masztu pogodowego tj. temperatura, wilgotność, ciśnienie, promieniowanie słoneczne dla okresu od 08.11.2014 r. do 03.01.2016 r. Czas uśredniania danych wynosił 10 min. Dane te są podstawą wykresów i charakterystyk prezentowanych w niniejszym rozdziale. W Tabeli 3.6 zestawiono dane opisujące parametry pracy obiektu. Zamieszczono w niej również dane pochodzące z masztu pogodowego zainstalowanego na potrzeby pomiaru lokalnych warunków wietrznych na etapie planowania inwestycji jak również po jej realizacji. Maszt pogodowy umożliwił pomiar temperatury oraz prędkości wiatru na trzech wysokościach 40, 70 i 100 metrów.

W przypadku tej elektrowni widoczny jest niski poziom średniej mocy generowanej, który jest spowodowany małymi średnimi prędkościami wiatru. Średnie procentowe wykorzystanie elektrowni wiatrowej w badanym okresie wynosiło 20%.

Na rysunku 3.33 przedstawiono deklarowaną przez producenta charakterystykę mocy turbiny NEG Micon NM60/1000. Wynika z niej, że turbina dla średnich prędkości wiatru 6-7 m/s powinna generować moc równą 84-144,2 kW.



Rysunek 3.33: Charakterystyka mocy turbiny NM60/1000 z zaznaczonym średnim punktem pracy oraz histogram prędkości wiatru elektrowni FW4 [źródło: opracowanie własne na podstawie [76]]

Tabela 3.6: Zestawienie szacowanych oraz zmierzonych minimalnych, średnich, maksymalnych wartości parametrów charakterystycznych dla elektrowni FW4

| | Elektrownia FW4 | | | |
|---|----------------------|----------------------|--------|------|
| | Wartości szacunkowe* | Wartości zmierzone** | | |
| | | Min. | Śr. | Max. |
| Liczba turbin*** | 1 | 0 | 0,77 | 1 |
| Prędkość wiatru turbina [m/s] | 4-5 (10 m.n.p.g.) | 0 | 5,85 | 25,4 |
| Prędkość wiatru na wys. 40 m [m/s]**** | - | 0,3 | 5,68 | 22,8 |
| Prędkość wiatru na wys. 70 m [m/s]**** | - | 0,3 | 6,45 | 24,1 |
| Prędkość wiatru na wys. 100 m [m/s]**** | - | 0,3 | 7,22 | 25,5 |
| Temperatura turbina [°C] | 8-9 | -17 | 10,6 | 39 |
| Temperatura maszt [°C]**** | 8-9 | -14 | 8,9 | 37,3 |
| Ciśnienie [hPa] | 1013,25 | 650 | 949,6 | 1022 |
| Promieniowanie słoneczne [W/m ²] | 125,57 | 1,2 | 129,24 | 1477 |
| Moc [MW] | 1 | 0 | 0,2 | 1,1 |

* - wartości deklarowane przez producenta, średnie dla lokalizacji elektrowni lub odczytane z Rysunku 3.4


** - wartości wyznaczone na podstawie zgromadzonych danych dla analizowanego okresu (Rysunek 3.3)

*** - zainstalowana/pracująca


**** - maszt pogodowy zainstalowano nieopodal planowanej inwestycji na potrzeby pomiaru lokalnych warunków wietrznych. Maszt pogodowy umożliwił pomiar temperatury oraz prędkości wiatru.

Analizie poddano temperaturę, prędkość i kierunek wiatru w miejscu zainstalowania elektrowni. Przez pewien okres turbina nie pracowała ze względu na zbyt niską prędkość wiatru (poniżej progu załączenia turbiny). Jednostka wytwórcza w badanym okresie dwóch lat produkowała energię przez 77% czasu. Na rysunku 3.34 zamieszczono miesięczny względny czas pracy turbiny. Najkrócej pracowała ona w miesiącu październiku, listopadzie oraz lipcu. W tym okresie elektrownia produkowała energię przez 65-68% miesiąca. Najdłużej jednostka pracowała w grudniu (średnio przez 86% miesiąca).

Zmienność średnich prędkości wiatru w zależności od miesiąca przedstawiono na rysunku 3.35. Największe i najmniejsze średnie prędkości wiatru zarejestrowano odpowiednio w grudniu ($\sim 7,23$ [m/s]) oraz czerwcu ($\sim 4,82$ [m/s]).




Rysunek 3.34: Minimalne, średnie, maksymalne procentowe wykorzystanie elektrowni FW4 w poszczególnych miesiącach analizowanego okresu



Rysunek 3.35: Minimalna/Średnia/Maksymalna miesięczna prędkość wiatru dla elektrowni FW4

Do pełnej analizy pracy farmy wiatrowej przydatny może okazać się wykres kierunku i prędkości wiatru (tzw. róża wiatrów), który zamieszczono na Rysunku 3.36.




Rysunek 3.36: Róża wiatrów farmy FW4


Wynika z niego, że dominujące prędkości wiatru zawierają się w przedziale 0-10 [m/s]. Przekłada się to bezpośrednio na charakter pracy turbiny. Obiekt przez większość czasu pracuje ze znaczną zmiennością produkowanej energii (Rysunek 3.33). Niewielkie zmiany prędkości wiatru wpływają na znaczne zamiany wielkości generowanej mocy.

Dodatkowym parametrem jaki ma wpływ na działanie elektrowni i wielkość produkcji energii jest temperatura. Charakterystykę przedstawiającą jej miesięczną zmienność zamieszczono na Rysunku 3.37. W przypadku temperatury widoczne są znaczne sezonowe zmiany, najniższe średnie temperatury występowały w styczniu ($\sim -0,12$ [°C]), najwyższe w sierpniu ($\sim 21,35$ [°C]).


Z punktu widzenia pracy elektrowni wiatrowej fundamentalnym parametrem elektrycznym jest generowana średnia moc czynna. Ze względu na bilansowanie energii oraz profilowanie jej zużycia, ważna może okazać się analiza średniej wielkości mocy generowanej przez elektrownię w zależności od dnia tygodnia. Na Rysunku 3.38 przedstawiono tą zależność. Rysunki 3.39-3.40 przedstawiają natomiast zmianę profilu produkcji w zależności od godziny oraz miesiąca.




Rysunek 3.37: Minimalna, średnia, maksymalna temperatura otoczenia elektrowni FW4 w poszczególnych miesiącach analizowanego okresu



Rysunek 3.38: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych dniach tygodnia analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.39: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych godzinach analizowanego okresu (w % mocy zainstalowanej)



Rysunek 3.40: Minimalna, średnia, maksymalna generowana moc czynna elektrowni FW1 w poszczególnych miesiącach analizowanego okresu (w % mocy zainstalowanej)

3.2 Badanie wpływu czynników zewnętrznych na pracę elektrowni wiatrowej

Ilość energii elektrycznej generowanej przez elektrownię wiatrową silnie zależy od wpływu czynników pogodowych, a także umiejscowienia poszczególnych turbin wewnątrz farmy. W pierwszym przypadku wynika to z praw fizyki dotyczących działania turbiny, w drugim – z ukształtowania terenu i zjawiska wzajemnego oddziaływania turbin na siebie – tzw. "zasłaniania" się turbin. Elektrownie wiatrowe zazwyczaj lokalizowane są na dużym obszarze przez co rozkład prędkości wiatru jest nierównomierny.

Największy wpływ na ilość generowanej energii ma prędkość wiatru jednak analizie poddano również dodatkowe czynniki wpływu takie jak: temperatura, ciśnienie oraz dodatkowo kierunek wiatru.

Tabela 3.7 prezentuje współczynnik korelacji Pearsona między badanymi czynnikami odniesionymi do mocy elektrowni. Najsilniejsza korelacja występuje dla prędkości wia-

Tabela 3.7: Współczynnik korelacji Pearsona - czynniki dodatkowe/moc elektrowni¹⁰

| Czynnik wpływu | Współczynnik korelacji | | | |
|------------------------------|------------------------|------|-------|-------|
| | FW1 | FW2 | FW3 | FW4 |
| Temperatura otoczenia[°C] | -0,13 | -* | -0,12 | -0,15 |
| Ciśnienie atmosferyczne[hPa] | -0,24 | -* | -* | -* |
| Kierunek wiatru [°] | 0,14 | -* | 0,05 | 0,05 |
| Liczba pracujących turbin | 0,46 | 0,46 | 0,62 | 0,48 |
| Prędkość wiatru [m/s] | 0,90 | 0,92 | 0,89 | 0,83 |

* - współczynnik nie został obliczony z powodu braku dostępności danych

tru, co w przypadku farm wiatrowych wydaje się oczywiste. Nieco mniejszy współczynnik korelacji występuje z liczbą pracujących turbin. Może być to spowodowane znaczną zmiennością produkcji w czasie oraz występowaniem na przykład okresowych remontów. W przypadku kierunku wiatru jedynie dla elektrowni wiatrowej FW1 widoczna jest zauważalna dodatnia korelacja. Interesującymi czynnikami są również ciśnienie oraz temperatura, które wykazują ujemne współczynniki korelacji.

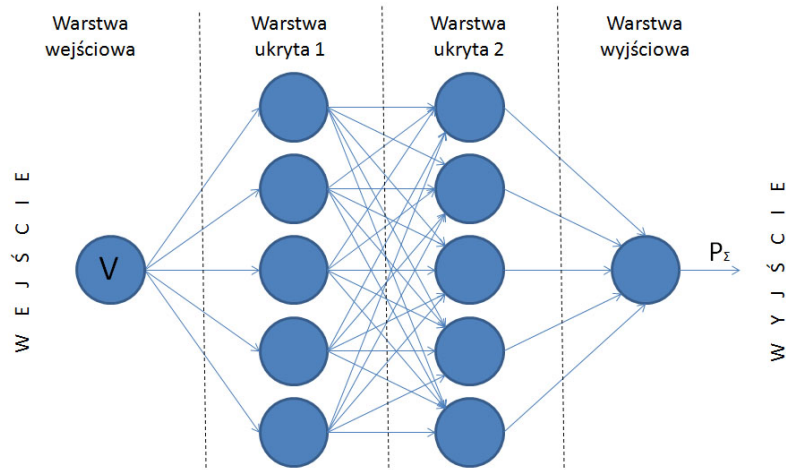
¹⁰Współczynniki zamieszczone w tabeli zostały wyznaczone na podstawie zgromadzonych danych dla poszczególnych obiektów zgodnie z rysunkiem 3.3.

3.2.1 Wpływ temperatury otoczenia na pracę elektrowni

Ze względu na zgromadzony zbiór danych analizę wpływu temperatury wykonano dla elektrowni wiatrowej FW1, FW3 oraz FW4.

Zbiór danych źródłowych w każdym przypadku podzielono na dwa podzbiory. W pierwszym umieszczono dane związane z temperaturą otoczenia $T < 5^{\circ}\text{C}$, a w drugim dane dla temperatury $T > 15^{\circ}\text{C}$. Wybór zakresów dokonano arbitralnie w taki sposób, aby przyjęte graniczne wartości temperatur umożliwiły odtworzenie charakterystyk mocy elektrowni wiatrowej.

Temperatura w zbiorze zmieniała się w zakresie od -17°C do 39°C . Wybór granicznych temperatur pozwolił uzyskać zbiory o podobnej liczebności (w odniesieniu do temperatur). Dla otrzymanych dwóch zbiorów danych (dla każdej elektrowni) zbudowano modele sieci neuronowych (rys. 3.41).




Rysunek 3.41: Struktura sieci neuronowej dla analizy wpływu czynników zewnętrznych na pracę elektrowni wiatrowej

Przygotowane dwa zbiory danych (Zbiór A - $T < 5^{\circ}\text{C}$, Zbiór B - $T > 15^{\circ}\text{C}$), wykorzystano w procesie organizacji zbioru uczącego oraz procesu uczenia sieci. Na wejście oraz wyjście sieci neuronowej podano odpowiednio prędkość wiatru oraz moc.

Po wykonaniu procesu optymalizacji w rozumieniu minimalizacji błędu średniokwadratowego otrzymano sieci, które pozwoliły na odtworzenie charakterystyki mocy elektrowni $P = f(V_w)$.

W oparciu o doświadczenia, w obu przypadkach uczono sieć neuronową o identycznej topologii. W pierwszych dwóch warstwach sieć zawierała po pięć neuronów z logistyczną

funkcją aktywacji, a w warstwie wyjściowej pojedynczy neuron liniowy. Wyniki odtwarzania przez sieć krzywej mocy elektrowni przedstawiono na rysunkach 3.42-3.44.




Rysunek 3.42: Elektrownia FW1 - a) Wyznaczona przy pomocy sieci neuronowych charakterystyka mocy dla $T < 5^{\circ}C$ i $T > 15^{\circ}C$, b) różnica mocy elektrowni dla obu przypadków względem mocy zainstalowanej


Na rysunku 3.42 przedstawiono dwie charakterystyki mocy będące odpowiedzią sieci neuronowej dla niskich ($T < 5^{\circ}C$) oraz wysokich temperatur ($T > 15^{\circ}C$).

Na rysunkach 3.43-3.44 zamieszczono analogicznie jak w poprzednim przypadku dwie charakterystyki mocy odpowiednio dla elektrowni wiatrowej FW3 i FW4.

Jak wynika z tabeli 3.7 oraz rysunków 3.42-3.44 temperatura wpływa na kształt charakterystyki mocy elektrowni wiatrowej. W przypadku elektrowni wiatrowej FW3 największa różnica występuje dla prędkości wiatru 9,4 m/s i wynosi 1,63 MW. Stanowi to ponad 8% mocy zainstalowanej elektrowni wiatrowej. Dla farm wiatrowych FW1 i FW4 różnice rosną wraz ze wzrostem prędkości wiatru i sięgają nawet 10-15% zainstalowanej mocy elektrowni.




Rysunek 3.43: Elektrownia FW3 - a) Wyznaczona przy pomocy sieci neuronowych charakterystyka mocy dla $T < 5^{\circ}C$ i $T > 15^{\circ}C$, b) różnica mocy elektrowni dla obu przypadków względem mocy zainstalowanej



Rysunek 3.44: Elektrownia FW4 - a) Wyznaczona przy pomocy sieci neuronowych charakterystyka mocy dla $T < 5^{\circ}C$ i $T > 15^{\circ}C$, b) różnica mocy elektrowni dla obu przypadków względem mocy zainstalowanej

3.2.2 Wpływ ciśnienia atmosferycznego na pracę elektrowni

Analizę wpływu ciśnienia atmosferycznego wykonano w identyczny sposób jak dla temperatury. Ze względu na posiadane dane badania wykonano dla jednej farmy wiatrowej FW1. Wyodrębniono dwa zbiory danych. W pierwszym umieszczono dane związane z ciśnieniem mniejszym od 997 hPa, a w drugim dane związane z ciśnieniem większym od 1018 hPa. Wybór granicznych ciśnień zorganizowano w taki sposób, aby uzyskać zbiory o podobnej liczebności umożliwiające odtworzenie charakterystyki mocy. Dla otrzymanych dwóch zbiorów danych zbudowano modele sieci neuronowych (rys. 3.41). Zaproponowano modele neuronowe o takiej samej strukturze jak dla analizy wpływu temperatury otoczenia na pracę elektrowni, odtwarzające charakterystykę mocy elektrowni. Wyniki uczenia sieci przedstawiono na rysunku 3.45.




Rysunek 3.45: a) Charakterystyka mocy dla elektrowni FW1 ($p < 997hPa$ i $p > 1018hPa$), b) różnica mocy elektrowni dla obu przypadków względem mocy zainstalowanej

Współczynnik korelacji ciśnienia i mocy dla elektrowni wiatrowej jest równy -0,24 (Tabela 3.7), może to świadczyć o blisko dwukrotnie większym wpływie tego czynnika


niż w przypadku temperatury. W rzeczywistości wpływ ten może nie być aż tak istotny, z powodu proporcjonalnie małych zmian ciśnienia w ciągu roku (ciśnienie zmieniało się w zakresie od 982 do 1035 hPa). Średnie ciśnienie w analizowanym okresie prawie dwóch lat wynosiło 1012 hPa, co przy różnicy maksymalnego i minimalnego ciśnienia wynoszącej 53 hPa daje zmiany wartości na poziomie zaledwie 5%. Przedstawione wyniki nie potwierdzają znaczącego wpływu ciśnienia atmosferycznego na kształt charakterystyki mocy elektrowni.

3.2.3 Wpływ kierunku wiatru na pracę elektrowni wiatrowej

Wyodrębniono osiem zbiorów danych, w których kierunek wiatru zmieniał się co 45°. Analizę przeprowadzono w identyczny sposób jak w poprzednich przypadkach. Wyniki uczenia sieci dla elektrowni wiatrowych FW1 oraz FW3 przedstawiono na rysunkach 3.46-3.47.



Rysunek 3.46: Elektrownia FW1 - a) Charakterystyka mocy elektrowni FW1 dla kierunków wiatru w przedziałach co 45 stopni, b) różnica generowanej mocy dla wybranych kierunków wiatru względem mocy zainstalowanej



Rysunek 3.47: Elektrownia FW3 - a) Charakterystyka mocy elektrowni FW3 dla kierunków wiatru w przedziałach co 45 stopni, b) różnica generowanej mocy dla wybranych kierunków wiatru względem mocy zainstalowanej

Analizując wykresy z rysunku 3.46, można zauważyć, że w przedziale prędkości od 3 do 8 m/s rozbieżności są małe, nieprzekraczające 0,5 MW. Przy większych prędkościach zwiększają się do ponad 1 MW. Nieco większe różnice widoczne są w przypadku farmy wiatrowej FW3 (Rysunek 3.47) jednak może to być spowodowane zbyt małym zbiorem uczącym dla wybranych kierunków, co uniemożliwiło uzyskanie pełnego zakresu zmienności prędkości wiatru i mocy (na potrzeby budowania charakterystyki mocy).

Jak można zauważyć na rysunku 3.28 dominującymi są kierunki północny oraz północno-wschodni, w pozostałych kierunkach zmienność prędkości wiatru jest mała.

Dla badanego zbioru danych trudno wyróżnić trend wskazujący na wpływ kierunku wiatru na przebiegi charakterystyk mocy. W całym badanym zakresie charakterystyki się przeplatają i nie można wyróżnić jednej dominującej lub odstającej od pozostałych.

Podobnych informacji dostarcza analiza korelacyjna (Tabela 3.7), w której współ-

czynniki dla kierunku wiatru wynoszą 0,05-0,14. W Tabeli 3.8 zamieszczono wyznaczone współczynniki w rozbiciu na poszczególne kierunki wiatru. Współczynnik korelacyjny dla kierunku wiatru i mocy po podziale na 8 zakresów kątowych zmienia się w zakresie od -0,19 do 0,1 co może świadczyć o braku korelacji pomiędzy tymi parametrami.

Tabela 3.8: Współczynnik korelacji Pearsona - kierunek wiatru/moc elektrowni FW3*

| Kierunek wiatru [°] | Współczynnik korelacji | Liczebność zbioru |
|---------------------|------------------------|-------------------|
| 0-45 | 0,04 | 6167 |
| 45-90 | 0,10 | 13863 |
| 90-135 | 0,10 | 13901 |
| 135-180 | 0,09 | 10297 |
| 180-225 | -0,03 | 16317 |
| 225-270 | -0,03 | 20823 |
| 270-315 | -0,19 | 13018 |
| 315-360 | -0,03 | 5475 |

* - Współczynniki zamieszczone w tabeli zostały wyznaczone na podstawie zgromadzonych danych dla elektrowni wiatrowej FW3 zgodnie z rysunkiem 3.3.

3.3 Elektrownia fotowoltaiczna

Panel fotowoltaiczny składa się z wielu pojedynczych ogniw połączonych ze sobą szeregowo lub/i równolegle w celu otrzymania nominalnego napięcia wyjściowego i/lub prądu. W ogniwie fotowoltaicznym energia promieniowania słonecznego przekształcana jest na energię elektryczną, przy wykorzystaniu półprzewodnikowego złącza typu p-n. Do ogniwa docierają fotony, o energii większej niż szerokość przerwy energetycznej półprzewodnika. Elektrony przemieszczają się do obszaru n, natomiast w obszarze p pozostają dziury. W wyniku tego zjawiska na stykach wyjściowych powstaje różnica potencjałów. Energia fotonu jest wprost proporcjonalna do częstotliwości promieniowania, a zależność tę można przedstawić jako [77]:

$$E = hv \quad (3.7)$$

gdzie: h – stała Plancka ($h = 6,626 \cdot 10^{-34} [\text{J} \cdot \text{s}]$), v – częstotliwość promieniowania [Hz]

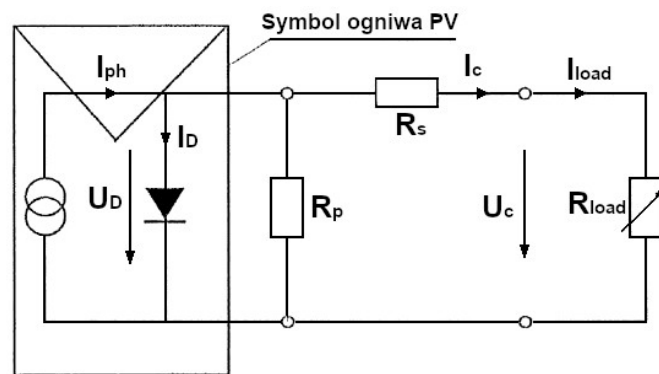
$$v = \frac{c}{\lambda} \quad (3.8)$$

gdzie:

c – prędkość rozchodzenia się światła w próżni ($c = 2,998 \cdot 10^8$ [m/s]),

λ - długość fali promieniowania [m].

W nocy lub przy znacznym zachmurzeniu, gdy do ogniwa nie dociera wystarczająca ilość światła zachowuje się ono jak dioda. Jeżeli strumień promieniowania słonecznego zwiększy się, ogniwo zaczyna działać podobnie jak źródło prądu elektrycznego. Na rysunku 3.48 przedstawiono schemat elektryczny ogniwa fotowoltaicznego:



Rysunek 3.48: Schemat elektryczny układu równoważnego do ogniwa PV [77]

Prąd ogniwa w uproszczeniu można wyrazić jako [77]:

$$I_c = I_{ph} - I_0 \left[\exp\left(\frac{q}{\sigma \cdot T_c} (U_c - I_c \cdot R_s)\right) - 1 \right] - \frac{U_c + I_c \cdot R_s}{R_p} \quad (3.9)$$

gdzie:

R_s - rezystancja szeregową $[\Omega]$,

R_p - rezystancja równoległa $[\Omega]$,

R_{load} - rezystor nastawny obciążający,

q - ładunek elektronu ($q = 1,60219 \cdot 10^{-19}$ [J]),

I_D - prąd tak zwanej "ciemnej" diody [A],

I_c - prąd pojedynczego ogniwa [A],

U_c - napięcie pojedynczego ogniwa [V],

T_c - temperatura ogniwa [K],

σ - stała Stefana Boltzmanna.

Moc panela fotowoltaicznego można opisać wzorem [78]:

$$P_{PF} = U_M \cdot I_M = N_M \cdot U_c \cdot I_c = N_M \cdot \left(\ln \left(1 - \frac{I_c}{C_1 \cdot G} \right) U_c^t + U_c^{OC0} + C_3 (v + C_2 \cdot G - T_c^0) - R_s \cdot I_c \right) I_c \quad (3.10)$$

gdzie:

- U_M - napięcie panela fotowoltaicznego [V],
- I_M - prąd panela fotowoltaicznego [A],
- N_M - liczba ogniw fotowoltaicznych,
- U_c - napięcie pojedynczego ogniwa [V],
- G - natężenie promieniowania słonecznego [W/m^2],
- U_c^t - napięcie generacji termicznej [V],
- U_c^{OC0} - napięcie jałowe ogniwa w warunkach standardowych [V],
- v - temperatura powietrza [$^{\circ}\text{C}$],
- T_c^0 - temperatura ogniwa (warunki standardowe),
- C_1, C_2, C_3 - stałe.

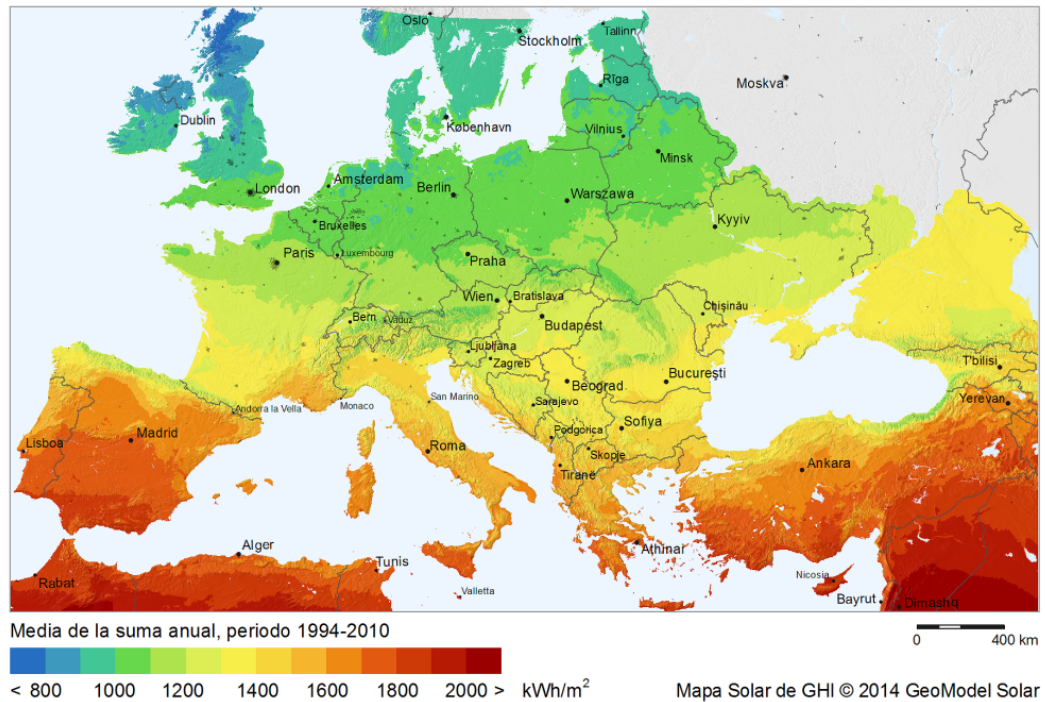
Praca ogniwa fotowoltaicznego zależna jest przede wszystkim od takich parametrów jak:

- natężenie promieniowania słonecznego – G [W/m^2] i usłonecznienie – h [godziny] lub inaczej nasłonecznienie (napromieniowanie) – H [J/m^2],
- temperatura ogniwa,
- geometria układu słońce-panel PV.

Wzrost temperatury ma wpływ na obniżenie napięcia obwodu otwartego ogniwa fotowoltaicznego. Dzieje się tak przy małym wzroście prądu zwarcia, co ma bezpośredni wpływ na zmniejszenie mocy ogniwa. Przyjmuje się, że jest to około 0,4% mocy na 1 [$^{\circ}\text{C}$] [79]. Zjawisko to spowodowane jest zwiększeniem prądu wstecznego będącego wynikiem samoistnej generacji par elektron-dziura. Temperatura ogniwa zależna jest od takich czynników jak:

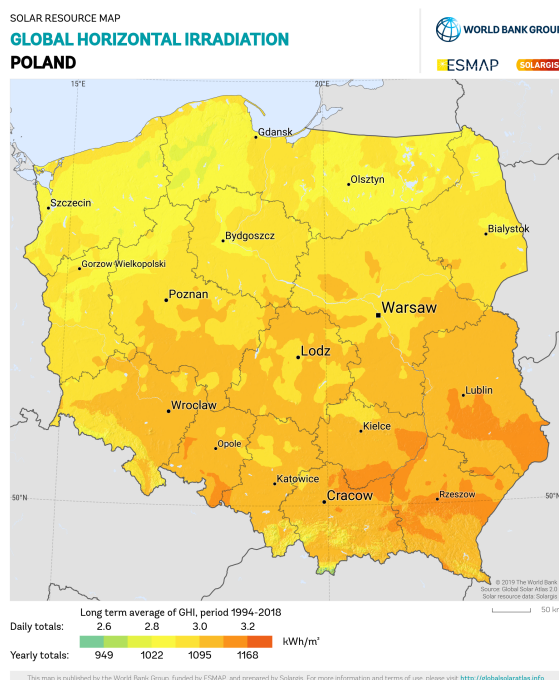
- temperatura powietrza,
- wilgotność,
- wietrzność,
- możliwość odprowadzania ciepła.

Dominującym czynnikiem wpływającym na wielkość produkcji energii paneli fotowoltaicznych jest nasłonecznienie. Jak wynika z rysunku 3.49 jest ono silnie zróżnicowane na terenie Europy. Największe wartości występują w części południowej tj. Hiszpanii, Portugalii, Włoszech oraz Grecji.

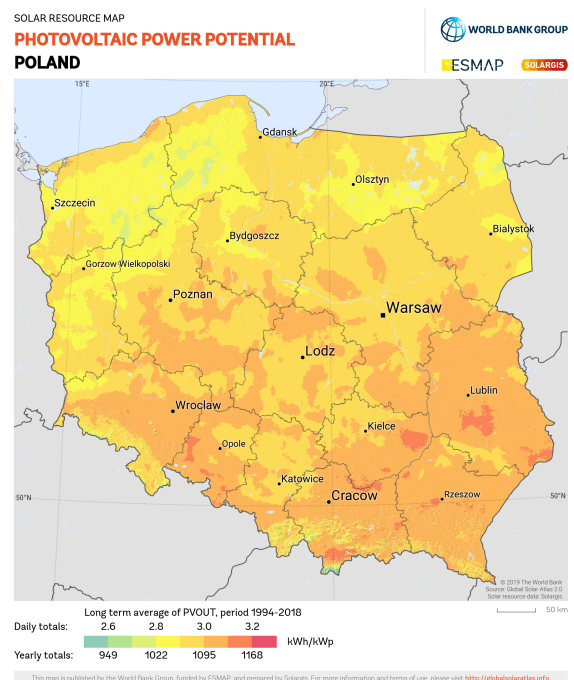


Rysunek 3.49: Europa - średnie nasłonecznienie w latach 1994-2010 [80]

Na rysunkach 3.50-3.51 przedstawiono średnie nasłonecznienie oraz potencjał energetyczny elektrowni fotowoltaicznych dla Polski oraz Grecji. W Polsce nasłonecznienie w zależności od regionu wynosi 949-1168 kWh/m², w Grecji jest zdecydowanie wyższe i mieści się w zakresie 1168-1899 kWh/m². Podobnie jest w przypadku potencjału energetycznego - dla Polski 949-1168 kWh/kWp, - dla Grecji 1314-1753 kWh/kWp.

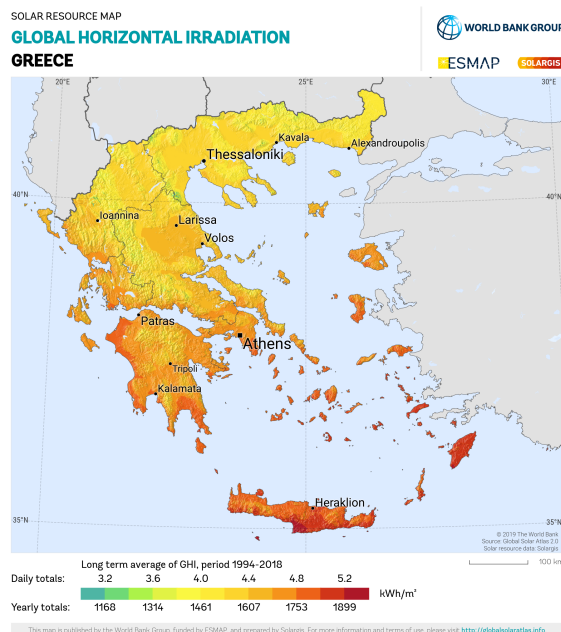


(a) Nasłonecznienie



(b) Potencjał energetyczny PV

Rysunek 3.50: Nasłonecznienie oraz potencjał energetyczny PV - Polska [80]



(a) Nasłonecznienie



(b) Potencjał energetyczny PV


Rysunek 3.51: Nasłonecznienie oraz potencjał energetyczny PV - Grecja [80]

3.3.1 Elektrownia fotowoltaiczna PV1

Elektrownia fotowoltaiczna zlokalizowana jest na terenie Krakowa (Rysunek 3.2, 3.52). W skład elektrowni wchodzi 240 paneli polikrystalicznych (SL280) o maksymalnej mocy 280 Wp oraz 4 inwertery SMA 15000 TL o mocy znamionowej 15 kW (3.53)[10]. Moc zainstalowana elektrowni to 60 kWp. Zgodnie z danymi producenta sprawność paneli fotowoltaicznych wynosi 14,43%, napięcie otwartego obwodu to 36,98 V, a prąd zwarciovowy 7,57 A. Panele zamontowano na wolno stojącym stelażu aluminiowym o nachyleniu 30 stopni. Elektrownia składa się z czterech rzędów takiej konstrukcji, na których zamontowano po 60 paneli. Rysunek 3.53 przedstawia schemat elektryczny połączeń elektrowni fotowoltaicznej.




Rysunek 3.52: Elektrownia fotowoltaiczna PV1 [74]



Rysunek 3.53: Schemat elektryczny elektrowni fotowoltaicznej PV1

Na rysunku 3.54 przedstawiono charakterystyki napięciowo-prądowe zainstalowanego w elektrowni ogniwa fotowoltaicznego dla przykładowych wartości promieniowania słonecznego. Jak widać ilość produkowanej energii jest silnie zależna od natężenia promieniowania słonecznego. Nie jest to jednakże jedyny czynnik mający wpływ na moc ogniwa co zostało opisane w rozdziale 3.4.




Rysunek 3.54: Charakterystyki napięciowo-prądowe dla natężenia promieniowania słonecznego odpowiednio 1000, 800, 500, 200 [W/m^2] [81]


W najbliższej okolicy elektrowni na maszcie zamontowano stację pogodową Vantage Pro2 Plus [82], która umożliwia gromadzenie rzeczywistych danych meteorologicznych w jakich pracowała elektrownia. Stacja rejestruje następujące parametry: natężenie promieniowania słonecznego, promieniowanie UV, temperaturę, prędkość wiatru, ciśnienie atmosferyczne, wilgotność powietrza, wielkość opadów. Umożliwia agregację danych i zapis w nieulotnej pamięci urządzenia, a także zdalny odczyt oraz pobranie danych bezpośrednio z miernika. Stacja meteorologiczna uśrednia dane w okresach 30 minutowych. Dane elektryczne takie jak prądy, napięcia, moce oraz inne wskaźniki jakości energii elektrycznej agregowano z interwałem 10 minutowym. W ich skład wchodziła również średnia moc elektrowni fotowoltaicznej będąca wartością wyjściową sieci neuronowej na etapie budowy, testowania i weryfikacji. Ponieważ modele prognostyczne wymagają dostarczenia zarówno danych meteorologicznych jak i mocy, konieczne jest ujednoczenie okresu ich uśredniania. W tym celu zastosowano interpolację danych pogodowych rzeczywistych oraz prognozowanych do okresu 10-minutowego, dla którego rejestrowana była moc czynna farmy fotowoltaicznej. Na potrzeby pracy przygotowano zbiór długookresowych danych zawierający zmierzone dane pogodowe oraz elektryczne, a także prognozowane dane pogodowe pochodzące z dwóch niezależnych źródeł - Instytutu Meteorologii i Gospodarki Wodnej (IMiGW) oraz portalu pogodowego Weather Underground (WU). Po połączeniu otrzymano zbiór składający się ze zmierzonych danych takich jak: moc czynna, natężenie promieniowania słonecznego, temperatura, prędkość i kierunek wiatru, wilgotność oraz prognozowanych danych pogodowych: temperatura otoczenia oraz punktu rosy, zachmurzenie, prędkość i kierunek wiatru, wilgotność, ciśnienie dla okresu od 09.06.2016 r. do 19.02.2018 r. W celu oceny prawidłowości prognoz pogody wyznaczono średnie (4.11), średnie absolutne (MAE) (4.12), oraz znormalizowane średnie absolutne (NMAPE) (4.19) błędy prognoz.

Na rysunkach 3.55-3.67 przedstawiono zmienność czynników meteorologicznych w czasie od 16.8.2016 23:20 do 22.9.2016 5:40 (5000 wektorów 10-minutowych danych). Na rysunku 3.55 zaprezentowano przebieg natężenia promieniowania słonecznego, rysunek 3.57 przedstawia błędy prognoz pogody względem zarejestrowanych lokalnie danych.


W analizowanym okresie maksymalne średnie 10-minutowe natężenie promieniowania słonecznego wynosiło $972 [W/m^2]$, średnia wartość to około $117 [W/m^2]$. W Tabeli 3.9 zestawiono minimalne, maksymalne oraz średnie wartości najważniejszych czynników meteorologicznych występujących w najbliższym otoczeniu elektrowni fotowoltaicznej.




Rysunek 3.55: Natężenie promieniowania słonecznego - dane zmierzone oraz prognozowane elektrowni PV1



Rysunek 3.56: Natężenie promieniowania słonecznego - dane zmierzone oraz prognozowane elektrowni PV1 - 1 tydzień



Rysunek 3.57: Natężenie promieniowania słonecznego - Błąd prognozy (Model IMiGW oraz WU) względem danych pomiarowych PV1

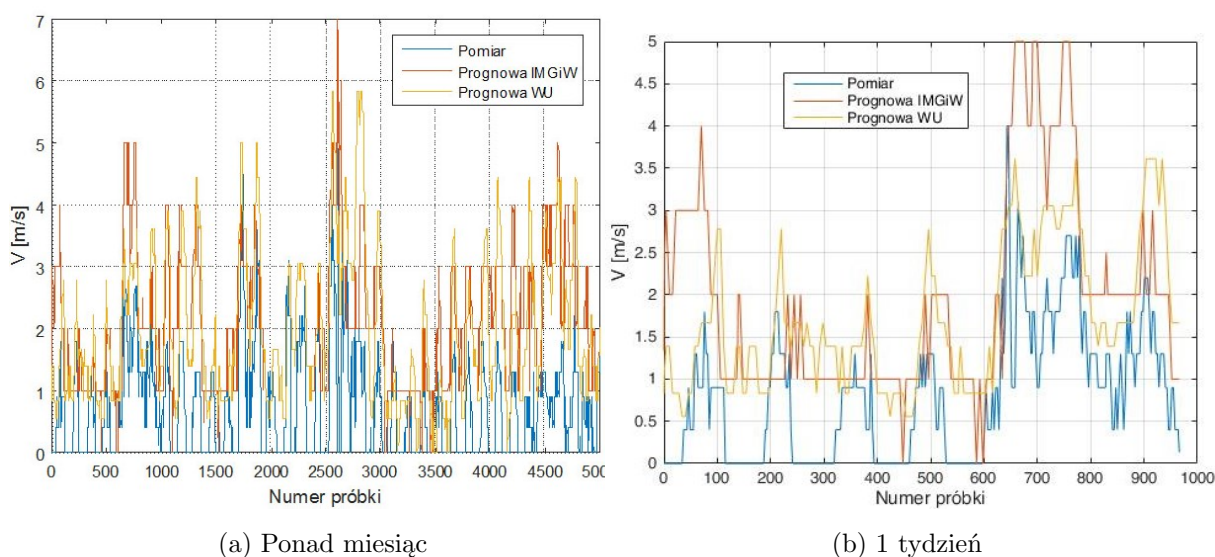


Rysunek 3.58: Natężenie promieniowania słonecznego - Błąd prognozy (Model IMiGW oraz WU) względem danych pomiarowych PV1 - 1 tydzień


Tabela 3.9: Zestawienie teoretycznych/deklarowanych oraz średnich parametrów charakterystycznych dla analizowanej elektrowni fotowoltaicznej

| | Wartość teoretyczna / deklarowana | Elektrownia PV | | |
|--|--------------------------------------|----------------|-------|-------|
| | | Min. | Śr. | Max. |
| Natężenie promieniowania słonecznego [W/m ²] | 125,57 | 0 | 117 | 972 |
| Prędkość wiatru [m/s] | 4-5 (10 m.n.p.g.) | 0 | 1,9 | 20,9 |
| Temperatura otoczenia [°C] | 8-9 | -11,7 | 12,23 | 37,9 |
| Ciśnienie atmosferyczne [hPa] | 1013,25 | 982,7 | 1016 | 1036 |
| Wilgotność [%] | 80 | 23 | 78,87 | 99 |
| Moc [kW] | 60 | 0 | 7,78 | 39,54 |


Rysunki 3.59-3.60 przedstawiają porównanie dokładności prognoz prędkości wiatru w miejscu elektrowni PV1. Porównano dane zarejestrowane przez stację pogodową oraz udostępnione przez IMiGW i portal pogodowy Weather Underground. Rzeczywiste pomiary były średnio mniejsze o około 1,0 [m/s] od prognoz, co może być spowodowane umieszczeniem wiatromierza na wysokości około 3 metrów od poziomu gruntu.



Rysunek 3.59: Prędkość wiatru - dane zmierzone oraz prognozowane PV1




Rysunek 3.60: Prędkość wiatru - Błąd prognozy (Model IMiGW i WU) względem danych zmierzonych elektrowni PV1




Rysunek 3.61: Prędkość wiatru - Błąd prognozy (Model IMiGW i WU) względem danych zmierzonych PV1 - 1 tydzień


Na rysunkach 3.62-3.67 zaprezentowano zarejestrowane oraz prognozowane wartości temperatury oraz wilgotności dla elektrowni fotowoltaicznej PV1. Porównując dane zarejestrowane przez stację pogodową oraz wygenerowane przez IMiGW oraz portal pogody Weather Underground można zauważyć pewne zależności. Rzeczywiste pomiary były średnio mniejsze o około $1,0 [m/s]$, co może być spowodowane umieszczeniem wiatromieryza na wysokości około 3 metrów od poziomu gruntu.




Rysunek 3.62: Temperatura - dane zmierzone oraz prognozowane elektrowni PV1



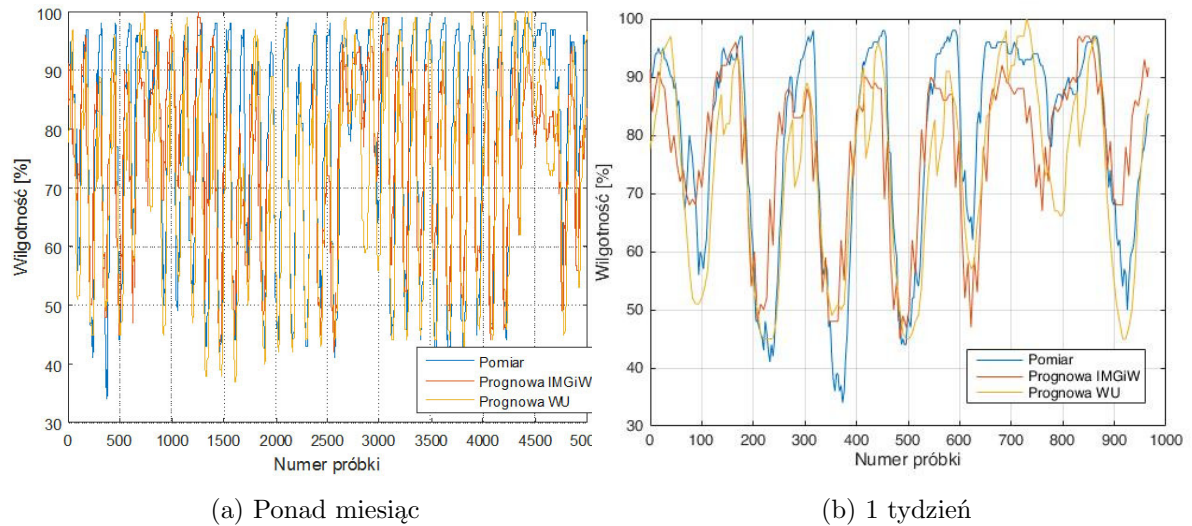
Rysunek 3.63: Temperatura - dane zmierzone oraz prognozowane elektrowni PV1 - 1 tydzień



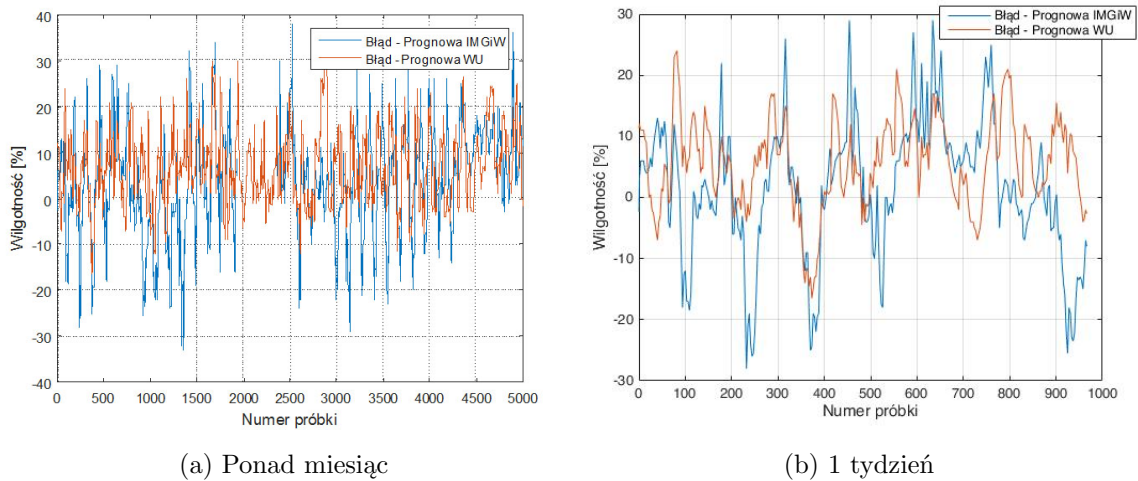
Rysunek 3.64: Temperatura - Błąd prognozy (Model IMiGW i WU) PV1



Rysunek 3.65: Temperatura - Błąd prognozy (Model IMiGW i WU) - elektrownia PV1 - 1 tydzień




Rysunek 3.66: Wilgotność - dane zmierzone oraz prognozowane PV1




Rysunek 3.67: Wilgotność - Błąd prognozy (Model IMiGW oraz WU) PV

Rysunek 3.68 przedstawia przebieg zagregowanej mocy czynnej 10-minutowej w funkcji czasu dla elektrowni fotowoltaicznej o mocy zainstalowanej 60 [kWp]. Widoczna jest okresowa zmienność mocy w czasie. Linia przerywaną zaznaczono przykładowy dzień, który poddano dalszej analizie. W analizowanym okresie maksymalna średnia 10-minutowa moc elektrowni wyniosła 39,54 [kW], natomiast moc średnia 6,73 [kW].

Wielkość produkcji jest silnie uzależniona od pory dnia oraz od warunków meteorologicznych takich jak promieniowanie słoneczne, zachmurzenie, temperatura otoczenia, prędkość wiatru (chłodzenie ogni, szybkość przemieszczania się zachmurzenia) oraz wilgotność. Rysunek 3.69 przedstawia zmienność mocy w czasie dla dnia słonecznego (01.09.2016 r. - dane 10-minutowe).




Rysunek 3.68: Elektrownia fotowoltaiczna PV1: Przykładowy przebieg średniej mocy w funkcji czasu (czas uśredniania - 10 min)




Rysunek 3.69: Moc elektrowni fotowoltaicznej PV1 – dzień słoneczny - zaznaczony linią przerywaną na rysunku 3.68 - dzień 01.09.2016 r. (czas uśredniania - 10 min)

Jest ona charakterystyczna dla tego obiektu i paneli fotowoltaicznych zainstalowanych na nieruchomej konstrukcji ze stałym kątem nachylenia. Zdecydowanie większa zmienność produkcji występuje w dni pochmurne. Na rysunkach 3.70-3.71 przedstawiono zmienność mocy elektrowni PV1 w dniach z przelotnym zachmurzeniem oraz pochmurnego.



Rysunek 3.70: Moc elektrowni fotowoltaicznej PV1 – dzień z przelotnymi zachmurzeniami - dzień 02.09.2016 r. (czas uśredniania - 10 min)



Rysunek 3.71: Moc elektrowni fotowoltaicznej PV1 – dzień pochmurny - dzień 03.10.2016 r. (czas uśredniania - 10 min)

3.3.2 Elektrownia fotowoltaiczna PV2

Elektrownia fotowoltaiczna PV2¹¹ zlokalizowana jest w Centre for Renewable Energy Sources and Saving (CRESS) na obszarze Attyki w Grecji (Rysunek 3.72).




Rysunek 3.72: Elektrownia fotowoltaiczna PV2 [83]

Panele zgrupowane zostały w trzy obszary: CRES-4 (90 paneli SF115A o nachyleniu 30° i azymucie 22° SW), CRES-5 (64 paneli Conergy 105L o nachyleniu 45° i azymucie 0° S), CRES-6 (48 paneli Conergy 105L o nachyleniu 90° i azymucie 22° SW) - łącznie 202 panele. Moc zainstalowana elektrowni to 22,11 kWp. Sprawność zainstalowanych paneli fotowoltaicznych SF115A/105L wynosi odpowiednio 11/12,29%, krzem polikrystaliczny/monokrystaliczny, napięcie otwartego obwodu to 21.3/21,6 V, prąd zwarcia 7,55/6,5 A, a moc jednostkowa paneli 115/105 Wp. Panele zamontowano na nieruchomych stelażach. Rysunek 3.73 przedstawia schemat elektryczny połączeń elektrowni fotowoltaicznej. Wszystkie panele Conergy 105L zostały przyłączone do sieci przy pomocy przekształtników jednofazowych.

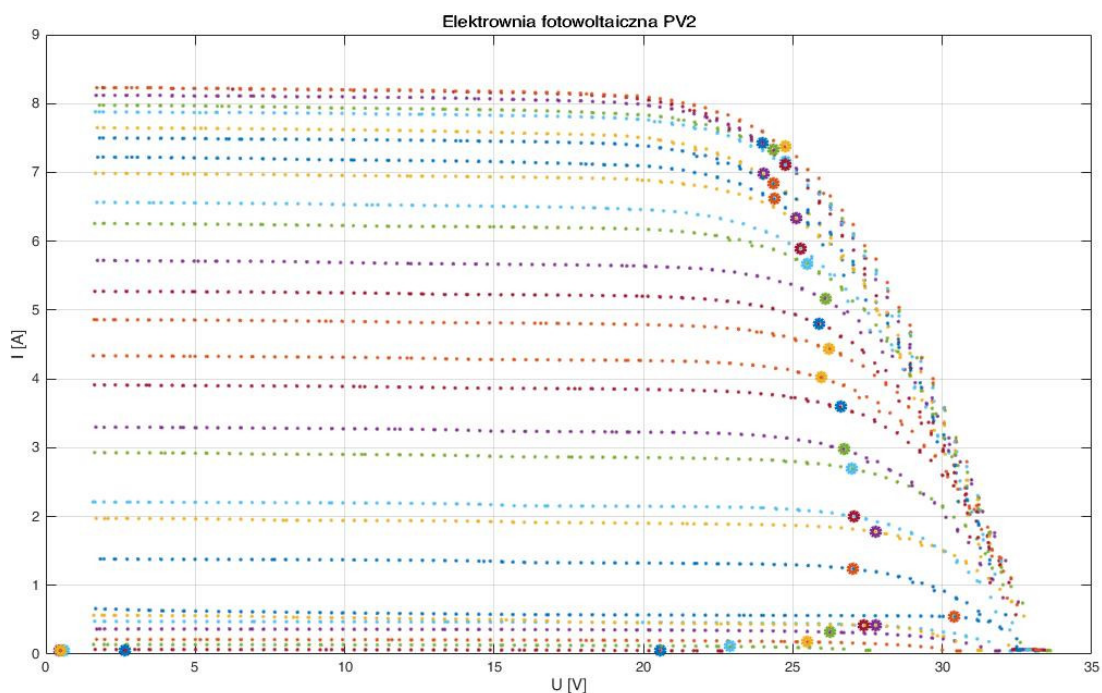
W ramach elektrowni szczegółowo badano panele fotowoltaiczne wykorzystane do budowy elektrowni fotowoltaicznej PV2. Zarejestrowano dla nich charakterystyki napięciowo-prądowe składające się z 150 punktów pracy oraz 1 minutową częstotliwością rejestracji. Tego typu pomiar pozwala na rzeczywiste oszacowanie mocy paneli w zależności od chwilowego nasłonecznienia. Pomiar nie jest obciążony błędem wynikającym z nieoptymalnego wyboru punktu pracy falownika.

¹¹Prezentowane dane dla elektrowni PV2 zostały pozyskane przez autora pracy podczas wizyty w CRESS w ramach projektu ERIGrid - European Research Infrastructure supporting Smart Grid. Projekt miał na celu udostępnienie know-how i dobrych praktyk w zakresie użytkowania oraz zarządzania systemami inteligentnych sieci i rozproszonych zasobów energii.



Rysunek 3.73: Schemat elektryczny elektrowni fotowoltaicznej PV2

Na rysunku 3.74 zaprezentowano wybrane charakterystyki napięciowo-prądowe wraz z zaznaczonym optymalnym punktem pracy. Przedstawia on jak ze zmianą natężenia promieniowania słonecznego falownik poszukuje maksymalnej mocy jaką jest w stanie pozyskać z przyłączonych do niego dwóch połączonych szeregowo paneli SF115A.



Rysunek 3.74: Zarejestrowane charakterystyki napięciowo-prądowe dwóch paneli SF115A z dnia 27.04.2018

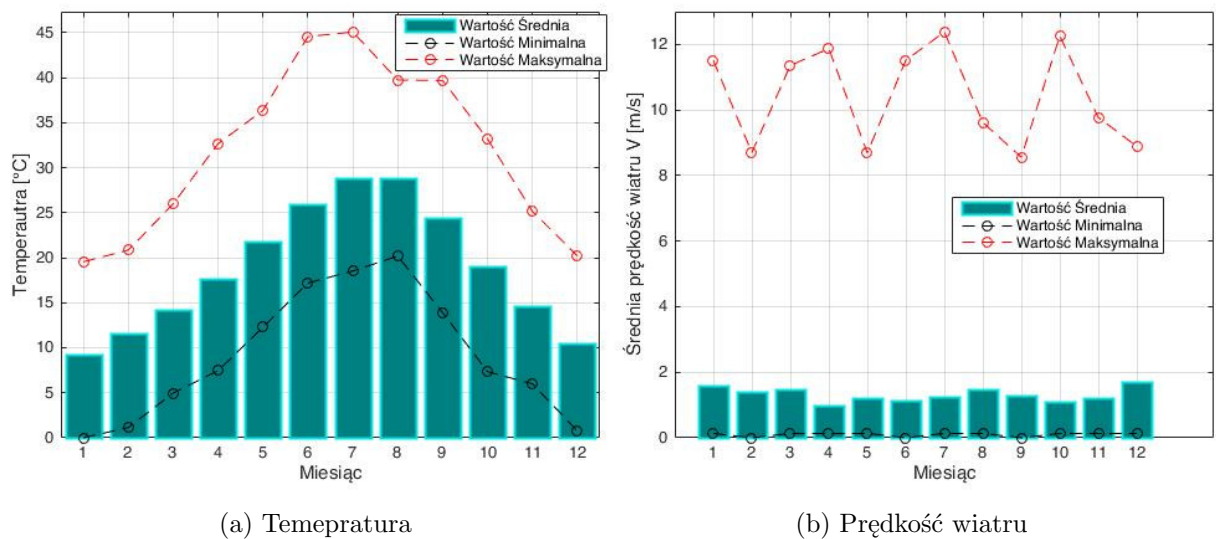
Znalezienie punktu pracy falownika dla badanych paneli wymagało przeprowadzenia procedury testowej sprawdzającej moc dla 150 punktów (rysunek 3.74) z częstotliwością

1/15 Hz. Dla wybranego dnia 27.04.2018 przygotowano zestawienie zmienności mocy w zależności od natężenia promieniowania słonecznego i zaprezentowano je w Tabeli 3.10.

Tabela 3.10: Zmienność maksymalnej mocy w funkcji natężenia promieniowania słonecznego dla testowanych dwóch paneli SF115A wykorzystanych do budowy elektrowni PV2


| Irr | [W/m ²] | 20 | 72 | 290 | 399 | 510 | 621 | 724 | 825 | 902 | 989 | 1023 | 1025 |
|-----|---------------------|------|------|------|-----|------|------|------|------|------|------|------|------|
| P | [W] | 5 | 17 | 49 | 73 | 96 | 116 | 135 | 149 | 161 | 177 | 178 | 182 |
| U | [V] | 25,5 | 30,4 | 27,8 | 27 | 26,6 | 26,2 | 26,1 | 25,3 | 24,4 | 24,8 | 24 | 24,7 |
| I | [A] | 0,2 | 0,5 | 1,8 | 2,7 | 3,6 | 4,4 | 5,2 | 5,9 | 6,6 | 7,2 | 7,4 | 7,4 |

Na rysunkach 3.75a i b przedstawiono warunki pracy elektrowni fotowoltaicznej, w tym prędkości wiatru oraz temperatury. Najniższe temperatury występują w miesiącach grudniu oraz styczniu dla których minimalna temperatura spada do wartości bliskich 0 °C. Rysunki 3.76a i b przedstawiają natężenie promieniowania słonecznego oraz moc dla poszczególnych miesięcy.




Rysunek 3.75: Warunki pracy elektrowni fotowoltaicznej PV2

Pomimo zlokalizowania elektrowni w południowej części Europy warunki meteorologiczne oraz elektryczne różnią się od siebie dla poszczególnych miesięcy. Rysunki 3.77-3.78 przedstawiają zależność mocy panela od natężenia promieniowania słonecznego (wartości zmierzone).




(a) Natężenie promieniowania słonecznego




(b) Moc panela fotowoltaicznego


Rysunek 3.76: Wartości minimalne, średnie oraz maksymalne dla poszczególnych miesięcy - 2 panele SF115A




(a) Styczeń




(b) Luty




(c) Marzec



(d) Kwiecień




(e) Maj




(f) Czerwiec


Rysunek 3.77: Zależność mocy od natężenia promieniowania słonecznego - 2 panele SF115A - I półrocze




(a) Lipiec




(b) Sierpień




(c) Wrzesień



(d) Październik



(e) Listopad




(f) Grudzień

Rysunek 3.78: Zależność mocy od natężenia promieniowania słonecznego - 2 panele SF115A - II półrocze


Na rysunkach 3.77-3.78 można zauważyć, że charakterystyki nie są liniowe. Może być to spowodowane uwzględnieniem jedynie oddziaływania natężenia promieniowania słonecznego na moc, z pominięciem innych czynników meteorologicznych wpływających na sprawność paneli. Widoczna jest również zbliżona do liniowej koncentracja punktów wzdłuż dwóch lub więcej prostych, co może wynikać z faktu montażu paneli oraz pyrometru w nieco innej lokalizacji. Najbardziej zbliżone do liniowych są charakterystyki zarejestrowane w miesiącu Listopadzie oraz Grudniu. Charakteryzują się one mniejszym od pozostałych natężeniem promieniowania słonecznego oraz mocami.

Zmienność średniej wartości mocy dla poszczególnych godzin zaprezentowano na rysunku 3.79 dla okresu ponad dwóch lat (24.06.2016-08.02.2019 - rejestracja co 1 minutę).




Rysunek 3.79: Moc panela fotowoltaicznego elektrowni PV2 dla poszczególnych godzin

Zmienność mocy trójfazowej oraz w poszczególnych fazach elektrowni fotowoltaicznej PV2 dla dnia słonecznego zaprezentowano na rysunku 3.80. Można na nim zaobserwować przesunięcie w czasie maksimum produkcji dla fazy L1 oraz L2/L3. Jest ono spowodowane różną orientacją paneli fotowoltaicznych względem kierunku południowego oraz zastosowaniem falowników jednofazowych. Dla porównania na rysunku 3.81 przedstawiono zmienność produkcji w dzień z przelotnymi zachmurzeniami.



Rysunek 3.80: Moc elektrowni fotowoltaicznej PV2 - dzień słoneczny - 19.02.2019 r. (czas uśredniania - 1 min)



Rysunek 3.81: Moc elektrowni fotowoltaicznej PV2 - dzień z przelotnymi zachmurzeniami - 21.02.2019 r. (czas uśredniania - 1 min)

3.4 Badanie wpływu czynników zewnętrznych na pracę elektrowni fotowoltaicznej

Na rynku najbardziej popularne są dwa typy paneli fotowoltaicznych: monokrystaliczne i polikrystaliczne. Różnice w ilości produkcji energii w znacznym stopniu zależą od tego jaki typ ogniw zastosowano. Do pozostałych czynników można zaliczyć sposób montażu: statyczne lub dynamiczne ustawienie paneli (Trackery), konfigurację połączeń poszczególnych paneli i ogniw fotowoltaicznych w ich wnętrzu.

Produkcja energii elektrycznej przez elektrownię fotowoltaiczną uzależniona jest w dominującym stopniu od chwilowego natężenia promieniowania słonecznego. Jednak nie jest to jedyny czynnik mający wpływ na ilość wytwarzanej energii. Dodatkowe czynniki można podzielić na trzy grupy: meteorologiczne, lokalizacyjne oraz techniczne. Do czynników meteorologicznych zalicza się wilgotność, ciśnienie, prędkość wiatru oraz temperaturę. Czynniki lokalizacyjne to przede wszystkim długość i szerokość geograficzna oraz zasłanianie ogniw przez obiekty zlokalizowane w pobliżu.

Poniżej analizie poddano wpływ wybranych czynników pogodowych na pracę elektrowni fotowoltaicznej.

Analizie poddano zbiór zawierający zarejestrowane dane takie jak moc generowana, natężenie promieniowania słonecznego, temperatura, prędkość i kierunek wiatru, wilgotność powietrza, jego ciśnienie atmosferyczne dla okresu od 09.06.2015 r. do 19.02.2018 r.

Tabela 3.11 prezentuje współczynnik zależności liniowej między czynnikami pogodowymi odniesionymi do mocy elektrowni.

Tabela 3.11: Współczynnik korelacji Pearsona - warunki meteorologiczne/moc elektrowni PV1

| Czynnik meteorologiczny | Współczynnik korelacji |
|--|------------------------|
| Wilgotność | -0,56 |
| Kierunek wiatru [°] | -0,02 |
| Ciśnienie [hPa] | 0,02 |
| Prędkość wiatru [m/s] | 0,19 |
| Temperatura [°C] | 0,48 |
| Natężenie promieniowania słonecznego [W/m ²] | 0,89 |


Jak wynika z tabeli 3.11 największe współczynniki korelacji występują dla promieniowania słonecznego ($r=0,89$), wilgotności (zależność jest ujemna $r=-0,56$), temperatury ($r=0,48$) oraz prędkości wiatru ($r=0,19$).

Analogicznie jak w podrozdziale 3.2 dane podzielono na dwa zbiory:

- wilgotność ($< 40\%$ oraz $> 90\%$),
- temperatura ($< 3^{\circ}\text{C}$ oraz $> 30^{\circ}\text{C}$)
- prędkość wiatru ($< 0,35\text{ m/s}$ oraz $> 7,5\text{ m/s}$)

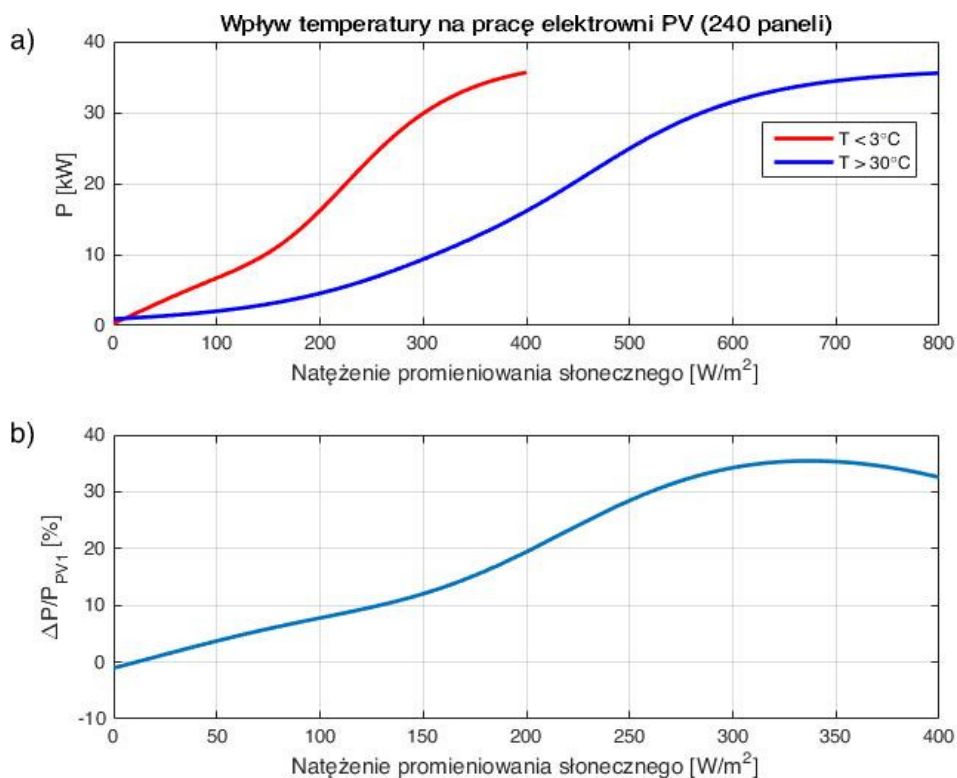
Następnie zastosowano sieci neuronowe do wyznaczenia charakterystyk mocy dla danych z poszczególnych zakresów.

Na rysunkach 3.82-3.84 zamieszczono wpływ wilgotności, temperatury oraz prędkości wiatru na pracę elektrowni fotowoltaicznej PV1.




Rysunek 3.82: a) wyznaczona charakterystyka mocy dla wilgotności $< 40\%$ oraz $> 95\%$, b) różnica generowanej mocy dla obu przypadków w % mocy zainstalowanej

Dla wybranego zakresu $T < 3^{\circ}\text{C}$ maksymalne natężenie promieniowania słonecznego w przypadku elektrowni PV1 wynosiło 400 W/m^2 . Wymusiło to zakończenie czerwonej charakterystyki na rysunku 3.83 w tym punkcie.



Rysunek 3.83: a) Charakterystyka mocy dla $T < 3^\circ C$ i $T > 30^\circ C$, b) różnica generowanej mocy dla obu przypadków w % mocy zainstalowanej



Rysunek 3.84: a) Charakterystyka mocy dla $V < 0,35$ m/s i $V > 7,5$ m/s, b) różnica generowanej mocy dla obu przypadków w % mocy zainstalowanej

Wielkość produkcji uzależniona jest od temperatury paneli (rys. 3.83). Te same ogniwa w zimie przy niższej temperaturze otoczenia wyprodukują więcej energii niż w lecie przy tym samym poziomie natężenie promieniowania. Pośrednio wpływ na temperaturę ogniw ma również wiatr (rys. 3.84), owiewający i chłodzący ogniwa. Współczynniki korelacji przedstawione w Tabeli 3.11 oraz rysunki 3.82-3.84 potwierdzają istotność czynników meteorologicznych takich jak wilgotność, temperatura, prędkość wiatru na pracę elektrowni fotowoltaicznej. Jak wynika z rysunków w skrajnych przypadkach różnice w wielkościach produkcji wynosiły nawet 17-33% mocy zainstalowanej w elektrowni fotowoltaicznej.

4 Modele prognostyczne dedykowane OZE oparte o sztuczną inteligencję


Zmieniająca się gospodarka rynkowa, wymusza podejmowanie decyzji bazujących coraz częściej na niepewnych i niepełnych danych. Dlatego już od wielu lat rozwijane są modele pozwalające usprawnić proces decyzyjny. Szybko rozwijające się techniki informatyczne, umożliwiają wdrażanie kolejnych coraz bardziej złożonych (pod względem obliczeniowym) modeli.

Zaproponowany w pracy model prognostyczny jest kombinacją modelu statystycznego wykorzystującego sztuczne sieci neuronowe, bazującego na numerycznych prognozach pogody. W celu poprawy skuteczności prognozowania zaproponowano kilka wersji modeli, które następnie poddano badaniom.

4.1 Jednokierunkowe sieci neuronowe

4.1.1 Modele sieci neuronowej

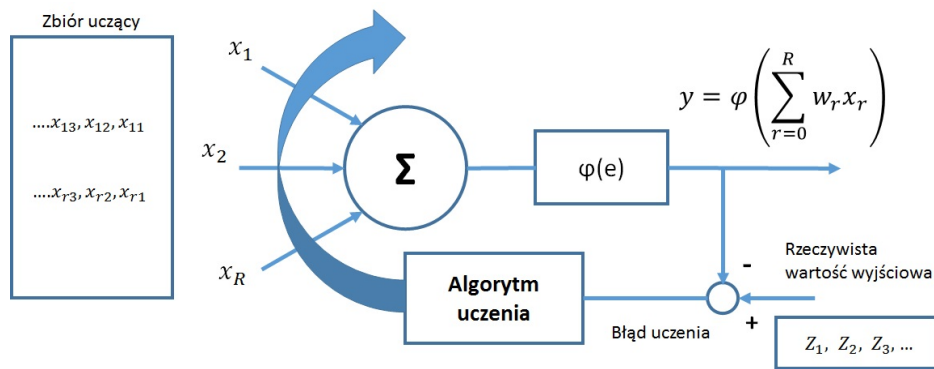
Wzorowane na systemach biologicznych sztuczne sieci neuronowe (SSN) wykorzystywane są do przetwarzania informacji. Autorzy artykułów na przykład [16][59][84] oraz książek na przykład [85][86][87] wykazują, że są one efektywnym narzędziem do rozwiązywania problemów prognostycznych. Dzieje się tak głównie dzięki temu, że modele te posiadają zdolność do aproksymacji dowolnej wielowymiarowej, nieliniowej funkcji (Rysunek 4.1). Aproksymowana funkcja otrzymywana jest w procesie uczenia sieci. Jest to cecha wyróżniająca model spośród innych. Proces uczenia polega na utworzeniu tzw. zbioru uczącego tzn. zbioru wartości parametrów wejściowych i wyjściowych obiektu. Sieć neuronowa w procesie uczenia modyfikuje swoje parametry, aby znaleźć łączące je relacje. Model w procesie uczenia jest optymalizowany na podstawie historycznych informacji pochodzących z obiektu.



Rysunek 4.1: Podstawowa struktura modelu obiektu

Na atrakcyjność stosowania sieci neuronowych wpływa także możliwość ciągłej ich adaptacji. Może być ona realizowana przez usuwanie ze zbioru uczącego najstarszych oraz dodawanie nowych danych. Następnie sieć jest ponownie uczona, dzięki czemu otrzymuje się tak zwany model kroczący, który adaptuje się na bieżąco do zmieniających się warunków.

Sztuczne sieci neuronowe są systemami przetwarzania informacji opartymi na równoległej pracy wielu neuronów. Neuron (analogicznie do biologicznego odpowiednika) jest elementem o wielu wejściach i jednym wyjściu. Z każdym wejściem związana jest waga, która w procesie uczenia jest modyfikowana. Model pojedynczego sztucznego neuronu, sposób uczenia oraz obliczania odpowiedzi przedstawiono na rysunku 4.2.



Rysunek 4.2: Model neuronu [10]

W procesie uczenia modyfikowane są wagi (sygnałów wejściowych) neuronu, w taki sposób aby zminimalizować wskaźnik jakości (4.1):

$$Q = \frac{1}{2} \sum_k (z_k - \varphi(\sum_{i=0}^R w_i x_i))^2 \quad (4.1)$$

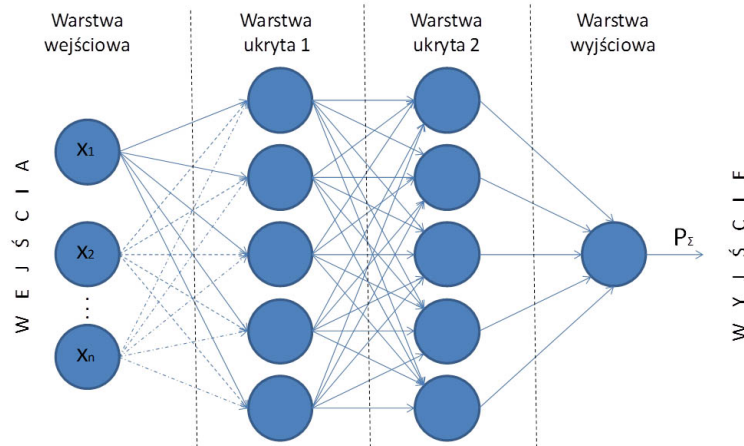
gdzie: w_r - waga i-tego wejścia, z_k - rzeczywista/zmierzona wartość wyjściowa, φ - wynik uczenia.

Proces uczenia ma za zadanie minimalizację funkcji 4.1 metodą iteracyjną przy pomocy algorytmu największego spadku. Proces dla prostego neuronu liniowego sprowadza się do dodania (lub odjęcia jeśli błąd jest ujemny) od wektora wag części wektora sygnałów wejściowych (4.2):

$$w_i^{(new)} = w_i^{(old)} \pm \eta \sum_k e(k) x_i(k) \quad (4.2)$$

gdzie: η - współczynnik szybkości uczenia sieci, $e(k)$ - błąd uczenia, $x_r(k)$ - wartość i-tego wejścia.

Sieć neuronowa jednokierunkowa zbudowana jest z warstwy wejściowej, warstw ukrytych oraz warstwy wyjściowej. Poszczególne warstwy posiadają neurony tego samego typu, jednak w różnych warstwach możliwe jest zastosowanie odmiennych typów neuronów. Przykładową strukturę jednokierunkowej sieci neuronowej zaprezentowano na rysunku 4.3.



Rysunek 4.3: Jednokierunkowa sieć neuronowa

Regularna struktura sieci neuronowych pozwala uogólnić algorytm uczenia wykorzystywany do uczenia pojedynczego neuronu na całą sieć neuronową. Najczęściej wykorzystywaną metodą uczenia sieci jest metoda wstecznej propagacji błędów, z języka angielskiego BackPropagation (BP) [88]. Obecnie istnieje również wiele innych metod na przykład resilient backpropagation [89], metoda gradientów sprzężonych oraz metoda Levenberga–Marquardta oparta na nieco bardziej zaawansowanym algorytmie matematycznym [86].

Algorytm Levenberga-Marquardta, nazywany jest również algorytmem optymalizacji nieliniowej. Łączy w sobie cechy metody największego spadku i metody Gaussa-Newtona, jest algorytmem iteracyjnym. Metoda w porównaniu do metody BP charakteryzuje się większą szybkością działania, jednak odbywa się to kosztem zwiększenia zapotrzebowania na pamięć podręczną podczas obliczeń [90]. Jest oparta o algorytm rozwiązywania nieliniowego problemu najmniejszych kwadratów, który został opisany przez Marquardt'a w pracy [91]. Metoda regularyzacji Levenberga-Marquardta sprowadza się do zastąpienia macierzy hesjanu (podczas optymalizacji newtonowskiej) jej przybliżeniem opartym na obliczeniach gradientu, wraz z odpowiednio dobranym czynnikiem regularyzacyjnym [90]. W algorytmie tym przyjmuje się kwadratową postać funkcji błędów opisaną zależnością:

$$E(\vec{w}) = \sum_{k=1}^N \sum_{i=1}^m [r_{ki}(\vec{w})]^2 \quad (4.3)$$

gdzie: r_{ki} jest błędem przyporządkowanym do i -tego wyjścia sieci dla k -tego obrazu uczącego.

Jakobian możemy zapisać jako:

$$J(\vec{w}) = \begin{bmatrix} \frac{\partial r_{11}}{w_1} & \frac{\partial r_{11}}{w_2} & \dots & \frac{\partial r_{11}}{w_n} \\ \frac{\partial r_{21}}{w_1} & \frac{\partial r_{21}}{w_2} & \dots & \frac{\partial r_{21}}{w_n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial r_{N1}}{w_1} & \frac{\partial r_{N1}}{w_2} & \dots & \frac{\partial r_{N1}}{w_n} \\ \frac{\partial r_{1m}}{w_1} & \frac{\partial r_{1m}}{w_2} & \dots & \frac{\partial r_{1m}}{w_n} \\ \frac{\partial r_{2m}}{w_1} & \frac{\partial r_{2m}}{w_2} & \dots & \frac{\partial r_{2m}}{w_n} \\ \vdots & \vdots & \vdots & \vdots \\ \frac{\partial r_{Nm}}{w_1} & \frac{\partial r_{Nm}}{w_2} & \dots & \frac{\partial r_{Nm}}{w_n} \end{bmatrix} \quad (4.4)$$

gdzie:

$$r_w = [r_{11} \dots r_{N1} r_{12} \dots r_{N2} \dots r_{1m} \dots r_{Nm}]^T \quad (4.5)$$

Dla przyjętej funkcji błędu gradient wyraża się za pomocą:

$$\Delta E(\vec{w}) = J(\vec{w})^T r(\vec{w}) \quad (4.6)$$

Przybliżenie macierzy hesjanu to:

$$H(\vec{w}) = J(\vec{w})^T J(\vec{w}) + u \quad (4.7)$$


gdzie u jest czynnikiem regularyzacyjnym. W algorytmie Levenberga-Marquardta nie ma konieczności obliczania dokładnej wartości hesjanu, ponieważ używane jest oszacowanie (4.6, 4.7). Dlatego wektor wag w epoce $t+1$ to:

$$\vec{w}_{t+1} = \vec{w}_t - \frac{\Delta E(\vec{w})}{J(\vec{w})^T J(\vec{w}) + u_t} \quad (4.8)$$

Czynnik u_t tzw. funkcja postępu procesu uczenia, może być dobierany w rozmaity sposób. Początkowo czynnik ten powinien przyjmować duże wartości w porównaniu z wartościami własnymi macierzy $J(\vec{w})^T J(\vec{w})$. Wraz ze zmniejszaniem się błędów popełnianych przez sieć czynnik ten zmniejsza się dążąc do zera. Dodanie czynnika u_t wprowadza dwuetapowość obliczeń, początkowo algorytm przeprowadza minimalizację funkcji metodą największego spadku, by stopniowo przejść w pobliżu rozwiązania do aproksymacji hesjanu za pomocą rozwinięcia pierwszego rzędu. Powoduje to dynamiczne przejście algorytmu Levenberga-Marquardta do algorytmu Gaussa-Newtona o kwadratowej zbieżności. Ze względu na zalety metody opisane powyżej została ona wybrana do optymalizacji zaproponowanych sieci neuronowych.

4.1.2 Uczenie sieci neuronowej i budowa modelu prognostycznego

Na rysunku 4.4 przedstawiono proces przygotowania modelu prognostycznego dedykowanego do prognozowania produkcji energii.

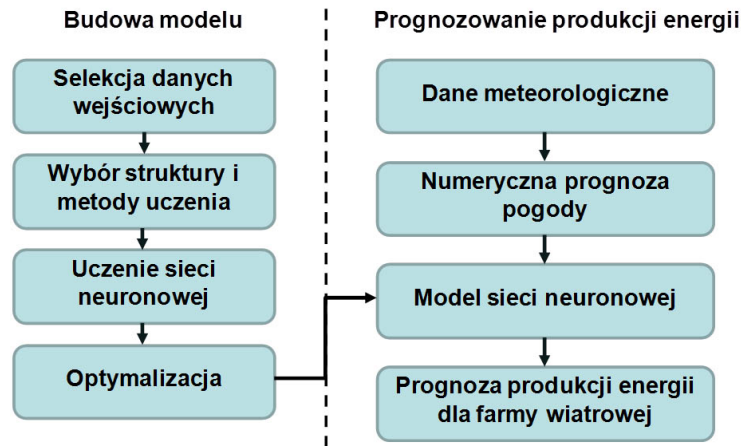


Rysunek 4.4: Proces przygotowania modelu prognostycznego

Proces składa się z dwóch etapów: Etap I - Uczenie sieci, Etap II - Weryfikacja. Na rysunku 4.5 zaprezentowano etapy selekcjonowania oraz wyboru struktury sieci neuronowych oraz danych wejściowych do modelu.

4.2 Narzędzia do oceny jakości modeli prognostycznych

Ocena trafności predykcji jest istotnym elementem procesu budowy modelu prognozy. Należy pamiętać, że budowanie oraz proces douczania sieci powinien mieć charakter ciągły.



Rysunek 4.5: Metodologia prognozowania

Wyniki oceny mogą posłużyć do korekcji bieżącej prognozy w danym okresie prognozy, gdy jest to wymagane i możliwe. Mogą również posłużyć jako element korekty wykonanych przez model prognoz lub być informacją decydującą o konieczności przebudowania modelu.

4.2.1 Mierniki bezwzględne

Poniżej zaprezentowano miary liczbowe pozwalające na ocenę jakości predykcji modelu prognostycznego.

Przyjęto następujące oznaczenia:

y_t - rzeczywista wartość zmiennej prognozowanej dla okresu t ,

y_t^* - prognoza zmiennej dla okresu t ,

n_p - liczba prognoz w danym okresie.

- Błąd bezwzględny (ang. absolute error, AE)

$$q_t = y_t - y_t^* \quad (4.9)$$

- Błąd całkowity (ang. Integrated Absolute Error, IAE) [16]

$$IAE = \int_0^{\infty} |q(t)| dt \quad (4.10)$$

- Średni błąd (ang. mean error, ME)

$$ME = \frac{1}{T} \sum_{t=1}^T q_t \quad (4.11)$$

gdzie: T - liczba rekordów danych.

- Średni absolutny błąd (ang. mean absolute error, MAE)

$$MAE = \frac{1}{T} \sum_{t=1}^T |q_t| \quad (4.12)$$

- Średni okresowy błąd (ang. mean periodic error)

$$q_p = \frac{1}{n_p} \sum_{t=1}^{n_p} q_t \quad (4.13)$$

gdzie: n_p - liczba rekordów danych dla wybranego okresu.

- Błąd średni kwadratowy (ang. mean squared error, MSE)

$$s^{*2} = \frac{1}{T} \sum_{t=1}^T q_t^2 \quad (4.14)$$

- Pierwiastek błędu średniokwadratowego (ang. root mean squared error, RMSE)

$$RMSE = \sqrt{s^{*2}} \quad (4.15)$$

4.2.2 Mierniki względne

Pozwalają na ocenę modelu pod kątem wielkości przeszacowania lub niedoszacowania prognozy względem rzeczywistych wartości. Tego typu mierniki mogą mieć znaczenie przy jakościowej ocenie modelu. Mierniki względne zaburzają ocenę w przypadku małych wartości zmiennej prognozowanej (wartości bliskie zero). W takim przypadku błędy względne osiągają znaczne wartości.

- Błąd względny (ang. relative error, RE)

$$\Sigma_t = \frac{y_t - y_t^*}{y_t} = \frac{q_t}{y_t} \quad (4.16)$$

- Średni błąd procentowy (ang. mean percentage error, MPE)

$$MPE = \frac{1}{T} \sum_{t=1}^T \frac{q_t}{y_t} \cdot 100 = \frac{1}{T} \sum_{t=1}^T \Sigma_t \cdot 100 \quad (4.17)$$

- Średni absolutny błąd procentowy (ang. mean absolute percentage error, MAPE)

Błąd MAPE niesie informację o średniej wartości błędów prognoz dla n okresów, wyrażonych w procentach rzeczywistych wartości zmiennej prognozowanej. Dzięki temu wartości MAPE umożliwiają porównanie dokładności prognoz otrzymywanych za pomocą różnych modeli.

$$MAPE = \frac{1}{T} \sum_{t=1}^T |\Sigma_t| \cdot 100 \quad (4.18)$$

- Znormalizowany średni absolutny błąd procentowy (ang. normalized mean absolute error, NMAPE)

$$NMAPE = \frac{1}{T} \sum_{i=1}^N \left| \frac{q_t}{C} \right| * 100 \quad (4.19)$$

gdzie: C - moc zainstalowana turbiny/elektrowni

- Znormalizowany pierwiastek błędu średniokwadratowego (ang. normalized root mean square error, NRMSE) [16]

$$NRMSE = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T q_t^2}}{C} * 100 \quad (4.20)$$

W rozdziałach 4.2.1-4.2.2 wyszczególniono wiele mierników oceny modelu prognostycznego. Jak wynika z badań przeprowadzonych dla analizowanych obiektów, zdarza się, że poprawa jednych mierników powoduje pogorszenie innych. Przez to ocena jakości modelu jest utrudniona. Ze względu na swoje właściwości statystyczne do dalszej analizy wybrano trzy podstawowe mierniki (MAE, MAPE oraz NMAPE), zdaniem autora najlepiej nadające się do porównywania modeli oraz pozwalające określić liczbowo zmianę dokładności generowanych prognoz, zwłaszcza w przypadku analiz wykonywanych na dużych zbiorach danych. Ponieważ błąd MAPE jest wrażliwy na małe wartości rzeczywistych pomiarów y_t , w niektórych przypadkach zastąpiono go znormalizowanym średnim absolutnym błędem procentowym.

4.2.3 Współczynniki oraz szacunkowe błędy przyszłe

Błędy ex-ante dostarczają informację o zasadności wykonania prognozy oraz o spodziewanych odchyleniach od rzeczywistej wartości zjawiska [92]. Do ich wyznaczania stosuje się zazwyczaj błędy predykcji [93]:

$$D_t = f(Y_t - Y_t^p) \quad (4.21)$$

gdzie:

Y_t - możliwe realizacje zmiennej prognozowanej dla $t > n$,

Y_t^p - możliwe prognozy zmiennej prognozowanej dla $t > n$.

Błąd ten może być jedynie szacowany, gdyż w chwili wyznaczania prognozy wartość rzeczywista nie jest znana.

- Obciążenie predykcji $E(D_t)$

Wartość wskaźnika określa przeszacowane lub niedoszacowane prognozy.

$E(D_t) > 0$ – prognozy niedoszacowane,

$E(D_t) < 0$ – prognozy przeszacowane.

- Średni błąd predykcji

Wskaźnik informuje o ile średnio rzeczywiste wartości prognozowanej zmiennej mogą różnić się od wartości obliczonych prognoz.

- Bezwzględny błąd predykcji

$$D_t = \sqrt{D_t^2}, \quad t > n \quad (4.22)$$

- Względny błąd predykcji

$$V = \frac{D_t}{Y_t^p}, \quad t > n \quad (4.23)$$

Zarówno błąd względny jak i bezwzględny mogą być obliczane dla pojedynczego punktu lub okresu $t > n$. Jeżeli prognoza jest wyznaczana dla przedziału czasu $t \in [n + 1, \dots, T]$ to błąd należy obliczyć dla tego samego okresu.

- Współczynnik korelacji linowej prognozy

Współczynnik korelacji linowej prognozy 4.24 mieści się w zakresie od -1,0 do 1,0 włącznie (jest wskaźnikiem bezwymiarowym). Opisuje stopień liniowej zależności pomiędzy dwoma zestawami danych:

$$\sum r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(x, y)}{s(x) \cdot s(y)} \quad (4.24)$$

gdzie:

x_i, y_i - zmienne losowe o dyskretnym rozkładzie dla $i=1,2,\dots,n$,

\bar{x}, \bar{y} - wartości średnie x,y

$cov(x, y)$ - kowariancja zmiennych x i y,

$s(x)$ - odchylenie standardowe zmiennej x,

$s(y)$ - odchylenie standardowe zmiennej y,

- bezwzględny błąd prognozy ex-ante

Wyznaczona miara umożliwia określenie oczekiwanego przeciętnego odchylenia zmiennej prognozowanej od prognozy dla czasu $t > n$. Obliczany jest według wzoru [94][95]:

$$V_t = \sqrt{\sum_{i=0}^m \widehat{P}_{it}^2 D^2(P_i) + 2 \sum_{i=0}^{m-1} \sum_{j>i} \widehat{P}_{it} P_{jt} \text{cov}(\widehat{P}_i, P_j) + s^2} \quad (4.25)$$

gdzie:

\widehat{P}_{it} - prognoza i-tej zmiennej objaśniającej,

$D^2(P_i)$ - ocena wariancji wielkości P_i ,

$\text{cov}(P_i, P_j)$ - kowariancja wielkości P_i oraz P_j ,

s^2 - kwadrat odchylenia standardowego reszt.

- względny błąd prognozy ex-ante Błąd umożliwia wybór najlepszej prognozy z spośród wygenerowanych i wyznaczany jest z wzoru [94][95]:

$$\eta_t = \frac{V_t}{\widehat{P}_t} \cdot 100 \quad (4.26)$$

W niniejszej pracy do oceny modeli prognostycznych wykorzystywano historyczne dane dlatego do oceny jakości posłużono się błędami ex-post predykcji. Nie mniej jednak mierniki jakimi są błędy ex-ante są istotne w szczególności w przypadku konieczności szacowania możliwych przyszłych odchyżeń prognozy od wartości rzeczywistych.

4.3 Czynniki wpływające na prognozowanie produkcji energii

Wielkość produkcji energii w elektrowniach wiatrowych i fotowoltaicznych jest silnie zależna od zmiennych w czasie czynników meteorologicznych występujących w bezpośrednim otoczeniu elektrowni. Im precyzyjniejsze jest oszacowanie tej wartości, tym mniej kosztowne staje się jej bilansowanie w systemie energetycznym. Jednak nie są to jedyne czynniki mające wpływ na wielkość energii produkowanej przez te elektrownie.

4.3.1 Elektrownie wiatrowe

Do pozostałych czynników wpływających na chwilową wielkość mocy czynnej generowanej przez elektrownię wiatrową można zaliczyć m.in.:

- wybór najbardziej korzystnego dla układu sterowania turbiną kąta nachylenia łopat,
- wybór najbardziej korzystnego dla układu sterowania turbiną kierunku obrotu gondoli,
- chwilowy współczynnik mocy,
- zużycie energii na potrzeby własne,
- czasowe zużycie elementów,
- okresowe serwisy i remonty.

W przypadku elektrowni wiatrowej tylko część informacji jest rejestrowana i zapisywana w zainstalowanych systemach SCADA. Aktualnie rozwijane modele prognostyczne w większości pomijają wpływ powyższych czynników na wielkość produkcji. Tego typu dane dostępne są wyłącznie producentom/serwisantom turbin i nie są udostępniane użytkownikowi.

Bardziej złożona jest prognoza produkcji wykonywana dla całej farmy, składającej się z wielu turbin. W takim przypadku należy uwzględnić nowe czynniki takie jak liczba aktualnie pracujących turbin i ukształtowanie terenu. Zmiana prędkości wiatru bliska granicznej wartości załączenia turbin, może spowodować wyłączenie części z nich. Ponowny rozruch jest czasochłonny, co wpływa na wielkość rzeczywistej produkcji oraz błąd prognozy.

4.3.2 Elektrownie fotowoltaiczne


W przypadku elektrowni fotowoltaicznych najważniejszym składnikiem warunkującym wielkość produkcji jest natężenie promieniowania słonecznego docierającego do paneli oraz inne elementy i zjawiska meteorologiczne. Podobnie jak w przypadku elektrowni wiatrowych nie są to jednak jedyne czynniki wpływające na wielkość produkcji. Do dodatkowych można zaliczyć:

- wybór punktu maksymalnej mocy MPP przez sterownik falownika,
- sposób połączenia ogniw/paneli i odporność na miejscowe zacienienia,
- czasowe starzenie się elementów i utrata sprawności,
- zarysowania i zabrudzenia powierzchni paneli,
- dynamika zmienności warunków pogodowych.

Stacje meteorologiczne przekazują informację na temat sumy okresowych ilości energii lub średnie wartości gęstości strumienia promieniowania docierającego do powierzchni poziomej. Analogiczna sytuacja występuje w przypadku prognoz generowanych przez modele numerycznych prognoz pogody. Wielokrotnie w takim przypadku model nie udostępnia informacji na temat nasłonecznienia lub strumienia promieniowania słonecznego, dostępna jest jedynie informacja na temat zachmurzenia. Pociąga to za sobą konieczność znalezienia zależności pomiędzy tymi parametrami, a w konsekwencji przeliczenia ich wartości. Do realizacji założonego celu dobrze sprawdzają się modele oparte o sztuczną inteligencję.

4.3.3 Efekt uśredniania

Większość dostępnych danych pochodzących z elektrowni wiatrowych oraz fotowoltaicznych jest uśredniana z różnym interwałem czasowym. Rysunek 4.6 przedstawia charakterystykę mocy dla turbiny wiatrowej ENERCON E 70-E4.



Rysunek 4.6: Charakterystyka mocy dla turbiny ENERCON E 70-E4 z naniesionymi dwoma punktami pracy [źródło: opracowanie własne na podstawie [49]]

Na wykresie zaznaczono dwa punkty pracy turbiny dla prędkości równej 5 [m/s] oraz 10 [m/s]. Wielkość mocy wytwarzanej to odpowiednio 127 [kW] oraz 1223 [kW]. W zależności od typu oraz celu agregacji danych najczęściej spotykanym okresem uśredniania jest 1 min, 10 min, 15 min. Przykładowe dane zaprezentowano w tabeli 4.1:

Uśrednianie danych powoduje utratę cennych informacji na temat zmienności rozważanego zjawiska. Dokładność modeli prognostycznych maleje wraz ze wzrostem "chwilowej" zmienności. Tabela 4.1 przedstawia przykład uśredniania 10 minutowego z danych 1 minutowych. W pierwszym rozważanym przypadku w stronę turbiny wiatrowej I wieje wiatr z prędkością 10 [m/s] przez połowę okresu uśredniania to jest 5 minut. Na podstawie informacji odczytanej z krzywej mocy wyznaczono moc generowaną równą 1223 [kW] co daje sumaryczną 10 min wyprodukowaną energię równą 101,92 [kWh]. W drugim przypadku w stronę turbiny wiatrowej II wieje wiatr z prędkością 5 [m/s] przez cały okres uśredniania to jest 10 minut. Na podstawie informacji odczytanej z krzywej mocy wyznaczono moc generowaną równą 127 [kW]. W obu przypadkach średnia 10 minutowa prędkość wiatru wynosi 5 [m/s], jednak turbina I w ciągu 10 min powinna wyprodukować energię równą 101,92 [kWh], natomiast turbina II energię równą 21,17 [kWh].

Tabela 4.1: Przykład uśredniania - Turbina ENERCON E 70-E4

| t [min] | V1 [m/s] | V2 [m/s] | P1 [kW] | P2 [kW] | E1 [kWh] | E2 [kWh] |
|----------|----------|----------|---------|---------|----------|----------|
| 1 | 10 | 5 | 1223 | 127 | 20,38 | 2,12 |
| 2 | 10 | 5 | 1223 | 127 | 20,38 | 2,12 |
| 3 | 10 | 5 | 1223 | 127 | 20,38 | 2,12 |
| 4 | 10 | 5 | 1223 | 127 | 20,38 | 2,12 |
| 5 | 10 | 5 | 1223 | 127 | 20,38 | 2,12 |
| 6 | 0 | 5 | 0 | 127 | 0 | 2,12 |
| 7 | 0 | 5 | 0 | 127 | 0 | 2,12 |
| 8 | 0 | 5 | 0 | 127 | 0 | 2,12 |
| 9 | 0 | 5 | 0 | 127 | 0 | 2,12 |
| 10 | 0 | 5 | 0 | 127 | 0 | 2,12 |
| Σ | - | - | 6115 | 1270 | 101,92 | 21,17 |
| Średnia | 5 | 5 | 611,5 | 127 | - | - |

4.4 Prognozowanie z wykorzystaniem sieci neuronowych

Sieci neuronowe ze względu na swoje właściwości umożliwiają generowanie prognoz z uwzględnieniem różnych czynników meteorologicznych. Na jakość prognoz wpływ ma zarówno zbiór wykorzystywanych danych jak i struktura sieci (liczba neuronów, warstw ukrytych).

W oparciu o doświadczenie autora pracy zaproponowano następujące struktury sieci neuronowych (będące wynikiem wielu symulacji), które zestawiono w Tabeli 4.2.

Każda sieć w celu uzyskania właściwego rozłożenia wag poszczególnych połączeń neuronowych była uczona pięciokrotnie - optymalizowano je pod kątem błędu MAE (4.12). Kolejnym istotnym czynnikiem mającym wpływ na dokładność generowanych prognoz jest dobór właściwego zbioru danych wejściowych. Uwzględniając posiadane dane zaproponowano 16 różnych konfiguracji danych wejściowych (Tabela 4.3) i przetestowano ich wpływ na prognozy.

Analogiczne konfiguracje struktur danych wejściowych przygotowano dla elektrowni fotowoltaicznej i zestawiono w Tabeli 4.4.

Dla analizowanych obiektów zgromadzono różne typy danych dlatego nie we wszystkich obiektach możliwe było przetestowanie wszystkich konfiguracji. W Tabeli 4.5 zestawiono przetestowane konfiguracje ze względu na badany obiekt.

Łącznie przygotowano 4230 sieci neuronowych, z których wybrano dla każdej konfi-

Tabela 4.2: Struktury sieci neuronowych

| L.P. | Liczba neuronów w warstwach | | | Liczba warstw |
|------|-----------------------------|----------|------------|---------------|
| | wejściowej | ukrytych | wyjściowej | ukrytych |
| 1 | N* | 5 | 1 | 2 |
| 2 | | 7 | | |
| 3 | | 10 | | |
| 4 | | 15 | | |
| 5 | | 20 | | |
| 6 | | 25 | | |
| 7 | N* | 5 | 1 | 3 |
| 8 | | 7 | | |
| 9 | | 10 | | |
| 10 | | 15 | | |
| 11 | | 20 | | |
| 12 | | 25 | | |
| 13 | N* | 5 | 1 | 4 |
| 14 | | 7 | | |
| 15 | | 10 | | |
| 16 | | 15 | | |
| 17 | | 20 | | |
| 18 | | 25 | | |

* - liczba neuronów wejściowych N zależna od liczby strumieni danych wejściowych

guracji po jednej strukturze połączeń sieci neuronowych. Jako kryterium użyto średni absolutny błąd prognozy (MAE). W efekcie otrzymano 864 sieci neuronowe, które poddano porównaniu.

4.4.1 Prognozowanie produkcji energii elektrowni wiatrowej

Na podstawie przeprowadzonych badań wybrano zarówno struktury sieci jak i zbiory danych uczących dla poszczególnych obiektów. Jako kryterium porównawcze struktury danych wybrano absolutny błąd MAE (4.12) oraz absolutny procentowy błąd prognozy MAPE (4.18) wielkości mocy generowanych przez elektrownie.

Tabela 4.3: Analizowane struktury danych wejściowych - elektrownia wiatrowa

| | Struktura danych | | | | | | | | | | | | | | | |
|-----------------|------------------|---|---|---|---|---|---|---|---|----|----|----|----|----|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
| Prędkość wiatru | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x |
| Kierunek wiatru | | | x | x | x | | x | | | x | | x | x | x | | |
| Liczba turbin | | x | x | x | x | | | | | x | x | | | x | x | x |
| Temperatura | | | | x | x | x | | x | | | x | x | x | x | x | |
| Ciśnienie | | | | | x | x | | | x | x | x | x | x | x | x | |
| Miesiąc | | | | | | | | | | | | | x | x | x | x |

Tabela 4.4: Analizowane struktury danych wejściowych - elektrownia fotowoltaiczna


| | Struktura danych | | | | | | | | | | | | | | | |
|--------------------------------------|------------------|---|---|---|---|---|---|---|---|----|----|----|----|----|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
| Natężenie promieniowania słonecznego | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x |
| Kierunek wiatru | | | x | x | x | | x | | | x | | x | x | x | | |
| Prędkość wiatru | | x | x | x | x | | | | | x | x | | | x | x | x |
| Temperatura | | | | x | x | x | | x | | | x | x | x | x | x | |
| Ciśnienie | | | | | x | x | | | x | x | x | x | x | x | x | |
| Miesiąc | | | | | | | | | | | | | x | x | x | x |

Tabela 4.5: Analizowane konfiguracje struktur danych (ze względu na badany obiekt)

| Elektrownia | Struktura danych | | | | | | | | | | | | | | | |
|-------------|------------------|---|---|---|---|---|---|---|---|----|----|----|----|----|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 | 13 | 14 | 15 | 16 |
| FW1 | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x |
| FW2 | x | x | | | | | | | | | | | | | | x |
| FW3 | x | x | x | | | | x | | | | | | | | | x |
| FW4 | x | x | x | x | | | x | x | | | | | | | x | x |
| PV1 | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x | x |

4.4.1.1 Elektrownia wiatrowa FW1

Na potrzeby prognozowania produkcji energii elektrycznej elektrowni wiatrowej FW1 przebadano 1440 różnych sieci neuronowych. Na Rysunku 4.7 zamieszczono zmierzoną oraz prognozowaną charakterystykę mocy w zależności od prędkości wiatru dla której błąd MAE/MAPE był najniższy.




Rysunek 4.7: Prognoza produkcji energii dla elektrowni wiatrowej FW1

Prognozy generowano dla zbioru danych wejściowych oraz struktury sieci zgodnie z Tabelą 4.3 oraz 4.5 dla elektrowni FW1.


Porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) w zależności od struktury sieci neuronowej zamieszczono na Rysunku 4.8.

Na Rysunkach 4.9a-4.9b zamieszczono porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) - w zależności od struktury danych wejściowych.

Jak wynika z Rysunków 4.8-4.9 dla elektrowni wiatrowej FW1 prognozy charakteryzują się największą dokładnością dla struktury danych nr 14 oraz struktury sieci nr 7 niezależnie od wybranego MAE/MAPE błędu prognozy.




(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.8: Zestawienie dokładności prognoz ze względu na wybraną strukturę sieci neuronowej dla elektrowni wiatrowej FW1



(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.9: Zestawienie dokładności prognoz ze względu na wybraną strukturę danych dla elektrowni wiatrowej FW1

4.4.1.2 Elektrownia wiatrowa FW2

Ze względu na ograniczony zbiór danych wejściowych, możliwe było wykonanie analizy dla struktur danych zamieszczonych w Tabeli 4.5. W związku z tym na potrzeby prognozowania produkcji energii elektrycznej elektrowni wiatrowej FW2 przebadano 270 różnych sieci neuronowych. Prognozy generowano dla zbioru danych wejściowych oraz struktury sieci zgodnie z Tabelą 4.3 oraz 4.5 dla elektrowni FW2. Porównanie prognoz produkcji elektrowni wiatrowej z wartościami zmierzonymi zaprezentowano na Rysunku 4.10.




Rysunek 4.10: Prognoza produkcji energii dla elektrowni wiatrowej FW2


Porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) w zależności od struktury sieci neuronowej zamieszczono na Rysunku 4.11.

Na Rysunkach 4.12a i b zamieszczono porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) - w zależności od struktury danych wejściowych.

Jak wynika z Rysunków 4.11-4.12 dla elektrowni wiatrowej FW2 prognozy charakteryzują się największą dokładnością dla struktury danych nr 16 oraz struktury sieci nr 13/4 w zależności od wybranego błędu prognozy MAE/MAPE.




(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.11: Zestawienie dokładności prognoz ze względu na wybraną strukturę sieci neuronowej dla elektrowni wiatrowej FW2



(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.12: Zestawienie dokładności prognoz ze względu na wybraną strukturę danych dla elektrowni wiatrowej FW2

4.4.1.3 Elektrownia wiatrowa FW3


Zbiór danych wejściowych dla elektrowni FW3 to: prędkość i kierunek wiatru, liczba pracujących turbin, miesiąc. Ze względu na posiadany zbiór danych wejściowych, możliwe było wykonanie analizy dla struktur danych zamieszczonych w Tabeli 4.5. Na potrzeby prognozowania produkcji energii elektrycznej elektrowni wiatrowej FW3 przebadano 450 różnych sieci neuronowych. Prognozy generowano dla zbioru danych wejściowych oraz struktury sieci zgodnie z Tabelą 4.3 oraz 4.5 dla elektrowni FW3. Zestawienie prognoz oraz zarejestrowanych zależności prędkości wiatru od mocy przedstawiono na Rysunku 4.13.




Rysunek 4.13: Prognoza produkcji energii dla elektrowni wiatrowej FW3

Na rysunku 4.13 można zaobserwować zbiór punktów powyżej charakterystyki mocy, które mogą być związane z nierównomiernym rozkładem prędkości wiatru wewnątrz elektrowni lub znaczną zmiennością prędkości wiatru oraz efektem uśredniania opisanym w podrozdziale 4.3.3. Na kolejnym rysunku 4.14 przedstawiono porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) w zależności od badanej struktury sieci neuronowej.

Rysunki 4.15a-4.15b zawierają porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) - w zależności od struktury danych wejściowych.

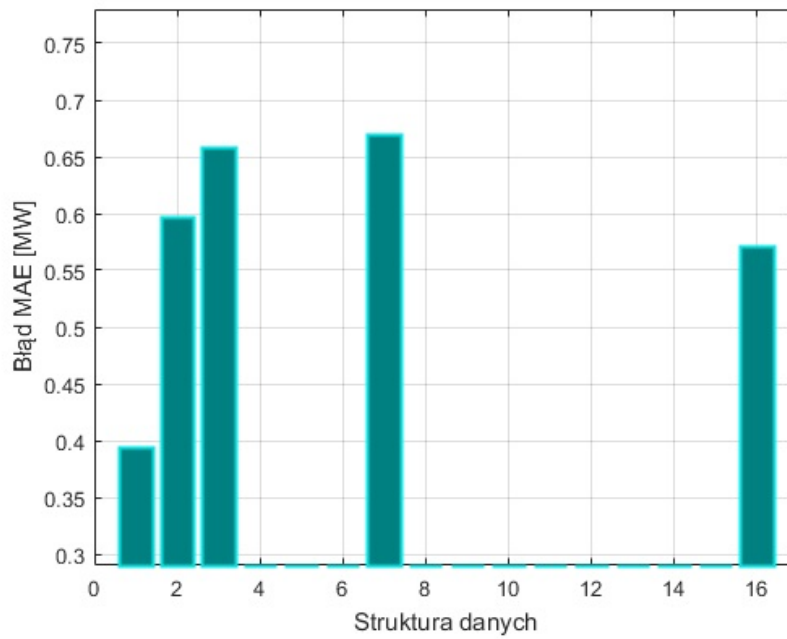


(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.14: Zestawienie dokładności prognoz ze względu na wybraną strukturę sieci neuronowej dla elektrowni wiatrowej FW3



(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.15: Zestawienie dokładności prognoz ze względu na wybraną strukturę danych dla elektrowni wiatrowej FW3

Jak wynika z Rysunków 4.14-4.15 dla elektrowni wiatrowej FW3 prognozy charakteryzują się największą dokładnością dla struktury sieci nr 18 oraz danych nr 1 niezależnie od wybranego błędu prognozy MAE/MAPE.

4.4.1.4 Elektrownia wiatrowa FW4

Dane wejściowe dla elektrowni FW4 to: prędkość i kierunek wiatru, temperatura, liczba pracujących turbin, miesiąc. Ze względu na posiadany zbiór danych wejściowych, wykonano analizy dla struktur danych zamieszczonych w Tabeli 4.5. Na potrzeby prognozowania produkcji energii elektrycznej elektrowni wiatrowej FW4 przebadano 630 różnych sieci neuronowych. Prognozy generowano dla zbioru danych wejściowych oraz struktury sieci zgodnie z Tabelą 4.3 oraz 4.5 dla elektrowni FW4. Porównując prognozy z rzeczywistymi danymi na Rysunku 4.16 widoczna jest dokładność zaproponowanego modelu.




Rysunek 4.16: Prognoza produkcji energii dla elektrowni wiatrowej FW4


Rysunek 4.17 zawiera porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) w zależności od badanej struktury sieci neuronowej.

Na Rysunkach 4.18a i b zamieszczono porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) - w zależności od struktury danych wejściowych.

Z Rysunków 4.17-4.18 wynika, że dla elektrowni wiatrowej FW4 prognozy charakteryzują się największą dokładnością dla struktury danych nr 4 oraz struktury sieci nr 1/2 zależnie od wybranego błędu prognozy MAE/MAPE.




(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.17: Zestawienie dokładności prognoz ze względu na wybraną strukturę sieci neuronowej dla elektrowni wiatrowej FW4



(a) Błąd MAE



(b) Błąd MAPE

Rysunek 4.18: Zestawienie dokładności prognoz ze względu na wybraną strukturę danych dla elektrowni wiatrowej FW4


4.4.2 Prognozowanie produkcji energii elektrowni fotowoltaicznej

Na podstawie przeprowadzonych badań wybrano zarówno struktury sieci jak i zbiory danych uczących dla elektrowni PV1. Jako kryterium porównawcze struktury danych wybrano absolutny błąd MAE (4.12) oraz absolutny procentowy błąd prognozy MAPE (4.18) wielkości mocy generowanej przez elektrownie.

Ze względu posiadany zbiór danych wejściowych, wykonano analizy dla struktur danych zamieszczonych w Tabeli 4.5. Dane wejściowe dla modelu prognostycznego elektrowni fotowoltaicznej to:


1. natężenie promieniowania słonecznego
2. kierunek wiatru
3. prędkość wiatru
4. temperatura
5. ciśnienie atmosferyczne
6. miesiąc

Na potrzeby prognozowania produkcji energii elektrycznej elektrowni fotowoltaicznej PV1 przebadano 1440 różnych sieci neuronowych. Zestawienie wartości zmierzonych i prognozowanych mocy od natężenia promieniowania słonecznego zamieszczono na Rysunku 4.19.




Rysunek 4.19: Prognoza produkcji energii dla elektrowni fotowoltaicznej PV1

Prognozy generowano dla zbioru danych wejściowych oraz struktury sieci neuronowej zgodnie z Tabelą 4.4. Porównanie dokładności prognoz ze względu na błąd MAE/MAPE w zależności od badanej struktury sieci neuronowej zamieszczono na Rysunku 4.20.




(a) Błąd MAE




(b) Błąd MAPE

Rysunek 4.20: Zestawienie dokładności prognoz ze względu na wybraną strukturę sieci neuronowej dla elektrowni fotowoltaicznej PV1

Rysunki 4.21a-4.21b zawierają porównanie dokładności prognoz ze względu na średni absolutny błąd (MAE) oraz średni absolutny procentowy błąd (MAPE) - w zależności od struktury danych wejściowych.



(a) Błąd MAE



(b) Błąd MAPE

Rysunek 4.21: Zestawienie dokładności prognoz ze względu na wybraną strukturę danych dla elektrowni fotowoltaicznej PV1

Z Rysunków 4.20-4.21 wynika, że dla elektrowni fotowoltaicznej PV1 prognozy charakteryzują się największą dokładnością dla różnych struktury danych w zależności od wybranego kryterium MAE/MAPE) nr 5/11 oraz struktury sieci nr 9/12.

4.5 Podsumowanie

Sieci neuronowe wykorzystane do prognozowania produkcji energii elektrycznej przez elektrownię wiatrową lub fotowoltaiczną dzięki swoim cechom mogą w sposób naturalny uwzględnić czynniki zewnętrzne oraz w razie konieczności zależności z nimi związane. W przypadku rozległych elektrowni, warunki pogodowe w różnych punktach mogą być zróżnicowane, na przykład lokalne zacienienia od chmur, odbicia wiatru wynikające z ukształtowania terenu itp.

Należy pamiętać, że prognozy pogody generowane przez modele numeryczne są to uśrednione dane wygenerowane dla danego punktu siatki prognostycznej. W efekcie informacja ta nie uwzględnia lokalnych warunków. Uczenie sztucznych sieci neuronowych przy wykorzystaniu historycznych danych pozwala otrzymać model uwzględniający lokalne czynniki.

Na podstawie przeprowadzonej analizy wykonano zestawienie wyników symulacji i zamieszczono je w Tabeli 4.6.

Tabela 4.6: Wyznaczone struktury dla badanych obiektów

| | Analizowany obiekt | | | | |
|------------------|--------------------|-----|-----|-----|----|
| | FW1 | FW2 | FW3 | FW4 | PV |
| Kryterium MAE | | | | | |
| Struktura sieci | 7 | 13 | 18 | 1 | 9 |
| Struktura danych | 14 | 16 | 1 | 4 | 5 |
| Kryterium MAPE | | | | | |
| Struktura sieci | 7 | 13 | 18 | 2 | 12 |
| Struktura danych | 14 | 16 | 1 | 4 | 11 |

Jak wynika z Tabeli 4.6 pomimo, iż za każdym razem wykorzystano i przetestowano ten sam zbiór struktur sieci neuronowych to w zależności od obiektu najbardziej korzystne konfiguracje liczby neuronów i warstw różniły się między sobą. Obiekty wyselekcjonowano w taki sposób, aby każdy charakteryzował się indywidualnymi cechami, takimi jak moc zainstalowana, rozległość przestrzenna elektrowni, lokalizacja. W rozprawie analizie poddano dobór struktury danych wejściowych na podstawie których wykonywane były prognozy. Również w tym przypadku w zależności od dostępności danych można było wyszczególnić różne struktury. Podczas prac można było zauważyć, że wprowadzenie

temperatury otoczenia podnosi dokładność prognoz.

Z kolei wprowadzenie parametru takiego jak ciśnienie wprowadza większy szum i prawdopodobieństwo błędnych prognoz. Występowanie dużych błędów jest większe.

Ważnym elementem mającym wpływ na jakość prognozy jest dostępność wiarygodnych i kompletnych danych. Istotnym czynnikiem jest również synchronizacja ich w czasie. Dane wykorzystywane w procesie uczenia pochodzą często z różnych przyrządów pomiarowych, nie posiadających systemu synchronizacji czasu. Sztuczne sieci neuronowe dedykowane do prognozowania produkcji energii mają za zadanie znaleźć funkcję aproksymującą charakterystykę mocy elektrowni. Jak wynika z przeprowadzonej analizy sieci dzięki swoim właściwościom umożliwiają aproksymację dowolnej wielowymiarowej, nieliniowej funkcji - jest to proces relatywnie łatwy, jednak równocześnie czasochłonny. Zaproponowane sieci neuronowe są w stanie wychwycić zależności występujące w elektrowniach wiatrowych oraz fotowoltaicznych.

5 Analiza porównawcza modeli prognostycznych rozwijanych przez jednostki zewnętrzne

W celu weryfikacji modeli prognostycznych wykonanych z użyciem sztucznych sieci neuronowych zaproponowano porównanie ich z dwoma innymi modelami prognostycznymi dedykowanymi do predykcji energii elektrowni wiatrowych. Porównanie było możliwe dzięki realizacji projektu pod nazwą: *Badania nad opracowaniem wytycznych, technik i technologii dla systemów kompensacji mocy biernej, inteligentnego monitoringu wewnętrznych sieci elektroenergetycznych oraz ogniw fotowoltaicznych dedykowanych obiektom hybrydowym opartym wyłącznie o źródła odnawialne*. Projekt współfinansowany był ze środków Europejskiego Funduszu Rozwoju Regionalnego w ramach Programu Operacyjnego Innowacyjna Gospodarka w ramach priorytetu 1 - Badania i rozwój nowoczesnych technologii (Poddziałanie 1.3.1 - Projekty Rozwojowe).

Dane oraz rysunki zostały zaczerpnięte lub opracowane na bazie raportów wykonanych w ramach projektu między innymi:

- Opracowanie modeli neuronowych do prognozowania produkcji energii elektrycznej z elektrowni wiatrowych oraz opracowanie wyników badań na potrzeby monografii na przykładzie elektrowni wiatrowej FW3 [96].
- Opracowanie raportu oceniającego skuteczność prognozowania energii produkowanej przez turbiny wiatrowe metodą regresji wielokrokowej opartej o rozkład kanoniczny zmiennej losowej a metodą prognozowania wykorzystującej sztuczne sieci neuronowe [97].
- Analiza porównawcza jakości działania modeli prognostycznych generacji wiatrowej [98].

Analizę skuteczności prognoz wykonano dla trzech elektrowni wiatrowych oznaczonych jako FW1, FW2, FW3 (Tabela 3.1).

5.1 Metoda Rozkładu Kanonicznego Wektora Zmiennych Losowych (MRK)

Metody oparte o korelację kanoniczną wykorzystywane są w różnych dziedzinach nauki, począwszy od analizy danych finansowych [99], przez prognozowanie cen na giełdzie [13] jak i w energetyce do prognozowania długoterminowego zapotrzebowania na moc

szczytową Krajowego Systemu Energetycznego [100]. Zaproponowana metoda Rozkładu Kanonicznego Wektora Zmiennych Losowych różni się od popularnych obecnie metod bazujących na sztucznej inteligencji. Jest to istotna cecha ze względu na możliwość zastosowania tej metody jako weryfikującej lub współdziałającej z metodami wykorzystującymi na przykład sieci neuronowe tworząc wspólnie metody hybrydowe.

Metoda MRK należy do rodziny metod ekonometryczno–statystycznych. Program wykonuje operacje matematyczno–statystyczne na zmiennych objaśniających w celu pozbycia się problemu współliniowości zmiennych. Model ze względu na swoje właściwości jest uniwersalny pod względem horyzontu czasowego prognozy. Za jego pomocą można budować prognozy: ultrakrótkoterminowe, krótkoterminowe, średnioterminowe i długoterminowe. Dokładność modelu MRK jest zależna od prawidłowego doboru zmiennych objaśniających oraz ich kolejności. Ustalenie kolejności wprowadzania zmiennych do modelu jest jednym z ważniejszych elementów jego przygotowania ponieważ w procesie prognozy wykorzystuje się warunkowe rozkłady prawdopodobieństwa [100].

W literaturze [101][102] można znaleźć różne kryteria właściwej selekcji zmiennych objaśniających w prognostycznych modelach ekonometrycznych. Model MRK opiera się na rozkładzie kanonicznym wektora losowego przez co z definicji spełniona jest większość kryteriów doboru zmiennych [14].

5.1.1 Opis modelu MRK

W metodzie tej [95] przyjmuje się, że pewien proces opisany jest wektorem losowym X , którego składowe są ze sobą skorelowane. W metodzie dąży się do znalezienia wektora V , będącego takim przekształceniem wektora X , którego elementy byłyby ze sobą nieskorelowane oraz będą funkcjami liniowymi składowych wektora X . Powyższe przekształcenie można wykonać stosując metodę rozkładu kanonicznego [100]. Wówczas wektor V można wyznaczyć jako [100]:

$$\begin{aligned}
 V_{1n} &= X_{01n} \\
 V_{2n} &= X_{02n} - a_{21}V_{1n}, \\
 V_{3n} &= X_{03n} - a_{31}V_{1n} - a_{32}V_{2n}, \\
 &\vdots \\
 V_{in} &= X_{0in} - a_{i1}V_{1n} - a_{i2}V_{2n} - \dots - a_{i,i-1}V_{(i-1)n}
 \end{aligned}
 \tag{5.1}$$

Powyższe równanie można zapisać w postaci:

$$V_{in} = X_{0in} - \sum_{j=1}^{i-1} a_{ij} V_{jn} \quad (5.2)$$

dla: $i=1,2,\dots,m$; $j=1,2,\dots,i-1$; $n=1,2,\dots,N$;

gdzie:

- i - numer składowej X_i ,
- m - liczba składowych wektorów \mathbf{X}, \mathbf{V} ,
- n - kolejna obserwacja,
- N - liczba realizacji każdej ze składowych,
- V_i - składowe wektora \mathbf{V} ,
- X_i - składowe wektora \mathbf{X} ,
- $X_{0i} = X_i - \overline{x_{x_i}}$ - zmienna scentralizowana,
- $\overline{x_{X_i}}$ - wartość średnia składowej X_i ,
- $\overline{\mathbf{X}_x}$ - wektor wartości średnich wektora \mathbf{X}_0 ,
- a_{ij} - współczynniki rozkładu kanonicznego zapewniające brak korelacji dla zmiennych V_i .

Podczas budowy modelu współczynniki a_{ij} są wyznaczone ze wzoru:

$$k_{ij} = E\{X_{0i}X_{0j}\} = \frac{1}{T} \sum_{t=1}^T x_{0it} \cdot x_{0jt} \quad (5.3)$$

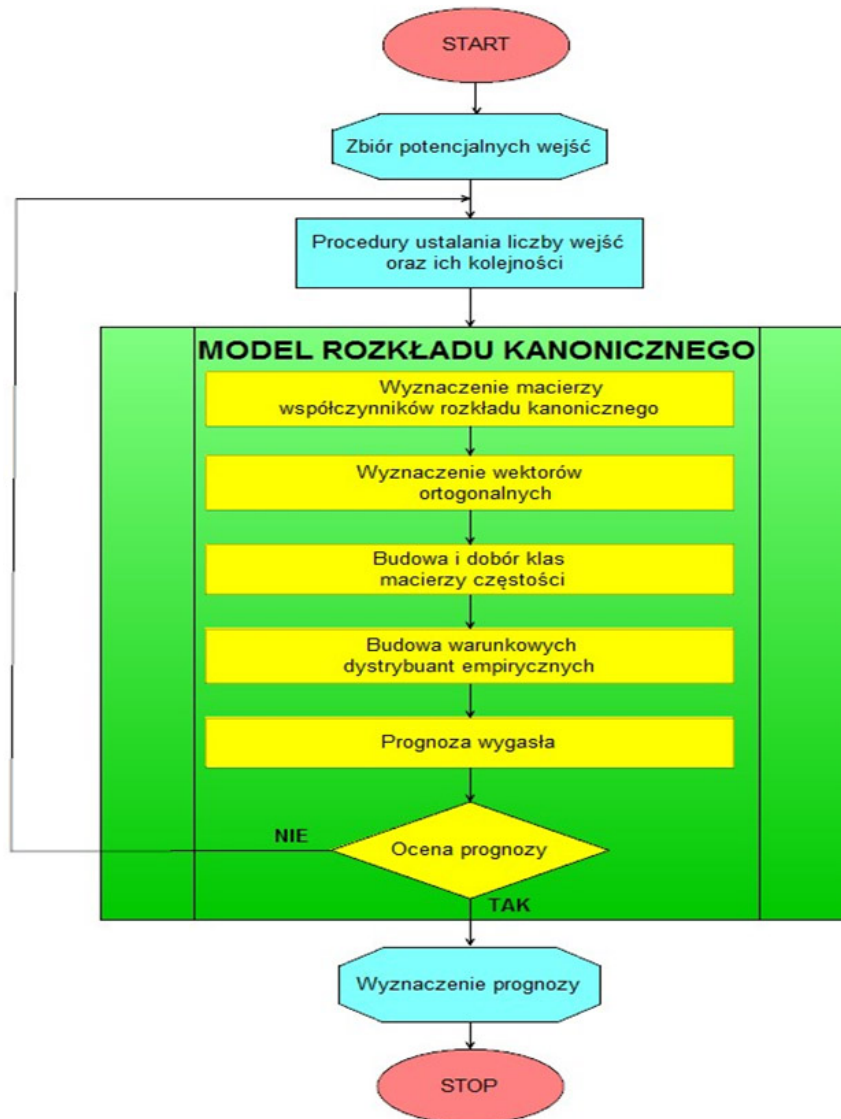
gdzie:

- $k_{ij} = E\{X_{0i}X_{0j}\}$ - moment korelacyjny zmiennych i oraz j ,
- $E\{X_i\}$ - wartość oczekiwana zmiennej X_i .

Procedura prognozy wykorzystująca model MRK została przedstawiona na rysunku 5.1.

Opracowany model [103] oparty na metodzie MRK przeznaczony jest do wykonania ultrakrótkich prognoz mocy wytwarzanej w elektrowniach wiatrowych. Za pomocą aplikacji opracowanej przez autorów na potrzeby opracowania: "Raport z oceny skuteczności prognozowania energii produkowanej przez turbiny wiatrowe przy wykorzystaniu metody regresji wielokrokowej opartej o rozkład kanoniczny wektora zmiennych losowych" wykonano prognozy dla trzech elektrowni wiatrowych z interwałami czasowymi 10. minutowymi (elektrownie FW1, FW2) lub 15. minutowymi (elektrownia FW3) w horyzoncie siedmiodniowym¹².

¹²Zgromadzone dane z obiektów FW1-FW3 pochodziły z różnych systemów pomiaru i gromadzenia danych SCADA, przez co posiadały inne interwały uśredniania danych.



Rysunek 5.1: Schemat blokowy procedury predykcji MRK (źródło: [14])

Kod źródłowy posiadał zaimplementowane metody umożliwiające dobór zmiennych objaśniających w modelu: metodę składowych głównych oraz metodę Hellwiga. Na bazie wielu eksperymentów stwierdzono, że bardziej wydajną metodą pod względem szybkości i wydajności obliczeń jest metoda Hellwiga i tę ostatecznie wybrano do wykonania końcowych prognoz [103]. Model MRK rozbudowano o możliwość wykonania analizy fraktalnej, co umożliwiło zwiększenie dokładności generowanych prognoz. W programie zaimplementowano kilka metod dynamicznego wyznaczania wykładnika Hursta z prędkości wiatru oraz mocy (dodatkowe zmienne wchodzą do modelu jako zmienne opóźnione). Kolejną modyfikacją modelu było wzbogacenie go o możliwość stworzenia hybrydy polegającej na wykorzystaniu własności średniej ruchomej o dowolnej stałej wygładzania tak, aby

w efekcie końcowym prognozy unikać gwałtownych odpowiedzi modelu na losowe skoki zmiennych objaśniających, które powodowały również nieproporcjonalną odpowiedź modelu w postaci przeszacowanych lub niedoszacowanych wartości prognozy [103].

W celu obliczenia wariancji oraz współczynników rozkładu, uwzględniając k zmiennych można posłużyć się wzorem:

$$a_{kl} = \frac{Var_{k1}}{Var_{11}} Var_{X_s} = k_{kk} - \sum_{s=1}^{k-1} a_{ks}^2 Var_{V_s} a_{kl} = \frac{1}{Var_{V_l}(k_{kl} - \sum_{s=1}^{l-1} a_{ks} a_{ls} Var_{V_s})} \quad (5.4)$$

gdzie:

Var_{11} - wariancja zmiennej X_{0i} ,

Var_{X_s} - wariancja s-tej składowej w kategorii X,

Var_{V_s} - wariancja s-tej składowej w kategorii V.

Upraszczając układ równań 5.1 poprzez pominięcie indeksu n oznaczającego kolejne obserwacje, otrzymuje się:

$$\begin{aligned} X_{01} &= V_{01} \\ X_{02} &= a_{21}V_1 + V_2, \\ X_{03} &= a_{31}V_1 + a_{32}V_2 + V_3, \\ &\vdots \\ X_{0m} &= a_{m1}V_1 + a_{m2}V_2 + \dots + a_{m,m-1}V_{m-1} + V_m, \end{aligned} \quad (5.5)$$

W procesie prognozy metodą MRK występowały dwa przypadki z punktu widzenia wektora X:

- Znana jest realizacja tylko pierwszej składowej X_1 - wtedy pozostałe składowe X_2, \dots, X_{m-1}, X_m są prognozowane.
- Znane są realizacje p składowych poprzedzających prognozę, wówczas prognozowanych jest (m=p) zmiennych.

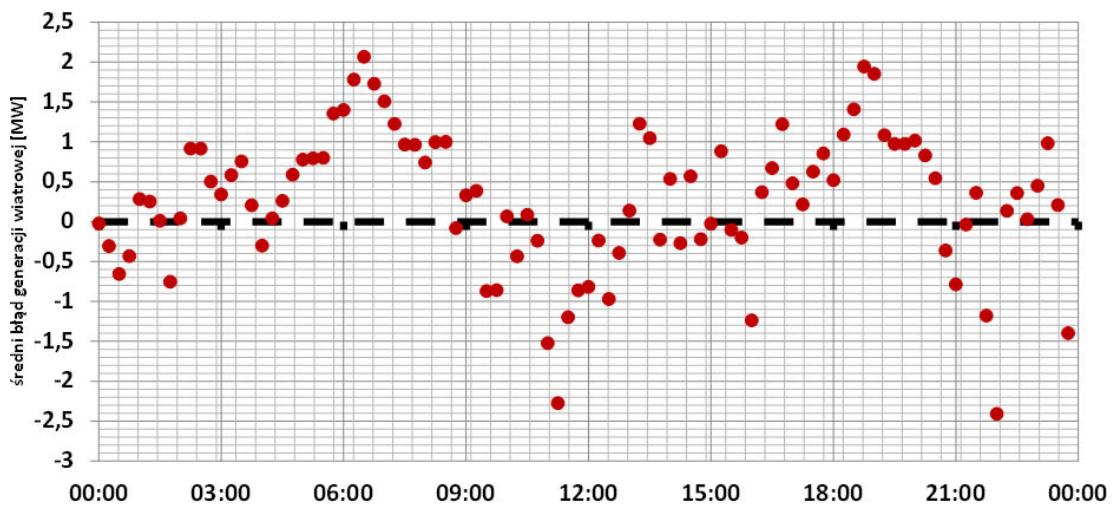
Zmienne X_1, X_2, \dots, X_p są przyjmowane jako zmienne objaśniające, natomiast składowe X_{p+1} wraz z kolejnymi są zmiennymi endogenicznymi.

Należy pamiętać, że proces doboru zmiennych i ich kolejności w wektorze losowym jest bardzo czasochłonny. Istnieją metody np. Hellwiga [104], które pozwalają skrócić ten czas, jednak czasochłonność opracowania prognozy gwałtownie rośnie wraz z liczbą zmiennych uwzględnianych w modelu.


5.1.2 Analiza dokładności i wiarygodności prognoz

W rozdziale tym przedstawiono wybrane wyniki prognoz wykonane metodą MRK dla trzech farm wiatrowych FW1, FW2 (rozdzielczość prognoz 15 min) oraz FW3 (rozdzielczość prognoz 10 min) w wybranych okresach czasowych.


Na rysunkach od 5.2, 5.4, 5.6 zaprezentowano wykresy błędu bezwzględnego prognoz mocy elektrowni wiatrowych dla okresu od 25.08.2013 r. do 31.08.2013 r, kolejno dla obiektów FW1, FW2, FW3. Natomiast na rysunkach 5.3, 5.5, 5.7 przedstawiono wykres błędów względnych dla tych samych obiektów i okresu.




Rysunek 5.2: Metoda MRK - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW1 o mocy zainstalowanej 20 MW [103]




Rysunek 5.3: Metoda MRK - Wartość średniego błędu względnego prognoz generacji wiatrowej elektrowni FW1 o mocy zainstalowanej 20 MW [103]




Rysunek 5.4: Metoda MRK - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW2 o mocy zainstalowanej 120 MW [103]



Rysunek 5.5: Metoda MRK - Wartość średniego błędu względnego prognoz generacji wiatrowej elektrowni FW2 o mocy zainstalowanej 120 MW [103]



Rysunek 5.6: Metoda MRK - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW3 o mocy zainstalowanej 30 MW [103]



Rysunek 5.7: Metoda MRK - Wartość średniego błędu względnego prognoz generacji wiatrowej elektrowni FW3 o mocy zainstalowanej 30 MW [103]

Na rysunkach 5.2 oraz 5.6 widoczna jest zmienność błędów w zakresie od -2,5 MW do 2 MW. Zdecydowanie większe wartości błędów zarejestrowano dla elektrowni wiatrowej FW2. W przypadku tego obiektu błąd bezwzględny prognoz zmieniał się w granicach od -17 MW do 9 MW. Różnice te spowodowane są wielkością elektrowni (zarówno pod względem zajmowanego obszaru jak i mocy zainstalowanej) dla jakiej wykonano prognozy. Bardziej miarodajnym parametrem oceny jakości prognoz jest błąd względny prognoz, który umożliwia bieżącą ocenę przeszacowania lub niedoszacowania prognozy.

Jak wynika z rysunków 5.5 oraz 5.7 zmienność błędów względnego zawiera się w przedziale od -1,5 do 1,5%. Większe błędy prognozy zarejestrowano dla farmy wiatrowej FW1, dla której błąd zmieniał się w zakresie od -1,5 do 2,6%

Z powyższych wykresów wynika, że metoda prognoz MRK dobrze sprawdza się w prognozowaniu generacji energii w elektrowniach opartych o odnawialne źródła energii. Jak widać metoda dobrze poradziła sobie również z dużym zróżnicowaniem elektrowni, zarówno pod względem mocy zainstalowanej, jak i lokalnych warunków atmosferycznych związanych z obszarem zajmowanym przez daną elektrownię. Jak zauważono w opracowaniu [103] największy wpływ na dokładność prognozy miała prędkość wiatru. Wyniki prognoz opracowane z wykorzystaniem metody Rozkładu Kanonicznego Wektora Zmiennej Losowych zostaną poddane analizie porównawczej w kolejnym rozdziale.

5.2 Metoda adaptacyjnej krzywej mocy (AKM)

Jest to metoda pozwalająca na symulację pracy turbiny wiatrowej lub elektrowni przy wykorzystaniu oszacowanej charakterystyki mocy.

Graficznie charakterystyka mocy elektrowni wiatrowej przedstawia zmiany wartości produkcji energii elektrycznej [kW] w funkcji prędkości wiatru [m/s] [15].


Jak podają autorzy pracy [15] dominującym czynnikiem jaki ma wpływ na generowaną moc elektrowni jest prędkość wiatru. Dlatego im dokładniejsza jest prognoza prędkości wiatru tym precyzyjniejsza będzie predykcja mocy wytworzonej przez elektrownię wiatrową.

5.2.1 Opis modelu AKM

Model Adaptacyjnej Krzywej Mocy został opracowany na podstawie danych historycznych (prędkości wiatru oraz mocy generowanej przez turbinę). Rzeczywista zależność mocy od prędkości wiatru (z powodu wielu czynników) odbiega od idealnej charakterystyki zaprezentowanej na rysunku 5.8 oraz deklarowanej przez producenta turbiny. W efekcie otrzymuje się nieregularny przebieg, który należy poddać aproksymacji funkcją sigmoidalną [105]:

$$f(x) = \frac{c}{1 + e^{-a(x-b)}} \quad (5.6)$$


gdzie: a, b, c – współczynniki aproksymujące charakterystykę.




Rysunek 5.8: Charakterystyka mocy dla elektrowni wiatrowej FW3 [15]

W modelu AKM kryterium dopasowania jest minimalizacja błędu średniokwadratowego. W rezultacie otrzymuje się charakterystykę, wykorzystywaną w kolejnych etapach do wyznaczenia prognozy generowanej mocy.

Rysunek 5.9 przedstawia zarejestrowane dane historyczne turbiny wiatrowej elektrowni FW2 oraz wyznaczoną na ich podstawie funkcję aproksymującą. Na rysunku 5.10 przedstawiono przykładowy podział danych pomiarowych na klasy.



Rysunek 5.9: Zależność mocy od prędkości wiatru elektrowni FW2 dla metody AKM [15]



Rysunek 5.10: Podział danych elektrowni FW1 na klastry z zaznaczeniem centroidów dla metody AKM [15]


Autorzy raportu [15] zwracają uwagę na najważniejsze problemy związane z wykonaniem prognoz. Zaliczyć do nich można liczbę danych pomiarowych zgromadzonych dla poszczególnych elektrowni wiatrowych. Zbiór historycznych danych to w zależności od obiektu oraz czasu uśredniania dziesiątki tysięcy wierszy danych. Dane te jednocześnie służą do budowy modelu i wyznaczenia współczynników aproksymujących. Tak duża liczba informacji może spowodować wydłużenie czasu przygotowania prognozy. W celu zredukowania tego czasu autorzy zaproponowali wykorzystanie metody k-średnich. Pozwoliło to na podzielenie zbioru na kilka klastrów wraz z centroidami, które stały się jednocześnie zbiorami danych na podstawie których przeliczono model.

Wykonane badania weryfikujące wpływ grupowania danych na błąd prognozy [99] potwierdzają, że różnice w wielkościach wyznaczonych błędów są małe. W związku z tym można przyjąć, że metoda grupowania danych ma niewielki wpływ na średni błąd otrzymanej prognozy. Metody grupowania mogą być szczególnie przydatne w przypadku struktur, w których mamy do czynienia z dużą liczbą danych, jak na przykład systemy agregujące wiele elektrowni.


5.2.2 Analiza dokładności i wiarygodności prognoz

W rozdziale zamieszczono wybrane wyniki prognoz wykonane metodą AKM dla trzech farm wiatrowych FW1, FW2 (rozdzielczość prognoz 15 min) oraz FW3 (rozdzielczość prognoz 10 min) z wybranego miesiąca.


Na rysunkach 5.11-5.16 zaprezentowano wykresy średniego błędu bezwzględnego prognoz generacji wiatrowej dla lipca, kolejno dla farm wiatrowych FW1, FW2, FW3.




Rysunek 5.11: Metoda AKM - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW1 o mocy zainstalowanej 20 MW (dzień 26.08.2013 r.) [15]




Rysunek 5.12: Metoda AKM - Wartość średniego znormalizowanego błędu względnego prognoz generacji wiatrowej elektrowni FW1 o mocy zainstalowanej 20 MW [15]




Rysunek 5.13: Metoda AKM - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW2 o mocy zainstalowanej 120 MW (dzień 26.08.2013 r.) [15]



Rysunek 5.14: Metoda AKM - Wartość średniego znormalizowanego błędu względnego prognoz generacji wiatrowej elektrowni FW2 o mocy zainstalowanej 120 MW [15]



Rysunek 5.15: Metoda AKM - Wartość średniego błędu bezwzględnego prognoz generacji wiatrowej elektrowni FW3 o mocy zainstalowanej 30 MW (dzień 26.08.2013 r.) [15]



Rysunek 5.16: Metoda AKM - Wartość średniego znormalizowanego błędu względnego prognoz generacji wiatrowej elektrowni FW3 o mocy zainstalowanej 30 MW [15]

Analizując rysunki 5.11-5.15 można zauważyć zmienność błędu bezwzględnego w zależności od dnia prognozy. Widoczne są także pojedyncze kilkukrotnie większe od średniego błędu bezwzględnego błędy prognozy. Tak duże jednostkowe błędy predykcji mogą być spowodowane błędnym działaniem modelu prognostycznego lub być skutkiem nietypowego działania elektrowni. Może to być np. efekt czasowego wyłączenia turbin z powodów eksploatacyjnych, wystąpienia znacznych podmuchów wiatru wyłączających turbiny ze względów bezpieczeństwa lub zbyt małych prędkości poniżej wartości startowej.


Jak wynika z rysunków 5.11-5.15 model AKM dobrze radzi sobie z prognozowaniem mocy dla elektrowni wiatrowych niezależnie od mocy zainstalowanej jak i lokalizacji farmy. Wynikowe prognozy opracowane z wykorzystaniem metody Adaptacyjnej Krzywej Mocy zostaną poddane analizie porównawczej w kolejnym rozdziale.

5.3 Porównanie dokładności prognoz generowanych przez modele oparte o SNN, AKM i MRK

W celu weryfikacji poprawności oraz jakości generowanych prognoz metodę sztucznych sieci neuronowych (SNN), porównano z symulacjami wykonanym przy wykorzystaniu MRK oraz AKM. W tym celu przygotowano zbiór danych uczących, który również posłużył do budowy pozostałych modeli. Przygotowano dodatkowe dane dla okresu 1 roku, które posłużyły jako zbiór danych weryfikujących i porównawczych.

5.3.1 Elektrownia wiatrowa FW1

W celu wykonania porównania zaproponowano i przygotowano sieć neuronową, wzorując się na wynikach Rozdziału 4 tabela 4.2 oraz 4.6. Do prognozowania zastosowano sieć składającą się z trzech warstw ukrytych z pięcioma neuronami. Modele MRK oraz AKM w czasie prognozowania uwzględniały jedynie prędkość wiatru jako daną wejściową, dlatego do predykcji przy użyciu sieci neuronowej wybrano strukturę danych wejściowych nr 1 (Tabela 4.2). Sieć wielokrotnie uczono w celu minimalizacji błędu MAE prognozy. Wynik uczenia zaprezentowano na Rysunku 5.17.




Rysunek 5.17: Zmierzona oraz prognozowana charakterystyka mocy elektrowni wiatrowej FW1

Na przedstawionej krzywej mocy widoczne są różnice pomiędzy próbkami zmierzonymi i prognozowanymi. Jest to wynik doboru struktury danych uwzględniającej jedną daną wejściową - prędkość wiatru.

Rzeczywista produkcja energii elektrowni wiatrowej zależy też od innych czynników pogodowych co szerzej opisano w Rozdziale 3.

Porównanie wyników prognoz wykonanych przy użyciu modeli SNN, MRK, i AKM zamieszczono na rysunkach 5.18-5.23.




Rysunek 5.18: Prognozowana charakterystyka mocy elektrowni wiatrowej FW1 - porównanie


Prognozy wykonane zostały dla reprezentatywnego okresu 1 roku, na Rysunku 5.22 przedstawiono miesięczne błędy MAE dla poszczególnych modeli prognostycznych.

Zmienność wielkości produkcji energii w elektrowniach wiatrowych w czasie jest znaczna. W celu zobrazowania trudności z jaką muszą poradzić sobie modele zamieszczono Rysunki 5.19-5.21.


Jak można zauważyć na Rysunku 5.20 w pełnym okresie miesiąca Maja zbieżność prognoz wygenerowanych przez poszczególne modele z danymi zmierzonymi jest znaczna - błąd MAE: 0,54 MW (MRK), 0,42 MW (AKM), 0,39 MW (SNN). Narzędziem dobrze obrazującym dokładność prognoz dla dużego zbioru danych jest dystrybuanta błędów prognoz, którą zamieszczono na Rysunku 5.23.




Rysunek 5.19: Porównanie prognoz elektrowni wiatrowej FW1 - miesiąc maj




Rysunek 5.20: Błąd prognozy mocy elektrowni wiatrowej FW1 - miesiąc maj



Rysunek 5.21: Porównanie prognoz elektrowni wiatrowej FW1 - dzień 22.05.2013 r.



Rysunek 5.22: Porównanie prognoz elektrowni wiatrowej FW1 - w poszczególnych miesiącach roku




Rysunek 5.23: Dystrybuanta błędu prognozy mocy elektrowni wiatrowej FW1 wyznaczona dla okresu 1 roku

Zaproponowana metoda sztucznych sieci neuronowych w porównaniu do pozostałych generuje prognozy z mniejszym błędem. Zdarzają się jednak okresy dla których dokładność proponowanego modelu jest mniejsza (np. w lutym lub listopadzie). Jak opisano w rozdziale 4 wyniki prognoz mogą być jeszcze lepsze uwzględniając dodatkowe czynniki (poza prędkością wiatru) w zbiorze wejściowym modelu prognostycznego.


5.3.2 Elektrownia wiatrowa FW2

Dla kolejnej analizowanej elektrowni wiatrowej FW2 również zaproponowano i przygotowano sieć neuronową w celu wykonania porównania. Do prognozowania wykorzystano sieć składającą się z czterech warstw ukrytych po piętnaście neuronów w każdej warstwie - rozdział 4 tabela 4.2 oraz 4.6. Do predykcji przy użyciu sieci neuronowej wybrano strukturę danych wejściowych nr 2 (Tabela 4.2). Sieć wielokrotnie uczono w celu minimalizacji błędu MAE prognozy. Wynik uczenia sieci neuronowej SNN oraz porównanie wyników prognoz wykonanych przy użyciu modeli MRK i AKM zamieszczono na Rysunku 5.24. Podobnie jak w przypadku elektrowni FW1 na przedstawionej charakterystyce mocy widoczne są różnice pomiędzy danymi zmierzonymi i prognozowanymi. Są one nieco mniejsze ponieważ do prognozowania użyto oprócz prędkości wiatru również informację

dotyczącą liczby pracujących turbin. Prognozy wykonane zostały dla okresu 1 roku. Na Rysunku 5.25 przedstawiono miesięczne błędy MAE dla poszczególnych modeli prognozy stycznych.




Rysunek 5.24: Prognozowana charakterystyka mocy elektrowni wiatrowej FW2 - porównanie




Rysunek 5.25: Porównanie prognoz elektrowni wiatrowej FW2 - w poszczególnych miesiącach roku


Również dla tej elektrowni zmienność mocy w czasie jest znaczna, co można zaobserwować na Rysunkach 5.26-5.28. Narzędziem dobrze obrazującym dokładność prognoz dla dużego zbioru danych jest dystrybuanta błędu prognoz, również dla elektrowni FW2 wykonano odpowiednie zestawienie i zamieszczono na Rysunku 5.29.




Rysunek 5.26: Porównanie prognoz elektrowni wiatrowej FW2 - miesiąc maj



Rysunek 5.27: Błąd prognozy mocy elektrowni FW2 - miesiąc maj



Rysunek 5.28: Porównanie prognoz elektrowni wiatrowej FW2 - dzień 22.05.2013 r.



Rysunek 5.29: Dystrybuanta błędu prognozy dla elektrowni wiatrowej FW2


Dystrybuanta zaproponowanego modelu sieci neuronowej w całym zakresie mocy znajduje się po lewej stronie pozostałych charakterystyk, co potwierdza że charakteryzuje się on większą dokładnością prognozy.

5.3.3 Elektrownia wiatrowa FW3

Trzecią analizowaną elektrownią wiatrową dla której wykonano porównanie prognoz jest obiekt oznaczony jako FW3.

Do prognozowania wykorzystano sieć składającą się z czterech warstw ukrytych po dwadzieścia pięć neuronów w każdej warstwie - rozdział 4 Tabela 4.2 oraz 4.6. Modele MRK oraz AKM w czasie prognozowania uwzględniały jedynie prędkość wiatru jako daną wejściową, dlatego do predykcji przy użyciu sieci neuronowej wybrano strukturę danych wejściowych nr 1 (Tabela 4.2).


Sieć wielokrotnie uczono w celu znalezienia wag połączeń sieci neuronowych dla których błąd MAE prognozy będzie najmniejszy. Wynik uczenia zaprezentowano na Rysunku 5.30.




Rysunek 5.30: Zmierzona oraz prognozowana charakterystyka mocy elektrowni wiatrowej FW3

Porównanie wyników prognoz wykonanych przy użyciu modeli SNN, MRK, i AKM zamieszczono na Rysunku 5.31. Prognozy wygenerowane przez poszczególne modele zostały wykonane dla tego samego okresu 1 roku.

Na Rysunku 5.32 przedstawiono miesięczne błędy MAE dla poszczególnych modeli prognostycznych.




Rysunek 5.31: Prognozowana charakterystyka mocy elektrowni wiatrowej FW3 - porównanie




Rysunek 5.32: Porównanie prognoz elektrowni wiatrowej FW3 - w poszczególnych miesiącach roku


Zmienność wielkości produkcji energii i prognoz w czasie przedstawiono przykładowo na Rysunkach 5.33-5.34. Na Rysunku 5.35 zamieszczono dystrybuantę błędów prognoz. Jak można zauważyć modele SNN i AKM posiadają zbliżony rozkład błędów i jest on w całym zakresie mniejszy lub porównywalny do MRK.



Rysunek 5.33: Porównanie prognoz elektrowni wiatrowej FW3 - Miesiąc Maj



Rysunek 5.34: Porównanie prognoz elektrowni wiatrowej FW3 - dzień 22.05.2013 r.



Rysunek 5.35: Dystrybuanta błędów prognozy dla elektrowni wiatrowej FW3

5.4 Podsumowanie

Do najistotniejszych zalet porównywanych metod należą:

1. Metoda regresji wielokrokowej opartej o rozkład kanoniczny zmiennej losowej (MRK)
 - rodzina metod ekonometryczno – statystycznych
 - uniwersalność pod względem horyzontu prognozy
 - model usprawniony dzięki implementacji kilku metod dynamicznego wyznaczania wykładnika Hursta oraz wprowadzeniu dodatkowych zmiennych do modelu
 - model może bazować na różnych danych objaśniających
 - możliwość zwiększenia dokładności modelu poprzez implementację np. metody składowych głównych Pojemności Integralnej Hellwiga, elementów analizy fraktalnej.

2. Metoda adaptacyjnej krzywej mocy (AKM)
 - odwzorowanie krzywej mocy dla całej elektrowni
 - uniwersalność pod względem horyzontu prognozy
 - możliwość bazowania na różnych danych wejściowych
 - predykcja wykonana na podstawie funkcji aproksymującej
 - możliwość usprawnienia oraz zwiększenia dokładności modelu poprzez metodę k-

średnich i budowania charakterystyk w zależności od liczby pracujących obiektów.

3. Metoda oparta o sztuczne sieci neuronowe (SNN)

- rodzina metod statystycznych
- uniwersalność pod względem horyzontu prognozy
- możliwość bazowania na różnych danych wejściowych
- możliwość prognozy różnych danych wyjściowych
- odporność na częściową utratę danych np. wag połączeń, poprzez ponowne uczenie sieci
- uniwersalność i szybkość metody
- zdolność do uogólniania zdobytej wiedzy
- możliwość usprawnienia oraz zwiększenia dokładności modelu poprzez dobór istotnych danych wejściowych, struktury sieci.

Na podstawie przeprowadzonej analizy w Tabelach 5.1-5.3 zestawiono wyniki prognoz wykonanych przy użyciu metod:

- Rozkładu Kanonicznego Wektora Zmiennych Losowych (MRK).
- Adaptacyjnej krzywej mocy (AKM).
- Sztucznych sieci neuronowych (SNN).

Wybrano cztery kryteria oceny dokładności prognoz. Są to:

- Średni absolutny błąd prognozy (MAE).
- Średni absolutny procentowy błąd prognozy (MAPE).
- Procentowy udział błędów mniejszych od 2,5% oraz 5% mocy zainstalowanej elektrowni.

Jak wynika z porównania wszystkie trzy metody: rozkład kanoniczny wektora zmiennych losowych, adaptacyjna krzywa mocy oraz prognozowania wykorzystująca sztuczne sieci neuronowe pozwoliły na wygenerowanie precyzyjnych prognoz. Jak widać na Rysunkach 5.22, 5.25, 5.32 dla wielu okresów sieci neuronowe generowały precyzyjniejsze prognozy.

W wielu przypadkach zauważono duże błędy prognoz występujące dla wszystkich trzech analizowanych metod. Takie zachowanie modeli opartych o różne metody prognozyczne może świadczyć o nieprawidłowości w pomiarze lub zapisie prędkości wiatru.

Wszystkie trzy zaproponowane metody mają swoje zalety oraz widoczny jest ich potencjał. Połączenie i wykorzystanie możliwości wszystkich trzech metod mogłoby pozwolić na osiągnięcie efektu synergii.

Tabela 5.1: Porównanie modeli prognostycznych MRK, AKM i SNN - elektrownia FW1

| Parametr | | Model | Minimalnie | Średnio | Maksymalnie |
|---|------|------------|------------|-------------|-------------|
| MAE | [MW] | MRK | 0,37 | 0,79 | 1,9 |
| | [MW] | AKM | 0,33 | 0,65 | 1,81 |
| | [MW] | SNN | 0,3 | 0,59 | 1,72 |
| MAPE | [%] | MRK | 16 | 21 | 27 |
| | [%] | AKM | 8 | 14 | 18 |
| | [%] | SNN | 9 | 13 | 16 |
| Błąd $\leq 2,5\%$ mocy zainstalowanej | [%] | MRK | 34 | 57 | 73 |
| | [%] | AKM | 45 | 70 | 82 |
| | [%] | SNN | 32 | 65 | 81 |
| Błąd $\leq 5\%$ mocy zainstalowanej | [%] | MRK | 55 | 79 | 92 |
| | [%] | AKM | 65 | 87 | 95 |
| | [%] | SNN | 56 | 84 | 94 |

Tabela 5.2: Porównanie modeli prognostycznych MRK, AKM i SNN - elektrownia FW2

| Parametr | | Model | Minimalnie | Średnio | Maksymalnie |
|---|------|------------|-------------|-------------|-------------|
| MAE | [MW] | MRK | 2,63 | 4,35 | 7,57 |
| | [MW] | AKM | 2,53 | 3,64 | 6,06 |
| | [MW] | SNN | 2,11 | 3,14 | 5,03 |
| MAPE | [%] | MRK | 24 | 35 | 52 |
| | [%] | AKM | 18 | 28 | 49 |
| | [%] | SNN | 14 | 21 | 31 |
| Błąd $\leq 2,5\%$ mocy zainstalowanej | [%] | MRK | 40 | 56 | 71 |
| | [%] | AKM | 43 | 63 | 73 |
| | [%] | SNN | 44 | 65 | 76 |
| Błąd $\leq 5\%$ mocy zainstalowanej | [%] | MRK | 64 | 78 | 87 |
| | [%] | AKM | 68 | 85 | 90 |
| | [%] | SNN | 69 | 86 | 91 |

Tabela 5.3: Porównanie modeli prognostycznych MRK, AKM i SNN - elektrownia FW3

| Parametr | | Model | Minimalnie | Średnio | Maksymalnie |
|---|------|------------|-------------|-------------|-------------|
| MAE | [MW] | MRK | 0,43 | 1,14 | 3,44 |
| | [MW] | AKM | 0,23 | 0,83 | 3,77 |
| | [MW] | SNN | 0,21 | 0,70 | 3,75 |
| MAPE | [%] | MRK | 15 | 23 | 33 |
| | [%] | AKM | 7 | 11 | 35 |
| | [%] | SNN | 6 | 10 | 33 |
| Błąd $\leq 2,5\%$ mocy zainstalowanej | [%] | MRK | 43 | 67 | 86 |
| | [%] | AKM | 49 | 79 | 93 |
| | [%] | SNN | 48 | 80 | 95 |
| Błąd $\leq 5\%$ mocy zainstalowanej | [%] | MRK | 61 | 82 | 96 |
| | [%] | AKM | 70 | 93 | 99 |
| | [%] | SNN | 68 | 93 | 99 |

Można oczekiwać, że wyniki prognoz uzyskane za pomocą SNN przy wykorzystaniu dodatkowych danych wejściowych istotność, których została udowodniona w poprzednich rozdziałach byłyby jeszcze lepsze.

Kolejny rozdział poświęcono prognozowaniu produkcji energii elektrowni wiatrowych z wykorzystaniem danych pochodzących z kilku numerycznych prognoz pogody oraz sposobom ich korekty.


6 Wielopunktowa korekta prognoz produkcji energii elektrowni wiatrowej

Zwiększenie dokładności modeli prognostycznych generacji energii w elektrowniach wiatrowych i fotowoltaicznych wiąże się nie tylko z koniecznością doboru właściwej struktury danych wejściowych oraz sieci np. liczba neuronów w poszczególnych warstwach (co zostało opisane w Rozdziale 4), ale przede wszystkim potrzeby zapewnienia precyzyjnych danych wejściowych do modelu.

Modele prognostyczne bazują na danych pochodzących z numerycznych prognoz pogody, które są obciążone błędem oraz niedokładnością wynikającą z ograniczonej rozdzielczości siatki prognostycznej. Ważne jest zwiększenie dokładności prognozowanych parametrów pogodowych w porównaniu do rzeczywistych warunków występujących w najbliższym otoczeniu elektrowni.

6.1 Wielopunktowa korekta prognoz pogody

Rysunek 6.1 przedstawia korelację zmierzonych oraz prognozowanych przy pomocy NWP prędkości wiatru dla punktu zlokalizowanego najbliżej elektrowni.



Rysunek 6.1: Korelacja zmierzonych oraz prognozowanych NWP prędkości wiatru dla elektrowni FW4

Na rysunku 6.1 można zauważyć występowanie znacznych rozbieżności w prognozowanych oraz zmierzonych prędkościach wiatru. Punkty nieliniowo rozkładają się na powierzchni rysunku. Największe rozbieżności występują dla zmierzonych prędkości wiatru 4-10 m/s. W tym przedziale prognozy NWP charakteryzują się największym rozrzutem punktów w osi pionowej względem wartości zmierzonych. W tym zakresie charakterystyka mocy elektrowni wiatrowej jest silnie nieliniowa, co dodatkowo utrudnia predykcję i zwiększa jej błędy.

W celu zwiększenia dokładności prognoz zaproponowano przygotowanie dedykowanej sieci neuronowej, która ma na celu korektę numerycznych prognoz pogody. Sieci neuronowe bazują na danych pochodzących z wielu punktów zlokalizowanych w okolicy elektrowni. Do prognozowania wykorzystano ponadto dane z dwóch portali pogodowych udostępniających dane z NWP takie jak prędkość i kierunek wiatru, temperatura otoczenia i punktu rosy, ciśnienie oraz wilgotność. Struktury danych wejściowych porównano niezależnie, przyjmując jako kryterium absolutny błąd MAE oraz absolutny procentowy błąd (MAPE) predykcji.

Na potrzeby korekty prognozowanej prędkości wiatru elektrowni wiatrowej FW4 przebadano 1800 sieci neuronowych. Do prognozowania zaproponowano 30 struktur sieci neuronowych z liczbą warstw od 2 do 4 oraz neuronów w warstwie od 5 do 45 neuronów (Tabela 6.1).

Sieci zawierające większą liczbę neuronów oraz warstw wymagały do obliczeń wykorzystanie specjalnie przygotowanej jednostki obliczeniowej. Serwer wyposażono w dwa czterordzeniowe procesory o częstotliwości 3,00 GHz oraz pamięci operacyjnej 32 GB. Pomimo takich parametrów czas znalezienia macierzy wag sieci wynosił niejednokrotnie ponad 1 godzinę.


6.1.1 Wybór struktury sieci neuronowej

Porównanie dokładności prognoz (prędkości wiatru i temperatury) ze względu na średni absolutny błąd (MAE) w zależności od struktury sieci neuronowej zamieszczono na Rysunku 6.2a. Wykonano również analogiczne porównanie dokładności prognoz ze względu na średni procentowy błąd (MAPE) w zależności od struktury sieci neuronowej i zamieszczono je na Rysunku 6.2b. Rysunki 6.2a i b potwierdzają wpływ liczby neuronów na błąd prognozy. Im neuronów było więcej, tym skorygowana wartość prędkości wiatru była bardziej zbliżona do zmierzonej.


Tabela 6.1: Struktury sieci neuronowych - prognoza wielopunktowa

| L.P. | Liczba neuronów w warstwach | | | Liczba warstw ukrytych |
|------|-----------------------------|----------|------------|------------------------|
| | wejściowej | ukrytych | wyjściowej | |
| 1 | N* | 5 | 1 | 2 |
| 2 | | 7 | | |
| 3 | | 10 | | |
| 4 | | 15 | | |
| 5 | | 20 | | |
| 6 | | 25 | | |
| 7 | | 30 | | |
| 8 | | 35 | | |
| 9 | | 40 | | |
| 10 | | 45 | | |
| 11 | N* | 5 | 1 | 3 |
| 12 | | 7 | | |
| 13 | | 10 | | |
| 14 | | 15 | | |
| 15 | | 20 | | |
| 16 | | 25 | | |
| 17 | | 30 | | |
| 18 | | 35 | | |
| 19 | | 40 | | |
| 20 | | 45 | | |
| 21 | N* | 5 | 1 | 4 |
| 22 | | 7 | | |
| 23 | | 10 | | |
| 24 | | 15 | | |
| 25 | | 20 | | |
| 26 | | 25 | | |
| 27 | | 30 | | |
| 28 | | 35 | | |
| 29 | | 40 | | |
| 30 | | 45 | | |

* - liczba neuronów wejściowych N zależy od liczby strumieni danych wejściowych



(a) Błąd MAE



(b) Błąd MAPE

Rysunek 6.2: Porównanie struktur sieci neuronowych dla elektrowni wiatrowej FW4

Dla struktur 19 oraz 20 dalsze zwiększanie liczby neuronów nie wykazało zwiększenia dokładności prognoz. Zmiana liczby warstw ukrytych wiąże się z wydłużeniem procesu uczenia sieci i jedynie w ograniczonym zakresie przykłada się na jakość predykcji.


W Tabeli 6.2 zamieszczono zestawienie liczbowe średniego absolutnego błędu predykcji prędkości wiatru względem wartości zmierzonych.

Tabela 6.2: Porównanie struktur sieci neuronowych - Błąd MAE [m/s]

| Liczba warstw | Liczba neuronów | | | | | | | | | |
|---------------|-----------------|------|------|------|------|------|------|------|------|------|
| | 5 | 7 | 10 | 15 | 20 | 25 | 30 | 35 | 40 | 45 |
| 2 | 1,14 | 1,07 | 0,99 | 0,83 | 0,72 | 0,61 | 0,52 | 0,45 | 0,39 | 0,36 |
| 3 | 1,10 | 1,03 | 0,91 | 0,71 | 0,56 | 0,46 | 0,39 | 0,35 | 0,32 | 0,34 |
| 4 | 1,10 | 1,00 | 0,85 | 0,62 | 0,47 | 0,39 | 0,33 | 0,32 | 0,32 | 0,30 |

6.1.2 Wybór struktury danych wejściowych

Na potrzeby prognozowano zaproponowano 12 struktur danych zawierających informacje z 6 punktów zlokalizowanych w okolicy elektrowni wiatrowej pochodzących z dwóch różnych modeli numerycznych prognoz pogody NWP. W kolejnych strukturach danych od 1 do 6 informację wejściową do sieci neuronowej uzupełniano o prognozowaną prędkość wiatru dla kolejnego punktu prognostycznego. Dane dla struktur 1-3 pochodzą z pierwszego portalu pogodowego, 4-6 dodatkowo drugiego portalu pogodowego (Tabela 6.3). Na rysunku 6.3 przedstawiono wpływ zmiany struktury danych wejściowych na jakość korekty prędkości wiatru wyrażony błędem MAE.



Rysunek 6.3: Porównanie struktur danych dla elektrowni wiatrowej FW4 - Błąd MAE


Tabela 6.3: Analizowane struktury danych wejściowych - elektrownia FW4

| | | | Struktura danych | | | | | | | | | | | |
|-----------------|--------|---------|------------------|---|---|---|---|---|---|---|---|----|----|----|
| | | | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 | 11 | 12 |
| Prędkość wiatru | NWP1* | Punkt 1 | x | | | | | | | | | | | |
| | | Punkt 2 | x | x | | | | | | | | | | |
| | | Punkt 3 | x | x | x | | | | | | | | | |
| | NWP2** | Punkt 4 | x | x | x | x | | | | | | | | |
| | | Punkt 5 | x | x | x | x | x | | | | | | | |
| | | Punkt 6 | x | x | x | x | x | x | | | | | | |
| Temperatura | NWP1* | Punkt 1 | x | x | x | x | x | x | x | | | | | |
| | | Punkt 2 | x | x | x | x | x | x | x | x | | | | |
| | | Punkt 3 | x | x | x | x | x | x | x | x | x | | | |
| | NWP2** | Punkt 4 | x | x | x | x | x | x | x | x | x | x | | |
| | | Punkt 5 | x | x | x | x | x | x | x | x | x | x | x | |
| | | Punkt 6 | x | x | x | x | x | x | x | x | x | x | x | x |

* - numeryczna prognoza pogody pochodząca z modelu udostępnianego przez portal pogodowy WU

** - numeryczna prognoza pogody pochodząca z modelu udostępnianego przez portal pogodowy Dark Sky

Rysunek 6.4 przedstawia wpływ zmiany struktury danych wejściowych na jakość korekty prędkości wiatru wyrażony błędem MAPE.



Rysunek 6.4: Porównanie struktur danych dla elektrowni wiatrowej FW4 - Błąd MAPE

Jak wynika z Rysunków 6.3-6.4 dodanie do struktury danych wejściowych informacji z drugiego portalu pogodowego (struktury 4-6) pozwala zmniejszyć błąd MAE o ponad 60%, błąd MAPE o ponad 70%. Dodanie dodatkowej informacji dotyczącej temperatury w poszczególnych punktach jest mniejsza i wprowadza poprawę o kolejne 5-8%.

Przydatnym zestawieniem jest macierz wzajemnych korelacji danych wejściowych, która została zamieszczona w Tabeli 6.4. Widoczna jest istotna zależność prognozowanych prędkości wiatru (generowanych przy pomocy NWP - V_{p1-p6}) z wartościami zmierzonymi V_{p0} . Korelacja prognozowanych temperatur T_{p1-p6} z V_{p0} jest zdecydowanie mniejsza. Potwierdza to mniejszy wpływ temperatur na dokładność prognoz widoczny również na rysunkach 6.3-6.4.

Tabela 6.4: Macierz korelacji wzajemnych - dane wejściowe

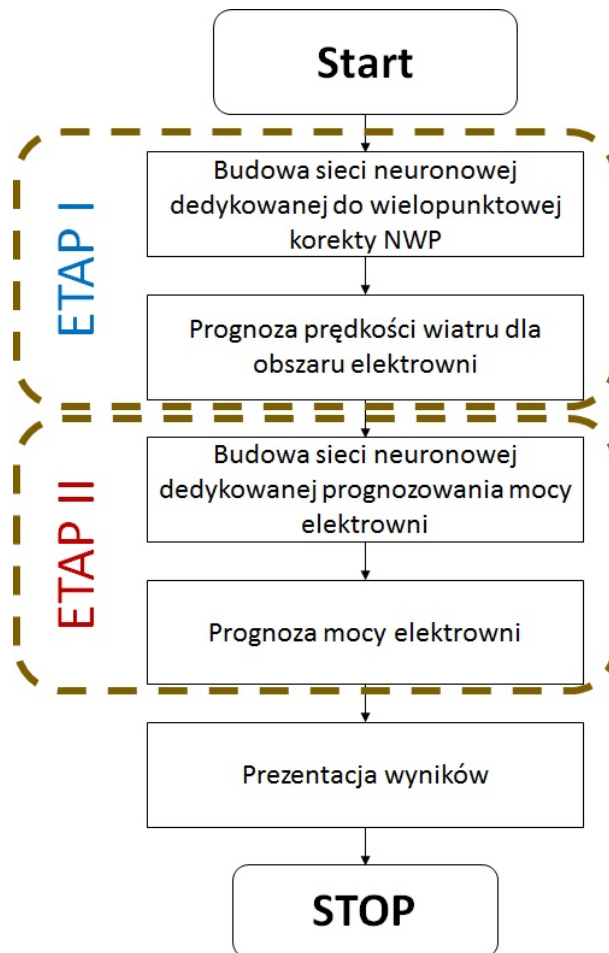
| | Prędkość wiatru - V | | | | | | | Temperatura - T | | | | | |
|----------|---------------------|-------|-------|-------|-------|-------|-------|-----------------|------|------|------|------|------|
| | p0 | p1 | p2 | p3 | p4 | p5 | p6 | p1 | p2 | p3 | p4 | p5 | p6 |
| V_{p0} | 1,00 | - | - | - | - | - | - | - | - | - | - | - | - |
| V_{p1} | 0,78 | 1,00 | - | - | - | - | - | - | - | - | - | - | - |
| V_{p2} | 0,76 | 0,99 | 1,00 | - | - | - | - | - | - | - | - | - | - |
| V_{p3} | 0,78 | 0,99 | 0,98 | 1,00 | - | - | - | - | - | - | - | - | - |
| V_{p4} | 0,79 | 0,96 | 0,96 | 0,95 | 1,00 | - | - | - | - | - | - | - | - |
| V_{p5} | 0,64 | 0,80 | 0,81 | 0,82 | 0,81 | 1,00 | - | - | - | - | - | - | - |
| V_{p6} | 0,68 | 0,86 | 0,88 | 0,84 | 0,87 | 0,75 | 1,00 | - | - | - | - | - | - |
| T_{p1} | -0,06 | -0,02 | -0,02 | -0,03 | -0,05 | -0,08 | -0,03 | 1,00 | - | - | - | - | - |
| T_{p2} | -0,06 | -0,02 | -0,03 | -0,04 | -0,05 | -0,08 | -0,03 | 1,00 | 1,00 | - | - | - | - |
| T_{p3} | -0,06 | -0,02 | -0,02 | -0,03 | -0,05 | -0,08 | -0,03 | 1,00 | 1,00 | 1,00 | - | - | - |
| T_{p4} | -0,06 | -0,04 | -0,04 | -0,05 | -0,06 | -0,09 | -0,04 | 0,99 | 0,99 | 0,99 | 1,00 | - | - |
| T_{p5} | -0,07 | -0,05 | -0,05 | -0,07 | -0,07 | -0,09 | -0,05 | 0,98 | 0,98 | 0,98 | 0,98 | 1,00 | - |
| T_{p6} | -0,06 | -0,04 | -0,04 | -0,05 | -0,06 | -0,08 | -0,04 | 0,99 | 0,99 | 0,98 | 0,99 | 0,98 | 1,00 |

6.2 Prognozowanie produkcji energii z wykorzystaniem wielopunktowej korekty prognoz pogody

Proces prognozowania produkcji energii z wykorzystaniem wielopunktowej korekty prognoz pogody składa się z dwóch etapów. Pierwszy to proces korekty prognozowanych wartości prędkości wiatru przy pomocy modeli NWP. W tym kroku dane prognostyczne korelowane są z wartościami zmierzonymi, pochodzącymi ze stacji pogodowej zainstalowanej

na gondoli turbiny. Drugi etap to proces prognozowania mocy elektrowni szerzej opisany w rozdziale 4.

Schemat blokowy przedstawiający zasadę działania systemu prognozowania zaprezentowano na rysunku 6.5.



Rysunek 6.5: Schemat blokowy systemu korekty oraz prognozowania mocy elektrowni wiatrowej

Na podstawie przeprowadzonych symulacji zaprezentowanych w podrozdziale 6.1.1 można wnioskować, że najlepszym narzędziem dla procesu preprocessingu danych jest model numer 19 (3 warstwy ukryte oraz 45 neuronów w warstwach) oraz 30 (4 warstwy ukryte oraz 40 neuronów w warstwach). Jako alternatywny model wybrano również ten, który charakteryzował się większym błędem w celu określenia jak istotny wpływ ma dobór struktury sieci neuronowej.

Dla powyższych modeli wykonano skorygowane prognozy prędkości wiatru dla obszaru elektrowni wiatrowej. Połowa zbioru posłużyła jako zbiór uczący do przygotowania mo-

delu prognozy mocy. Zaproponowana sieć neuronowa składała się z 3 warstw ukrytych po 15 neuronów. Do weryfikacji działania modeli użyto drugą połowę przygotowanego zbioru danych.

Przygotowano cztery modele prognozy mocy:


- Sieć I - jest to model sieci neuronowej przygotowany na potrzeby weryfikacji działania sieci wykorzystujących do prognozowania wielopunktową korektę danych. Na wejście podano prognozowaną przy pomocy NWP prędkość wiatru dla punktu zlokalizowanego najbliżej elektrowni.
- Sieć II - to prosty model sieci neuronowej składający się z trzech warstw ukrytych po 5 neuronów. Na wejście podano skorygowaną prognozę prędkości wiatru z 6 punktów dla obszaru elektrowni wiatrowej.
- Sieć III - została wytypowana na podstawie przeprowadzonych porównań modeli zaprezentowanych na rysunkach 6.2a i b w podrozdziale 6.1.1 jako struktura charakteryzująca się niskim błędem MAE oraz MAPE.
- Sieć IV - podobnie jak sieć III została wytypowana jako alternatywna na podstawie przeprowadzonych porównań modeli zaprezentowanych na rysunkach 6.2a i b w podrozdziale 6.1.1 jako struktura charakteryzująca się niskim błędem MAE oraz MAPE.

Wykonano prognozy mocy oraz porównano je z wartościami zmierzonymi, błędy predykcji dla poszczególnych sieci I-IV zestawiono w Tabeli 6.5.


Tabela 6.5: Zestawienie błędu prognozy mocy elektrowni FW4

| Błąd | Sieć I | Sieć II | Sieć III | Sieć IV |
|-----------|--------|---------|----------|---------|
| RMSE [kW] | 140,4 | 117,7 | 69,0 | 68,3 |
| MAE [kW] | 101,3 | 79,9 | 34,8 | 33,4 |
| MAD [kW] | 101,8 | 80,9 | 35,8 | 34,7 |
| MAPE [%] | 86,0 | 88,3 | 35,3 | 39,6 |
| NMAPE [%] | 10,1 | 8,0 | 3,5 | 3,3 |

Na rysunkach 6.6-6.9 zaprezentowano wyniki działania powyżej opisanych sieci neuronowych I-IV.




(a) Zależność zmierzzone prędkości wiatru od wartości prognozowanej NWP




(b) Charakterystyka mocy elektrowni

Rysunek 6.6: Prognoza mocy elektrowni - Sieć I




(a) Zależność skorygowanej prędkości wiatru od wartości zmierzonej i prognozowanej NWP




(b) Charakterystyka mocy elektrowni

Rysunek 6.7: Prognoza mocy elektrowni - Sieć II




(a) Zależność skorygowanej prędkości wiatru od wartości zmierzonej i prognozowanej NWP




(b) Charakterystyka mocy elektrowni

Rysunek 6.8: Prognoza mocy elektrowni - Sieć III



(a) Zależność skorygowanej prędkości wiatru od wartości zmierzonej i prognozowanej NWP



(b) Charakterystyka mocy elektrowni

Rysunek 6.9: Prognoza mocy elektrowni - Sieć IV

Na rysunku 6.6a przedstawiono zależność zmierzonej oraz prognozowanej przy pomocy NWP prędkością wiatru. Zależność jest silnie nieliniowa co świadczy, że pojedyncza prognoza wygenerowana przy pomocy numerycznej prognozy pogody może nie być wystarczająca do prognozowania mocy elektrowni. Potwierdza to rysunek 6.6b na którym zaprezentowano zmierzona charakterystykę mocy elektrowni oraz wartości prognozowane przez Sieć I. Dla znacznego obszaru wyniki prognoz nie pokrywają się z wartościami zmierzonymi. Błąd MAE dla tej sieci jest największy i wynosi 101,3 [kW] co odpowiada około 10% mocy zainstalowanej elektrowni. Działanie kolejnej sieci zaprezentowano na rysunku 6.7. Rysunek 6.7a przedstawia działanie sieci wykorzystującej wielopunktową prognozę pogody do korekty prognozy prędkości wiatru wiejącego na wysokości gondoli turbiny wiatrowej. W tym przypadku, podobnie jak dla Sieci I korelacja skorygowanej prędkości wiatru z wartościami zmierzonymi jest na niskim poziomie. Jak wynika z rysunków 6.2a i b ilość neuronów w poszczególnych warstwach ma istotny wpływ na dokładność modeli. Jakość wykonanej korekty przekłada się bezpośrednio na jakość prognoz mocy generowanych przez sieć w drugim etapie działania systemu. Wizualnie (rysunek 6.7b) oraz liczbowo (Tabela 6.5) wynik prognozy jest nieznacznie lepszy. Błąd MAE dla tej sieci wynosi 79,9 [kW] co odpowiada około 8% mocy zainstalowanej elektrowni. Znacznie lepszymi wynikami prognoz charakteryzują się sieci III oraz IV. Pomimo, iż ich struktura jest inna (3 oraz 4 warstwy ukryte) to pozwalają one na wygenerowanie prognoz o zbliżonej dokładności. Mniejsza liczba warstw to przede wszystkim możliwość ograniczenia czasu uczenia sieci neuronowej. Na rysunkach 6.8a oraz 6.9a zależność skorygowanej prędkości

kości wiatru do wartości zmierzonej jest bardziej liniowa w porównaniu z Sieciami I-II. Potwierdza to prawidłowość działania metody wykorzystania korekty wielopunktowej do generowania skorygowanych wartości na przykład prędkości wiatru. Prognozy mocy (rysunki 6.8b oraz 6.9b znacznie lepiej pokrywają się ze zmierzoną charakterystyką mocy elektrowni. W porównaniu z poprzednimi sieciami zmniejszył się błąd MAE do wartości 34,8 / 33,4 [kW] co stanowi około 3% mocy zainstalowanej elektrowni.

7 Podsumowanie

7.1 Opis wykonanych prac i oryginalnych osiągnięć naukowych

Przygotowanie modeli prognostycznych było związane z wykonaniem wielu czynności przygotowawczych oraz przejścia kolejnych etapów takich jak:

- Przygotowanie, gromadzenie oraz weryfikacja danych pomiarowych dla okresu minimum 1 rok.
- Zaprojektowanie struktur tabel oraz przygotowanie dedykowanego oprogramowania pozwalającego na dostęp do wybranych informacji.
- Analiza specyfiki i problematyki prognozowania produkcji energii w elektrowniach z uwzględnieniem czynników zewnętrznych: parametrów pogodowych, efektu wzajemnego zasłaniania się turbin wiatrowych (wake effect) itp.
- Zbudowanie modeli prognostycznych wykorzystujących sieci neuronowe, uczonych na zbiorze danych pochodzących z minimum 1 roku.
- Weryfikacja modeli neuronowych na podstawie rzeczywistych i prognozowanych danych - optymalizacja struktury, dobór i korekta danych wejściowych w celu minimalizacji błędów predykcji.
- Analiza porównawcza jakości prognoz z modelami przygotowanymi przez dwa zespoły badawcze z poza AGH (z Politechniki Częstochowskiej i Polskich Sieci Elektroenergetycznych).
- Gromadzenie oraz weryfikacja prognoz pogody NWP pochodzących z różnych portali pogodowych.
- Przygotowanie modeli wielopunktowej korekty prognoz pogody na potrzeby predykcji produkcji energii elektrowni.

Do oryginalnych osiągnięć naukowych pracy można zaliczyć:

- Przygotowanie reprezentatywnego zbioru pozwalającego na obserwację zależności występujących w elektrowniach, mającego na celu w przyszłości uproszczenie budowy modeli dla nowych obiektów.
- Wykonanie analizy wpływu czynników pogodowych na moc elektrowni.
- Propozycja szybkiej oceny jakości modelu prognostycznego na podstawie błędów prognoz.
- Dobór struktury danych wejściowych do modeli prognostycznych.
- Uczenie maszynowe sieci neuronowych mające na celu wyznaczenie wag połączeń

pozwalający na minimalizację średniego absolutnego błędu prognozy.

- Dobór struktury sieci neuronowej dedykowanej do prognozowania produkcji energii elektrycznej ze źródeł odnawialnych takich jak wiatr lub słońce.
- Porównanie zaproponowanych w pracy modeli z rozwijanymi przez zewnętrzne jednostki badawcze modelami MRK i AKM.
- Korekta numerycznych prognoz pogody wynikająca z uwarunkowań technicznych lub lokalizacyjnych.
- Współudział we wdrożeniu aplikacji prognostycznej dedykowanej dla firm działających na rynku energii.

7.2 Wnioski końcowe

W związku ciągłym wzrostem ilości energii pochodzącej z OZE metody prognostyczne stały się niezbędnym narzędziem wspierającym np. operatorów w zakresie sprawnego zarządzania siecią, a firmy komercyjne w obrębie lokalnego bilansowania i handlu energią. Aktualnie widoczny jest szybki rozwój tematyki związanej z prognozowaniem wielkości produkcji energii zwłaszcza elektrowniach wiatrowych i fotowoltaicznych. Prognozowanie ze źródeł odnawialnych jest zagadnieniem bardzo złożonym. Realizowane są nowe projekty badawczo-rozwojowe jak np. PROGO [106] mające na celu poprawę stabilności pracy Krajowego Systemu Energetycznego poprzez generowanie obszarowych prognoz produkcji OZE.

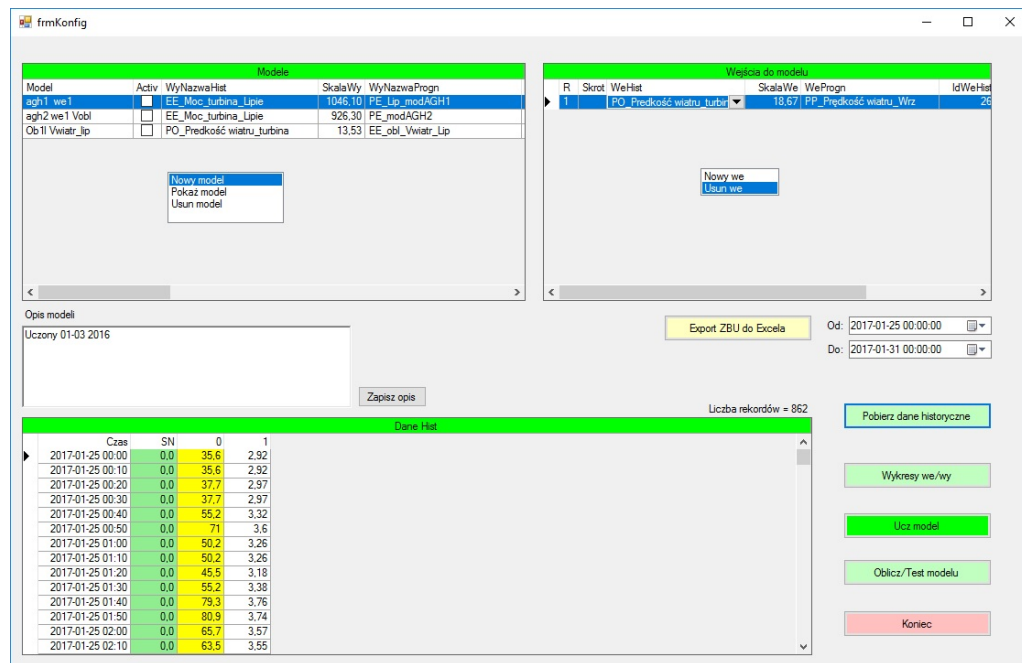
Wykonana analiza wpływu czynników pogodowych na moc elektrowni wykorzystującej OZE pozwoliła wytypować strukturę danych wejściowych oraz zwiększyć dokładność prognoz.

Zaproponowane w pracy modele sieci neuronowych umożliwiają wykonanie prognoz porównywalnych lub niejednokrotnie lepszych od modeli rozwijanych przez inne ośrodki, co potwierdza ich skuteczność.

Zaproponowane metody korekty numerycznych prognoz pogody na potrzeby prognozowania produkcji energii OZE pozwoliły na poprawę dokładności predykcji. W pracy przedstawiono ich działanie na rzeczywistym obiekcie.

Zagadnienia opisane w pracy zaowocowały powstaniem aplikacji, której autor jest współtwórcą. W wyniku działań została przygotowana aplikacja prognostyczna dedykowana dla firm działających na rynku energii. Wykonane oprogramowanie dedykowane jest do prognozowania - na podstawie zdefiniowanego zbioru danych elektrycznych i po-

godowych z przeszłości (dla rozważanej lokalizacji odnawialnego źródła) oraz prognozy meteorologicznej - generacji energii w poszczególnych godzinach dla horyzontu 24 godziny. Szczegóły dotyczące realizowanych prac znajdują się w [10]. Na rysunku 7.1 przedstawiono ekran główny modułu przygotowania modelu.



Rysunek 7.1: Ekran główny modułu organizowania modelu

Narzędzie przeznaczone jest do prognozowania energii wytworzonej w źródłach wiatrowych i słonecznych. System wykorzystujący metody sztucznej inteligencji bazuje na danych zgromadzonych w bazie danych MS SQL niezależnie od systemu SCADA realizującego archiwizację danych.

Program dedykowany jest do prognozowania mocy elektrowni na podstawie zdefiniowanego zbioru danych elektrycznych i pogodowych z przeszłości (dla rozważanej lokalizacji odnawialnego źródła) oraz prognozy meteorologicznej - generacji energii w poszczególnych godzinach dla 24 h. System prognozowania wykorzystujący metody sztucznej inteligencji bazuje na danych zgromadzonych w bazie danych MS SQL niezależnie od systemu SCADA realizującego archiwizację danych.

Wdrożona aplikacja jest przeznaczona do tworzenia prognoz generacji energii elektrycznej przez elektrownie wiatrowe lub instalacje fotowoltaiczne. Do prognozowania wykorzystywane są sztuczne sieci neuronowe. Uczenie odbywa się w oparciu o dane zbierane z lokalnego systemu SCADA oraz danych meteorologicznych pobieranych z ogólnie dostępnego portalu pogodowego. Dla obu przypadków przygotowano indywidualne opro-

gramowanie. Dana wejściowa do modelu prognozowania wypracowywana jest w oparciu o kilka publicznie dostępnych prognoz pogody.

Autor pracy przyszłe działania skieruje przede wszystkim na trzy aspekty pozwalające zwiększyć dokładność prognoz:

- preprocessing danych - właściwe przygotowanie danych wpływa zarówno na sam proces uczenia sieci jak i dokładność modeli. Jak wynika z przeprowadzonych prac związanych z rozprawą przydatne dane gromadzone są w różnych bazach danych. Zdarza, że pomimo ciągłej rejestracji parametrów pracy elektrowni przy pomocy systemów SCADA brakuje części danych. Konieczne jest znalezienie rekordów i uzupełnienie ich w razie konieczności. Istotnym zagadnieniem jest również filtracja zarejestrowanych danych pochodzących z elektrowni. Nie bez znaczenia jest przygotowanie zbioru uczącego oraz weryfikacyjnego w procesie
- "świadome" wykorzystanie głębokiego uczenia sieci neuronowych dedykowanych do prognozowania. Dobór strumieni wejściowych, określenie właściwej struktury oraz rodzaju sieci pozwoli skrócić proces uczenia oraz wymagania sprzętowe z nim związane.
- znalezienie metod zwiększenia dokładności prognoz NWP i dostosowanie ich do specyfiki pracy oraz wielkości przestrzennej elektrowni. Numeryczne prognozy pogody generowane są zazwyczaj z ograniczoną rozdzielczością siatki prognostycznej oraz dla wysokości 10 m npg. Elektrownie zazwyczaj zlokalizowane są na znacznej powierzchni. W przypadku elektrowni wiatrowych należy dodatkowo uwzględnić np. wysokość do osi piasty oraz długość skrzydła, natomiast w przypadku elektrowni fotowoltaicznych orientację paneli względem południa i nachylenie.

Literatura

- [1] Sejm RP, Ustawa z dnia 20 lutego 2015 r. o odnawialnych źródłach energii (nowelizacja 19 lipca 2019 r.), <http://prawo.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20150000478>, 2019-09-26.
- [2] Bloomberg New Energy Finance, New energy outlook 2018, <https://about.bnef.com/new-energy-outlook/>, 2018.
- [3] Parlament Europejski, Dyrektywa parlamentu europejskiego i rady 2009/29/we z dnia 23 kwietnia 2009 r. zmieniająca dyrektywę 2003/87/we w celu usprawnienia i rozszerzenia wspólnotowego systemu handlu uprawnieniami do emisji gazów cieplarnianych, <https://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2009:140:0063:0087:PL:PDF>, 2018-03-26.
- [4] Urząd Regulacji Energetyki, Mapa odnawialnych źródeł energii, <https://www.ure.gov.pl/uemapoze/mapa.html>, 2018-07-02.
- [5] PTPiREE, Energetyka dystrybucja i przesył, http://www.ptpiree.pl/raporty/2020/raport_ptpiree_druk.pdf, 2020.
- [6] Ministerstwo Klimatu, Polityka energetyczna polski do 2040 r., <https://www.gov.pl/web/klimat/minister-kurtyka-polityka-energetyczna-polski-do-2040-r-udziela-odpowiedzi-na-najwazniejsze-wyzwania-stojace-przed-polska-energetyka-w-najblizszych-dziesiecioleciach>, 2020-09-08.
- [7] green projects.pl, Ile energii w Polsce wytwarzamy z OZE?, <http://www.green-projects.pl/2017/12/energia-oze-wytwarzanie-polska-statystyki/>, 2018-06-29.
- [8] International Energy Agency, Global energy review 2020, <https://webstore.iea.org>, 2020.
- [9] International Energy Agency, Snapshot of global PV markets 2020, https://iea-pvps.org/wp-content/uploads/2020/04/IEA_PVPS_Snapshot_2020.pdf, 2020.
- [10] Hanzelka Z., Firlit A., *Elektrownie ze źródłami odnawialnymi - zagadnienia wybrane*, Wydawnictwa AGH, Kraków, 2015.
- [11] Woźny K., Kochanowski K., Perspektywy wdrożenia technologii magazynowania energii elektrycznej w polsce, *Polska Izba Magazynów Energii*, 2018.
- [12] Baczyński D., Kołodziejczyk K., Prognozowanie produkcji energii elektrycznej z OZE – wybrane problemy, <http://www.globema.pl/prognozowanie-produkcji-energii-elektrycznej-oze-wybrane-problemy/>, 2018.

- [13] Popławski T., Łyp J., Kurach M., Wykorzystanie modelu rozkładu kanonicznego wektora zmiennych do prognozy cen na rynku dnia następnego, *Rynek Energii*, 1:54-58, 2012.
- [14] Popławski T., Wykorzystanie metody rozkładu kanonicznego wektora zmiennych losowych w prognozowaniu, Prezentacja: Seminarium Smart Grid - KEiASPE AGH, 2014.
- [15] PSE Innowacje Sp. z o.o., Wykonanie prognoz z wykorzystaniem adaptacyjnej krzywej mocy elektrowni wiatrowej dla trzech wyróżnionych obiektów, 2014.
- [16] Ozkan M.B., Karagoz P., A novel wind power forecast model: Statistical hybrid wind power forecast technique (SHWIP), *IEEE Transactions on Industrial Informatics*, 11(2):375-386, 2015.
- [17] Miao He, Lei Yang, Junshan Zhang, Vittal V., A spatio-temporal analysis approach for short-term forecast of wind farm generation, *IEEE Transactions on Power Systems*, 29(4):1611-1622, 2014.
- [18] Pinson P. Tastu J., Discussion of “prediction intervals for short-term wind farm generation forecasts” and “combined nonparametric prediction intervals for wind power generation”, *IEEE Transactions on Sustainable Energy*, 5(3):1019-1020, 2014.
- [19] Le Xie, Yingzhong Gu, Xinxin Zhu, Genton M. G., Short-term spatio-temporal wind power forecast in robust look-ahead power system dispatch, *IEEE Transactions on Smart Grid*, 5(1):511-520, 2014.
- [20] Yang L., Zhang M., He J., Vittal V., Support-vector-machine-enhanced markov model for short-term wind power forecast, *IEEE Transactions on Sustainable Energy*, 6(3):791-799, 2015.
- [21] Ming Yang, Simeng Zhu, Meng Liu, Wei-Jen Lee, One parametric approach for short-term jpdf forecast of wind generation, *IEEE Transactions on Industry Applications*, 50(4):2837-2843, 2014.
- [22] Niya Chen, Zheng Qian, Xiaofeng Meng, Ian T. Nabney, Short-term wind power forecasting using gaussian processes, In *Proceedings of the Twenty-Third International Joint Conference on Artificial Intelligence, IJCAI '13*, : 2790–2796, Beijing, China, 2013, AAAI Press.
- [23] Yang M., Lin Y., Zhu S., Han X., Wang H., Multi-dimensional scenario forecast for generation of multiple wind farms, *Journal of Modern Power Systems and Clean Energy*, 3(3):361-370, 2015.

- [24] Mao Y., Shaoshuai W., A review of wind power forecasting prediction, In *International Conference on Probabilistic Methods Applied to Power Systems (PMAAPS)*, : 1-7, Beijing, China, 2016.
- [25] Yang C., Thatte A. A., Xie L., Multitime-scale data-driven spatio-temporal forecast of photovoltaic generation, *IEEE Transactions on Sustainable Energy*, 6(1):104-112, 2015.
- [26] Liu J., Fang W., Zhang X., Yang C., An improved photovoltaic power forecasting model with the assistance of aerosol index data, *IEEE Transactions on Sustainable Energy*, 6(2):434-442, 2015.
- [27] De Giorgi M. G., Congedo P. M., Malvoni M., Photovoltaic power forecasting using statistical methods: impact of weather data, *IET Science, Measurement & Technology*, 8(3):90-97, 2014.
- [28] Chao-Ming Huang, Shin-Ju Chen, Sung-Pei Yang, Chung-Jen Kuo, One-day-ahead hourly forecasting for photovoltaic power generation using an intelligent method with weather-based forecasting models, *IET Generation, Transmission & Distribution*, 9(14):1874-1882, 2015.
- [29] Wan C., Zhao J., Song Y., Xu Z., Lin J., Hu Z., Photovoltaic and solar power forecasting for smart grid energy management, *CSEE Journal of Power and Energy Systems*, 1(4):38-46, 2015.
- [30] Zhang Y., Beaudin M., Taheri R., Zareipour H., Wood D., Day-ahead power output forecasting for small-scale solar photovoltaic electricity generators, *IEEE Transactions on Smart Grid*, 6(5):2253-2262, 2015.
- [31] Monteiro C., Santos T., Fernandez-Jimenez L. A., Ramirez-Rosado I. J., Terreros-Olarte M. S., Short-term power forecasting model for photovoltaic plants based on historical similarity, *Energies*, 6(5):2624-2643, 2013.
- [32] Asmine M., Brochu J., Fortmann J., Gagnon R., Kazachkov Y., Langlois Ch. E., Larose Ch., Muljadi E., MacDowell Jason, Pourbeik P., Seman S.A., Wiens K., Model validation for wind turbine generator models, *IEEE Transactions on Power Systems*, 26(3):1769-1782, 2011.
- [33] Xu M., Gu T., Xu J., Wang K., Guo F. Li G., Electromechanical modeling of the direct-driven wind turbine generator considering the stochastic component of wind speed, *2nd IEEE Conference on Energy Internet and Energy System Integration (EI2)*, 2018.

- [34] Silva E.A., Bradaschia F., Cavalcanti M. C., Nascimento A. J., Michels L., Pietta L.P., An eight-parameter adaptive model for the singlediode equivalent circuit based on the photovoltaicmodule's physics, *IEEE Journal of Photovoltaics*, 7(4):1115-1123, 2017.
- [35] Carvalho L. M., Teixeira J., Matos M., Modeling wind power uncertainty in the long-term operational reserve adequacy assessment: a comparative analysis between the naive and the arima forecasting models, *International Conference on Probabilistic Methods Applied to Power Systems (PMAPS)*, 2016.
- [36] Li Jun-fang, Zhang Bu-han, Xie Guang-long, Li Yan, Mao Cheng-xiong, Grey predictor models for wind speed-wind power prediction, *Power System Protection Control*, 38(19):152-159, 2010.
- [37] Shenbing Hua, Shu Wang, Shuanglong Jin, Shuanglei Feng, Bo Wang, Wind speed optimisation method of numerical prediction for wind farm based on Kalman filter method, *The Journal of Engineering*, 2017(13):1146-1149, 2017.
- [38] Shan Gao, Yu He, Hao Chen, Wind speed forecast for wind farms based on ARMA-ARCH model, In *2009 International Conference on Sustainable Power Generation and Supply*, Nanjing, China, 2009.
- [39] Nair Krishnaveny R., Vanitha V., Jisma M., Forecasting of wind speed using ANN, ARIMA and hybrid models, *International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICT)*, : 170-175, 2017.
- [40] Shuxin Tian, Yang Fu, Ping Ling, Shurong Wei, Shu Liu, Kunpeng Li, Wind power forecasting based on arima-lgarch model, In *2018 International Conference on Power System Technology (POWERCON)*, Guangzhou, China, 2018, IEEE Xplore.
- [41] Sahay K. B., Srivastava S., Short-term wind speed forecasting of lelystad wind farm by using ANN algorithms, In *2018 International Electrical Engineering Congress (iEECON)*, Krabi, Thailand, 2018, IEEE Xplore.
- [42] Khodayar M., Wang J., Spatio-temporal graph deep neural network for short-term wind speed forecasting, *IEEE Transactions on Sustainable Energy*, 10(2):670-681, 2019.
- [43] Aoran Xu, Tao Yang, Jianwei Ji, Yang Gao, Cailian Gu, Application of cluster analysis in short-term wind power forecasting model, *The Journal of Engineering*, 2019(9):5423-5426, 2019.
- [44] Perveen G., Rizwan M., Goel N., Comparison of intelligent modelling techniques

- for forecasting solar energy and its application in solar PV based energy system, *IET Energy Systems Integration*, 1(1):34-51, 2019.
- [45] Yongqian Liu, Ying Sun, David Infield, Yu Zhao, Shuang Han, Jie Yan, A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (ot-svm), *IEEE Transactions on Sustainable Energy*, 8(2):451-457, 2017.
- [46] Aoran Xu, Tao Yang, Jianwei Ji, Yang Gao, Cailian Gu, Forecasting short-term wind speed based on iewt-lssvm model optimized by bird swarm algorithm, *The Journal of Engineering*, 2019(9):5423-5426, 2019.
- [47] Bartman J., Sztuczne sieci neuronowe, http://www.neurosoft.edu.pl/media/pdf/jbartman/sztuczna_inteligencja/NTI1.pdf, 2019-03-27.
- [48] Box G. E. P., Robustness in the strategy of scientific model building, *Academic Press*, : 201–236, 1979.
- [49] ENERCON GmbH, ENERCON Wind energy converters, <https://www.enercon.de/en/products/ep-2/e-70/>, 2010.
- [50] Pietrek S., Numeryczne modele prognoz pogody, http://zeszyty-naukowe.wysi.edu.pl/zeszyty/zeszyt1/Numeryczne_Models_Prognoz_Pogody.pdf, 2019-02-01.
- [51] Wikipedia, Numeryczna prognoza pogody, https://pl.wikipedia.org/wiki/Numeryczna_prognoza_pogody, 2020-03-20.
- [52] Madsen H., Nielsen H. A., Nielsen T. S., A tool for predicting the wind power production of off-shore wind plants, In *Proceedings of the Copenhagen Offshore Wind Conference & Exhibition*, Copenhagen, Denmark, 2005.
- [53] Pinson P., *Estimation of the uncertainty in wind power forecasting*, Rozprawa doktorska, Ecole des Mines de Paris, 2006.
- [54] Osowski S., *Metody i narzędzia eksploracji danych*, Wydawnictwo BTC, Legionowo, 2013.
- [55] Momot A., *Uczenie bayesowskie w modelowaniu rozmytym*, Rozprawa doktorska, Politechnika Śląska, 2004.
- [56] Stefanowski J., Svm – support vector machines metoda wektorów nośnych, <http://www.cs.put.poznan.pl/jstefanowski/ml/SVM.pdf>, 2019-01-18.
- [57] Wikipedia, Support-vector machine, https://en.wikipedia.org/wiki/Support-vector_machine, 2019-01-21.

- [58] X.-B. Meng, X. Z. Gao, L. Lu, Y. Liu, H. Zhang, A new bio-inspired optimisation algorithm: Bird swarm algorithm, *Journal of Experimental & Theoretical Artificial Intelligence*, 28(4):673-687, 2015.
- [59] Yona A., Senjyu T., Saber A. Y., Application of neural network to one-day-ahead 24 hours generating power forecasting for photovoltaic system, In *Intelligent Systems Applications to Power Systems, 2007. ISAP 2007*, : 1-6, Kaohsiung, Taiwan, 2007, IEEE.
- [60] Aprillia Happy, Hong-Tzer Yang, Chao-Ming Huang, Short-term photovoltaic power forecasting using a convolutional neural network–salp swarm algorithm, *Energies*, 13:1879, 04 2020.
- [61] Raza M. Q., Mithulananthan N., Li J., Lee K. Y., Gooi H. B., An ensemble framework for day-ahead forecast of pv output power in smart grids, *IEEE Transactions on Industrial Informatics*, 15(8):4624-4634, 2019.
- [62] Chen X., Du Y., Wen H., Jiang L., Xiao W., Forecasting-based power ramp-rate control strategies for utility-scale pv systems, *IEEE Transactions on Industrial Electronics*, 66(3):1862-1871, 2019.
- [63] Sanjari M. J., Gooi H. B., Nair N. C., Power generation forecast of hybrid pv–wind system, *IEEE Transactions on Sustainable Energy*, 11(2):703-712, 2020.
- [64] Paska J., Surma T., Wybrane zagadnienia modelowania niezawodności elektrowni wiatrowych, *Rynek Energii*, 93(2):43-48, 2011.
- [65] Picard A, Davis R S, Glaser M, Fujii K, Revised formula for the density of moist air (cipm-2007), *IOP PUBLISHING*, 45:149–155, 2008.
- [66] H. Lorenc, Struktura i zasoby energetyczne wiatru w Polsce. Materiały badawcze - instytut meteorologii i gospodarki wodnej: Meteorologia, https://books.google.pl/books?id=_84uHQAACAAJ, 1996.
- [67] AGH Pociask P., Szorstkość terenu, https://zasoby1.open.agh.edu.pl/dydaktyka/inzynieria_srodowiska/c.odnaw_zrodla_en/files/szorstkosc.htm, 2020-04-26.
- [68] Lorenc H., Struktura i zasoby energetyczne wiatru w polsce, *IMiGW*, 1996.
- [69] Lubośny Z., *Farmy wiatrowe w systemie elektroenergetycznym*, Wydawnictwa Naukowo-Techniczne, Warszawa, 2009.
- [70] Google Street View, Obraz elektrowni FW1 pochodzący z google street view, <https://www.google.pl/maps/>, 2019-07-03.
- [71] Nordex, Gamma generation - the 2.5 mw efficiency class, <http://www.nordex->

- france.fr/wp-content/uploads/2018/10/Nordex_Gamma.en.pdf, 2009.
- [72] MEGA S.A., Elektrownia wiatrowa FW2, <http://www.megasa.pl/pl/profile/wind-farms/28-farmy-w/89-wind-farm-margonin>, 2018-07-10.
- [73] Gamesa, Gamesa 2.0-2.5mw technological evolution, <https://pdf.directindustry.com/pdf/gamesa-electric/gamesa-20-25-mw/20927-546821.html>, 2013.
- [74] AGH, Badania nad opracowaniem wytycznych, technik i technologii dla systemów kompensacji mocy biernej, inteligentnego monitoringu wewnętrznych sieci elektroenergetycznych oraz ogniw fotowoltaicznych dedykowanych obiektom hybrydowym opartym wyłącznie o źródła odnawialne, <http://www.symoze.agh.edu.pl>, 2018-09-26.
- [75] oze.gep.com.pl, Wiatr jako źródło energii, <http://oze.gep.com.pl/tag/sprawnoscaerodynamiczna/>, 2020-04-20.
- [76] NEG Micon, NEG Micon NM 60/250-1000, <https://pl.wind-turbine-models.com/turbines/313-neg-micon-nm-60-1000>, 2013.
- [77] Sarniak M.T., *Podstawy fotowoltaiki*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2008.
- [78] Wasilewski J., Baczyński D., Krótkoterminowe prognozowanie produkcji energii elektrycznej w systemach fotowoltaicznych, *Rynek Energii*, 5(96):47-51, 2011.
- [79] Kaczmarczyk D., Wydajność paneli fotowoltaicznych, <https://fotowoltaikaonline.pl/efektywnosc>, 2020-04-22.
- [80] SOLARGIS, Weather data and software for solar power investments, <http://solargis.info>, 2019-09-26.
- [81] SunLink PV, Sl280-24m285 high efficiency mono-crystalline solar module - 305 w maximum power, <http://www.sunlinkpv.com>, 2018-10-26.
- [82] Davis Instruments, Wireless vantage pro2 plus stations, https://www.davisinstruments.com/product_documents/weather/manuals/07395-234.IM.06312.pdf, 2019.
- [83] CRES, Centre for renewable energy sources and saving (CRES), <http://www.cres.gr/cres/index.html>, 2019-03-15.
- [84] Katsigiannis Y. A., Tsikalakis A. G., Georgilakis P. S., Hatziargyriou N. D., Improved wind power forecasting using a combined neuro-fuzzy and artificial neural network model, *Springer Berlin Heidelberg*, 3955:105-115, 2006.

- [85] Hertz J., Krogh A., Palmer R.G., *Wstęp do obliczeń neuronowych*, WNT, Warszawa, wydanie drugie edition, 1993.
- [86] Tadeusiewicz R., Gąciarz T., Borowik B., Leper B., *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*, Wydawnictwa Polska Akademia Umiejętności, Kraków, 2007.
- [87] Rymarczyk R., *Decyzje symulacyjne sieci neuronowe*, Wydawnictwo Wyższej Szkoły Bankowej, Poznań, 1997.
- [88] Jing Li, Ji hang Cheng, Jing yuan Shi, Fei Huang, Brief introduction of back propagation (bp) neural network algorithm and its improvement, *Advances in Computer Science and Information Engineering, Springer, Berlin*, 2:553-558, 2012.
- [89] M. Riedmiller, H. Braun, A direct adaptive method for faster backpropagation learning: The rprop algorithm, In *IEEE International Conference on Neural Networks*, : 586-591, San Francisco, USA, 1993.
- [90] Rusiecki A., *Algorytmy uczenia sieci neuronowych odporne na błędy w danych*, Rozprawa doktorska, Politechnika Wrocławska, 2007.
- [91] Marquardt D., An algorithm for least squares estimation of non-linear parameters, *J. Soc. Ind. Appl. Math.*, : 431-441, 1963.
- [92] Kordalska A., Prognozowanie i symulacje wykład 1, <http://enauczanie.pg.edu.pl>, 2020-04-25.
- [93] Wikipedia, Błędy prognozy ex ante, https://pl.wikipedia.org/wiki/B%C5%82%C4%99dy_prognozy_ex_ante, 2020-04-23.
- [94] Cieślak M., *Prognozowanie gospodarcze. Metody i zastosowanie*, Wydawnictwo Naukowe PWN, Warszawa, 2001.
- [95] Popławski T., *Wybrane zagadnienia prognozowania długoterminowego w systemach elektroenergetycznych*, Wydawnictwo Politechniki Częstochowskiej, Częstochowa, 2014.
- [96] AGH KEiASPE, Raport: Opracowanie modeli neuronowych do prognozowania produkcji energii elektrycznej z elektrowni wiatrowych oraz opracowanie wyników badań na potrzeby monografii na przykładzie elektrowni wiatrowej FW3, Materiał niepublikowany - opracowanie wewnętrzne, 2014.
- [97] AGH KEiASPE, Raport: Opracowanie raportu oceniającego skuteczność prognozowania energii produkowanej przez turbiny wiatrowe metodą regresji wielokrokowej opartej o rozkład kanoniczny zmiennej losowej a metodą prognozowania wy-

- korzystującej sztuczne sieci neuronowe., Materiał niepublikowany - opracowanie wewnętrzne, 2014.
- [98] AGH KEiASPE, Raport: Analiza porównawcza jakości działania modeli prognostycznych generacji wiatrowej., Materiał niepublikowany - opracowanie wewnętrzne, 2015.
- [99] Todros K., Hero A. O., Measure transformed canonical correlation analysis with application to financial data, In *IEEE 7th Sensor Array and Multichannel Signal Processing Workshop (SAM)*, : 361-364, Hoboken, USA, 2012.
- [100] Popławski T., Dąsal K., Łyp J., Długoterminowa prognoza mocy szczytowej dla kse, *Polityka Energetyczna*, 12(2):497-509, 2009.
- [101] Dąsal K., Popławski T., Dobór zmiennych wejściowych w modelu prognoz długoterminowych funkcją q , *Przegląd Elektrotechniczny*, 85(2):144–148, 2009.
- [102] Grabiński T., Wydymus S., Zeliaś A., *Metody doboru zmiennych w modelach ekonometrycznych*, PWN, Warszawa, 1982.
- [103] PSE Innowacje Sp. z o.o., Raport z oceny skuteczności prognozowania energii produkowanej przez turbiny wiatrowe przy wykorzystaniu metody regresji wielokrokowej opartej o rozkład kanoniczny wektora zmiennych losowych, 2014.
- [104] Popławski T., Wykorzystanie metody rozkładu kanonicznego wektora zmiennych losowych w prognozowaniu, http://www.smartgrid.agh.edu.pl/documents/prezentacje/2014/1.07.2014_T.Poplawski.pdf, 2014.
- [105] Popławski T., Szelaż P., Głowiński C., Adamowicz Ł., Całus D., Zastosowanie modeli ARMA do przewidywania mocy i energii pozyskiwanej z wiatru, *Polityka Energetyczna*, 13(2):385–400, 2010.
- [106] Globema, Obszarowe prognozowanie produkcji OZE – PROGO, <https://www.globema.pl/prognozowanie-oze/>, 2020.

OŚWIADCZENIE AUTORA PRACY

Oświadczam, świadomy odpowiedzialności karnej za poświadczenie nieprawdy, że niniejszą pracę doktorską wykonałem osobiście i samodzielnie oraz nie korzystałem ze źródeł innych niż wymienione w pracy.

.....

(podpis)

Kraków, 20.10.2020 r.