



**POLITECHNIKA
GDAŃSKA**

WYDZIAŁ ELEKTROTECHNIKI
I AUTOMATYKI

Imię i nazwisko autora rozprawy: mgr inż. Tomasz Rubanowicz
Dyscyplina naukowa: Elektrotechnika

ROZPRAWA DOKTORSKA

Tytuł rozprawy w języku polskim: Prognozowanie mocy wytwórczej farmy wiatrowej

Tytuł rozprawy w języku angielskim: Wind Power Generation Forecasting

Promotor <i>podpis</i>	Drugi promotor <i>podpis</i>
dr hab. inż. Elżbieta Bogalecka prof. nadzw. PG	
Promotor pomocniczy <i>podpis</i>	Kopromotor <i>podpis</i>

Gdańsk, rok 2016

Spis treści

1. UZASADNIENIE TEMATU	4
1.1. CEL PRACY I HIPOTEZY BADAWCZE	10
1.2. STRUKTURA PRACY	11
1.3. PRZEDMIOT BADANIA I DANE POMIAROWE	11
2. OPIS BADANYCH OBIEKTÓW	13
2.1. WARUNKI WIATROWE NA FARMIE WIATROWEJ	13
2.2. OD CZEGO ZALEŻY MOC FARMY WIATROWEJ?	23
2.2.1. MOC POJEDYNCZEJ SIŁOWNI A MOC FARMY	27
2.2.2. MOC FARMY A WYŁĄCZENIA I AWARIE	31
2.2.3. MOC FARMY Z OGRANICZENIEM MOCY	32
2.2.4. MOC FARMY W WARUNKACH SILNYCH PODMUCHÓW WIATRU	41
2.2.5. MOC FARMY Z EFEKTEM PRZESŁONIĘCIA	49
2.3. PODSUMOWANIE ANALIZY MOCY	56
3. BUDOWA MODELU MOCY FW	57
3.1. MODELE PROGNOSTYCZNE W LITERATURZE – STAN AKTUALNY	57
3.2. STRUKTURA MODELU MOCY	59
3.3. UCZENIE I TESTOWANIE MODELU MOCY (SIECI ELMANA)	64
3.3.1. MODEL Z JEDNYM WEJŚCIEM: ŚREDNIA PRĘDKOŚĆ WIATRU	64
3.3.2. MODEL Z DWOMA WEJŚCIAMI: ŚREDNIA PRĘDKOŚĆ I KIERUNEK WIATRU	70
3.3.3. MODEL Z JEDNYM WEJŚCIEM: PRĘDKOŚĆ WIATRU Z MASZTU METEO	75
3.3.4. TESTOWANIE MODELU MOCY INNĄ PORĄ ROKU	80
3.4. BADANIE WŁAŚCIWOŚCI MODELU MOCY	83
4. WYNIKI BADAŃ – PORÓWNANIE DWÓCH MODELI MOCY FW	89
4.1. MIARA BŁĘDU	89
4.2. WYBÓR SKUTECZNEGO MODELU MOCY FW	91
5. PODSUMOWANIE	96
6. LITERATURA	98

Najważniejsze oznaczenia, skróty i symbole


CRO	- cena rozliczeniowa odchylenia energii elektrycznej
CROs	- cena rozliczeniowa odchylenia sprzedaży energii elektrycznej z RB
CROz	- cena rozliczeniowa odchylenia zakupu energii elektrycznej na RB
EW	- elektrownia wiatrowa
FW	- farma wiatrowa, park wiatrowy, zespół pojedynczych siłowni wiatrowych
G01÷G24	- numery poszczególnych siłowni wiatrowych
IRiESD	- Instrukcja Ruchu i Eksploatacji Sieci Dystrybucyjnej
IRiESP	- Instrukcja Ruchu i Eksploatacji Sieci Przesyłowej
KSE	- Krajowy System Elektroenergetyczny
KwG(nr)	- indywidualny pomiar kierunku wiatru Kw bezpośrednio na siłowni
KwM50	- pomiar kierunku wiatru na maszcie meteorologicznym na wysokości 50 metrów n.p.g.
OSD	- Operator Sieci Dystrybucyjnej
OSP	- Operator Sieci Przesyłowej
OZE	- Odnawialne Źródła Energii
PcG(nr)	- indywidualny pomiar generacji mocy Pw bezpośrednio na siłowni
PSE	- Polskie Sieci Elektroenergetyczne
RB	- Rynek Bilansujący
REE	- Rynek Energii Elektrycznej
SSN	- Sztuczne Sieci Neuronowe, sieci
UE	- Unia Europejska
uOZE	- Ustawa z dnia 20 lutego 2015 roku o odnawialnych źródłach energii (Dz.U. 2015 poz.478 z dnia 3 kwietnia 2015 roku)
VwG(nr)	- indywidualny pomiar prędkości wiatru Vw bezpośrednio na siłowni
VwM50	- pomiar prędkości wiatru na maszcie meteorologicznym na wysokości 50 metrów n.p.g.
WAsP	- Wind Atlas Analysis and Application Program



1. Uzasadnienie tematu

Przyjęte w Polsce nowe standardy polityki energetycznej Unii Europejskiej (UE), wdrożone w życie w dniu 4 maja 2015 roku w postaci Ustawy o Odnawialnych Źródłach Energii (uOZE), stworzyły przedsiębiorcom nowe możliwości inwestowania kapitału na krajowym REE [1, 2]. Poprzez wyznaczony kierunek rozwoju widoczny jest szybszy rozwój OZE, w tym elektrowni wiatrowych. Moc zainstalowana elektrowni wiatrowych w Polsce na dzień 31.12.2015 roku wynosiła 4978 MW (wg PSE) i odgrywa coraz bardziej istotną rolę w krajowej produkcji energii elektrycznej (EE). Rosnąca generacja mocy ze źródeł wiatrowych jest wyzwaniem dla Operatorów (odpowiedzialnych za bezpieczeństwo energetyczne kraju) w zakresie bieżącego bilansowania mocy wytwórczej jak i dla spółek handlowych (sprzedawców kupujących i rozliczających wytworzoną EE w OZE, w szczególności sprzedawców z urzędu).

Źródła wiatrowe można sklasyfikować pod względem struktury FW oraz mocy znamionowej (patrz rys.1). Utrzymującym się trendem jest budowanie FW a nie pojedynczych siłowni. Farmy składają się z zespołu od kilku do kilkudziesięciu pojedynczych siłowni, podłączonych do jednego GPZ. Do małych jednostek wytwórczych OZE zalicza się siłownie o mocy znamionowej poniżej 200 kW [1]. W niniejszej pracy przeanalizowano warunki generacji mocy dwóch farm wiatrowych o mocy zainstalowanej 3 MW oraz 50 MW.



Rys.1 Klasyfikacja struktur elektrowni wiatrowych

Rosnący udział elektrowni wiatrowych w KSE wymusza utrzymywanie zwiększonych rezerw mocy w energetyce konwencjonalnej, co niewątpliwie powoduje wzrost kosztów działalności energetycznej [87]. Stąd też dalszy rozwój energetyki

wiatrowej nie będzie możliwy bez znaczącego postępu technologicznego, przede wszystkim w sprawnym magazynowaniu wytworzonej EE. Na dzień dzisiejszy nie ma efektywnego, poza elektrowniami szczytowo-pompowymi i opłacalnego ekonomicznie sposobu magazynowania EE. Oznacza to, iż prognozowanie zapotrzebowania odbiorców oraz generacji wytwórców (w tym jednostek wiatrowych) jest niezbędną czynnością w zapewnieniu ciągłych dostaw EE odbiorcom końcowym. Dlatego też, zgodnie z przyjętymi warunkami w IRiESP, właściciele jednostek wytwórczych przyłączonych do KSE zobowiązani są do sporządzania i zgłaszania Operatorowi w określonym czasie grafików dobowo-godzinowych pracy własnych obiektów (prognozy mocy wytwórczej). Przygotowanie prognozy mocy FW wymaga wiedzy eksperckiej oraz narzędzi wspomagających i jest znacznie trudniejsze niż w przypadku pojedynczych siłowni ze względu na ich strukturę.

Prognozowanie mocy wytwórczej FW to dwa procesy: prognozowanie pogody i estymacja mocy wytwórczej w każdej godzinie doby odpowiadająca prognozie pogody. Prognozowaniem pogody zajmują się wyspecjalizowane instytucje, z którymi zawierane są umowy na świadczenie usług meteorologicznych. W ramach tych umów sporządzane są prognozy meteorologiczne w określonych horyzontach czasowych, przy jednoczesnym uwzględnieniu różnych czynników, m.in. geograficznej lokalizacji FW, wysokości gondoli nad poziomem gruntu, czy też historycznych danych pomiarowych. Trudno jest uzyskać dobrą prognozę pogody z odchyleniami na poziomie 5% m.in. najczęściej z powodu dużej odległości, jaka dzieli stację meteorologiczną (maszt meteo) od badanego obiektu. Ocenia się, że najlepsze prognozy uzyskuje się do 10 km, z błędem rzędu 20-30% [3,4,5], nawet przy wykorzystaniu wyspecjalizowanych narzędzi dostępnych na rynku, tj. WASP, czy WindPro [13,14,15]. Dokładność oferowanych prognoz nie daje gwarancji osiągnięcia idealnych, z zerowym błędem, prognoz mocy źródeł wiatrowych. Najlepszymi prognozami pogody dla FW są lokalne numeryczne prognozy krótkoterminowe, które oparte są na podstawowych zasadach fizyki przepływu powietrza [6,17].

Zmieniające się w ciągu doby warunki meteorologiczne powodują dużą zmienność produkcji EE pochodzącej z FW. Dynamika warunków meteorologicznych sprawia, że elektrownie wiatrowe zaliczane są do „niespokojnych” źródeł. Produkcja EE nie wynika wyłącznie z mocy zainstalowanej FW, ale przede wszystkim z wartości chwilowej prędkości wiatru oraz struktury obiektu. Ze względu na częściowo losową wartość mocy czynnej, dokładne jej oszacowanie w dłuższym horyzoncie czasowym

jest trudne. Oczywistym jest również, że im dłuższy horyzont predykcji, tym większy jest błąd prognozy mocy [5,18]. Skutkiem błędu prognozy jest odchylenie, czyli różnica pomiędzy planowaną godzinową EE, a godzinową EE rzeczywiście wyprodukowaną (wykonaniem) i oddaną do KSE – pomierzoną przez układ pomiarowo-rozliczeniowy, uwzględniająca straty przesyłowe. Charakter pracy FW sprawia, że odchylenia są nieuniknione, a uczestnicy rynku ponoszą koszty niezbilansowania na RB; trudne do przewidzenia na etapie zawierania kontraktu sprzedaży/zakupu EE. Powstające koszty mogą przyczynić się w dłuższej perspektywie do braku płynności finansowej każdego uczestnika rynku [34, 87].

W energetyce sprzedawcy, operatorzy i wytwórcy sporządzają prognozy dla różnych okresów, tj. długoterminowe (roczne i dłuższe), średnioterminowe (kwartalne i miesięczne) oraz krótkoterminowe (dobowo-godzinowe). Prognozy długoterminowe są prognozami wstępnymi, które są następnie korygowane na podstawie dokładniejszych danych pomiarowych, w kolejnych okresach: miesięcznym i dobowym. Czym bliżej terminu dostawy EE, tym prognoza dokładniejsza. Najlepsze prognozy uzyskuje się w ramach Rynku Dnia Bieżącego (RDB), kilka godzin przed dostawą EE. Prognozy krótkoterminowe przygotowywane są w horyzoncie dwudziestoczworgodzinnym w układzie dobowo-godzinowym w dniu poprzedzającym kolejną dobę handlową. W prognozach dobowych wykorzystuje się dostępną wiedzę o obiekcie, a więc dane katalogowe, dane pomiarowe pozyskane w czasie rzeczywistym (m.in. poprzez system SCADA) oraz bieżącą prognozę meteorologiczną. Wyprzedzenie dobowe wynika z warunków kontraktowania EE. Czym dokładniejsza prognoza długoterminowa i miesięczna mocy wytwórczej FW tym mniejsze koszty uczestnictwa na RB (powstałe odchylenia w dniu fizycznej dostawy EE).

Prognozowanie mocy wytwórczej FW w horyzoncie 24-godzinnym wymaga zarówno wiarygodnej prognozy wietrzności jak i narzędzi wspomagających. Narzędzie to jest dedykowanym modelem mocy FW. Model powinien uwzględniać nie tylko ogólne zasady przetwarzania energii wiatru na energię mechaniczną, ale cechy szczególne konkretnej farmy. Ilość czynników wpływających na moc farmy jest duża [36] i dokładna prognoza mocy, nawet przy dokładnej prognozie pogody jest obciążona błędem. Jednym z istotnych czynników zmniejszających błąd jest doświadczenie operatora (osoby wykonującej prognozę). Jednym ze źródeł błędów jest nieuwzględnienie cech osobniczych konkretnej farmy. Cechy te wynikają

z m.in. miejsca posadowienia, topologii terenu, rozległości i topologii farmy (struktury obiektu), czy rodzaju elektrowni i sposobu ich sterowania. Część cech można ująć analitycznie, ale niektóre, jak np. lokalne warunki wiatrowe na rozległej farmie, czy tzw. przesłonięcie są ilościowo trudne do określenia.

W procesie predykcji należy zwracać szczególną uwagę na jakość danych wejściowych oraz metody ich uzyskiwania i przetwarzania ze względu na możliwość kumulacji błędów. W prognozowaniu wykorzystuje się modele o różnej konstrukcji. Literatura tematu jest obszerna i opisywanych jest wiele metod prognozowania mocy [16, 24, 26, 28, 30]. Ponadto na rynku funkcjonuje kilka dedykowanych narzędzi prognostycznych [19÷22, 27]. Coraz więcej publikacji opisuje modele hybrydowe, które łączą ze sobą kilka modeli [11, 48, 49, 50, 65]. Modele mocy FW można podzielić na modele:

1. Analityczne (modele fizykalne), oparte na fizykalnych zasadach przetwarzania energii wiatru na energię elektryczną [23, 32], które wykorzystują takie dane jak:
 - warunki wiatrowe w badanej lokalizacji (dynamikę zmian) i wysokość gondoli EW,
 - efekt wzajemnego przesłonięcia masztów EW,
 - katalogową krzywą mocy elektrowni posadowionych na farmie.
2. Statystyczne, opisujące związek pomiędzy prognozowanymi parametrami wiatru, a wyjściową mocą wytwórczą na drodze analizy statystycznej [39, 44].
3. Behawioralne – oparte na metodach sztucznej inteligencji (np. SSN) [7, 8, 9, 25].

Każdy z tych modeli ma inną konstrukcję, dokładność, złożoność obliczeniową i zakres stosowania. Powyższe podejścia prognostyczne mają zalety i wady, które wymieniono w tabeli 1.

Tabela 1. Klasyfikacja metod prognozowania

Metoda	Zalety	Wady
Analityczna	Łatwa do obliczeń, nie wymaga specjalistycznego oprogramowania, ani komputerów dużej mocy.	Dobór współczynników wagowych przez człowieka, wymagana wiedza ekspercka operatora.

Statystyczna	Wykorzystuje trendy i wahania sezonowe, cykliczne i przypadkowe, daje możliwość ustalenia najbardziej prawdopodobnej mocy.	Liczna baza danych.
Behawioralna (SSN)	Nie wymaga ingerencji człowieka w dobór współczynników wagowych, ma zdolność generalizacji, sieci potrafią prawidłowo reagować na nowe dane.	Wymagany proces uczenia sieci, trudności przy wyborze struktury sieci dla modelu, wymagana duża moc obliczeniowa komputerów.

Zaletą stosowania modeli neuronowych i statystycznych, w przeciwieństwie do modeli analitycznych (fizykalnych), jest brak konieczności posiadania pełnej informacji o modelu obiektu oraz jego parametrach. Model statystyczny wymaga jednak bardziej licznego zbioru danych niż SSN. Sieć działa jako całość i poszczególne jej elementy mają wkład w zadanie. Rodzaj sieci neuronowej określa sposób połączenia składowych neuronów oraz kierunek przepływu sygnałów. SSN stanowią alternatywę dla powszechnie stosowanych modeli prognostycznych (fizykalnych i statystycznych) i mogą być uzupełniającym narzędziem wykorzystywanym w predykcji mocy FW, a w szczególności przy tworzeniu krzywej mocy.

Wybór modelu ma wpływ na koszty i okres jego przygotowania. Modele neuronowe należą do grupy modeli zaawansowanych i wymagają większych nakładów czasowych na przygotowanie niż modele fizykalne czy statystyczne. Modele tego typu wymagają poprawnych danych pomiarowych, właściwej struktury i rozmiaru sieci (dobrej metodą doświadczalną) oraz odpowiedniej metody uczenia sieci. Parametry SSN ustalone są w procesie uczenia. Dzięki temu procesowi sieci potrafią prawidłowo odtworzyć właściwości obiektu na podstawie rzeczywistych pomiarów, tzw. wzorców uczących (*learning patterns*). Wzorce te tworzą pewien zbiór zwany ciągiem uczącym (*learning sequence*), definiowanym jako zbiór par (dla metod uczenia z nauczycielem), np. prędkości wiatru i mocy FW. Na podstawie zbioru uczącego przeprowadzany jest proces uczenia sieci, który ma na celu wydobyć zależności ukrytych w danych wejściowych. Celem końcowym uczenia sieci jest znalezienie optymalnych współczynników wagowych, tak by model prawidłowo odtwarzał krzywą mocy obiektu. Pomimo posiadanych danych pomiarowych oraz gotowych modeli

matematycznych, bez odpowiedniej wiedzy i doświadczenia predykcja może okazać się nieskuteczna. Wiedzę i doświadczenie można osiągnąć dzięki długotrwałym obserwacjom pracy badanych źródeł wiatrowych.

W krajach o dużej ilości FW potrzeba predykcji mocy pojawiła się znacznie wcześniej niż w Polsce. Pierwsze modele neuronowe pojawiły się w połowie lat 90. Według [4, 5, 52, 66], badania nad narzędziami prognostycznymi przeznaczonymi do predykcji generacji mocy farm prowadzone są nieustannie w Danii od 1992 roku. W wyniku przeprowadzonych badań opracowano m.in. system informatyczny pod nazwą: Wind Power Prediction Tool (skrót: WPPT). System ten, stworzony we współpracy z Technical University w Danii, jest ustawicznie rozwijany i udoskonalany. System opiera się na danych statystycznych i danych rzeczywistych (on-line) pomierzonych bezpośrednio w FW oraz na prognozowanych danych meteorologicznych. Autorzy systemu WPPT poinformowali w 2001 roku [53÷56, 67], że przy użyciu opracowanego systemu, są w stanie prognozować generację mocy z dokładnością 90 % (jedną godzinę przed dostawą EE), z dokładnością 70 % (9 godzin przed dostawą EE), z dokładnością 60 % (24 godziny przed dostawą EE), i z dokładnością 50 % (36 godzin przed dostawą EE). Ponadto, w latach 2002 – 2005 na Uniwersytecie Kassel w Niemczech i w instytucie „Fraunhofer Institute for Wind Energy and Energy System Technology”, opracowano oprogramowanie: „Wind Power Management System (WPMS)”, wykorzystujące model neuronowy do przewidywania mocy wytwórczej FW na podstawie wzorców pogodowych. System WPMS został wdrożony w 2003 roku na rynku Wielkiej Brytanii w ramach projektu DISPOWER.

W latach 2002 – 2006 roku UE sfinansowała (po części) projekt ANEMOS (ENK5-CT-2002-00665), którego celem było zbadanie i opracowanie narzędzi do predykcji generacji mocy FW w oparciu o numeryczne prognozy pogody. KE przeznaczyła na ten cel 2,5 mln EURO, a koszty całego projektu wyniosły ponad 4 mln EURO. Projekt był realizowany przez konsorcjum jednostek naukowych i przemysłu. Dzięki projektowi powstało wiele publikacji [57÷59], które są ogólnie dostępne. W ramach projektu ANEMOS opracowano około 15 zaawansowanych modeli prognostycznych (wykorzystujących wymienione wcześniej modele), które zostały wdrożone w przemyśle przez podmioty biorące udział w projekcie. W Danii (ELSAM), Francji (EDF), Hiszpanii (EHN, IDAE) wdrożono modele predykcji dla FW (podejście indywidualne), natomiast w Grecji (PPC), Irlandii (ESB i SONI)

oraz w Niemczech (EWE) wdrożono modele uwzględniające FW (podejście obszarowe).

W efekcie projektów i prac badawczych uzyskano wspólną platformę przepływu informacji ANEMOS, dzięki której zwiększono bezpieczeństwo sieci przesyłowych. W skład platformy wchodzi siedem różnych modeli prognostycznych ww. krajów. O nieustannym rozwoju i poszukiwaniach dokładniejszych metod prognozowania może świadczyć podejście Amerykańskiego Departamentu Energetyki (U.S. DOE), który w czerwcu 2010 roku przeznaczył 6 mln dolarów na opracowanie systemu prognozowania mocy wytwarzanej przez FW. Od tamtego czasu powstało wiele podmiotów na świecie świadczących usługi prognozowania mocy FW (np. w Rumunii, w Izraelu, jak również w Polsce).

Biorąc pod uwagę, że polski rynek energetyki wiatrowej, jest rynkiem stosunkowo młodym, w pracy podjęto temat możliwości predykcji generacji mocy wytwórczej FW za pomocą sztucznych sieci neuronowych.

1.1.Cel pracy i hipotezy badawcze

Ze względu na charakter pracy źródeł wiatrowych predykcja mocy FW wymaga budowy modeli eksperckich, m.in. modeli neuronowych, które nie są tak powszechnym przedmiotem badań w Polsce jak w krajach, gdzie elektrowni wiatrowych jest znacznie więcej. W ostatnich latach w Polsce nie przeprowadzono badań na szeroką skalę ukierunkowanych na rozwiązanie kwestii predykcji mocy wytwórczej FW za pomocą modeli neuronowych.

Celem rozprawy było zbadanie przydatności modeli neuronowych do odtworzenia krzywych mocy FW na potrzeby prognoz krótkoterminowych (do 24 godzin) i udzielenie odpowiedzi na następujące pytania, tj.:

1. Jakie czynniki mają wpływ na generację mocy wytwórczej FW?
2. Czy na podstawie prędkości wiatru na rozległej FW można uzyskać oczekiwaną moc wytwórczą reprezentującą cały obiekt z akceptowalnym błędem?
3. Czy uwzględnienie w modelu dodatkowych czynników, np. kierunku wiatru, poprawia dokładność prognozy mocy wytwórczej FW?
4. Czy na podstawie prędkości wiatru z odległego masztu meteorologicznego, posadowionego od farmy w odległości do 10 km, istnieje możliwość uzyskania prognozy mocy o oczekiwanej jakości?

5. Czy model mocy FW nauczony na danych z wybranego okresu (np. zimowego), sprawdzi się w innym okresie (np. letnim)?

Pytania te często są zadawane przez inwestorów planujących budowę FW, a uzyskanie odpowiedzi ułatwi wybór modelu prognostycznego. W efekcie można skrócić czas przygotowania modelu mocy (dla nowo wybudowanego lub już istniejącego obiektu) a także można ograniczyć koszty ponoszone za niezbilansowanie EE na RB.

W celu weryfikacji modeli uzyskano dostęp do danych pomiarowych (meteorologicznych i produkcyjnych) dwóch farm zlokalizowanych na terenie północnej Polski i dokonano ich analizy. Na podstawie rzeczywistych danych była możliwość odtworzenia krzywych mocy obu badanych FW. Dzięki krzywym mocy można sporządzać prognozy generacji mocy wytwórczej.

1.2. Struktura pracy

W rozdziale 1 uzasadniono temat pracy doktorskiej wskazując m.in. cel pracy oraz przedmiot badań. W rozdziale 2 przedstawiono analizę danych pomiarowych, strukturę wybranych FW, wyjaśniono zależność mocy farmy od zmiennych warunków wiatrowych. W rozdziale 3 opisano stan aktualnie opisanych w literaturze modeli prognostycznych, a także pokazano budowę badanych modeli mocy FW i oceniono ich jakość. W rozdziale 4 przedstawiono wyniki badań i podsumowano je wnioskami. Rozdział 5 zawiera kierunki dalszych badań. Pracę kończy rozdział 6, który zawiera spis literatury.

1.3. Przedmiot badania i dane pomiarowe

Przedmiotem badań były właściwości modeli mocy FW stworzone w oparciu o SSN, które poddano różnym wymuszeniom. Z wielu znanych struktur SSN, do badań wybrano sieć rekurencyjną Elmana (ang. *Simple Recurrent Networks*). Wyboru dokonano doświadczalnie, porównując ze sobą wyniki symulacji uzyskane za pomocą innych struktur neuronowych, tj. sieci jednokierunkowej jednowarstwowej, czy też sieci jednokierunkowej wielowarstwowej. Model mocy FW zaimplementowano w programie MATLAB. Sieć Elmana jest siecią rekurencyjną, wielowarstwową. W ramach badań sprawdzono 11 metod uczenia SSN, a najlepszymi metodami uczenia sieci okazały się dwie metody, tj.: Levenberga-Marquardta oraz Beyesa. Jedną z zalet metody Bayesa

jest to, że skraca czas uczenia sieci przy dużej próbce uczącej i uczy sieć jedynie do momentu osiągnięcia najlepszej generalizacji. W procesie uczenia nie dąży więc do minimalizacji błędu sieci, a do maksymalizacji zdolności generalizacyjnych. Metoda ta zapobiega przeuczeniu sieci w przeciwieństwie do metody Levenberga-Marquardta.


Fundament tych modeli stanowią dane pomiarowe dwóch funkcjonujących FW o różnych mocach zainstalowanych, o różnej strukturze obiektu, zlokalizowane w różnych miejscach lecz w tym samym regionie kraju (na północy). Ponieważ dane pomiarowe zostały udostępnione przez właścicieli jako poufne i tylko na potrzeby tych badań, to zostały one w pracy unormowane. Oznacza to, że nie został pokazany dokładny wolumen wyprodukowanej EE, a jedynie profil generacji mocy dla określonych warunków meteorologicznych.

2. Opis badanych obiektów


2.1. Warunki wiatrowe na farmie wiatrowej

Farmy poddawane są różnorodnym warunkom wiatrowym, a ich efektywność, czyli maksymalne wykorzystanie energii strumienia wiatru, zależy także od prawidłowego rozmieszczenia EW na obszarze względem dominujących kierunków wiatru.

Na rysunkach 2 i 3 przedstawiono topologie badanych FW zlokalizowanych w północnej części Polski, które nazwano: Farma A oraz Farma B. Farma A zbudowana jest z 4 siłowni wiatrowych typu Enercon, natomiast Farma B składa się z 24 siłowni typu Vestas (do badań tej farmy wykorzystano dane z tylko 5 siłowni). Obie farmy A i B oddalone są od siebie o około 100 km. Badania prowadzono w oparciu o ograniczoną liczbę danych pomiarowych. Dla Farmy A i B pozyskano dane o prędkości i kierunku wiatru z anemometrów umieszczonych na każdej gondoli (na wysokości piasty: 76 m i 100 m n.p.g.). Pomiary mocy wytwórczej oraz warunków wiatrowych dokonywane są z krokiem 10-cio minutowym. Pozyskano dane z różnych okresów roku. Dane meteorologiczne oraz produkcyjne pozyskano za pomocą systemu SCADA.




Rys.2 Rozmieszczenie 4 siłowni wiatrowych Farmy A



Rys.3 Rozmieszczenie 5 z 24 siłowni wiatrowych Farmy B

Na rys.2 przedstawiono strukturę Farmy A z siłowniami posadowionymi obok siebie w średniej odległości. Siłownie posadowione są w jednej linii w odległości do pięciu średnic (5-D) łopat wirnika (zamieszczonych na gondoli), czyli nie większej niż 250 metrów (średnica łopat to 48 metrów). Wszystkie siłownie Farmy A są tego samego rodzaju, a wysokość wież nie przekracza 76 m n.p.g. Natomiast na rys.3 przedstawiono rozległą FW (Farma B) o strukturze rozproszonej. Siłownia nr G03 posadowiona jest na wzniesieniu o wysokości 50 m n.p.m. w odległości około 2700 metrów od siłowni nr G09 oraz G10 i około 5400 metrów od siłowni nr G23 i G24. Siłownie nr G09 i G10 posadowione są na 61 metrowym wzniesieniu n.p.m, a siłownie nr G23 i G24 na wysokości 65,4 metra i 64 metrów n.p.m. Odległość pomiędzy siłowniami nr G10 i G23 wynosi około 3400 metrów. Wszystkie siłownie Farmy B są tego samego rodzaju. Farma B zajmuje powierzchnię kilku kilometrów kwadratowych. Farma ta jest podzielona na 3 mniejsze obszary, podłączone wspólnie do jednego GPZ-tu. Podział farmy na mniejsze obszary dodatkowo może utrudniać predykcję mocy wytwórczej dla tego obiektu. Farma A została podłączona do sieci dystrybucyjnej OSD, natomiast Farma B bezpośrednio do sieci przesyłowej OSP. Mając dane meteorologiczne z jednego masztu pomiarowego, odległego od farmy, dokładność predykcji może budzić wątpliwości. Trudność predykcji mocy tego typu instalacji OZE wynika z dużej różnicy chwilowych warunków meteorologicznych. Prędkości wiatru na rozległej FW mogą różnić się nawet o ponad 30% (rys.4).




Rys.4 Prędkość wiatru na gondolach Farmy B, a) w trakcie 3 dni, b) w trakcie 1 doby

Prędkość wiatru pomierzona na gondoli nr G03 (rys.4-b) różni się od pozostałych czterech. Mimo, że siłownia G03 jest pierwsza względem napływającego wiatru (północno-zachodniego), to inne nieoczywiste przyczyny powodują, że wiatr tej siłowni jest wyraźnie mniejszy. Układ pomiarowy funkcjonował prawidłowo, co potwierdzają pomiary z wcześniejszych dni (rys.4-a). W pierwszych godzinach doby warunki wiatrowe dla wszystkich siłowni były zbliżone do siebie, a w kolejnych zaczęły się znacząco zmieniać, w szczególności dla tej siłowni. Wpływ na taką różnicę miało w zdecydowanej mierze ukształtowanie terenu wokół farmy, wysokość wzniesienia na którym została posadowiona (od 11 do 14 metrów niżej względem pozostałych siłowni) oraz odległość od pozostałych turbin (ok. 2700 metrów).

Przy tak różnych wartościach prędkości wiatru trudno jest ustalić „reprezentatywną” prędkość wiatru (obszarowo, jak i względem wysokości n.p.g.), z której będzie


wyznaczona prognoza mocy. Tym bardziej, że moc jest silnie nieliniową funkcją wiatru i niewielkie zmiany w oszacowaniu wiatru skutkują dużymi zmianami prognozy mocy. Pomiar prędkości wiatru jest wiarygodny, natomiast pomiar kierunku na gondoli niekoniecznie. Na podstawie pomiarów z gondoli można określić średnią prędkość wiatru, ale nie można określić dokładnie kierunku i wobec tego nie może być użyty w modelu mocy FW. Wynika to z zasady działania pomiaru. Czujnik mierzy kierunek względem osi gondoli a nie określonego kierunku, np. północnego. Niedokładna kalibracja punktu odniesienia może powodować, że gondola jest właściwie ustawiona, ale wartość zmierzona podawana jest z błędem systematycznym. Dlatego też średni kierunek wiatru może okazać się nieadekwatny dla całej FW. Wpływ kierunku wiatru na moc jest jednak mniejszy niż prędkości wiatru i objawia się głównie w przesłonięciu i ewentualnie w profilu pionowym wiatru przy zróżnicowanej szorstkości terenu.



Rys.5 Kierunek wiatru na gondolach Farmy B, a) w trakcie 3 dni, b) w trakcie 1 doby


Na rys.5 przedstawiono pomiar kierunku wiatru za ten sam okres co prędkość wiatru na rys.4. Porównując ze sobą oba te rysunki (rys.4 i 5) można zauważyć, że wraz ze zmianą kierunku wiatru zmienia się nie tylko prędkość wiatru, ale również rozkład prędkości wiatru na farmie. Jak wynika z rys.4 i 5 prędkość wiatru G03 zmieniła się w stosunku do innych po zmianie kierunku wiatru z południowo-zachodniego na północno-zachodni co oznacza, że G03 jest przesłonięta, pracuje w cieniu innego obiektu.

W Polsce dominuje kierunek wiatru południowo-zachodni i z punktu widzenia produkcji EE (generacji mocy wytwórczej) Farma A jest najlepiej usytuowana względem dominującego wiatru. Oznacza to efektywną generację mocy w ciągu roku. Można więc traktować ją jako farmę wzorcową dla osób projektujących tego typu obiekty. Na rys.6 pokazano różę wiatru za okres jednego roku (około 10000 próbek – pomiarów 10-cio minutowych) dla poszczególnych siłowni Farmy A. Podczas zmiany kierunku wiatru Farma A narażona jest na efekt przesłonięcia [40]. Efekt ten skutkuje mniejszą generacją mocy niektórych siłowni, w szczególności kiedy kierunek wiatru jest północno-zachodni lub południowo-wschodni. W dalszej części pracy omówiono bardziej szczegółowo wspomniany efekt przesłonięcia i jego wpływ na generację mocy.



Rys.6 Częstotliwość kierunku wiatru dla Farmy A (okres ponad roczny)

Na rys.7 przedstawiono kierunki wiatru pomierzone na gondolach siłowni względem kierunku na maszcie meteorologicznym (posadowionym na farmie). Kierunek wiatru pomierzony bezpośrednio na gondolach siłowni może być istotny, ale dane pomiarowe obarczone są błędem ze względu na brak odniesienia do tego samego kierunku, czyli wiatromierz wskazuje dobrze zmienność kąta, ale należy pamiętać, iż punkt startowy „0”, niekoniecznie wskazuje północny kierunek. Widoczne linie trendu na tym rysunku przedstawiają taką sytuację. Gdyby siłownie miały identycznie skonfigurowany układ pomiaru kierunku, linie trendu pokrywałyby się ze sobą tylko w przypadku, gdyby miały taki sam kierunek wiatru.



Rys.7 Kierunek wiatru na gondolach Farmy B względem masztu meteorologicznego

W poniższych tabelach (2 i 3) przedstawiono wartości współczynnika korelacji pomiędzy badanymi zmiennymi: prędkością wiatru pomierzoną na gondolach ($V_{wG03} \div V_{wG24}$), a także na maszcie meteorologicznym (V_{wM50}) na wysokości 50 m n.p.g oraz generacją mocy poszczególnych siłowni (P_c). Badany okres to ciąg 7 dni, gdzie próba z pomiarów co 10 min liczyła $N = 1008$. W tabelach przedstawiono również korelację między średnią prędkością wiatru (wyliczoną dla całej FW i oznaczoną jako V_{wFarma}), a sumą generacji poszczególnych siłowni i sumą farmy (P_{cFarma}). Wyniki korelacji oznaczono kolorem żółtym (V_{wFarma} oraz P_{cFarma}).

Tabela 2 Analiza korelacji przed usunięciem błędnych pomiarów (marzec)

	VwG03	VwG09	VwG10	VwG23	VwG24	VwM50	PcG03	PcG09	PcG10	PcG23	PcG24	VwFarma	PcFarma
VwG03	1,000												
VwG09	0,940	1,000											
VwG10	0,934	0,946	1,000										
VwG23	0,904	0,952	0,933	1,000									
VwG24	0,912	0,947	0,953	0,976	1,000								
VwM50	0,917	0,911	0,931	0,886	0,910	1,000							
PcG03	0,977	0,924	0,925	0,889	0,903	0,914	1,000						
PcG09	0,912	0,975	0,927	0,926	0,924	0,901	0,931	1,000					
PcG10	0,920	0,929	0,980	0,905	0,930	0,928	0,941	0,943	1,000				
PcG23	0,827	0,886	0,867	0,923	0,903	0,830	0,831	0,890	0,865	1,000			
PcG24	0,907	0,935	0,939	0,945	0,969	0,911	0,923	0,947	0,948	0,921	1,000		
VwFarma	0,960	0,981	0,976	0,978	0,982	0,933	0,945	0,957	0,956	0,904	0,963	1,000	
PcFarma	0,941	0,964	0,961	0,951	0,959	0,929	0,958	0,977	0,973	0,935	0,982	0,979	1,000

Po usunięciu błędnych pomiarów ze zbiorów danych, korelacja pomiędzy zmiennymi stała się silniejsza, co widoczne jest w tabeli nr 3. Za błędne pomiary przyjęto m.in. wartości zerowe wynikające z wyłączenia siłowni. Wykluczono, iż układ pomiarowy siłowni mógłby błędnie dokonywać pomiaru wielkości fizycznej.

Tabela 3 Analiza korelacji po usunięciu błędnych pomiarów ze zbioru (marzec)

	VwG03	VwG09	VwG10	VwG23	VwG24	VwM50	PcG03	PcG09	PcG10	PcG23	PcG24	VwFarma	PcFarma
VwG03	1,000												
VwG09	0,943	1,000											
VwG10	0,938	0,949	1,000										
VwG23	0,910	0,953	0,938	1,000									
VwG24	0,917	0,949	0,955	0,978	1,000								
VwM50	0,923	0,917	0,936	0,894	0,914	1,000							
PcG03	0,976	0,928	0,932	0,897	0,910	0,924	1,000						
PcG09	0,915	0,974	0,931	0,927	0,927	0,908	0,936	1,000					
PcG10	0,924	0,933	0,980	0,912	0,933	0,933	0,948	0,948	1,000				
PcG23	0,901	0,940	0,925	0,969	0,952	0,896	0,917	0,953	0,931	1,000			
PcG24	0,913	0,938	0,944	0,949	0,972	0,919	0,933	0,953	0,955	0,976	1,000		
VwFarma	0,962	0,982	0,978	0,979	0,983	0,938	0,949	0,957	0,958	0,960	0,966	1,000	
PcFarma	0,946	0,964	0,964	0,952	0,960	0,937	0,967	0,980	0,978	0,977	0,986	0,980	1,000

Jak wynika z powyższych tabel prędkość wiatru: z masztu meteo i bezpośrednio z gondoli poszczególnych EW, są ze sobą dosyć silnie skorelowane. Zapewne korelacja mogłaby być silniejsza, gdyby nie różnica między wysokościami, na których dokonano pomiaru. Silniejsza korelacja pomiędzy tymi wartościami występuje wtedy, gdy uśrednimy prędkość wiatru ze wszystkich EW. Silna korelacja występuje również pomiędzy mocą a prędkością wiatru. Korelacja pomiędzy prędkością wiatru zmierzoną na siłowni G03 a wiatrem z siłowni G23 i G24 jest mniejsza ze względu na dużą

odległość między tymi instalacjami, przekraczającą 5 km. Wiatr na maszcie meteo jest słabiej skorelowany z mocą EW, niż wiatr z gondoli EW, co jest oczywiste. Natomiast uśredniony wiatr (V_{wFarma}) i moc (P_{cFarma}) dla całej farmy są silniej ze sobą skorelowane niż każda siłownia osobno.

Wielkość średniej V_w dla całej farmy (V_{wFarma}) została wyliczona z pomiarów chwilowych prędkości wiatru, mierzonych na gondolach, siłowni pracujących w danej chwili (1):

$$V_{wFarma} = V_{sr10min} = \frac{\sum_{j=1}^n \frac{\sum_{i=1}^n V_{i,j}}{k}}{n}, \quad (1)$$


gdzie: $V_{sr10min}$ - średnia prędkość wiatru na farmie z granulacją 10-cio minutową, $V_{i,j}$ - średnia prędkość wiatru mierzona na wysokości gondoli, k - ilość próbek pomiaru prędkości wiatru w czasie 10 minut, n - liczba pracujących siłowni na FW.

Z obliczeń wynika, że średnia prędkość wiatru (V_{wFarma}) jest silnie skorelowana z sumą mocy farmy (P_{cFarma}), patrz tabela 2 i 3, pomimo tego, że każda siłownia pracuje na trochę innym wietrze. Oznacza to, że układy regulacji poszczególnych siłowni pracują dokładnie, tzn. moc siłowni zależy prawie jednoznacznie od wiatru tej siłowni. Przy tak wysokim współczynniku korelacji średnia prędkość wiatru może być reprezentatywną wartością dla całej farmy i może być skutecznie wykorzystywana do modelu mocy farmy wiatrowej i predykcji mocy. Zbiory uczące powinny być oczyszczone z błędnych pomiarów w celu uzyskania wyższego współczynnika korelacji, jak wykazano w powyższej tabeli.


Podmioty przygotowujące prognozy pogody dla źródeł wiatrowych muszą posiadać podstawowe informacje o obiekcie, m.in. wysokość i odległość farmy od stacji meteorologicznej, szorstkość terenu wokół stacji metrologicznej (uwzględniające wszelkie wysokie przeszkody, w tym budynki), jak i farmy. Silna korelacja pomiędzy prędkością wiatru na maszcie a średnią prędkością wiatru dla całej FW oznacza, że wprawdzie wartości są różne, ale trend jest taki sam, co pozwala przypuszczać, że będzie można w modelu FW użyć średniej prędkości, albo dokładnej prognozy. Średni współczynnik korelacji rzędu 0,92 wynika m.in. z niewielkiej odległości masztu meteorologicznego od FW oraz z ukształtowania terenu. Przebadano również kierunek wiatru, który nie jest skorelowany z mocą siłowni, a jak się okazało wpływa na moc FW. Kierunki wiatru na maszcie meteorologicznym i gondolach siłowni są silniej skorelowane niż w przypadku obu prędkości wiatru, co widoczne jest w tabeli nr 3.

Oznacza to tylko tyle, że zmienność obszarowa prędkości jest większa niż kierunku. Kierunek wiatru ma wpływ na przesłonięcie i pionowy profil wiatru.

Poniżej przedstawiono rzeczywiste prędkości wiatru (rys.8) zmierzone na gondolach Farmy B i maszcie meteoerologicznym o wysokości 50 m n.p.g. za wybrany okres. Zgodnie z przypuszczeniem prędkość wiatru na maszcie meteo o wysokości 50 metrów jest mniejsza niż na wysokości gondoli średnio o około 1 m/s.



Rys.8 Prędkość wiatru na farmie (VwFarma) i na maszcie meteo (M50) w okresie 7 dni



Rys.9 Kierunek wiatru na farmie (KwFarma) i na maszcie meteo(M50) w okresie 7 dni
(w tym samym co na rys. 10)

Na rys.9 pokazano średni kierunek wiatru na farmie i na maszcie. Z rysunku wynika, to o czym wspomniano, że pomijając niewytłumaczalne błędy danych, systematyczne, różniące się o około 30 stopni, wskazują na nieprzydatność danych o kierunku do budowy modelu mocy FW. Jak wynika z powyższego, uśredniona (zagregowana)

wartość V_w dla całej FW może przynieść więcej korzyści niż przy indywidualnym wyznaczaniu tej wartości dla każdej siłowni z osobna. Ważnym jest to, aby prognostyczny model meteorologiczny zbudowany został z rzeczywistych pomiarów dla tego typu źródeł (z ich obszaru lub obszaru, gdzie ma powstać planowana farma) i na odpowiedniej wysokości nad poziomem gruntu.

Podsumowanie

Analiza danych pomiarowych z farm wiatrowych umożliwiła zaobserwowanie zjawisk, mających wpływ na ich wyjściową moc elektryczną. W rozdziale tym pokazano cechy, właściwości wiatru na rozległej farmie wiatrowej, czyli prędkości i kierunku: zmienność terytorialną (obszarową), zmienność z wysokością, korelacje między wiatrami oraz między wiatrami a mocą farmy oraz które dane pomiarowe mogą być wykorzystane do identyfikacji parametrów modelu. Czynniki mające największy wpływ na generację mocy wytwórczej, można podzielić na czynniki zewnętrzne oraz wewnętrzne. Do czynników wewnętrznych zaliczają się cechy osobnicze obiektu, tj. lokalizacja farmy (topologia farmy – scentralizowana czy rozproszona, sposób rozmieszczenia EW na farmie i odległości między nimi, rozmieszczenie EW względem dominujących kierunków wiatru, co skutkuje wpływem efektu przesłonięcia, wysokość nad poziomem gruntu, otoczenie farmy – lokalizacja geograficzna, ukształtowanie terenu – orografia, szorstkość terenu) oraz typ poszczególnych farm (krzywa mocy EW, sposób eksploatacji – awarie techniczne, moment bezwładności, układy sterowania). Do czynników zewnętrznych można zaliczyć warunki meteorologiczne (atmosferyczne), tj. prędkość (V_w) i kierunek wiatru (K_w), częstość zmian, dynamikę kierunku wiatru, turbulencję wiatru, gęstość powietrza (wynikająca z temperatury powietrza i ciśnienia atmosferycznego), cykliczność roczną i dobową wiatru oraz opady.

Na potrzeby budowy i weryfikacji modelu prognostycznego potrzebne są dane pomiarowe o kierunku i prędkości wiatru oraz mocy. Przykładowe przebiegi generacji mocy Farmy B: wiosna, lato, jesień, zima, przedstawiono na rys.19. Bezpośrednie pomiary na siłowniach dają możliwość poznania cech charakterystycznych całego obiektu, ale ze względu na lokalizację anemometru umieszczonego na gondoli za łopatom, pomiary strumienia wiatru nie odzwierciedlają faktycznych warunków wiatrowych występujących na FW [63]. Punkty pracy elektrowni i farmy leżą w innych



punktach niż krzywej katalogowej. Ze względu na duże koszty zakupu systemu SCADA, nie wszystkie farmy posiadają możliwość pomiaru V_w i K_w bezpośrednio na gondolach, a wartości generacji mocy FW rejestrowane są tylko przez układy pomiarowo-rozliczeniowe (liczniki) zamieszczone w punkcie przyłączenia farmy do sieci elektroenergetycznej (GPZ). Takie rozwiązanie stosują spółki energetyczne. Należy jednak pamiętać, iż wartość z licznika energii jest wartością zagregowaną, czyli uwzględniającą już wszelkie zjawiska, jakim była poddana farma, m.in. straty przesyłowe wyprodukowanej EE, efekt przesłonięcia, czy też nieprzewidywalne awarie i planowane przeglądy techniczne. Przy wartości zagregowanej trudno jest poznać cechy szczególne obiektu. W przypadku Farmy B, pomiary dodatkowo pozyskano z zewnętrznego masztu meteorologicznego, zlokalizowanego w odległości nieprzekraczającej 10 km od FW. Należy wziąć pod uwagę, iż w zbiorach danych pomiarowych mogą występować dane obarczone błędem wynikającym, np. z braku okresowej kalibracji anemometrów. Dane te mogą wpływać na błędy prognoz generacji mocy. Stąd też dane do procesu uczenia należy wstępnie ocenić, ocenić ich poprawność. Tylko poprawne dane mogą być używane, czyli takie, które nie są znacząco oddalone od pozostałych dla określonych warunków wiatrowych.

2.2. Od czego zależy moc farmy wiatrowej?

Moc rzeczywista FW nie jest wielokrotnością mocy wynikającej z krzywej producenta (katalogowej) każdej pojedynczej siłowni wchodzącej w skład zespołu. Dzieje się tak dlatego, że moc znamionowa pojedynczej EW podawana jest przez producenta dla: określonych standardowych warunków zewnętrznych (gęstości powietrza $1,225 \text{ kg/m}^3$) oraz przy optymalnym ustawieniu względem wiatru i określonym sposobie sterowania. Krzywa mocy jest podawana dla całego zakresu prędkości wiatru. W rzeczywistości każda siłownia pracuje w innych warunkach wiatrowych, zmiennej temperaturze, wilgotności i gęstości powietrza.


Na poniższych wykresach przedstawiono przebiegi czasowe generacji mocy: łącznie dla 5 siłowni Farmy B oraz indywidualnie dla jej poszczególnych siłowni, w różnych porach roku, tj. w okresie letnim (rys.10) oraz zimowym (rys.11). Każdy z nich to okres jednego tygodnia. Na rysunkach widać również dwie wartości prędkości wiatru z masztu meteo oraz uśrednioną z gondoli. Znając prędkość wiatru pomierzoną

bezpośrednio na gondoli EW można w przybliżeniu odtworzyć rzeczywistą krzywą mocy każdej siłowni. Jak widać na rys.10 i 11 każda siłownia generuje inną wartość mocy wytwórczej w poszczególnych godzinach doby, co potwierdza, że każda EW pracuje w trochę odmiennych warunkach wiatrowych. Na każdym z tych rysunków widoczne są dane znacząco oddalone w pewnych sytuacjach od pozostałych, które mogą świadczyć o zaistniałej awarii siłowni lub też innym ograniczeniu podczas pracy, np. przeglądzie serwisowym. Przeglądy serwisowe planowane są przede wszystkim w okresie letnim, kiedy prędkości wiatru są najmniejsze. Znając tylko zagregowaną moc wytwórczą FW, odczytaną w GPZ (poprzez układ pomiarowo-rozliczeniowy), nie ma możliwości przeprowadzenia dokładnej analizy pracy obiektu i uwzględnienia wszystkich czynników wpływających na moc poszczególnych siłowni. Przykładowo na rys.10 b) widać jak w siódmym dniu tygodnia doszło do wyłączenia siłowni nr G24, w zagregowanej mocy FW na rys.10 a) tego już nie widać. Więcej podobnych sytuacji widać na przebiegach przedstawionych na poniższych rysunkach. W tabeli 4 pokazano współczynniki korelacji pomiędzy prędkością wiatru z masztu i uśrednioną prędkością wiatru dla całej Farmy B a rzeczywistą generacją mocy.


Tabela 4 Korelacja mocy Farmy B

Korelacja mocy	Okres letni			Okres zimowy		
	<i>V_{wM50}</i>	<i>V_{wFarma}</i>	<i>P_{cFarma}</i>	<i>V_{wM50}</i>	<i>V_{wFarma}</i>	<i>P_{cFarma}</i>
V _{wM50}	1			1		
V_{wFarma}	0,890	1		0,923	1	
P_{cFarma}	0,851	0,944	1	0,884	0,962	1

Z tabeli wynika, że prędkości wiatru w okresie zimy są lepiej skorelowane z generacją mocy (wsp. 0,962) niż w okresie letnim (wsp. 0,944). Zimą wiatry są znacznie silniejsze, co można wnioskować na podstawie generacji mocy (różnica dla badanego okresu wyniosła 44%). Może to wynikać również z mniejszej dynamiki zmiany kierunku wiatru, który przyczynia się do zmian prędkości wiatru. Moc farmy jest silnie skorelowana z wartością średnią prędkości wiatru ze wszystkich gondoli. Oznacza to, że układy regulacji każdego wiatraka działają bardzo precyzyjnie. Korelacja pomiędzy mocą farmy a prędkością wiatru z masztu meteo umieszczonego na farmie w niezaburzonej strumieniu powietrza jest także wysoka, ale istotnie niższa. Świadczy to o problemie z określeniem na podstawie prognozy pogody tzw. reprezentatywnej prędkości wiatru. Szczególnie przy farmie o rozległej strukturze.




a)




b)

Rys.10 Generacja mocy farmy i średnia prędkość wiatru Farmy B i pojedynczych jej 5 siłowni porą letnią (07-13.06.2009 roku)



a)



b)

Rys.11 Generacja mocy farmy i średnia prędkość wiatru Farmy B i pojedynczych jej 5 siłowni porą zimową (15-21.11.2008 roku)

Z danych pomiarowych przedstawionych na rys.10 i 11 można uzyskać zależność $P = f(V)$, czyli zbiór punktów pracy FW. Model mocy FW ma za zadanie odtworzenie aktualnej krzywej mocy, czyli każdej prędkości wiatru przyporządkować jedną wartość mocy farmy, jak na rys.12. Krzywe mocy odgrywają kluczową rolę w procesie prognozowania mocy wytwórczej FW. Na potrzeby budowy modelu mocy FW usunięto najbardziej odstające błędne pomiary ze wszystkich zbiorów danych, aby krzywa mocy FW była wiarygodna. Na rys.12 a) przedstawiono krzywe mocy poszczególnych siłowni (Farmy B), a na rys.12 b) łącznie dla wszystkich siłowni uzyskane na podstawie oryginalnych, niezmodyfikowanych danych pomiarowych. Przy małych prędkościach wiatru rzeczywista krzywa mocy zbliżona jest do katalogowej, natomiast przy większych wiatrach różni się znacznie. W efekcie moc jest mniejsza niż można byłoby oczekiwać dla określonych warunków wiatrowych.


Wcześniejsze badania wskazują, że w pewnych okresach czasu, przy tzw. dynamicznej pogodzie, istotną rolę odgrywa też dynamika wiatru. Można rozważyć zastosowanie nie tylko wartości aktualnej wiatru, ale także wartości poprzednich co pozwoli na odwzorowanie dynamiki wiatru. Największe różnice pomiędzy mocą katalogową a rzeczywistą występują w okolicach znamionowej prędkości wiatru (zagięcie i ograniczenie mocy).

2.2.1. Moc pojedynczej siłowni a moc farmy


Suma mocy katalogowej pojedynczych siłowni, tworzących FW, daje wartość maksymalną (moc zainstalowaną), jaką jest w stanie osiągnąć farma dla znamionowych prędkości wiatru. Wartość mocy znamionowej FW można wykorzystać przy ocenie jakości zbudowanego modelu prognostycznego. Moc pojedynczej siłowni wyrażona jest zależnością (2):

$$P_c = \frac{1}{2} C_p \cdot \rho \cdot A \cdot V_w^3 \quad (2)$$

gdzie $C_p=f(\lambda,\beta)$ jest współczynnikiem mocy zależnym od tzw. wyróżnika szybkobieżności $\lambda=\omega R/V$; β - kątem ustawienia łopat wirnika, A – powierzchnią omiatania, V_w – prędkością wiatru i ρ - gęstością powietrza.




a) Moc 5 turbin Farmy B w funkcji prędkości wiatru – przed (marzec)




b) Moc Farmy B w funkcji prędkości wiatru – przed (marzec)





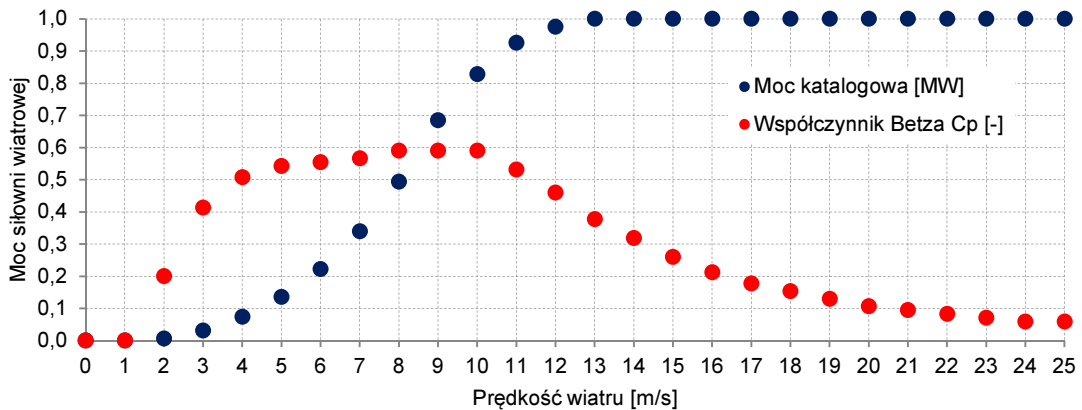
c) Moc 5 turbin Farmy B w funkcji prędkości wiatru – po (marzec)



d) Moc Farmy B w funkcji prędkości wiatru – po (marzec)

Rys.12 a, b, c, d) Zbiór punktów pracy pojedynczych siłowni oraz farmy (marzec), a i b) krzywa mocy przed usunięciem błędnych danych, c i d) krzywa mocy po usunięciu błędnych danych

Charakterystyka $P_c = f(V)$ elektrowni zależy więc od rodzaju elektrowni i sposobu jej sterowania. Na rys.13 pokazano przykładową charakterystykę katalogową.



Rys.13 Punkty pracy silowni w funkcji prędkości wiatru wraz ze współczynnikiem Betza

Z kształtu C_p wynika, że moc jest wynikiem nieliniowego przekształcenia prędkości wiatru. Charakterystykę podaną w katalogu, zgodnie z normą EN61400-12-1:2006, uzyskuje się z danych pomiarowych i po sprowadzeniu do warunków standardowych ($\rho=1,225 \text{ kg/m}^3$). Jak już wspomniano w warunkach rzeczywistych charakterystyka elektrowni nie pokrywa się z katalogową z powodu odmiennych warunków. Zależność mocy od gęstości powietrza (czynnik wskazujący porę roku), a więc od temperatury, ciśnienia i wilgotności wynika bezpośrednio z równania (2). Zmiana gęstości powietrza o 10% jest w naszych warunkach klimatycznych normalnym zjawiskiem.

Przykładowo: dwie farmy o tej samej mocy zainstalowanej, ale o różnej strukturze (rozmieszczenia EW na terenie farmy) i jej obszarowej lokalizacji (nad morzem czy w górach), pomimo podobnych warunków wiatrowych, wygenerują inną ilość EE. Różnica może wynikać także z powodu efektu przesłonięcia. Na FW o gęstym rozmieszczeniu silowni można zaobserwować efekt wzajemnego przesłaniania się EW, natomiast w przypadku farm o rozproszonej strukturze już niekoniecznie. W dalszej części pracy przedstawiono różne sytuacje występujące na FW i ich wpływ na generację mocy wytwórczej.

2.2.2. Moc farmy a wyłączenia i awarie

Siłownie poddawane są różnym wymuszeniom wiatrowym, które przyspieszają degradację części mechanicznych poszczególnych EW. Zmiany kierunku wiatru, w szczególności w okresie letnim, wymuszają na układach regulacji częste zmiany położenia gondoli względem strumienia wiatru. W efekcie nadmierna eksploatacja może prowadzić do wyłączenia siłowni lub awarii. Poniżej pokazano wybrane, najczęściej występujące awarie.

Tabela 5 Rodzaje awarii technicznych turbin

TYP AWARII	PRZYCZYNA POSTOJU LUB AWARII SIŁOWNI
Awarie energetyczne	Zaniki napięcia na GPZ
	Zwarcia symetryczne i niesymetryczne, doziemienia
Awarie hydrauliczne	Niski poziom oleju
	Niskie ciśnienie oleju w przekładni zębatej (wysoka temperatura przekładni)
	Wysoka temperatura łożyska
	Wysoka temperatura przekładni zębatej
	Wysoka temperatura tarcz hamulcowych


Do wyłączenia mogą przyczynić się również inne sytuacje, np. uderzenie pioruna w łopaty i ich uszkodzenie [72]; może też dojść do ograniczenia mocy z powodu wysokich, nadmiernych drgań lub spadku ciśnienia oleju. Częste wyłączenia wpływają na generację mocy i zaburzają dane pomiarowe, w szczególności dane zagregowane w GPZ. Na rys.14, 15 i 16 przedstawiono moc Farmy A i jej pojedynczych siłowni oraz kierunki wiatru. Na rys.16 c) pokazano przebiegi mocy poszczególnych siłowni ze wskazaniem w trzeciej dobie na przerwę w generacji mocy EW nr G03. Siłownia wstrzymała generację na pewien okres, po czym wróciła do pracy, a algorytm odpowiedzialny za ukierunkowanie gondoli względem strumienia wiatru, próbował dopasować właściwy kąt dzięki czujnikowi kierunku, co widać na rys.16 a). Podobne zjawisko wystąpiło również dobę później z tym, że dotyczyło innej siłowni (nr G02). Na rys.16 b) w mocy zagregowanej FW nie widać momentu wyłączenia siłowni, a jedynie mniejszą generację. Nie mając dostępu do informacji o wyłączeniu siłowni, trudno dostrzec takie zjawisko z poziomu analizy danych zagregowanych. Podobnie jest na znacznie większej Farmie B, gdzie również nie widać momentu wyłączenia siłowni (patrz rys.19 b).

Na rys.17, 18 i 19 przedstawiono wpływ zmiany kierunku wiatru na moc Farmy B i jej pojedyncze siłownie. Na rys.17 widoczne są krzywe mocy Farmy B (rzeczywista i katalogowa) oraz średni kierunek wiatru w funkcji prędkości wiatru. Przez większość czasu w tym okresie dominującym kierunkiem był kierunek południowo-zachodni ze zmianą na kierunek północno-zachodni i następnie na krótki czas na północno-wschodni. To właśnie w tym czasie doszło do wyłączenia siłowni nr G023. Wniosek z analizy sugeruje, iż czym większa zmienność kierunku wiatru, tym częściej dochodzi do wyłączeń ze względu na przeciążenia mechaniczne wywołane podmuchami wiatru.


2.2.3. Moc farmy z ograniczeniem mocy

Jak wspomniano wcześniej (rys.14÷19), siłownie poddawane są różnym wymuszeniom wiatrowym. Układy sterowania pracą EW odpowiedzialne są nie tylko za efektywne wykorzystanie panujących warunków wiatrowych, lecz również za ich bezpieczeństwo konstrukcyjne. W przypadku wystąpienia awarii (np. wzrostu temperatury przekładni zębatej) lub też drgań konstrukcji może dojść do ograniczenia mocy FW. Zjawisko można zaobserwować na rys.21 i 22 c) oraz 24 i 25 c). Moc jednej siłowni (G02) została ograniczona do ponad 30% mocy znamionowej (rys.21). Natomiast na rysunkach 22 c) została ograniczona moc siłowni nr G03. Na rys.22 widoczne są również drobne różnice osobnicze, tzn. generacja mocy przez poszczególne siłownie nie jest identyczna dla tej samej prędkości wiatru, a wpływ na to ma inny kierunek wiatru dla każdej siłowni z osobna, np. moc siłowni nr G02 jest mniejsza niż pozostałych.


Do ograniczenia mocy dochodzi z różnych powodów, oprócz awarii, to przede wszystkim ze względu na ochronę przed uszkodzeniem. Największym zagrożeniem dla FW są silne podmuchy wiatru przekraczające wartość maksymalną, gdzie zadaniem układu sterowania jest wyłączenie poszczególnych siłowni przy określonej prędkości wiatru (dla badanych modeli siłowni to 25 m/s). Dane obciążone stanami nienormalnymi farmy nie mogą być uwzględniane przy ustalaniu parametrów obiektu, czyli przy identyfikacji.




Rys. 14 Moc Farmy A w funkcji prędkości wiatru




Rys. 15 Moc turbin w funkcji prędkości wiatru Farmy A



a)




b)




c)


Rys.16 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej z 4 turbin, b) łączna moc farmy, c) indywidualna moc dla każdej z 4 turbin




Rys.17 Moc Farmy B i średni kierunek wiatru w funkcji prędkości wiatru




Rys.18 Moc 5 turbin w funkcji prędkości wiatru Farmy B (okres wiosenny)



a)




b)




c)


Rys.19 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy B: a) kierunek wiatru dla każdej z 5 turbin, b) łączna moc farmy, c) indywidualna moc dla każdej z 5 turbin




Rys.20 Moc Farmy A w funkcji prędkości wiatru




Rys.21 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)





b)




c)

Rys.22 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej z 4 turbin, b) łączna moc farmy, c) indywidualna moc dla każdej z 4 turbin




Rys.23 Moc Farmy A w funkcji prędkości wiatru


Rys.24 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)



b)




c)

Rys.25 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej turbiny, b) łączna moc farmy, c) indywidualna moc dla każdej z 5 turbin

2.2.4. Moc farmy w warunkach silnych podmuchów wiatru

Odchylenie mocy farmy od krzywej katalogowej może wynikać także z dużej energii podmuchów wiatru i metody pomiaru (uśredniania). Układ sterowania generatora działa co około 400 μ s, a układy *pitch* (czyli pozycjonowania łopat) kilka razy na sekundę. Wynika to z dynamiki obiektu. Dane na potrzeby np. operatora zbierane są co 2 sekundy, a następnie uśredniane za 10 minut (zgodnie z normą) i w pracy są wykorzystywane dane uśrednione. Przy dynamicznej pogodzie te uśrednione wartości nie tworzą jednej krzywej mocy, która jest określana dla stabilnych warunków pracy.

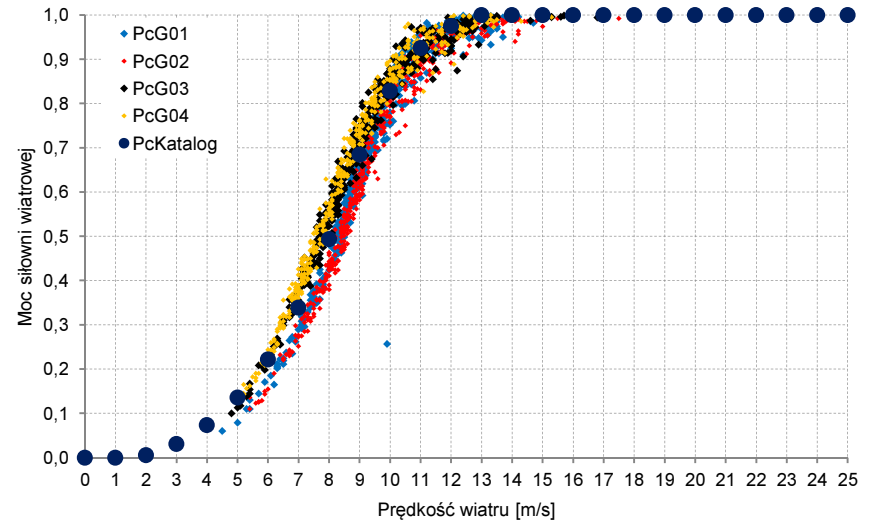

Na rys.26 przedstawiono średnią wartość generacji mocy za ostatnie 10 minut, na tle katalogowej krzywej mocy, w funkcji chwilowej prędkości wiatru: 1 punkt pomiarowy (mniejsze kropki), to wartość mocy za okres 2 sekund. P_{sr} oznacza średnią wartość mocy po 10-ciu minutach. Chwilowe wartości prędkości wiatru również zostały uśrednione V_{sr} . W efekcie średnia wartość mocy może być nad katalogową krzywą mocy. Można wnioskować, iż punkty pracy znajdują się w pewnym obszarze wokół katalogowej krzywej mocy.



Rys.26 Wartość średnia mocy P_{sr} (największa kropka) 10-cio minutowa otrzymana z pomiarów dwusekundowych w funkcji chwilowej prędkości wiatru V_{sr} (V_{start} oznacza startową prędkość siłowni wiatrowej, V_n – znamionową prędkość wiatru, V_{max} – wyłączeniową prędkość wiatru, P_n – znamionową moc urządzenia)


Farma poddawana jest w okresie eksploatacji różnym warunkom wiatrowym również gwałtownym zmianom wiatru. Te wąskie strefy przejściowe pomiędzy różnymi (pod względem temperatury i wilgotności) masami powietrza, mogą sprawić, że farma osiągnie w krótkim czasie maksymalną moc lub zostanie wyłączona ze względu na bezpieczeństwo konstrukcyjne (po przekroczeniu określonej prędkości wiatru, około 25 m/s) w danej dobie, co jest rzadkim zjawiskiem, lecz spotykanym (patrz rys.31 i 32 c). Fronty atmosferyczne niosą ze sobą silne podmuchy wiatru, co widać na rys.32 b i c oraz 35 b i c. Poza przyczyną o której wspomniano jest jeszcze kilka innych: moc elektrowni zależy od prędkości obrotowej a nie od prędkości wiatru. Wiatr jest mierzony na gondoli a wiatr na kole wiatrowym może być trochę inny, większy. Jest jeszcze inna gęstość powietrza i dynamika elektrowni, np. wiatr jest już mniejszy a elektrownia obraca się jeszcze szybciej i chwilowo generuje większą moc.

Z rys.30÷32 wynika, że w drugiej dobie zaczęło mocno wiać, kierunek wiatru był stabilny (średnio 245 st.), a prędkość wiatru zmieniała się szybko, co potwierdzają wyłączenia siłowni wiatrowych. Na rys.33÷35 widoczne jest ograniczenie mocy przy prędkości wiatru wyłączającej siłownię, co potwierdza prawidłowe funkcjonowanie układu regulacji. Silne podmuchy wiatru oprócz tego, że mogą wyłączyć siłownię, to mogą również uszkodzić siłownię na końcu mechanicznie, np. odrywając łopaty od piasty, itp.




Rys.27 Moc Farmy A w funkcji prędkości wiatru


Rys.28 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)





b)




c)

Rys.29 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej turbiny, b) łączna moc dla farmy, c) indywidualna moc dla każdej z 5 turbin




Rys.30 Moc Farmy A w funkcji prędkości wiatru


Rys.31 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)

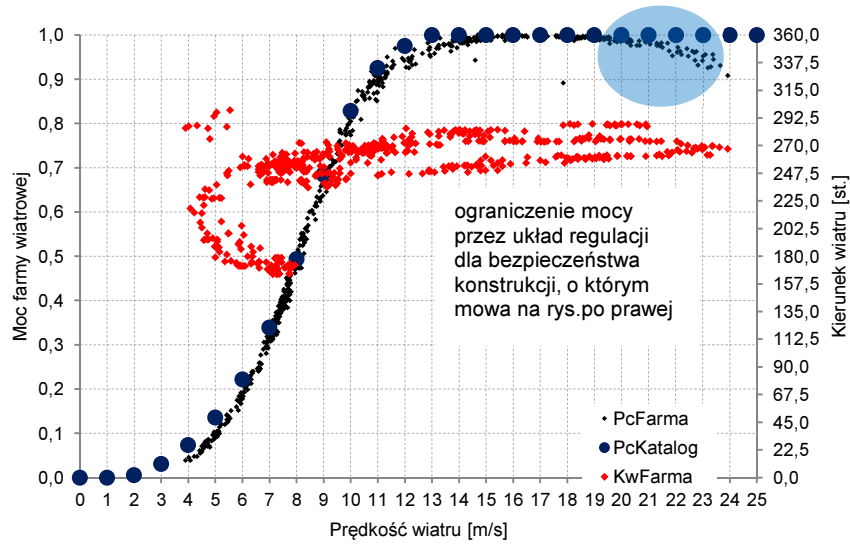


b)




c)


Rys.32 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej turbiny, b) łączna moc dla farmy, c) indywidualna moc dla każdej z 5 turbin




Rys.33 Moc Farmy A w funkcji prędkości wiatru




Rys.34 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)



b)



c)


Rys.35 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej turbiny, b) łączna moc dla farmy oraz c) indywidualna moc dla każdej z 5 turbin

2.2.5. Moc farmy z efektem przesłonięcia

Oprócz analizy prędkości wiatru zarejestrowanego na FW wykonano również analizę zmiany kierunku wiatru, mającego także wpływ na generację mocy FW. Kierunek wiatru wpływa na moc farmy w dwojaki sposób (patrz rys.39 i 40):


1. Zależnie od kierunku może być różna szorstkość terenu, a więc i profil pionowy wiatru. Jeżeli jest konieczność ekstrapolacji prędkości wiatru na inną wysokość to przy różnej szorstkości otrzymuje się różne wartości.
2. Zależnie do kierunku wiatru poszczególne siłownie mogą się wzajemnie przesłaniać [40]. Zależnie od poziomu przesłonięcia moc farmy jest różna (dla Farmy A to dwa kierunki - około 315 stopni oraz 135 stopni).

Zmienność wiatru zależy od ukształtowania terenu, typu pokrycia terenu, rozmieszczenia różnych przeszkód (np. wysokich drzew), obecności zbiorników wodnych. Ukształtowanie terenu wpływa na zachowanie się strug powietrza omiatających dany obszar. Wszelkie przeszkody terenowe powodują zawirowania strugi powietrza (turbulentność wiatru). Szorstkość terenu określana jest wartością współczynnika [75, 88] dla każdej lokalizacji (np. dla terenu otwartego, wiejskiego i z wysokimi przeszkodami, tj. miasto, las, itp.), gdzie znajduje się farma. Parametr ten ma wpływ na profil pionowy wiatru. Jeżeli wokół FW teren jest zróżnicowany, to zależnie od kierunku wiatru prędkość na wysokości piasty jest inna. Na rys.36 przedstawiono profil pionowy wiatru przy zmiennej szorstkości terenu z $V = 4$ m/s. Im większy współczynnik szorstkości terenu, tym większa zmienność wiatru z wysokością [10, 75].



Rys.36 Prędkość wiatru w funkcji wysokości dla różnych współczynników szorstkości (alfa)

Na rys.37 pokazano z kolei zmienność wiatru z wysokością dla różnych prędkości na wysokości pomiarowej, ale przy stałej szorstkości terenu $\alpha = 0,165$ [wg 75].



Rys.37 Prędkość wiatru w funkcji wysokości dla współczynnika alfa równego 0,165

Współczynnik szorstkości terenu dla farm zlokalizowanych w północnej części kraju (w pobliżu morza) został sklasyfikowany dla badanych farm wg duńskiej klasyfikacji na poziomie pierwszym ($\alpha = 0,165$, rys.36 i 37). W literaturze spotykane są również inne klasyfikacje [26, 74, 76]. Poziom pierwszy oznacza najczęściej, iż teren wokół farmy jest otwartą przestrzenią, z niewielką ilością drzew, krzewów i zabudowań (bardzo rzadkich). Dla otwartych wód współczynnik szorstkości terenu przyjmowany jest na poziomie zerowym. Natomiast kierując się w głąb lądu, współczynnik ten stopniowo się zwiększa (maksymalnie do poziomu piątego). Stąd też można przyjąć, że dla wiatrów wiejących od morza (z północy) szorstkość terenu jest niższa niż dla wiatrów wiejących od lądu.


Efekt przesłonięcia określa się zmniejszenie mocy siłowni pracującej w cieniu innej elektrowni lub przesłonięcia, wskutek mniejszej prędkości wiatru. Jeżeli siłownie na farmie zostały posadowione w bliskiej od siebie odległości (np. w mniejszej niż 3-D średnicy wirnika), takie zjawisko będzie często występowało. Wraz ze zmianą kierunku wiatru zmieniają się warunki pracy poszczególnych elektrowni wynikające ze wzajemnego przesłaniania. Wpływ przesłonięcia zależy od struktury FW: wzajemnego rozlokowania siłowni i ustawienia względem dominującego kierunku wiatru [77]. Każda siłownia pracuje w innym punkcie pracy i spadek mocy spowodowany, m.in. przesłonięciem, może być duży (nawet o 20-25%, wybrany przypadek patrz tabela 6). Mniejsza generacja mocy przez poszczególne siłownie

o 20-25%, przy częstym występowaniu tego typu zjawiska, zagreguje w dłuższym okresie większe straty w rozrachunku energii netto.

Tabela 6 Analiza wzajemnego przesłaniania się siłowni w okresie 2 godzin (Farma A)

Efekt przesłonięcia	PcG01	PcG02	PcG03	PcG04	PcFarma
Średnia prędkość wiatru VwŚr [m/s] za 2 h	5,7	5,6	5,3	5,2	5,5
Średni kierunek wiatru KwŚr [st.] za 2 h	312,3	297,7	315,8	295,8	305,4
Suma mocy jednej turbiny za 2 h	0,250	0,195	0,195	0,187	0,827
Suma PcFarma z przesłonięciem za 2 h	0,827				
Suma PcFarma bez przesłonięcia (moc PcG01*4 siłownie) za 2 h	1,000				
Błąd względny rzeczywisty $\frac{P_{cG01} - P_{cG02} + 04}{P_{cG01}} [\%]$	0,0%	21,9%	22,1%	25,3%	17,3%


W tabeli 6 przedstawiono wyniki różnic generacji mocy siłowni nr G02÷G04 po wystąpieniu efektu przesłonięcia. Siłownie te zostały przesłonięte przez turbinę nr G01 (kierunek wiatru zmienił się z północno-zachodniego na północno-wschodni, rys.38), co skutkowało stopniowym spadkiem generacji widocznym już od siłowni nr G02 (dobrze widocznym na rys.40) aż do ostatniej stojącej w szeregu nr G04. Błąd względny wyliczono w odniesieniu do generacji mocy siłowni nr G01.




Rys.38 Zmiana kierunku wiatru na Farmie A

Znając warunki meteorologiczne oraz moc farmy z poprzednich godzin, można oszacować straty mocy powstałe na skutek wzajemnego przesłaniania się siłowni, a także wielokrotność i dynamikę zmian kierunku wiatru. Dynamika zmian kierunku

napływającego strumienia powietrza, jest na ogół pomijana w algorytmach do prognozowania mocy. Na rys.39 i 40 pokazano zmianę mocy poszczególnych siłowni Farmy A pod wpływem prędkości i kierunku wiatru w ciągu jednej doby.



Rys.39 Moc 4 turbin wiatrowych Farmy A, prędkość i kierunek wiatru





Rys.40 Analiza wzajemnego przesłonięcia się 4 turbin wiatrowych Farmy A (z rys.38)

Na rys.40 (w 30-tej minucie) widoczna jest dynamiczna zmiana kierunku wiatru, gdzie kierunek wiatru w ciągu 10-ciu minut zmienił się dla wszystkich siłowni średnio o około 30 stopni. W ciągu tej badanej doby zjawisko to już więcej razy nie wystąpiło. Powstała różnica generacji mocy pomiędzy siłowniami wynika przede wszystkim z efektu przesłonięcia, szczególnie widocznego dla turbiny PcG04 (tabela 6). Częste dynamiczne zmiany kierunku wiatru jak również turbulencje wiatru powodują lokalne nieoptymalne ustawienie gondoli względem wiatru i zmniejszenie mocy. Pewną rolę odgrywa także układ sterowania: obrotem gondoli i kątem ustawienia łopat.


Zjawisko przesłonięcia, czyli zmniejszenia prędkości wiatru siłowni pracującej w cieniu, ma oczywisty wpływ na moc generowaną. Ujęcie analityczne tego zjawiska wymaga znajomości topologii terenu, a przede wszystkim topologii farmy oraz kierunku wiatru. Przesłonięcie na farmie występuje prawie zawsze i obniża moc siłowni i farmy. Skala tego zjawiska zależy przede wszystkim od odległości między siłowniami. Dla mniej licznych farm, lub siłowni ustawionych w jednej linii, przesłonięcie jest w większym stopniu uzależnione od kierunku wiatru. Zarówno zmienność wiatru na terenie farmy jak i profil pionowy wiatru, są funkcją kierunku wiatru. Przy posadowieniu farmy na terenie o zróżnicowanej topologii, np. farmy nad brzegiem morza (zjawisko bryzy morskiej), wpływ kierunku wiatru na moc farmy może być istotny.

Wpływ kierunku wiatru można również zaobserwować na krzywej mocy poszczególnych siłowni (rys.42), w mniejszym stopniu na krzywej farmy ze względu na zagregowane odchylenia (rys.41). Oczywistym jest, że wraz ze zmianą kierunku wiatru zmienia się również prędkość wiatru i z tym związana generacja mocy (rys.43 a). FW pracująca nieustannie w określonych stabilnych warunkach wiatrowych generuje wartości mocy zbliżone do katalogowych (rys.41) pod warunkiem, że nie występuje zbyt duża dynamika zmiany kierunku wiatru. Na rys. 43 b i c) widać dynamikę zmiany kierunku wiatru i wpływ na generację mocy, najczęściej w postaci spadku mocy. Zmiana kierunku wiatru sprawia, że układ sterowania siłownią ustawia gondolę przy każdej zmianie w optymalnym położeniu względem napływającego strumienia wiatru. Zmiana kierunku wiatru ma mniejszą skalę wpływu na generację mocy niż prędkość wiatru, co wynika ze wzoru (2).




Rys.41 Moc Farmy A w funkcji prędkości wiatru


Rys.42 Moc 4 turbin w funkcji prędkości wiatru Farmy A



a)



b)



c)

Rys.43 Generacja mocy i średnia prędkość wiatru w funkcji czasu Farmy A: a) kierunek wiatru dla każdej z 4 turbin, b) łącznie dla farmy, c) indywidualnie dla każdej z 4 turbin

2.3. Podsumowanie analizy mocy

Podczas analizy czynników mających wpływ na generację mocy wytwórczej farmy zwrócono szczególną uwagę na dynamikę zmian kierunku wiatru. Przy zmianie kierunku wiatru dochodzi do zmiany wartości prędkości wiatru (np. patrz rys.41÷43), która przekłada się na prędkość obrotową wirnika generatora. Prędkość wiatru ma największy wpływ na wolumen generacji mocy (odgrywa najistotniejszą rolę w predykcji mocy FW). Uwzględnienie kierunku wiatru w modelach mocy może poprawić jakość prognozy, lecz w mniejszym stopniu niż przy posiadaniu dokładniejszej prognozy pogody. Przy budowie modelu mocy ważnym jest również uwzględnienie gęstości powietrza. Różnica w wolumenie generacji mocy (pomiędzy najbardziej skrajnymi okresami: letnim i zimowym) wynika m.in. przede wszystkim z gęstości powietrza (zimą jest większa niż latem) oraz mniejszej dynamiki i częstotliwości zmiany kierunku wiatru. Generalnie jest tak, że w miesiącach letnich wiatry są słabsze, ale o większej zmienności niż w miesiącach zimowych. Z analizy wynika również, że należy posiadać informację o liczbie gotowych do pracy siłowni na farmie, a także ograniczenia konstrukcyjne i regulacyjne w układach sterowania. Zwrócono również uwagę na to, że dynamiczne zmiany kierunku występują przy małych prędkościach wiatru (w okresie letnim), co oznacza, że w modelach zimowych nie ma potrzeby uwzględniania dynamiki zmian kierunku wiatru.

Celem analizy było wyjaśnienie:

- wpływu zjawisk meteorologicznych na generację mocy (m.in. wielokrotności i dynamiki zmian kierunku strumienia powietrza),
- wpływu występowania awarii technicznych na moc farmy.

3. Budowa modelu mocy FW

3.1. Modele prognostyczne w literaturze – stan aktualny

Na świecie zrealizowano dotychczas wiele projektów mających na celu opracowanie skutecznych narzędzi wspomagających proces predykcji generacji mocy wytwórczej FW [4÷76]. W praktyce wykorzystuje się coraz bardziej popularne modele hybrydowe zbudowane z kilku innych modeli, np. fizykalnych i behawioralnych lub w innej konfiguracji. Wybór modelu podyktowany jest najczęściej aspektami ekonomicznymi. Niezależnie od budowy modelu, zadaniem każdego jest przetworzenie danych pomiarowych z systemów meteorologicznych w skali lokalnej jak i globalnej. Mając do dyspozycji również inne dane, np. szorstkość terenu, powierzchnię omiotu łopatek turbiny, lokalizację i rozmieszczenie obiektu, itp., nie zawsze można skutecznie wykorzystać te dodatkowe informacje. Każdy model ma inne właściwości i przeznaczenie (np. do prognoz długoterminowych, czy też krótkoterminowych). W literaturze tematu mało jest informacji o dynamice zmiany kierunku wiatru [33, 36, 37, 41, 44, 51], która wpływa na rzeczywistą krzywą mocy farmy. Krótkoterminowe prognozy mocy FW wymagają adekwatnego modelu uwzględniającego nie tylko wiatr, jako wymuszenie, ale także inne czynniki jak m.in.: przesłonięcie, temperaturę, profil pionowy, dynamikę wiatru, czy charakterystyki siłowni. Publikacje nie opisują szczegółowo sposobu dojścia do wyników i konkluzji. Natomiast dużo wspomina się o dynamice zmiany wartości prędkości wiatru.

3.1.1. Model fizykalny

Modele fizykalne [42, 46, 60] opierają się na opisie matematycznym zjawisk fizycznych w sensie jakościowym i ilościowym. Modele te wymagają dokładnych, nie zawsze dostępnych, danych i długotrwałej weryfikacji. Model fizykalny (analityczny) wykorzystuje dane o prędkości i kierunku wiatru oraz teoretyczną charakterystykę mocy producenta (punkty pracy). Z badań (rys.19) wynika, że moc każdej elektrowni jest silnie skorelowana (na poziomie 0,97) z prędkością wiatru mierzoną na gondolach siłowni. Największą trudnością jest budowa modelu dla farmy o rozproszonej strukturze, chociażby ze względu na określenie reprezentatywnej

wartości prędkości i kierunku wiatru. Z rys.7 wynika, że różnice na rozległej farmie mogą być istotne, rzędu nawet 30 %. Model farmy odtwarza moc obiektu dla określonych wymuszeń, z których głównymi są prędkość i kierunek wiatru na farmie, na wysokości gondoli. Wiatr z najbliższej stacji meteorologicznej (M50, patrz tabela 2 i 3) można potraktować, jako wymuszenie dla modelu. Współczynnik korelacji prędkości wiatru pomiędzy masztem meteorologicznym (M50), a siłownią wiatrową VwG03 jest wyższy niż w zestawieniu z siłowniami znacznie oddalonymi VwG23 i VwG24. Dokładność modelu, którego funkcją jest prognozowanie generacji mocy jest zadowalająca, gdy odległości między stacją meteorologiczną a lokalizacją źródeł wiatrowych jest mniejsza niż 10 km [46]. Dla stabilnych wiatrów model analityczny jest adekwatny, a błąd estymacji niewielki, natomiast w miesiącach letnich, przy słabych i mocno zmiennych wiatrach oraz dynamicznej pogodzie (wiatr termiczny) błąd modelu jest większy. W miesiącach letnich składowa wiatru tzw. lokalna ma większy udział i automatycznie korelacja pomiędzy wiatrem na farmie i w lokalizacji odległej jest mniejsza [60].

3.1.2. Modele statystyczne

Modele statystyczne (ANEMOS, ARIMA, itp.) wykorzystują zgromadzoną bazę danych do określenia mocy przyszłej z określonym prawdopodobieństwem błędu lub szukając podobnych zdarzeń w przeszłości [45, 61]. Modele te przedstawiają powiązania występujące pomiędzy rzeczywistymi zjawiskami, czyli umożliwiają badanie zależności pomiędzy prędkością wiatru a generacją mocy. Zakładając powtarzalność pewnych warunków wiatrowych na farmie, można statystycznie określić najbardziej prawdopodobną generację mocy w tych warunkach. W pracy [47] zaproponowano metodę prognozowania polegającą na połączeniu obu procesów, czyli na wnioskowaniu o mocy w określonej lokalizacji na podstawie prognozy wiatru dla lokalizacji odległej, wykorzystując metody statystyczne. Współczynnik korelacji ciągów czasowych prędkości wiatru [62] dla odległości do 10 km jest na tyle wysoki, że umożliwia jego wykorzystanie do predykcji, natomiast przy odległościach powyżej 20 km prognoza jest obciążona większym błędem [69].

3.1.3. Modele behawioralne

Modele behawioralne [43, 47, 69] wykorzystują wyniki pomiarowe do zbudowania modelu typu *black box* lub *grey box*. Są to modele obiektów nie oparte na fizycznym opisie związków między zmiennymi. Model behawioralny budowany jest tylko lub prawie tylko na podstawie informacji o zmiennych wejściowych i wyjściowych, określa związki między nimi, bez wnikania w sens fizyczny tych związków. Model behawioralny aproksymuje zachowanie obiektu. Do odtworzenia zachowania obiektu wykorzystuje się doświadczenie człowieka i np. sztuczne sieci neuronowe. Modele takie wymagają dużego zbioru danych uczących i weryfikujących.

3.1.4. Podsumowanie metod predykcji

Omówione w pracy metody prognostyczne są najczęściej spotykanymi w literaturze. Pragmatyka preferuje podejście hybrydowe [66, 71, 73]. Rezultaty stosowania tych metod nie mają jednoznacznej opinii, stąd tak wiele projektów mających na celu wskazanie najskuteczniejszych metod [31, 38, 64, 70]. Do predykcji mocy wytwórczej farm wykorzystuje się również modele neuronowe. Metody szeregów czasowych ARMA nie wymagają znacznych nakładów finansowych na przygotowanie predykcji lecz mają inne przeznaczenie ze względu na skuteczność działania. Metody te najlepiej sprawdzają się dla krótkiego horyzontu prognozy, np. 6-cio godzinnego. Ze względu na małą moc zainstalowanych siłowni wiatrowych w Polsce dotychczas nie było potrzeby stosowania specjalistycznych metod predykcji. Sieci neuronowe mogą stanowić alternatywę dla metod statystycznych w szczególności przy wyznaczaniu krzywych mocy dla instalacji o rozproszonej strukturze na terenie kraju.

3.2. Struktura modelu mocy


Powyższa (w rozdziale 2) analiza danych pomiarowych potwierdziła, iż prędkość (V_w) wiatru jest najważniejszym czynnikiem wpływającym na generację mocy wytwórczej FW. Inne czynniki wpływające na jej generację, tj. silne poddmuchy wiatru, gęstość powietrza, stan gotowości siłowni czy szorstkość terenu, w badaniach pominięto ze względu na trudności w ich pozyskaniu. Pomimo tego z analizy wynika, że w badanej Farmie B efekt przesłonięcia nie był istotny, tak jak dla Farmy A.

Zjawisko to ma większe znaczenie w okresach o dużej dynamice zmian kierunku wiatru, np. latem, ale nie można przesądzać tego definitywnie. Ocena przesłonięcia była trudna, ze względu na sposób pomiarów kierunku wiatru przez siłownię. Pomiary kierunku wiatru wykonano bezpośrednio na gondolach, a kalibracja punktu zerowego nie została przypisana dokładnie poszczególnym stronom świata, co uzasadniano wcześniej. Stąd też w badanych modelach mocy nie uwzględniono również przesłonięcia. Dlatego też w dalszej części pracy przedstawiono wyniki badań modelu mocy na przykładzie Farmy B (o rozległej strukturze).

Poszukując odpowiedzi na wcześniejsze postawione pytania, tj.:

- Czy uwzględnienie w modelu dodatkowych czynników, np. kierunku wiatru, poprawi dokładność prognozy mocy wytwórczej?
- Czy na podstawie średniej prędkości wiatru, FW o rozległej strukturze, można uzyskać oczekiwaną moc wytwórczą dla całego obiektu?
- Czy na podstawie prędkości wiatru z odległego masztu meteorologicznego, posadowionego od FW w odległości do 10 km, istnieje możliwość uzyskania prognozy mocy o oczekiwanej jakości?
- Czy sieć nauczona na danych letnich sprawdzi się w innych porach roku, np. zimą?

Zbudowano dwa modele prognostyczne, wykorzystujące strukturę sieci neuronowej Elmana. Ogólną strukturę modelu mocy FW przedstawiono na rys.44.



Rys.44 Ogólna struktura modelu mocy FW

Na powyższym rysunku przedstawiono strukturę modelu mocy składającą się z trzech części. W pierwszej znajdują się dane pomiarowe (historyczne – tylko w procesie uczenia - lub prognozowane, gdzie wprowadzane są dane wejściowe do modelu), w drugiej wybrana struktura sieci neuronowej (w niniejszej pracy jest to sieć Elmana), a w trzeciej wyniki uczenia i testowania modelu (w module tym można poznać przyszłą prognozę generacji mocy lub wykorzystać wyniki do innych analiz). Zanim wybrano strukturę sieci rekurencyjnej Elmana, przebadano wiele innych struktur, np. sieci

jednokierunkowe jednowarstwowe i wielowarstwowe sieci perceptronowe dla różnej liczby neuronów. Częściowa rekurencja sieci Elmana różni się od pozostałych sieci rekurencyjnych (tj. Hopfielda, Hamminga, sieci BAM, sieci ART), tym, że pętla sprzężenia zwrotnego rozpoczyna się na wyjściu warstwy ukrytej, a nie na wyjściu modelu i kończy się na wejściu do modelu, poprzez warstwę kontekstową, w której występują jednostkowe operatory opóźnienia sygnału propagowanego. Każdy neuron warstwy ukrytej ma swój odpowiednik w warstwie kontekstowej. Warstwa ta stanowi wspólnie z wejściami sieci wektor wejściowy. Przy zmianie stanu jednego neuronu wpływa się na całą sieć poprzez sprzężenie zwrotne. W efekcie uzyskuje się stan przejściowy, kończący się określonym stanem ustalonym (innym niż stan poprzedni). Biorąc pod uwagę nieliniowość funkcji aktywacji neuronów jest to dynamika nieliniowa, będąca istotną cechą sieci. Przy oznaczeniu funkcji aktywacji neuronu jako $f(u_i)$, gdzie u_i jest sumą wagową pobudzeń (sygnałem aktywacji), to sygnał wyjściowy neuronu oznacza jego stan (3):

$$y_i = f(u_i) = f\left(\sum_{j=1}^N W_{ij}x_j\right) \quad (3)$$

Przy sprzężeniu zwrotnym pobudzaniach dla neuronów są sygnały wyjściowe innych neuronów. Zmiana stanu neuronów jest opisana układem równań różniczkowych nieliniowych, który ma postać (Hopfield, 1984), (4):

$$\tau_i \frac{du_i}{dt} = \sum_{j=1}^N W_{ij}f(u_j) - u_i - b_i \quad (4)$$

dla $i = 1, 2, \dots, N$, przy czym b_i jest wartością progową, wynikającą z zewnętrznego źródła. Współczynnik τ_i jest pewną stałą wartością liczbową. Stan neuronu uzyskuje się z rozwiązania równań 3 i 4.


W warstwie ukrytej modelu mocy FW (rys.46 i 47) zastosowano funkcję aktywacji tangens hiperboliczny (rys.45 a), ze względu na mogące występować w zbiorze uczącym wartości ujemne i dodatnie (widoczne na rys.45 a i b). Natomiast w ostatniej warstwie użyto funkcji liniowej. Wybór właściwych funkcji aktywacji umożliwia osiągnięcie szybkiej zbieżności sieci oraz lepszą zdolność generalizacji sieci, odporną na błędne pomiary.




Rys.45 Funkcje aktywacji sieci, a) warstwa 1: f. tangensoidalna, b) warstwa 2: f. liniowa

W celu uzyskania większej dokładności sieci neuronowej modyfikuje się jej wartości wag i progów (*ang. bias*), za pomocą opisanych w tabeli 8 algorytmów. Celem algorytmów jest zmiana współczynników wagowych (w konkretnym kierunku) poszczególnych neuronów sieci (parametrów sieci) w określony sposób (wybrany algorytm), tzn. w pierwszej kolejności obliczane są błędy w warstwie ostatniej (na podstawie sygnałów wzorcowych). Sygnał błędu rozprzestrzenia się od warstwy ostatniej, aż do warstwy wejściowej, jako pewna funkcja błędów neuronów warstwy poprzedzającej. Korekcja wektora wag sieci oparta jest na minimalizacji funkcji miary błędu, która określona jest, jako suma kwadratów błędów na wyjściach sieci.

W ramach pracy zbadano różne modele neuronowe z różną liczbą wejść i neuronów w warstwie ukrytej. Modele zaimplementowano w programie Matlab. Uczono metodami wymienionymi w Tabeli 8 wykorzystując do tego narzędzia obiektowe Matlab. Do dalszych badań wybrano dwa modele: z jednym i dwoma wejściami. W pierwszym modelu na wejściu wprowadzono średnią prędkość wiatru (rys.46), natomiast w drugim średnią prędkość (V_w) i kierunek (K_w) wiatru (rys.47). Na wyjściu modeli otrzymuje się prognozowaną wartość generacji mocy (P_c) dla badanego obiektu.



Rys.46 Model mocy FW z jednym wejściem: prędkością wiatru



Rys.47 Model mocy FW z dwoma wejściami: prędkością i kierunkiem wiatru

Badania przeprowadzono metodą doświadczalną zmniejszając lub zwiększając liczbę neuronów, a także modyfikując i ucząc sieć różnymi metodami. Wybrane metody uczenia przedstawiono w tabeli 7. Celem algorytmów uczenia jest jak najlepsze odwzorowanie rzeczywistych warunków pracy farmy (danych wzorcowych) i uzyskanie jak najmniejszej różnicy błędu względem tych danych.

Tabela 7 Wybrane metody (algorytmy) uczenia sieci – jej trenowania

Lp.	Nazwa metody uczenia w Matlabie	Opis metody
1	trainlm	algorytm zmiennej metryki Levenberga-Marquardta wyposażony w funkcje redukcji pamięci przy dużych zbiorach uczących, posiada cechy metody Newtona (różni się tym, że do hesjanu dodawana jest macierz jednostkowa przemnożona przez dodatni współczynnik), zaś wraz z oddalaniem się punktu pracy od poszukiwanego minimum sposób jej działania zbliża się do metody najszybszego spadku (zaletą jest szybka zbieżność, a wadą wyznaczenie macierzy odwrotnej)
2	trainbr	algorytm Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (sieć Bayesa), zmodyfikowany algorytm Levenberga-Marquardta, stworzony w celu tworzenia sieci o lepszych własnościach uogólniania, posiadający procedury optymalizacji liczby parametrów sieci, w sposób graficzny reprezentują probabilistyczne zależności przyczynowo-skutkowe pomiędzy różnymi zmiennymi losowymi, odpowiadające zdarzeniom lub informacjom

Średnia prędkość wiatru (oznaczona dalej prędkością wiatru V_w) jest silniej skorelowana z łączną mocą Farmy B, niż prędkość z masztu meteorologicznego, co zostało przedstawione w tabeli 3. Oba modele neuronowe są modelami mocy FW do predykcji mocy wytwórczej Farmy B. Podczas procesu uczenia sieci z dwoma wejściami (prędkością V_w i kierunkiem K_w wiatru) zauważono, iż model ten nie osiąga tego samego, a nawet podobnego poziomu błędu uczenia, co model z jednym wejściem (V_w). Można wnioskować, iż przyczyną jest brak silnej korelacji pomiędzy generacją mocy a kierunkiem wiatru, czyli uwzględnienie w modelu kierunku wiatru może pogarszać prognozę mocy. Po zwiększeniu liczby neuronów do 25 uzyskano zbliżony poziom błędu uczenia do modelu z jednym wejściem, ale kosztem dłuższego czasu uczenia. W modelu z pojedynczym wejściem wystarczyło 15 neuronów, aby uzyskać możliwy najmniejszy błąd. Większa liczba neuronów wymaga znalezienia większej

liczby współczynników wagowych a to wymaga większego zbioru danych uczących, czyli danych z dłuższego okresu czasu.

3.3.Uczenie i testowanie modelu mocy (sieci Elmana)

W rozdziale tym pokazano przebiegi uczenia i testowania modelu mocy FW (Farmy B) z jednym (rys.46) i dwoma wejściami (rys.47). Model FW to dwa różne modele tj. zimowy i letni. Badania prowadzono wykorzystując dostępne dane pomiarowe z farmy B. Do sprawdzenia czy przy odmiennych warunkach wiatrowych i pogodowych (temperatura, zmienność wiatru, prędkość wiatru) obowiązuje ten sam model (o takich samych parametrach) wykorzystano dane pomiarowe przy różnorodnych warunkach wiatrowych: zimowych i letnich.

Celem każdego modelu było odtworzenie zależności między wielkościami wejściowymi (V_w , albo V_w i K_w) a mocą FW. W przypadku tylko jednej zmiennej wejściowej (V_w) odtworzeniu podlega krzywa mocy farmy. Modele zostały poddane badaniom w różnych skrajnych warunkach wiatrowych wynikających z pór roku: lata (rys.12) i zimy (rys.13). Oba okresy zostały podzielone na część uczącą (pierwsze 6 dni) i część testującą (ostatnią dobę). Za prędkość i kierunek wiatru przyjęto średnią prędkość i kierunek wiatru ($V_w^{\text{Śr}}$ i $K_w^{\text{Śr}}$) dla 5 siłowni wiatrowych (Farmy B), obliczone jako średnia prędkość i kierunek wiatru ze wszystkich czujników na gondolach. Z analizy wynika, iż średnia prędkość wiatru farmy ma silniejszą korelację względem łącznej generacji ze wszystkich siłowni, aniżeli prędkość z pojedynczej siłowni, czy też masztu meteorologicznego dla pozostałych. Więcej korelacji przedstawiono w tabeli 3.


3.3.1. Model z jednym wejściem: średnia prędkość wiatru

Przedmiotem badań jest model FW z jednym wejściem: prędkością wiatru. Ilość neuronów dobrano metodą prób i błędów kierując się błędem uczenia. Ustalono ilość neuronów w warstwie ukrytej na 15. Celem badań było sprawdzenie czy na podstawie średniej prędkości wiatru dla FW o rozległej strukturze, można uzyskać oczekiwaną moc wytwórczą dla całego obiektu? Badanie wykonano dla średniej prędkości wiatru ze wszystkich 5 siłowni Farmy B oraz prędkości wiatru pochodzącej z masztu


meteorologicznego. Za wartość uczącą przyjęto sumę generacji mocy 5 siłowni w poszczególnych godzinach doby.

Na rys.50 a) i b) przedstawiono wyniki uczenia sieci metodą Levenberga-Marquardta (PcTrainlm) oraz metodą Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (Bayesa) (PcTrainbr), które wymieniono w Tabeli 8. Na rys.50 a) i 53 a) przedstawiono przebiegi uczące z okresu letniego i zimowego oraz efekty uczenia sieci metodami PcTrainlm i PcTrainb. Oba zbiory zawierają dane pomiarowe, które uwzględniają stan nienormalnej pracy instalacji, częściowo awaryjny (np. przy ograniczeniu mocy siłowni). W okresie letnim doszło do wyłączenia w pojedynczych godzinach, natomiast w okresie zimowym kilka godzin z rzędu. Różnice widać na krzywych mocy na rys.48 i 51. Wnioskować można, że czym więcej błędnych danych (z czynnikami awaryjnymi) w zbiorze uczącym, tym mniejsza skuteczność modelu, co potwierdza test modelu na rys.49, 50 b) oraz 52 i 53 b). Na rys.53 b) widoczne są większe odchylenia prognozy od rzeczywistej wartości niż na rys.50 b). Ważna jest również wysokość, dla której wyliczono prędkość wiatru. Poszczególne siłownie FW często są rozmieszczane na różnych wysokościach względem siebie, ze względu na urozmaiconą orografię terenu. Znając tylko prędkość wiatru dla obiektu, należy uzgodnić dla jakiej wysokości wartość ta została przygotowana, a w przypadku konieczności ekstrapolować prognozę na oczekiwaną wysokość turbin wiatrowych.

Pomimo tego, że modele mocy uczone metodami PcTrainlm oraz PcTrainbr podobnie odtwarzają rzeczywiste wartości generacji mocy (PcFarma), to już na etapie testowania znacznie się różnią. Wskaźniki jakości modelu mocy przedstawiono w rozdziale 4.1.




Rys.48 Moc Farmy B w funkcji prędkości wiatru
 –wynik uczenia sieci w okresie letnim



Rys.49 Moc Farmy B w funkcji prędkości wiatru
 –wynik testowania sieci w okresie letnim




a)




b)


Rys.50 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim




Rys.51 Moc Farmy B w funkcji prędkości wiatru
–wynik uczenia sieci w okresie zimowym



Rys.52 Moc Farmy B w funkcji prędkości wiatru
–wynik testowania sieci w okresie zimowym



a)



b)

Rys.53 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie zimowym

3.3.2. Model z dwoma wejściami: średnia prędkość i kierunek wiatru


Przedmiotem badań jest model FW z dwoma wejściami: prędkością i kierunkiem wiatru. Ilość neuronów dobrano metodą prób i błędów kierując się błędem uczenia. Ustalono ilość neuronów w warstwie ukrytej na 15. Celem badań było sprawdzenie czy uwzględnienie w modelu dodatkowych czynników, np. kierunku wiatru, poprawi dokładność prognozy mocy wytwórczej? Jak wiadomo z analizy kierunek wiatru również wpływa na generację mocy, lecz w mniejszym stopniu niż prędkość wiatru. Wiadomo również z analizy, iż pomiar kierunku wiatru na gondolach nie jest dokładnie zgodny ze stronami świata, co utrudnia wykorzystanie tej wartości w modelach prognostycznych. W niniejszej pracy podjęto próbę budowy i zbadania modelu z uwzględnieniem kierunku wiatru. Na potrzeby badań zbudowano dwa różne modele FW zimowy i letni to dwa różne modele.

Na etapie uczenia przy uwzględnieniu kierunku wiatru zauważono, że sieć potrzebuje więcej czasu i neuronów na nauczenie się rzeczywistych wartości mocy. Sieć uczona metodą PcTrainbr nie nauczyła się wystarczająco dokładnie odtwarzać rzeczywistych wartości, co widoczne jest na rys.54, 57 a) oraz 58 i 60 a). W konsekwencji test modelu przebiegł bardzo negatywnie dla tej metody, rys.55 i 56 b) oraz 58 i 59 b).


Z testów modelu FW wynika, że uwzględnienie kierunku wiatru, zwłaszcza o niepewnym sposobie pomiaru (braku właściwej kalibracji względem stron świata), może skutkować większymi błędami już na etapie uczenia sieci, niż przy wykorzystaniu bardziej wiarygodnej i istotnej prędkości wiatru.

Podobnie jak w modelu z jednym wejściem, zbiór danych uczących nie powinien zawierać stanów nienormalnych farmy, czyli wyłączonych siłowni, nadzwyczajnych ograniczeń mocy. Jest bardzo ważne, aby zbiór uczący był zbiorem danych z tzw. normalnej pracy FW. Oznacza to, że dane uczące przed wykorzystaniem powinny być wstępnie ocenione.


Na rys.57÷59 zbiór jest źle uwarunkowany, bo w zbiorze uczącym są prędkości wiatru od 4 do 14 m/s a w zbiorze testującym są też wartości poniżej albo na granicy tego zakresu. Sieć nauczona jedną metodą dobrze sobie z tym radzi a druga na granicach przedziału 4-14 m/s daje większy błąd (miarę błędu omówiono w rozdziale 4.1).




Rys.54 Moc Farmy B w funkcji prędkości wiatru
–wynik uczenia sieci w okresie letnim



Rys.55 Moc Farmy B w funkcji prędkości wiatru
–wynik testowania sieci w okresie letnim




a)




b)


Rys.56 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim




Rys.57 Moc Farmy B w funkcji prędkości wiatru
 –wynik uczenia sieci w okresie zimowym



Rys.58 Moc Farmy B w funkcji prędkości wiatru
 –wynik testowania sieci w okresie zimowym



a)



b)


Rys.59 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie zimowym

3.3.3. Model z jednym wejściem: prędkość wiatru z masztu meteo


Przedmiotem badań jest model FW z jednym wejściem: prędkością wiatru z odległego masztu meteorologicznego. Ilość neuronów dobrano metodą prób i błędów kierując się błędem uczenia. Ustalono ilość neuronów w warstwie ukrytej na 15. Celem badań było sprawdzenie czy na podstawie prędkości wiatru z odległego masztu meteorologicznego, posadowionego od FW w odległości do 10 km, istnieje możliwość uzyskania prognozy mocy o oczekiwanej jakości? Za wartość uczącą sieć przyjęto sumę generacji mocy Farmy B. Podstawą do zbadania tego przypadku była silna korelacja między mocą FW a wiatrem z masztu, przedstawioną w tabeli 3.

Do badań wykorzystano prędkość i kierunek wiatru (V_w) z odległego masztu meteorologicznego posadowionego na obszarze farmy wiatrowej – Farma B (traktowanej jako dokładna prognoza pogody). Niestety, jak zaobserwowano na rys.60 i 62 a) oraz 63 i 65 a) obie metody uczenia nie potrafiły odpowiednio skutecznie odtworzyć rzeczywistych wartości generacji mocy dla obu okresów (letniego i zimowego). W efekcie prognozy znacznie odbiegają od oczekiwanej jakości, co widać na rys.61 i 62b) oraz 64 i 65 b). Wpływ na taką sytuację może mieć kilka czynników, np. wysokość na jakiej została pomierzona prędkość wiatru na maszcie meteo. Jeśli maszt meteo jest znacznie niższy niż siłownia wiatrowa, to dla poprawy jakości predykcji, należałoby ekstrapolować wartość prędkości wiatru z poziomu masztu meteo (z 50 m n.p.g) do wysokości turbin (na wysokość 80 m n.p.g). Różnica między prędkościami wiatru na obu wysokościach może wynosić średnio około 1 m/s. Kolejnym czynnikiem mogą być zapamiętane wagi w warstwie kontekstowej (wynikające z ograniczenia programowego Matlab). W takich przypadkach można już ponownie uruchomić proces uczenia sieci.


Podobne wyniki i wnioski uzyskano w przypadku modelu z dwoma wejściami (tj. prędkością i kierunkiem wiatru, jak w poprzednich analizach), stąd też nie zaprezentowano wyników graficznie i nie brano pod uwagę w dalszych badaniach.




Rys.60 Moc Farmy B w funkcji prędkości wiatru
–wynik uczenia sieci w okresie letnim



Rys.61 Moc Farmy B w funkcji prędkości wiatru
–wynik testowania sieci w okresie letnim




a)




b)

Rys.62 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim




Rys.63 Moc Farmy B w funkcji prędkości wiatru
–wynik uczenia sieci w okresie zimowym




Rys.64 Moc Farmy B w funkcji prędkości wiatru
–wynik testowania sieci w okresie zimowym





a)



b)


Rys.65 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie zimowym

3.3.4. Testowanie modelu mocy inną porą roku


Kolejnym etapem pracy było zbadanie czy sieć nauczona na danych letnich sprawdzi się w innych porach roku, np. zimową? Jak już wiadomo z wcześniejszej analizy, nie można zbudować jednego uniwersalnego modelu predykcji mocy FW. Z zasad fizyki, obserwacji i pomiarów wynika, że farma nie jest obiektem stacjonarnym, tzn. krzywa mocy nie jest taka sama w każdych warunkach, np. przy niskiej temperaturze i dużej gęstości powietrza moc zawarta w strumieniu powietrza jest większa i dla określonej prędkości wiatru moc elektrowni jest większa niż podczas wysokiej temperatury i małej gęstości powietrza. Zależność tą pokazuje rysunek (14 a i b). W celu sprawdzenia sieć uczono na danych jednej pory roku (np. okres zimowy), testowano na danych z innej pory roku (np. okres letni). Dzięki temu zbadano czy model nauczony na danych z okresu temperatur ujemnych np. -10 st.C, innej dynamiki wiatru, czy też zmienności kierunku wiatru, może dać większy błąd prognozy przy temperaturach dodatnich np. 30 st.C. Modele mocy Farmy B uczono na danych 6-cio dniowych z granulacją 10-cio minutową, a testowano na 1 dobie.

W różnych porach roku wiatr ma trochę inne właściwości, np. inne średnie prędkości, czy inna gęstość powietrza. Ponadto wraz ze zmianą pory roku zmienia się również temperatura oraz szorstkość terenu. Wszystko to powoduje, że istnieje realna obawa, że model sporządzony dla jednej pory roku nie będzie najlepszy dla innej. Dla sprawdzenia badano sieć zarówno z jednym (V_w) jak i dwoma wejściami (V_w i K_w) przy czym sieć była uczona na danych jednej pory roku, a testowana na danych testujących innej pory roku. Takie podejście może być dobrym rozwiązaniem, kiedy brakuje danych historycznych farmy, w szczególności na początku funkcjonowania obiektu (od początku uruchomienia instalacji OZE). Modele uczono na danych letnich i zimowych, a testowano krzyżowo, czyli sieć uczoną na danych letnich testowano z danymi z okresu zimowego i vice versa.

Na rys.66 i 68 a) przedstawiono wyniki modelu z jednym wejściem. Natomiast na rys.67 i 68 b) wyniki testowania modelu z dwoma wejściami. Z rysunków wynika, że model z jednym wejściem był skuteczniejszy niż z dwoma. Należy również brać pod uwagę porę roku i związaną z tym różną gęstość powietrza, bo widoczne są na rys.66 i 67 różnice w mocy: między rzeczywistą a odtworzoną, ze względu na to że porą letnią generacja mocy jest mniejsza niż zimą dla tych samych prędkości wiatru.




Rys.66 Moc Farmy B w funkcji prędkości wiatru –wynik testowania sieci z jednym wejściem lato-zima




Rys.67 Moc Farmy B w funkcji prędkości wiatru –wynik testowania sieci z dwoma wejściami lato-zima





a)



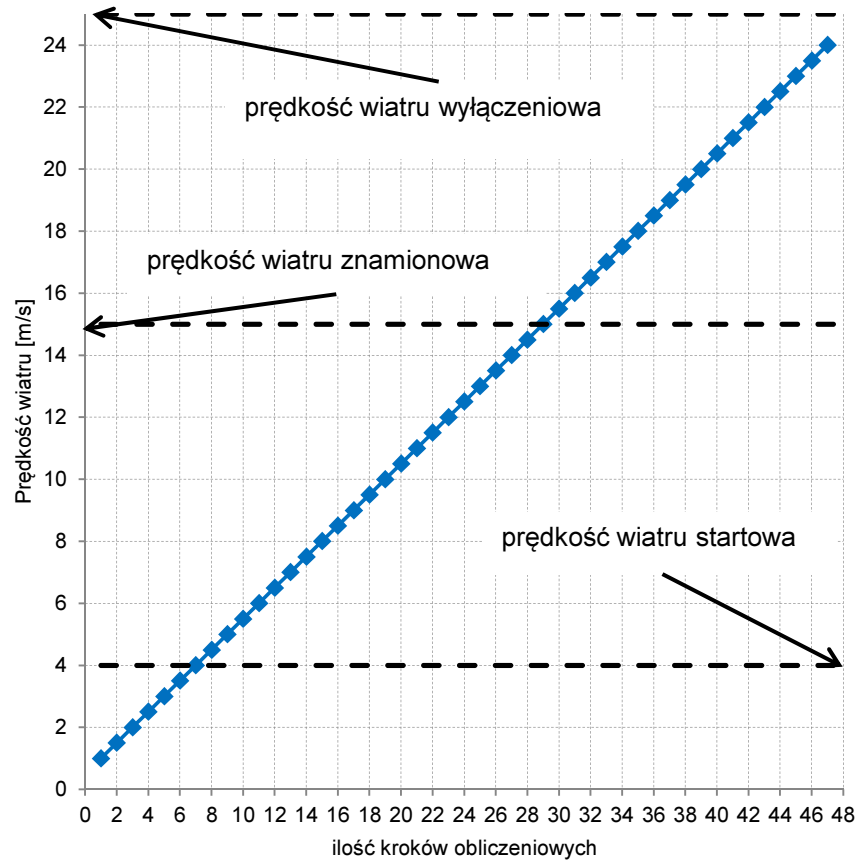
b)

Rys.68 Testowanie modelu (1 doba) (a) model tylko z jednym wejściem i (b) model z dwoma wejściami


3.4. Badanie właściwości modelu mocy

W rozdziale tym pokazano właściwości dynamiczne samego modelu neuronowego z jednym wejściem aby określić odtwarzaną krzywą mocy dla określonych wymuszeń wiatrowych. Badania przeprowadzono poddając model określonym wymuszeniom, czyli różnym ciągami danych wejściowych (prędkości wiatru). Na rys.69÷78 przedstawiono wyniki badań modelu uczonego dwoma metodami (*PcTrainlm* i *PcTrainbr*). W ramach badania sprawdzono odpowiedzi obu sieci na określone z góry wymuszenie (zmienną prędkość wiatru dla okresu letniego i zimowego). Rodzaj wymuszeń został przedstawiony na parzystych rysunkach 74÷78. Natomiast na nieparzystych rysunkach 69÷77 odpowiedzi na wymuszenie. Analiza wykazała, że w zależności od charakteru wymuszenia odpowiedź modelu ulega zmianie. Dzieje się tak, m.in. dlatego, że oba modele mocy są sieciami dynamicznymi (z częściową rekurencją). Zmiany na poniższych rysunkach oznaczono niebieskimi powierzchniami. Z wykresów wynika, że czym większa dynamika zmian prędkości wiatru, tym większe zmiany jakościowe w odpowiedzi (rys.70, 71 i 76), co przekłada się również na różne wolumeny generacji mocy. To, że sieć generuje wartości niższe niżby wynikało z wartości katalogowych jest oczywiste (bo występują straty przesyłowe, efekt przesłonięcia, itp.), ale widać również inne przyczyny jak na rys.70, gdzie widoczna jest różnica między mocą dla modelu uczonego na danych zimowych i modelu uczonego na danych letnich. Różnica wynika z gęstości powietrza: mniejszej w okresie letnim, niż zimowy, a także z większej dynamiki zmian kierunku wiatru. Zaobserwowano na rysunkach 72, 74 i 78 również to, że model uczony na danych letnich (*PcTrainlmLato*), jest bardziej odporny na gwałtowne zmiany prędkości wiatru niż model uczony na danych zimowych (*PcTrainlmZima*).


Z rysunku 72 wynika że krótkotrwała gwałtowna zmiana prędkości wiatru (lub błędnie wprowadzone dane) może powodować długotrwałe zaburzenie w pracy sieci. Na szczęście model służy do predykcji a prognozowany wiatr nie ulega tak gwałtownym zmianom. Spostrzeżenie to potwierdzają kolejne wykresy, sieć „zimowa” dobrze radzi sobie z wolnozmiennymi wymuszeniami, bo na takich była uczona a gorzej z szybkozmiennymi. Prędkość wiatru w okresie letnim częściej ulega zmianie niż w okresie zimy, stąd model *PcTrainlmLato* ma dobrane optymalnie współczynniki wagowe sieci do zmiennych warunków wiatrowych. Oba modele neuronowe powinny być stosowane zamiennie w zależności od pory roku.




Rys. 69 Kontrolowane wymuszenie dla rosnącej liniowo prędkości wiatru




Rys. 70 Odpowiedź modeli Farmy B w funkcji prędkości wiatru




Rys.71 Kontrolowane wymuszenie poprzez rosnącą prędkość wiatru




Rys.72 Odpowiedź modeli Farmy B w funkcji prędkości wiatru




Rys.73 Kontrolowane wymuszenie poprzez gwałtowną zmianę prędkości wiatru




Rys.74 Odpowiedź modeli Farmy B w funkcji prędkości wiatru




Rys. 75 Kontrolowane wymuszenie poprzez spokojną zmienność prędkości wiatru



Rys. 76 Odpowiedź modeli Farmy B w funkcji prędkości wiatru



Rys.77 Kontrolowane wymuszenie poprzez dynamiczną prędkość wiatru



Rys.78 Odpowiedź modeli Farmy B w funkcji prędkości wiatru

4. Wyniki badań – porównanie dwóch modeli mocy FW

Oczywistym jest, iż błąd prognozy mocy wynika z błędów prognozy meteorologicznej, jak również samego modelu mocy FW [81÷86]. Aby wybrać właściwy model predykcji należy przyjąć określoną miarę błędu.

4.1. Miara błędu

Na podstawie miary błędów można dokonać wyboru skutecznego modelu mocy FW. W niniejszym rozdziale zaproponowano cztery wskaźniki jakości, które umożliwiają wybór modelu. Na rys.81÷88 przedstawiono obliczone współczynniki jakości dla modelu z jednym (rys.81÷84) i dwoma (rys.85÷88) wejściami, które pozwalają na wybór modelu predykcji z grona różnych metod. Do oceny jakości modelu wykorzystano predykcję mocy FW (P_c^{FW}) uzyskaną na wyjściu modelu oraz rzeczywistą generację mocy (P_c). Oceniane przebiegi na rys.(14 a i b) generacji mocy FW pokazują, że błąd prognozy raz jest bliski 0% ($P_c^{Trainbr}$, tabela 9), a następnym razem przekracza nawet 50% i więcej. Do oceny jakości prognozy wybrano cztery kryteria, tj. sumę mocy w danym okresie (5), czyli energię [MWh], błąd bezwzględny (6), sumę odchyłeń wartości prognozowanej od rzeczywistej (7), oraz współczynnik zmienności (8) (dynamika). Na podstawie oceny można dokonać wyboru skutecznego modelu mocy na potrzeby predykcji dowolnej farmy. Wyniki uczenia i testowania sieci przedstawiono w tabelach 9 i 10.

Sumę mocy FW (energię) wyznaczono (5) dodając do siebie wszystkie wartości mocy:

$$P_c = \sum P_c \quad (5)$$

Suma mocy pokazuje różnicę łącznej mocy modelu FW względem rzeczywistej mocy. Jeżeli różnica będzie znacząca, kosztowna (poza rentownością), to lepiej takiego modelu nie stosować. Jeżeli będzie odwrotnie to, należy policzyć błąd bezwzględny mocy łączny dla całego okresu. Błąd ten można wyliczyć z zależności (6):

$$\Delta P_c = \sum P_c - \sum P_c^{FW} \quad (6)$$

gdzie: P_c - rzeczywista generacja mocy FW (wykonanie), P_c^{FW} - moc modelu FW.

Z błędu bezwzględnego mocy można dowiedzieć się, jaka jest rzeczywista różnica pomiędzy sumami mocy. Wartości można wyliczyć łącznie dla wszystkich pomiarów, a także dobowo-godzinowo, w zależności pod potrzeby analizy. Następnie liczymy odchylenie prognozy mocy. Sumę odchyłeń δP_c , czyli różnicę między mocą modelu a rzeczywistą mocą dla każdej pary indywidualnie, wyliczono z zależności (7):

$$\delta P_c = \sum_{i=1} |P_c - P_c^{FW}| \quad (7)$$

gdzie: P_c - rzeczywista moc (wykonanie) FW, P_c^{FW} - moc modelu FW.

Suma odchyłeń pozwala zaobserwować maksymalne lokalne odchylenia dla danych warunków w poszczególnych godzinach doby, co ma znaczenie dla kosztów uczestnictwa na RB (maksymalna cena CRO/CROz/CROs za EE na RB może osiągnąć nawet 1500 zł/MWh). Na końcu liczymy współczynnik zmienności (WzP_c) według następującej zależności (8):

$$WzP_c = \frac{|\sigma|}{\sum P_c} \cdot 100[\%] \quad (8)$$

gdzie: σ - odchylenie standardowe generacji mocy FW, P_c - średnia generacja mocy FW.

Odchylenie standardowe generacji mocy FW wyznaczono z zależności (9):

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (P_c - P_c^{FW})^2}{n - 1}}, \quad (9)$$

gdzie: n – liczba elementów w próbie.

Współczynnik zmienności przedstawia dynamikę zmienności mocy, czyli skrajnych wartości oddalonych od średniej. Czym wyższy współczynnik, tym większa dynamika. Zbyt duża dynamika modelu będzie generowała koszty z tytułu odchyłeń dobowo-godzinowych, co nie jest pożądane. Model mocy FW z niskim współczynnikiem zmienności zwiększa skuteczność prognozy, co potwierdzają rys.79÷82.

4.2. Wybór skutecznego modelu mocy FW

Dzięki powyżej opisanym wskaźnikom można w szybki sposób dokonać wyboru skutecznego modelu prognostycznego. W poniższych tabelach zestawiono wyliczone wskaźniki dla dwóch konfiguracji modelu mocy FW: modelu z jednym wejściem i modelu z dwoma wejściami. Wyniki pierwszego modelu oznaczono w tabelach: 8 i 9, jako VwFarma, natomiast drugiego VwKwFarma. W tabeli 8 przedstawiono wskaźniki jakości uczenia modelu na podstawie danych za okres 6 dni (próbka danych liczyła $N = 862$ pomiary), tj. sumę generacji mocy, z której można dowiedzieć się czy dany model osiąga zbliżone wolumeny energii elektrycznej do rzeczywistej sumy za dowolny okres; błąd bezwzględny modelu całej generacji mocy; sumę odchyleń mocy z modułu różnicy, aby dowiedzieć się jak duży jest wolumen różnicy względem rzeczywistej mocy, oraz współczynnik zmienności generacji mocy modelu mówiący o dynamice zmienności generacji mocy w badanym okresie. Model uczono na danych letnich i zimowych.

Tabela 8 Jakość nauczonych modeli neuronowych przy średniej prędkości wiatru dla całej Farmy B (próbka liczyła 862 pomiary – 6 dni)

Próbka	Pora roku i czynniki	VwFarma		VwKwFarma	
		lato	zima	lato	zima
862	Metoda uczenia				
Suma mocy [MW]	PcFarma (Pc)	266,7010	799,2590	266,7010	799,2590
	PcTrainlm	266,1560	792,4970	266,9650	799,4900
	PcTrainbr	266,6960	799,2780	266,2420	803,3350
Bł.bezwz [MWh]	PcFarma (Pc)	0,00000	0,00000	0,00000	0,00000
	PcTrainlm	0,54482	6,76226	0,26389	0,23053
	PcTrainbr	0,00495	0,01867	0,45883	4,07575
Suma odchyl.mocy [MW]	PcFarma (Pc)	0,0000	0,0000	0,0000	0,0000
	PcTrainlm	9,2750	18,6580	11,0340	17,6340
	PcTrainbr	8,2870	15,2990	62,0780	126,5920
Wsp.zmien.[%]	PcFarma (Pc)	1,34700	0,50500	1,34700	0,50500
	PcTrainlm	1,34800	0,51500	1,34700	0,50200
	PcTrainbr	1,34400	0,50400	1,30400	0,41600

Różnica w wolumenie mocy (błąd bezwzględny) dla metody PcTrainlm modelu z jednym wejściem wynosi 0,5450, a dla metody PcTrainbr 0,0050. Mając te dwie wartości nadal trudno podjąć decyzję, który model jest lepszy. Dlatego wyliczamy sumę odchyleń (rys.82), następnie współczynnik zmienności generacji mocy (rys.84). Porównujemy metody uczenia i wiadomo już który model jest lepszy. W tym badanym przypadku lepiej nauczył się model mocy za pomocą metody PcTrainbr. Analogicznie postępuje się

z pozostałymi konfiguracjami modelu i badanymi okresami. Definiowanie innych parametrów, tj. średniej arytmetycznej na tym etapie nie jest wskazane, bo ten parametr używany jest do wyliczenia odchylenia standardowego, więc został już uwzględniony.

W tabeli 9 przedstawiono wyniki jakości testowanego modelu dla okresu 1 doby (próbka danych liczyła $N = 144$ pomiary). Model testowano na danych letnich i zimowych.


Tabela 9 Jakość testowanych modeli neuronowych przy średniej prędkości wiatru dla całej Farmy B (próbka liczyła 144 pomiary – 1 doba)

Próbka	Pora roku i czynniki	VwFarma		VwKwFarma	
		lato	zima	lato	zima
144	Metoda uczenia				
Suma generacji mocy [MW]	PcFarma (Pc)	104,3280	49,5640	104,3280	49,5640
	PcTrainlm	102,4930	49,9320	102,9300	49,7800
	PcTrainbr	100,1900	48,8130	89,1240	67,9830
Bł.bezwz [MWh]	PcFarma (Pc)	0,00000	0,00000	0,00000	0,00000
	PcTrainlm	1,83533	0,36820	1,39775	0,21629
	PcTrainbr	4,13847	0,75099	15,20446	18,41915
Suma odchyl.mocy [MW]	PcFarma (Pc)	0,0000	0,0000	0,0000	0,0000
	PcTrainlm	2,4330	7,7480	2,1500	4,2120
	PcTrainbr	4,8470	4,9920	16,5150	23,6310
Wsp.zmien.[%]	PcFarma (Pc)	0,25800	1,13800	0,25800	1,13800
	PcTrainlm	0,26500	1,09100	0,26400	1,10800
	PcTrainbr	0,28300	1,14500	0,22700	0,68300


Analogicznie do powyższego wyliczamy błąd bezwzględny (różnicę między sumą mocy) i otrzymujemy dla metody PcTrainlm wartość 1,835 oraz dla PcTrainbr 4,138, (rys.87). To odwrotna sytuacja do procesu uczenia. Tym razem model PcTrainlm odtwarza wolumen generacji mocy z mniejszym błędem względem rzeczywistego wolumenu generacji mocy. Mniejsze są również pozostałe parametry, tj. suma odchylenia rys.84 i współczynnik zmienności rys.88. Suma odchylenia na rys.84 jest mniejsza, bo jest krótszy okres pomiarowy i dlatego wskaźniki bezwzględne nie są dobre. Dla zobrazowania sytuacji na rys.81÷88 przedstawiono wyniki uczenia badanych modeli na podstawie współczynników przedstawionych w tabelach: 8 i 9. Badane modele różnią się między sobą, co widać po otrzymanych wartościach. W pierwszym powyższym wariancie zbadano model z jednym wejściem, czyli uśrednioną prędkością wiatru dla całej Farmy B w dwóch porach roku (patrz rys.81÷84). W drugim rozpatrzono modele z dwoma wejściami prędkością i kierunkiem wiatru (patrz rys.85÷88), zgodnie z wcześniejszymi analizami w rozdziale 3. W pracy nie przedstawiano już przypadków dla prędkości i kierunku wiatru pochodzącego z masztu meteorologicznego, ze względu na podobne

obserwacje i wnioski, ale o większym błędzie. Na podstawie współczynnika zmienności można stwierdzić, że model uwzględniający tylko prędkość wiatru (VwFarma) jest skuteczniejszy niż model z kierunkiem wiatru. Co znajduje uzasadnienie w wynikach testowania modelu w tabeli 9. Różnice predykcji mocy między modelami wynikają przede wszystkim z metody uczenia sieci. Model uczony metodą PcTrainbr lepiej nauczył się odtwarzać rzeczywistą generację mocy, ale uzyskał słabszy wynik w rzeczywistych warunkach podczas testów.


Budowa jednego uniwersalnego modelu mocy będącego dobrym estymatorem dla każdego warunków wietrznych jest niemożliwa, co pokazano dalej w tabelach nr 9 i 10. Potwierdza to różnica błędów obu modeli względem rzeczywistej generacji mocy. Właściwa jest budowa modelu mocy o zmiennych parametrach sieci, które będą dobierane w oparciu o dane z okresu poprzedzającego predykcję generacji mocy, np. 2-3 tygodniowe, albo 6-7 dniowe. Z badań wynika, że sieć potrafi nauczyć się rzeczywistych warunków FW dla wszystkich pór roku, co widać na rysunkach (50 a i 53 a). Potrafi odtworzyć cechy charakterystyczne farmy, wymaga jednak dużego zbioru danych uczących i wiedzy eksperckiej. Tu uczono na danych za 6 dni, a to zdecydowanie za krótki czas. Jakość predykcji generacji mocy zależy nie tylko od modelu mocy, ale przede wszystkim od jakości prognozy pogody. W tabelach nr 9 i 10 przedstawiono uzyskane poziomy jakości wybranych modeli mocy. Jak wynika z etapu testowania, metody, które sprawdzają się lepiej w okresie letnim, gorzej radzą sobie w okresie zimowym i odwrotnie (rys.72). Sieć neuronowa jest dobrym estymatorem krzywej mocy FW.




Rys.79 Suma generacji obu modeli neuronowych wraz z rzeczywistą generacją w różnych porach roku (dane z tabeli nr 8, jedno wejście)




Rys.80 Suma odchył od średniej generacji mocy w różnych porach roku (dane z tabeli nr 8, jedno wejście)




Rys.81 Błąd bezwzględny dla różnych pór roku (dane z tabeli nr 8, jedno wejście)



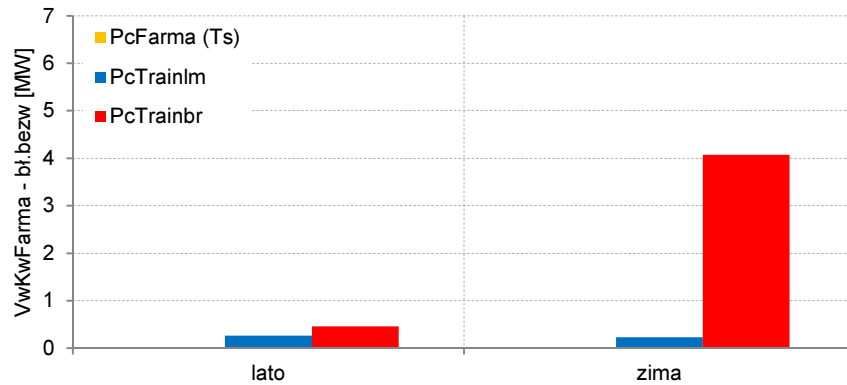
Rys.82 Dynamika zmian generacji mocy dla różnych pór roku (dane z tabeli nr 8, jedno wejście)




Rys.83 Suma generacji obu modeli neuronowych wraz z rzeczywistą generacją w różnych porach roku (dane z tabeli nr 8, dwa wejścia)



Rys.84 Suma odchył od średniej generacji mocy w różnych porach roku (dane z tabeli nr 8, dwa wejścia)



Rys.85 Błąd bezwzględny dla różnych pór roku (dane z tabeli nr 8, dwa wejścia)



Rys.86 Dynamika zmian generacji mocy dla różnych pór roku (dane z tabeli nr 8, dwa wejścia)

5. Podsumowanie

Celem pracy była budowa modelu prognozy mocy farmy wiatrowej (FW), czyli modelu odtwarzającego moc FW dla określonego ciągu uczonego danych wejściowych. Model odtwarza więc charakterystyki konkretnej FW. Spośród możliwych struktur modeli do realizacji i do badań wybrano model neuronowy. W ramach realizacji zadania poddano wnikliwej analizie dane pomiarowe pozyskane z rzeczywistych farm wiatrowych ze szczególnym uwzględnieniem wpływu zmienności warunków meteorologicznych na wartość generowanej mocy oraz warunki wiatrowe występujące na tego typu obiektach.

W wyniku tej analizy ustalono co ma wpływ na moc farmy i co ma wpływ na tyle istotny, że musi być uwzględnione w modelu. Wybrano dwie wielkości: prędkość wiatru jako wielkość podstawowa i dodatkowo kierunek wiatru. Z analizy danych pomiarowych wynika, że każda FW ma swoje cechy indywidualne i model musi mieć konstrukcję, która te cechy osobnicze odtworzy. Była to główna przyczyna wyboru modelu neuronowego. Do realizacji modelu wybrano sieć rekurencyjną Elmana uczoną metodą zmiennej metryki Levenberga-Marquardta oraz Levenberga-Marquardta z wbudowaną regularyzacją bayesowską. Wybór ten został poprzedzony szerokimi badaniami symulacyjnymi różnych struktur sieci uczonych różnymi metodami. Zaproponowano metodykę wyboru skutecznego modelu prognostycznego w oparciu o wybrane wskaźniki jakości, tj. sumę mocy, błąd bezwzględny, sumę odchyłeń oraz współczynnik zmienności mocy.

Opisane w pracy czynniki mające wpływ na moc farmy powinny być uwzględniane w modelach prognostycznych na różnych etapach procesu prognozowania. Wpływ na moc farmy mają nie tylko warunki meteorologiczne, ale także sposób funkcjonowania, sterowania tego typu obiektem jak i jej indywidualne warunki terenowe i rozlokowanie. Analizując dane pomiarowe można znaleźć pewne zależności charakterystyczne. Analizy wykazały, iż mając do dyspozycji rzeczywiste dane meteorologiczne, tj. prędkość i kierunek wiatru, gęstość powietrza, opady dla lokalnych warunków, oraz dane produkcyjne energii elektrycznej z poszczególnych siłowni oraz z licznika w GPZ, można zbudować sprawdzający się model prognostyczny. Otwartym zagadnieniem jest struktura modelu: deterministyczny oparty

na zjawiskach fizycznych i zależnościach analitycznych, czy model behawioralny zbudowany w oparciu o sieć neuronową.

Wyniki symulacji w pkt. 3.3 przeprowadzone na modelach mocy FW (dla różnych pór roku: latem i zimą) wskazują, że sieci neuronowe potrafią wygenerować zbliżone prognozy do rzeczywistej generacji mocy i dzięki temu mogą stanowić alternatywną metodę predykcji mocy. Odchylenia prognozowanej mocy od rzeczywistej mogą wynikać w właściwości modeli mocy FW. Jak zauważono modele mocy FW, które sprawdzają się lepiej w okresie letnim, gorzej radzą sobie w okresie zimowym i odwrotnie. Szczegółowe wyniki badań właściwości przedstawiono w pkt. 3.4, które wykazały, że sieć neuronowa pomimo ograniczonego zbioru historycznych danych pomiarowych potrafi odtworzyć krzywe mocy zbliżone do krzywych katalogowych z uwzględnieniem cech charakterystycznych obiektu. Mając do wyboru model analityczny, statystyczny lub model neuronowy, zdecydowanie należy przeprowadzić analizę współczynników jakościowych, a następnie dokonać stosownego wyboru modelu. Przed ostatecznym wyborem modelu należy zawsze przeprowadzić fazę testów, aby mieć większe prawdopodobieństwo trafności prognoz. Warto również rozważyć model hybrydowy. Z badań wynika, że sieć o odpowiedniej strukturze jest dobrym estymatorem mocy wytwórczej farmy i może być stosowana alternatywnie przy tworzeniu modeli hybrydowych. Najlepszą prognozę mocy FW uzyskuje się w horyzoncie krótkoterminowym na podstawie danych z masztów meteorologicznych posadowionych w bliskiej odległości od obiektu. Odległość ta nie powinna przekraczać 10 km. Dobra prognoza warunków pogodowych umożliwia uzyskanie dokładniejszej prognozy predykcji generacji mocy, a tym samym uniknięcia znaczącego odchylenia na rynku bilansującym.

Różnorodność struktur farm wiatrowych i liczba czynników wpływająca na generację mocy sprawia, że trudno jest opracować jeden uniwersalny model prognostyczny. Stąd też, najlepszymi modelami na rynku są modele hybrydowe (stworzone z kilku różnych modeli), które wykorzystują również modele behawioralne (m.in. sztuczne sieci neuronowe). Wybór właściwego modelu wymaga poświęcenia czasu oraz nakładu finansowego. Bez doświadczenia operatorskiego (człowieka wykonującego prognozę) wykonanie prognozy mocy może okazać się kosztownym uczestnictwem na rynku bilansującym, dlatego też w celu ograniczenia ryzyka warto poświęcić więcej czasu na etapie analizy danych pomiarowych.

6. Literatura

- [1] Ustawa z dnia 20 lutego 2015 roku o odnawialnych źródłach energii (Dz.U. 2015 poz.478 z dnia 3 kwietnia 2015 roku)
- [2] Dyrektywa Parlamentu Europejskiego i Rady 2009/28/WE z dnia 23 kwietnia 2009 r. w sprawie promowania stosowania energii ze źródeł odnawialnych zmieniająca i w następstwie uchylająca dyrektywy 2001/77/WE oraz 2003/30/WE. Dz. U. UE L 140 z dnia 5 czerwca, (2009)
- [3] Sveinbjornsson S., *Analysis of WasP (Wind Atlas Analysis and Application Program) in complex topographical conditions using measured production from a large scale wind farm*, A thesis submitted in partial fulfillment of the requirements for the degree, Department of Civil and Environmental Engineering, University of Washington (2013)
- [4] Mortensen N.G., Heathfield D.N., Myllerup L., Landberg L., Rathmann O., *Getting Started with WasP 9*, Risø-I-2571(EN), Risø National Laboratory (2007)
- [5] Landberg L., *Short-term prediction of local wind conditions*, Journal of Wind Engineering and Industrial Aerodynamics 89, s.235–245, Elsevier Science Ltd, PII: S0167-6105(00)00079-9, (2001)
- [6] Beyer H.G., Heinemann D., Mellinghoff H., Monnich K., Waldl H.-P., *Forecast of regional power output of wind turbines*, Carl von Ossietzky University of Oldenburg, D-26111 Oldenburg, EWEC, Nice (1999)
- [7] Rohrig K., *Online-supervision and prediction of 3.000 MW wind power*, Institut für Solare Energieversorgungstechnik e.V., D-34119 Kassel, Germany (2000)
- [8] Ernst B., Rohrig K., Jursa R., *Online-monitoring and prediction of wind power in German transmission system operation centres*, Institut für Solare Energieversorgungstechnik e.V., D-34119 Kassel, Germany (2003)
- [9] Kariniotakis G.N., Stavrakakis G.S., Nogaret E.F., *Wind power forecasting using advanced neural networks models*, IEEE Transactions on Energy Conversion, vol.11, No.4, 0885-8969/96, s. 762-767 (1996)
- [10] Landberg L., *A mathematical look at a physical power prediction model*,

- Department of Wind Energy and Atmospheric Physics, Riso National Laboratory, Wind Energy, No 1, s.23-28, 1095-4244/98/010023-06, (1998)
- [11] Zeng J., *Support Vector Machine-Based Short-Term Wind Power Forecasting*, IEEE 978-1-61284-788-7/11, (2011)
- [12] Pelikán E., Eben K., Resler J., Juruš P., Krč P., Brabec M., Brabec T. Musilek P., *Wind power forecasting by an empirical model using NWP outputs*, Institute of Computer Science AS CR (Prague, Czech Republic), University of Alberta (Edmonton, Canada), IEEE (2010)
- [13] Wind Energy Division, Risø DTU, www.wasp.dk, <http://www.risoe.dtu.dk>
- [14] EMD International A/S, www.emd.dk/WindPRO
- [15] RETScreen International, www.etscreen.net
- [16] Rubanowicz T., *Metody predykcji produkcji mocy parku wiatrowego*, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, nr 25, s. 145-149, ISSN 1425-5766, Gdańsk, (2008)
- [17] Rubanowicz T., Bogalecka E., *Ocena charakterystyki mocy parku wiatrowego*, PES-7, VII Ogólnopolska Konferencja Naukowo-Techniczna PTETiS, Kościelisko, 22-26.06 (2009), s. 21-24, ISBN 978-83-927653-2-5, (2009)
- [18] Rubanowicz T., Bogalecka E., *Analiza charakterystyk parku wiatrowego*, Wiadomości Elektrotechniczne nr 2, s. 15-20, ISSN 0043-5112, (2010)
- [19] Rubanowicz T., Bogalecka E., *Neuronowy model mocy farmy wiatrowej*, Mechanik Nr 7/2010, s. 579-586, ISSN 0025-6552, Warszawa, (2010)
- [20] Rubanowicz T., Bogalecka E., *Modele farmy wiatrowej na potrzeby prognozowania mocy*, X Krajowa Konferencja Naukowa SENE, Łódź (2011)
- [21] Rubanowicz T., Bogalecka E., *Model fizyczny – czy neuronowy? – narzędzia do predykcji mocy wytwarzanej przez elektrownie wiatrowe*, XVI Międzynarodowa Szkoła Komputerowego Wspomagania Projektowania, Wytwarzania i Eksploatacji, Jurata (2012)
- [22] Rubanowicz T., *Budowa modelu prognostycznego farmy wiatrowej w środowisku MATLAB*, XXII Seminarium Zastosowanie Komputerów w Nauce i Technice, Oddział Gdański PTETiS, Gdańsk (2012)
- [23] Landberg L., Waldl H.-P., Giebel G., Focken U., Lange M., Monnich K., Beyer H. G., Luig A., *Short-term prediction of regional wind power*

- production*, Publishable Final Report, Contract JOR3-CT97-0272 PL971254, (1999)
- [24] Alexiadis M.C., Dokopoulos P.S., Sahsamanoglou H.S., Manousaridis I.M., *Short-term forecasting of wind speed and related electrical power*, Solar Energy Vol. 63, No. 1, pp. 61–68, Pergamon PII: S0038-092X(98)00032-2, Elsevier Science Ltd (1998)
- [25] Damousis I.G., Dokopoulos P.D., *A genetic fuzzy model for wind speed prediction and power generation in wind parks*, Polytechnic School, Electrical and Computer Engineering Dept., Aristotle University of Thessaloniki, Greece (1999)
- [26] Salmon J.R., Walmsley J.L., *A two-site correlation model for wind speed, direction and energy estimates*, PII: S0167-6105(98)00119-6, Elsevier Science Ltd. (1999)
- [27] Landberg L., *Short-term prediction of the power production from wind farms*, PII: S0167-6105(98)0012-5, Elsevier Science Ltd. (1999)
- [28] Barbero A., Lopez J., Dorronsoro J.R., *Kernel methods for Wide area wind power forecasting*, Universidad Autonoma de Madrid, Spain's TIN 2004–07676, TIN 2007–66862 and CIT-120000-2007-69 projects, (2007)
- [29] Focken U., Lange M., Waldl H.-P., *Reduction of wind power prediction error by spatial smoothing effects*, Carl von Ossietzky University of Oldenburg, (2001)
- [30] Nielsen T.S., *Online prediction and control in nonlinear stochastic systems*, Technical University of Denmark, Ph.D. Thesis No. 84, (2002)
- [31] Jørgensen J.S., Moehrlen C., Gallachóir B., Sattler K., McKeogh E., *HIRPOM: Description of an operational numerical wind power prediction model for large scale integration of on- and offshore wind power in Denmark*, Danish Meteorological Institute, Copenhagen, Denmark and University College Cork, Ireland (2002)
- [32] Focken U., Langea M., Monnich K., Waldla H.-P., Beyer H.G., Luig A., *Short-term prediction of the aggregated power output of wind farms – a statistical analysis of the reduction of the prediction error by spatial smoothing effects*, PII: S0167-6105(01)00222-7, Journal of Wind Engineering and Industrial Aerodynamics 90 (2002) 231–246, Elsevier Science Ltd. 2002

- [33] Joensen A., *Short-term wind power prediction*, Technical University of Denmark, Ph.D. Thesis No. 108 (2002)
- [34] Saint-Drenan Y-M., *Wind power predictions analysis*, Part 2, Economical analysis, ECN-I-02-011 (2002)
- [35] Foley A.M., Leahy P.G., Marvuglia A., McKeogh E.J., *Current methods and advances in forecasting of wind power generation*, Renewable Energy 37, s. 1-8, Elsevier (2012)
- [36] Giebel G., Kariniotakis G., *Best Practice in Short-Term Forecasting. A Users Guide*, Report for the POW'WOW project (2009)
- [37] Malko J., *Przybliżenie mocy wytwórczych elektrowni wiatrowych*, Przegląd Elektrotechniczny, ISSN 0033-2097, r. 84 nr 9, (2008).
- [38] Rubanowicz T., Bogalecka E., *Warunki wiatrowe na rozległej farmie wiatrowej*, Mechanik Nr 7/2011, s. 29-36, PL ISSN 0025-6552, Warszawa (2011)
- [39] Flores J.J., Graff M., Rodriguez H., *Evolutionary design of ARMA and ANN models for time series forecasting*, Renewable Energy 44 (2012) 225-230, Elsevier (2012)
- [40] González-Longatt F., Wall P., Terzija V., *Wake effect in wind farm performance: Steady-state and dynamic behavior*, Renewable Energy 39 (2012) 329-338, Elsevier (2012)
- [41] Shi J., Guo J., Zheng S., *Evaluation of hybrid forecasting approaches for wind speed and power generation time series*, Renewable and Sustainable Energy Reviews 16, s. 3471–3480, Elsevier (2012)
- [42] Colak I., Sagiroglu S., Yesilbudak M., *Data mining and wind power prediction: A literature review*, Renewable Energy 46 (2012) 241-247, Elsevier (2012)
- [43] Tascikaraoglu A., Uzunoglu M., Vural B., *The assessment of the contribution of short-term wind power predictions to the efficiency of stand-alone hybrid systems*, Applied Energy 94, s. 156–165, Elsevier (2012)
- [44] Monteiro C., Bessa R., Miranda V., Botterud A., Wang J., Conzelmann G., *Wind power forecasting: State-of-the-Art 2009*, Decision and Information Sciences Division, ANL/DIS-10-1, Argonne National Laboratory (2009)

- [45] Tewari S., Geyer Ch.J., Mohan N., *A Statistical Model For Wind Power Forecast Error And Its Application To The Estimation Of Penalties In Liberalized Market*, IEEE, Paper no. TPWRS-00365-2010, (2011)
- [46] Artipoli G., Durante F., *Physical modeling in wind energy forecasting*, DEWI GmbH Italy, DEWI Magazin No. 44, (2014)
- [47] Kolhe M., Lin T.C., Maunuksela J., *GA-ANN For Short-Term Wind Energy*, ISSN 978-1-4244-6255-1/11/\$26.00, IEEE (2011)
- [48] Watters C.S., Leahy P., *Comparison Of Linear, Kalman Filter And Neural Network Downscaling Of Wind Speeds From Numerical Weather Prediction*, 978-1-4244-8782-0/11, IEEE (2011)
- [49] Catalão J.P.S., Pousinho H.M.I., Mendes V.M.F., *Hybrid Wavelet-PSO-ANFIS Approach for Short-term wind power forecasting in Portugal*, IEEE Transactions On Sustainable Energy, Vol. 2, No. 1, (2011)
- [50] Catalão J.P.S., Pousinho H.M.I., Mendes V.M.F., *Hybrid Intelligent Approach For Short-Term Wind Power Forecasting In Portugal*, IET Renewably Power Generation, Vol. 5, Iss. 3, pp. 251–257, www.ietdl.org, ISSN 1752-1416, (2011)
- [51] Chang W.-Y., A literature review of wind forecasting methods, *Journal of Power and Energy Engineering*, (2014) 2, 161-168 (2014)
- [52] Holttinen H., *Optimal electricity market for wind power*, *Energy Policy* 33 (2005) 2052–2063, Elsevier (2005)
- [53] Giebel G., *The State of the Art in short-term prediction of wind power*, Deliverable Report, A Literature Overview, 2nd Edition, Risø DTU, Wind Energy Division, ANEMOS (2011)
- [54] Giebel G., Kariniotakis G., Brownsword R., *State-of-the-art on methods and software tools for short-term prediction of wind energy production*, In: Proceedings of the EWEC, Madrid, Spain (2003)
- [55] Kariniotakis G.N., Marti I., Casas D., Pinson P., Nielsen T.S., Madsen H., Giebel G., Usaola J., Sanchez I., Palomares A.M., Brownsword R., Tambke J., Focken U., Lange M., Louka P., Kallos G., Lac C., Sideratos G., Descombes G., *What performance can be expected by short-term wind power prediction models depending on site characteristics?*, EWEC Conference, London (2004)

- [56] Kariniotakis G.N., Marti I., Nielsen T.S., Giebel G., Tambke J., Waldl I., Usaola J., *Advanced short-term forecasting of wind generation – Anemos*, IEEE (2006)
- [57] Kariniotakis G.N. i inni, *ANEMOS: Development of a next generation wind power forecasting system for the large-scale integration of Onshore & Offshore Wind Farms*, European Wind Energy Conference & Exhibition EWEC (2003)
- [58] Kariniotakis G.N., Halliday J., Brownsword R., Marti I., Maria A., *Next generation short-term forecasting of wind power – Overview of the ANEMOS Project*, HAL Id: hal-00526638 (2010)
- [59] Waldl I., Kariniotakis G.N., *The Anemos wind power forecasting platform technology – techniques and experiences*, EWEC (2006)
- [60] Sideratos G., Hatzigiorgiou N.D., *An advanced statistical method for wind power forecasting*, *IEEE Transactions On Power Systems*, Vol. 22, No. 1, (2007)
- [61] Juban J., Fugon L., Kariniotakis G., *Probabilistic short-term wind power forecasting based on Kernel density estimators*, Probabilistic wind power forecasting – European Wind Energy Conference – Milan, Italy, 7-10 May (2007)
- [62] Mabel M.C., Fernandez E., *Analysis of wind power generation and prediction using ANN: A case study*, *Renewable Energy* 33 (2008) 986–992, ScienceDirect (2007)
- [63] Wagner R., Jørgensen H.E., Paulsen U., Madsen H.A., Larsen T.J., Antoniou I., Thesbjerg L., *Wind characteristics measurement for large wind turbine power curve*, Risø/DTU (2008)
- [64] Monteiro C., Keko H., Bessa R., Miranda V., Botterud A., Wang J., Conzelmann G., *A quick guide to wind power forecasting: State of the Art 2009*, Argonne National Laboratory, ANL/DIS-10-2 (2009)
- [65] Soman S.S., Zareipour H., Malik O., Mandal P., *A review of wind power and wind speed forecasting methods with different time horizons*, IEEE (2009)
- [66] Mendes J., Bessa R.J., Keko H., Sumaili J., Miranda V., Ferreira C., Gama J., *Development and testing of improved statistical wind power forecasting methods*, Argonne National Laboratory, Inescporto, ANL/DIS-11-7, U.S.

- Department of Energy – Office of Science and Technical Information, (2011)
- [67] Botterud A., Zhou Z., Wang J., *Use of wind power forecasting in operational decisions*, Argonne National Laboratory, Inescporto, ANL/DIS-11-7, U.S. Department of Energy – Office of Science and Technical Information, (2011)
- [68] Halamay D.A., Brekken T.K.A., Simmons A., McArthur S., *Reserve requirement impacts of large-scale integration of wind, solar, and ocean wave power generation*, National Science Foundation under Grant No. 0846533, IEEE (2011)
- [69] Sideratos G., Hatziargyriou N.D., *Probabilistic wind power forecasting using radial basis function neural networks*, EU research project GA no 213740 “SafeWind”, National Technical University of Athens (2013)
- [70] Blonbou R, *Very short-term wind power forecasting with neural networks and adaptive Bayesian learning*, Renewable Energy 36 (2011), ScienceDirect (2010)
- [71] Ma Y., Runolfsson T., Jiang J.N., *Cluster analysis of wind turbines of large wind farm with diffusion distance method*, IET Renewable Power Generation, s. 1752-1416, (2011)
- [72] Beccali M., Culotta S., Galletto J.M., Macaione A., *Influence of raw data analysis for the use of neural networks for wind farms productivity prediction*, IEEE 978-1-4244-8930-5/11 (2011)
- [73] Pousinho H.M.I., Catalão J.P.S., *Wind power short-term prediction by a hybrid PSO-ANFIS approach*, IEEE 978-1-4244-5795-3/10 (2010)
- [74] Silva J., Ribeiro C., Guedes R., *Roughness length classification of Corine land cover classes*, MEGAJOULE – Consultants, EWEC (2007)
- [75] Ragheb .M., *Wind shear, roughness classes and turbine energy production*, (2015)
- [76] Ramli N.I., Idris Ali M., Syamsyul H. Saad M., Majid T.A., *Estimation of the roughness length in Malaysia using satellite image*, APOWE-VII, The Seventh Asia-Pacific Conference on Wind Engineering, Taipei, Taiwan, November (2009)
- [77] Barthelmie R.J., Rathmann O., Frandsen S.T., Hansen K., Politis E., Prospathopoulos J., Rados K., Cabezón D., Schlez W., Phillips J., Neubert A., *Modelling and measurements of wakes in large wind farms*, The Science

- of Making Torque from Wind, Journal of Physics: Conference Series 75 (2007) 012049, IOP Science (2007)
- [78] Frandsen S., Barthelmie R., Rathmann O., Jørgensen H.E., Badger J., Hansen K., Ott S., Rethore P-E., Larsen S.E., Jensen L.E., *Summary report: The shadow effect of large wind farms: measurements, data analysis and modeling*, Risø National Laboratory, Risø-R-1615(EN), ISBN 978-87-550-3616-1, (2007)
- [79] Barthelmie R., Schepers J.G., Rathmann O. and ather, *Flow and wakes in complex terrain and offshore: Model development and verification in UpWind*, EWEC (2007)
- [80] Barthelmie R., Giebel G., Cabezon D., Marti I., *Wp4: An overview of wind turbine wakes and short-term forecasting*, Prediction Of Waves, Wakes and Offshore Wind, Project POW'WOW, Contract No.: SES6 019898 (2009)
- [81] Duran M.J., Cros D., Riquelme J., *Short-term wind power prediction based on AR models*, Electrical Engineering Department Universidad de Sevilla, (2007)
- [82] Parkers J.; Tindal A., *Forecasting Short Term Wind Farm Production in Complex Terrain*, Garrard Hassan and Partners Ltd, www.gl-garradhassan.com, (2006)
- [83] Madsen H., Kariniotakis G., Nielsen H.A, Nielsen T.S., Pinson P., *Protocol for Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models*, Project ANEMOS, Contract No.: ENK5-CT-2002-00665 (2004)
- [84] Jursa R., *Wind power prediction with different artificial intelligence models*, IEEE (2006)
- [85] Lichota A., *Prognozowanie krótkoterminowe na lokalnym rynku energii elektrycznej*, Rozprawa doktorska, Akademia Górniczo-Hutnicza, Kraków (2006)
- [86] Giebel G., Sørensen P., *Forecast error of aggregated wind power*, Holttinen H., Risø National Laboratory, Trade Wind (2007)
- [87] Centrum Informacji o Rynku Energii, www.cire.pl
- [88] Rozporządzenie Ministra Ochrony Środowiska, Zasobów Naturalnych i Leśnictwa z dnia 3 września 1998 roku w sprawie metod obliczania stanu zanieczyszczenia powietrza dla źródeł istniejących i projektowanych, Dz.U. nr 122, poz. 805