



**POLITECHNIKA  
GDAŃSKA**

WYDZIAŁ ELEKTROTECHNIKI  
I AUTOMATYKI

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

**AUTOREFERAT  
ROZPRAWA DOKTORSKA**

Tytuł rozprawy w języku polskim: Prognozowanie mocy wytwórczej farmy wiatrowej

Tytuł rozprawy w języku angielskim: Wind Power Generation Forecasting

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

Gdańsk, rok 2019

**Spis treści**

<b>1. UZASADNIENIE TEMATU .....</b>	<b>4</b>
1.1. CEL PRACY I TEZY BADAWCZE .....	6
1.2. STRUKTURA PRACY .....	7
1.3. PRZEDMIOT BADANIA I DANE POMIAROWE .....	7
<b>2. OPIS BADANYCH OBIEKTÓW .....</b>	<b>8</b>
2.1. WARUNKI WIATROWE NA FARMIE WIATROWEJ .....	8
2.2. OD CZEGO ZALEŻY MOC FARMY WIATROWEJ? .....	10
<b>3. BUDOWA MODELU MOCY FW .....</b>	<b>11</b>
3.1. MODELE PROGNOSTYCZNE W LITERATURZE – STAN AKTUALNY .....	11
3.2. STRUKTURA MODELU MOCY .....	12
3.3. UCZENIE I TESTOWANIE MODELU MOCY (SIECI ELMANA) .....	13
3.3.1. MODEL Z JEDNYM WEJŚCIEM: ŚREDNIA PRĘDKOŚĆ WIATRU .....	14
3.3.2. MODEL Z DWOMA WEJŚCIAMI: ŚREDNIA PRĘDKOŚĆ I KIERUNEK WIATRU .....	17
3.3.3. MODEL Z JEDNYM WEJŚCIEM: PRĘDKOŚĆ WIATRU Z MASZTU METEO .....	17
3.3.4. TESTOWANIE MODELU MOCY W INNEJ PORZE ROKU .....	22
1.1. BADANIE WŁAŚCIWOŚCI MODELU MOCY .....	25
<b>2. WYNIKI BADAŃ – PORÓWNANIE DWÓCH MODELI MOCY FW .....</b>	<b>28</b>
2.1. MIARA BŁĘDU .....	28
2.2. WYBÓR SKUTECZNEGO MODELU MOCY FW .....	28
<b>3. PODSUMOWANIE .....</b>	<b>31</b>
<b>4. LITERATURA .....</b>	<b>33</b>

### Najważniejsze oznaczenia, skróty i symbole

EW	–	elektrownia wiatrowa
FW	–	farma wiatrowa
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)
Vw	–	średnia prędkość wiatru
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].

Rosnący udział elektrowni wiatrowych w KSE wymusza utrzymywanie zwiększonych rezerw mocy w energetyce konwencjonalnej, co niewątpliwie powoduje wzrost kosztów działalności energetycznej [28]. 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.

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. 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]. Najlepszymi prognozami pogody dla FW są lokalne numeryczne prognozy krótkoterminowe, które oparte są na podstawowych zasadach fizyki przepływu powietrza [6,17].

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, uwzględniającą straty przesyłowe. Powstające koszty po stronie uczestników rynku mogą przyczynić się w dłuższej perspektywie do braku płynności finansowej każdego z nich.

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). 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.

Prognozowanie mocy wytwórczej FW w horyzoncie 24-godzinnym wymaga zarówno wiarygodnej prognozy wietrzności jak i narzędzi wspomagających. Narzędzie to jest dedykowanym modelem mocy FW. Literatura tematu jest obszerna i opisywanych jest wiele metod prognozowania mocy [16, 24, 26, 28]. Ponadto na rynku funkcjonuje kilka dedykowanych narzędzi prognostycznych [19÷22, 27]. Coraz więcej publikacji opisuje modele hybrydowe, które łączą ze sobą kilka modeli [11, 12]. 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 [19, 24].
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. 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. Modele neuronowe wymagają poprawnych danych pomiarowych, właściwej struktury i rozmiaru sieci (dobranej metodą doświadczalną) oraz odpowiedniej metody uczenia sieci. Parametry SSN ustalane są w procesie uczenia. Celem końcowym uczenia sieci

jest znalezienie optymalnych współczynników wagowych, tak by model prawidłowo odtwarzał krzywą mocy obiektu.

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], 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 opiera się na danych statystycznych i danych rzeczywistych (on-line) pomierzonych bezpośrednio w FW oraz na prognozowanych danych meteorologicznych. 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. W ramach projektu ANEMOS opracowano około 15 zaawansowanych modeli prognostycznych, 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).

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 tezy badawcze**

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 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.

## 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 błędów sieci, a do maksymalizacji zdolności generalizacyjnych. Metoda ta zapobiega przeuczeniu sieci w przeciwieństwie do metody Levenberga-Marquardta.

Podstawą do budowy modeli są 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

Na rys.1 przedstawiono topologię badanej FW zlokalizowanej w północnej części Polski (Farma B). Farma B składa się z 24 siłowni typu Vestas (do badań tej farmy wykorzystano dane z tylko 5 siłowni). Badania prowadzono w oparciu o ograniczoną liczbę danych pomiarowych. Dla FW pozyskano dane o prędkości i kierunku wiatru z anemometrów umieszczonych na każdej gondoli (na wysokości piasty: 100 m n.p.g.). Pomiary mocy wytwórczej oraz warunków wiatrowych dokonywane są z krokiem 10-cio minutowym. Dane meteorologiczne oraz produkcyjne pozyskano za pomocą systemu SCADA z różnych okresów roku.



Rys.1 Rozmieszczenie 5 z 24 siłowni wiatrowych rozległej Farmy B

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. Prędkości wiatru na rozległej FW mogą różnić się nawet o ponad 30%.

Analiza danych pomiarowych z FW umożliwiła zaobserwowanie zjawisk, mających wpływ na ich wyjściową moc elektryczną. W rozdziale tym pokazano cechy, właściwości wiatru na rozległej FW, 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. Bezpośrednie pomiary na siłowniach dają możliwość poznania cech charakterystycznych całego obiektu, ale ze względu na lokalizację anemometru umieszczonego na gondoli za łopatomy, pomiary strumienia wiatru nie odzwierciedlają faktycznych warunków wiatrowych występujących na FW [13].

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). 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 obciążone 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.

## 2.2. Od czego zależy moc farmy wiatrowej?

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, która przekłada się na prędkość obrotową wirnika generatora. Prędkość wiatru ma największy wpływ na wolumen generacji mocy (odgrywa najistotniejszą rolę w predykcji mocy FW).

W poniższej Tabeli 1 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 ( $P_c$ ). W tabeli 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  $P_{cFarma}$ ). Po usunięciu błędnych pomiarów ze zbiorów danych, korelacja pomiędzy zmiennymi stała się silniejsza. Za błędne pomiary przyjęto m.in. wartości zerowe wynikające z wyłączenia siłowni. Silniejsza korelacja pomiędzy tymi wartościami występuje wtedy, gdy uśrednimy prędkość wiatru ze wszystkich EW.

*Tabela 1 Analiza korelacji pomiędzy prędkością wiatru na gondolach, a masztem meteo 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	<b>0,910</b>	0,953	0,938	1,000									
VwG24	<b>0,917</b>	0,949	0,955	0,978	1,000								
VwM50	<b>0,923</b>	<b>0,917</b>	<b>0,936</b>	<b>0,894</b>	<b>0,914</b>	<b>1,000</b>							
PcG03	<b>0,976</b>	0,928	0,932	0,897	0,910	0,924	1,000						
PcG09	0,915	<b>0,974</b>	0,931	0,927	0,927	0,908	0,936	1,000					
PcG10	0,924	0,933	<b>0,980</b>	0,912	0,933	0,933	0,948	0,948	1,000				
PcG23	0,901	0,940	0,925	<b>0,969</b>	0,952	0,896	0,917	0,953	0,931	1,000			
PcG24	0,913	0,938	0,944	0,949	<b>0,972</b>	0,919	0,933	0,953	0,955	0,976	1,000		
VwFarma	<b>0,962</b>	<b>0,982</b>	<b>0,978</b>	<b>0,979</b>	<b>0,983</b>	<b>0,938</b>	<b>0,949</b>	<b>0,957</b>	<b>0,958</b>	<b>0,960</b>	<b>0,966</b>	<b>1,000</b>	
PcFarma	<b>0,946</b>	<b>0,964</b>	<b>0,964</b>	<b>0,952</b>	<b>0,960</b>	<b>0,937</b>	<b>0,967</b>	<b>0,980</b>	<b>0,978</b>	<b>0,977</b>	<b>0,986</b>	<b>0,980</b>	<b>1,000</b>

Uwzględnienie kierunku wiatru w modelach mocy może poprawić jakość prognozy, lecz w mniejszym stopniu niż przy posiadaniu dokładniejszej prognozy pogody. 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 częstości 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 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

Omówione w pracy metody prognostyczne są najczęściej spotykanymi w literaturze. Pragmatyka preferuje podejście hybrydowe [16, 11, 13]. Rezultaty stosowania tych metod nie mają jednoznacznej opinii, stąd tak wiele projektów

mających na celu wskazanie najskuteczniejszych metod [12, 18, 14, 10]. 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.

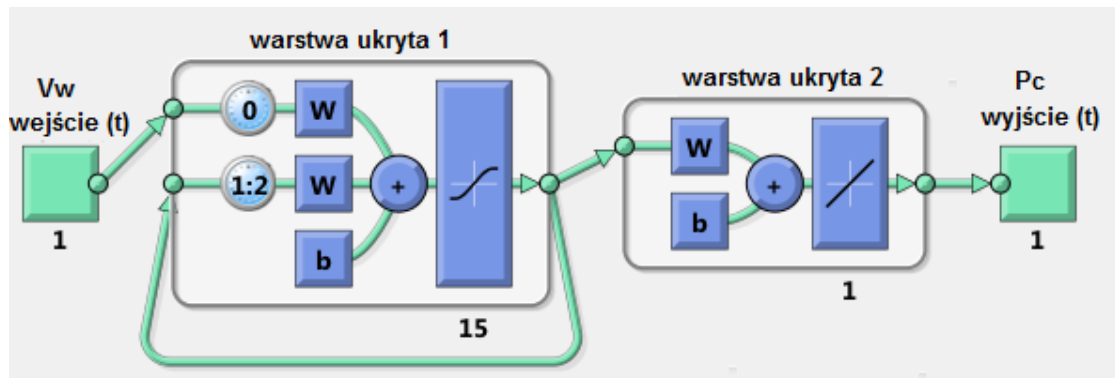
### 3.2. Struktura modelu mocy

Przedstawiona analiza danych pomiarowych w rozdziale 2 potwierdziła, iż prędkość ( $V_w$ ) wiatru jest najważniejszym czynnikiem wpływającym na generację mocy wytwórczej FW. Inne czynniki wpływające na jej generację, tj. silne podmychy 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 FW o skupionej strukturze. Zjawisko to ma większe znaczenie w okresach o dużej dynamice zmian kierunku wiatru, np. latem, ale nie można przesądzać tego definitywnie. Pomiary kierunku wiatru wykonano bezpośrednio na gondolach, a kalibracja punktu zerowego nie została przypisana dokładnie poszczególnym stronom świata, co uzasadniano w rozprawie. Stąd też w badanych modelach mocy nie uwzględniono również przesłonięcia. Dlatego też przedstawiono wyniki badań modelu mocy na przykładzie farmy o rozległej strukturze.

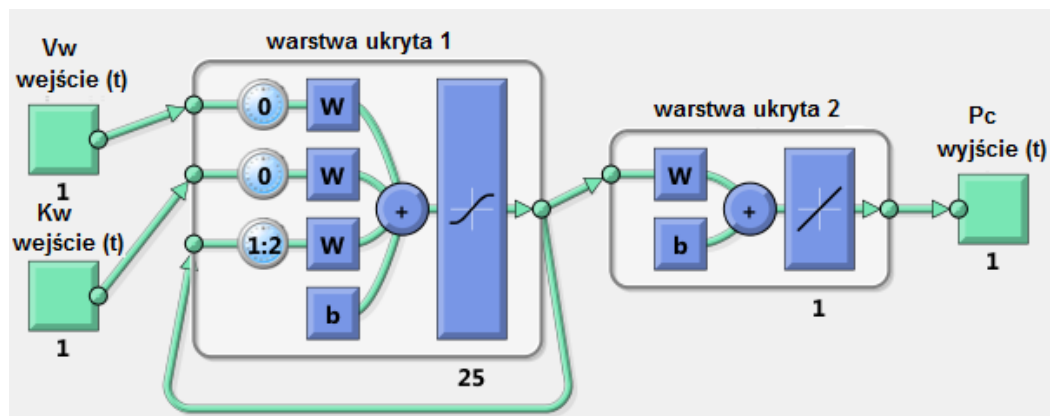
Poszukując odpowiedzi na postawione pytania zbudowano dwa modele prognostyczne, wykorzystujące strukturę sieci neuronowej Elmana. Częściowa rekurencja sieci Elmana różni się od pozostałych sieci rekurencyjnych (tj. Hopfielda, Hamminga, sieci BAM, sieci ART), tym, że pętla sprzężenia zwrotnego rozpoczyna 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). W celu uzyskania większej dokładności sieci neuronowej modyfikuje się jej wartości wag i progu (*ang. bias*), za pomocą algorytmów: zmiennej metryki Levenberga-Marquardta oraz Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (sieć Bayesa).

W ramach pracy zbadano metodą doświadczalną różne modele neuronowe z różną liczbą wejść i neuronów w warstwie ukrytej. Modele zaimplementowano w programie Matlab. Do dalszych badań wybrano dwa modele: z jednym i dwoma wejściami. W pierwszym modelu na wejściu wprowadzono średnią prędkość wiatru (rys.2), natomiast w drugim średnią prędkość ( $V_w$ ) i kierunek ( $K_w$ ) wiatru (rys.3). Na wyjściu modeli otrzymuje się prognozowaną wartość generacji mocy ( $P_c$ ) dla badanego obiektu.



Rys.2 Model mocy FW z jednym wejściem: prędkością wiatru



Rys.3 Model mocy FW z dwoma wejściami: prędkością i kierunkiem wiatru

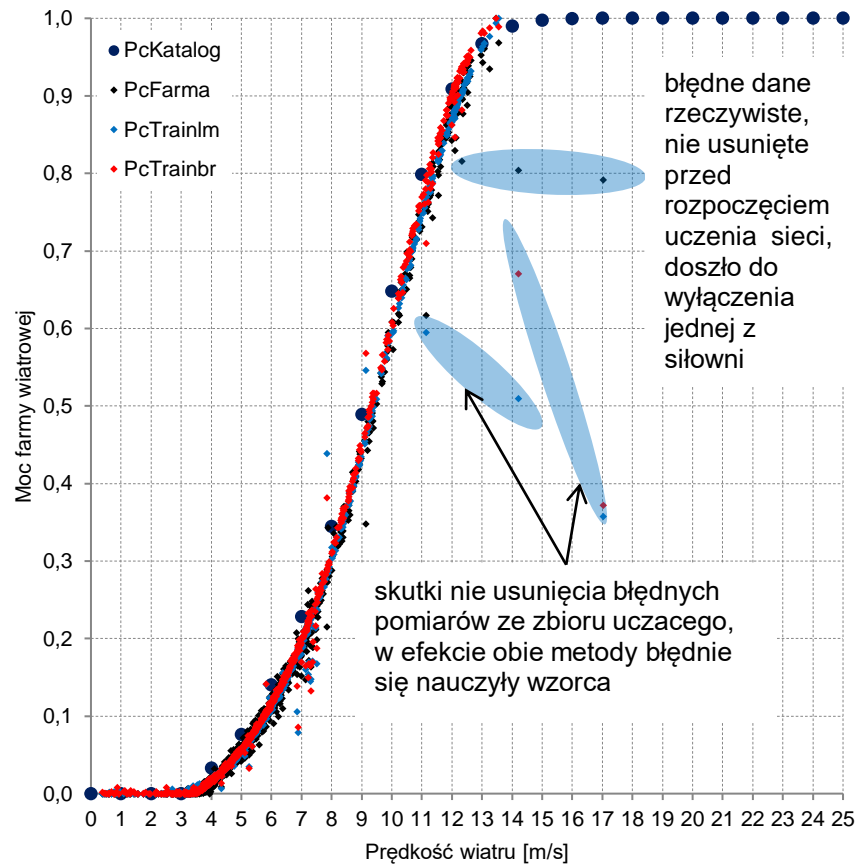
### 3.3. Uczenie i testowanie modelu mocy (sieci Elmana)

W rozdziale tym pokazano przebiegi uczenia i testowania modelu mocy FW z jednym (rys.2) i dwoma wejściami (rys.3). Model FW to dwa różne modele tj. zimowy i letni. Badania prowadzono wykorzystując dostępne dane pomiarowe z farmy.

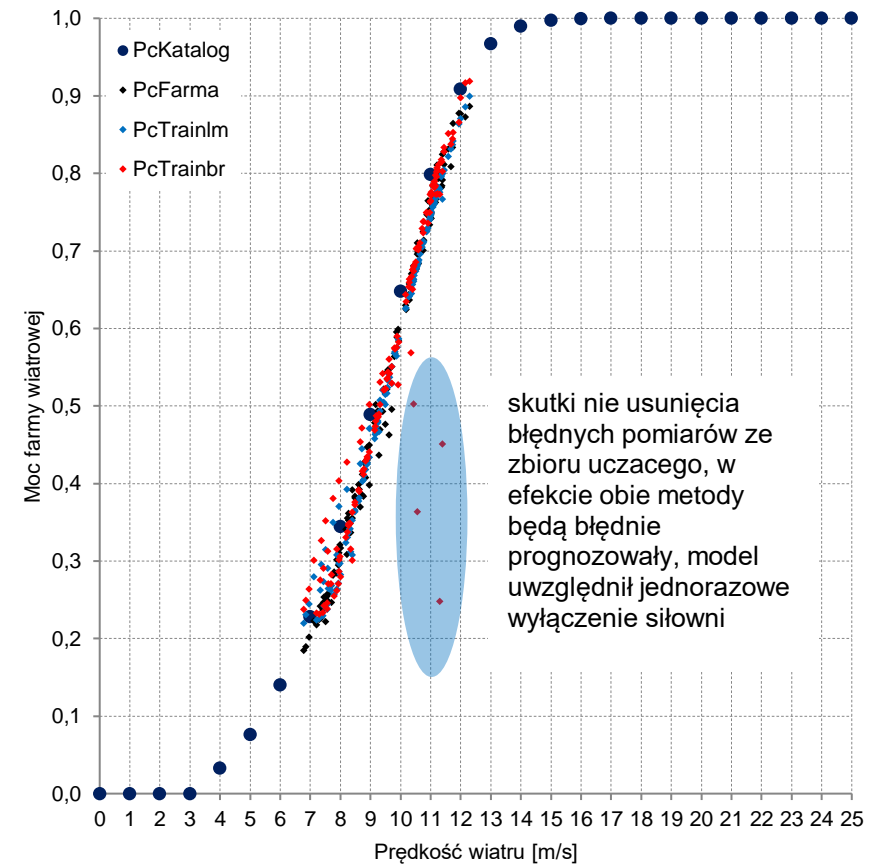
### 3.3.1. Model z jednym wejściem: średnia prędkość wiatru

Przedmiotem badań jest model FW z jednym wejściem: prędkością wiatru. Ilość neuronów dobrano metodą doświadczalną 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 FW oraz prędkości wiatru pochodzącej z masztu meteorologicznego. Za wartość uczącą przyjęto sumę generacji mocy 5 siłowni w poszczególnych godzinach doby.


Na rys.4 i 5 przedstawiono wyniki uczenia sieci metodą Levenberga-Marquardta (PcTrainlm) oraz metodą Levenberga-Marquardta z wbudowaną regularyzacją bayesowską (PcTrainbr). Na rys.6 a) przedstawiono przebiegi uczące z okresu letniego oraz efekty uczenia sieci metodami PcTrainlm i PcTrainb. 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. Wskaźniki jakości modelu mocy przedstawiono w rozdziale 4.1.




*Rys.4 Moc Farmy B w funkcji prędkości wiatru  
 –wynik uczenia sieci w okresie letnim*



*Rys.5 Moc Farmy B w funkcji prędkości wiatru  
 –wynik testowania sieci w okresie letnim*



a)



b)

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



### 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 kierunku 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.

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.


### 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 1.


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.7 i 9 a) obie metody uczenia nie potrafiły odpowiednio skutecznie odtworzyć rzeczywistych wartości generacji mocy dla obu okresów (letniego i zimowego). 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.7 Moc Farmy B w funkcji prędkości wiatru  
–wynik uczenia sieci w okresie letnim



Rys.8 Moc Farmy B w funkcji prędkości wiatru  
–wynik testowania sieci w okresie letnim

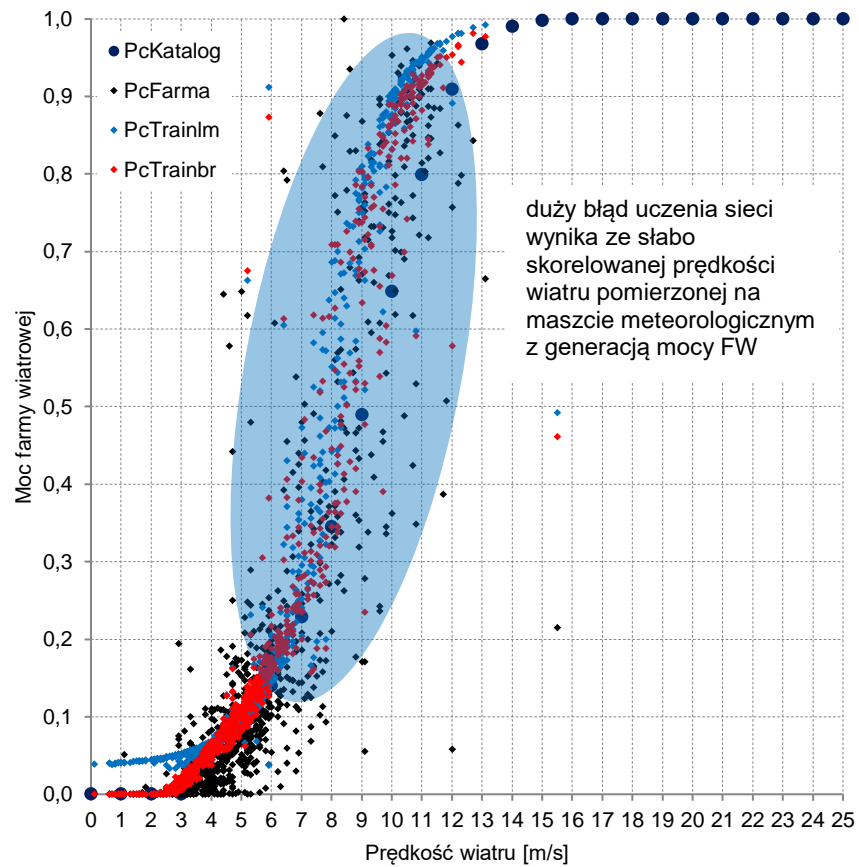


a)




b)


Rys.9 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim




*Rys.10 Moc Farmy B w funkcji prędkości wiatru  
–wynik uczenia sieci w okresie letnim*



*Rys.11 Moc Farmy B w funkcji prędkości wiatru  
–wynik testowania sieci w okresie letnim*



a)



b)


Rys.12 Generacja mocy Farmy B (a) uczenie sieci (6 dni) i (b) testowanie modelu (1 doba) w okresie letnim

### 3.3.4. Testowanie modelu mocy w innej porze roku

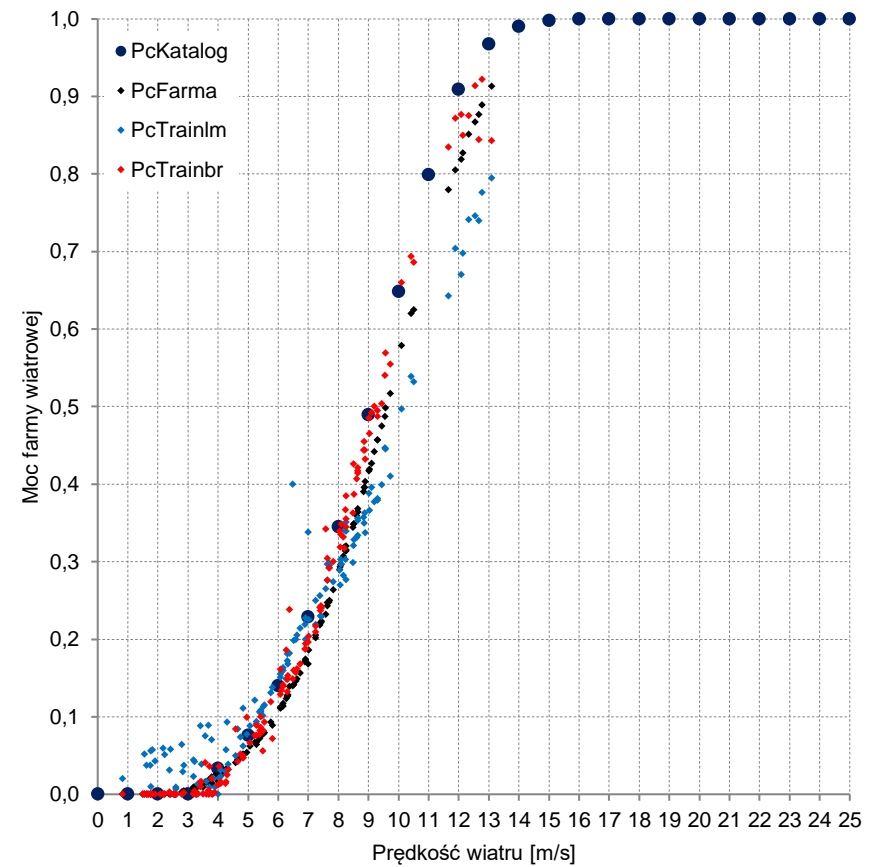
Kolejnym etapem pracy było zbadanie czy sieć nauczona na danych letnich sprawdzi się w innych porach roku, np. zimową? Jak już wiadomo z wcześniejszej analizy, nie można zbudować jednego uniwersalnego modelu predykcji mocy FW. Z zasad fizyki, obserwacji i pomiarów wynika, że farma nie jest obiektem stacjonarnym, 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. 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.

W różnych porach roku wiatr ma trochę inne właściwości, np. inne średnie prędkości, czy inną 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.13 i 15 a) przedstawiono wyniki modelu z jednym wejściem. Natomiast na rys.14 i 15 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.13 i 14 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.13 Moc Farmy B w funkcji prędkości wiatru –wynik testowania sieci z jednym wejściem lato-zima



Rys.14 Moc Farmy B w funkcji prędkości wiatru –wynik testowania sieci z dwoma wejściami lato-zima



a)



b)


Rys. 15 Testowanie modelu (1 doba) (a) model tylko z jednym wejściem i (b) model z dwoma wejściami




### 1.1. 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 ciągom danych wejściowych (prędkości wiatru). Na rys.16÷20 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 rys.17. Natomiast na rys.18 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.17 i 20), 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.17, 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 rys.19 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 rys.21 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. 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.



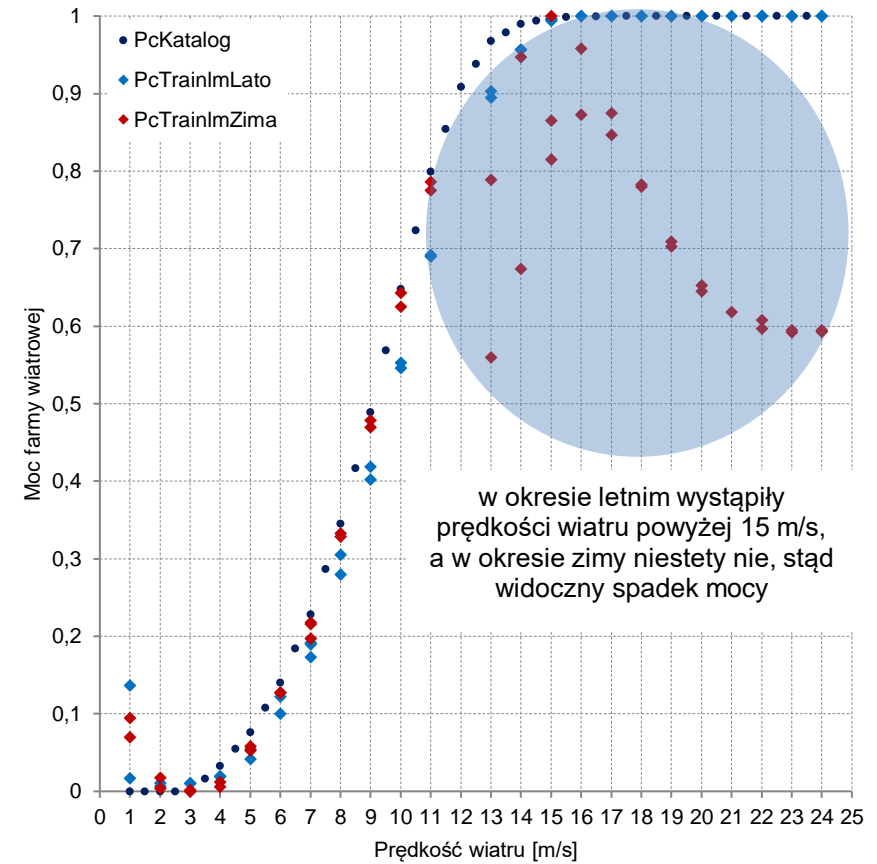
Rys.16 Kontrolowane wymuszenie dla rosnącej liniowo prędkości wiatru



Rys.17 Odpowiedź modeli Farmy B w funkcji prędkości wiatru



Rys.18 Kontrolowane wymuszenie poprzez rosnącą prędkość wiatru



Rys.19 Odpowiedź modeli Farmy B w funkcji prędkości wiatru

## 2. 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.

### 2.1. 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.20÷23 przedstawiono obliczone współczynniki jakości dla modelu z jednym (rys.20÷21) i dwoma (rys.22÷23) 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 ( $P_c$ ). Do oceny jakości prognozy wybrano cztery kryteria, tj. sumę mocy w danym okresie, czyli energię [MWh], błąd bezwzględny, sumę odchyleń wartości prognozowanej od rzeczywistej, oraz współczynnik zmienności (dynamika). Wyniki uczenia i testowania sieci przedstawiono w tabelach 2 i 3. Współczynnik zmienności przedstawia dynamikę zmienności mocy, czyli skrajnych wartości oddalonych od średniej. Czym wyższy współczynnik, tym większa dynamika mocy. Model mocy FW z niskim współczynnikiem zmienności zwiększa skuteczność prognozy.

### 2.2. Wybór skutecznego modelu mocy FW

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: 2 i 3, jako VwFarma, natomiast drugiego VwKwFarma. W tabeli 2 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 wolumeny energii elektrycznej zbliżone 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 2 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 wylicza się sumę odchyłeń (rys.21), następnie współczynnik zmienności generacji mocy (rys.23). Porównuje się 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. 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 3. Różnice predykcji mocy między modelami wynikają przede wszystkim z metody uczenia sieci.


Tabela 3 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
	PcTrainIm	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
	PcTrainIm	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
	PcTrainIm	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
	PcTrainIm	0,26500	1,09100	0,26400	1,10800
	PcTrainbr	0,28300	1,14500	0,22700	0,68300


Budowa jednego uniwersalnego modelu mocy będącego dobrym estymatorem dla każdych warunków wietrznych jest niemożliwa. Potwierdza to różnica błędów obu modeli względem rzeczywistej generacji mocy. Z badań wynika, że sieć potrafi nauczyć się rzeczywistych warunków FW dla wszystkich pór roku. Jak wynika z etapu testowania, metody, które sprawdzają się lepiej w okresie letnim, gorzej radzą sobie w okresie zimowym i odwrotnie. Sieć neuronowa jest dobrym estymatorem krzywej mocy FW.




Rys.20 Suma generacji obu modeli neuronowych wraz z rzeczywistą generacją w różnych porach roku (dane z tabeli nr 8, jedno wejście)



Rys.21 Suma odchyłeń od średniej generacji mocy w różnych porach roku (dane z tabeli nr 8, jedno wejście)



Rys.22 Błąd bezwzględny dla różnych pór roku (dane z tabeli nr 8, jedno wejście)



Rys.23 Dynamika zmian generacji mocy dla różnych pór roku (dane z tabeli nr 8, jedno wejście)

### 3. 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 podstawową 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 odchyleń 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 obarczone dużym błędem i okazać się kosztownym uczestnictwem na rynku bilansującym, dlatego też w celu ograniczenia ryzyka warto poświęcić więcej czasu na etapie analizy danych pomiarowych.

#### **4. 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] Zeng J., *Support Vector Machine-Based Short-Term Wind Power Forecasting*, IEEE 978-1-61284-788-7/11, (2011)
- [5] Wind Energy Division, Risø DTU, [www.wasp.dk](http://www.wasp.dk), <http://www.risoe.dtu.dk>
- [6] EMD International A/S, [www.emd.dk/WindPRO](http://www.emd.dk/WindPRO)
- [7] RETScreen International, [www.retscreen.net](http://www.retscreen.net)
- [8] 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)
- [9] 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)
- [10] Rubanowicz T., Bogalecka E., *Analiza charakterystyk parku wiatrowego*, Wiadomości Elektrotechniczne nr 2, s. 15-20, ISSN 0043-5112, (2010)
- [11] Rubanowicz T., Bogalecka E., *Neuronowy model mocy farmy wiatrowej*, Mechanik Nr 7/2010, s. 579-586, ISSN 0025-6552, Warszawa, (2010)
- [12] Rubanowicz T., Bogalecka E., *Modele farmy wiatrowej na potrzeby prognozowania mocy*, X Krajowa Konferencja Naukowa SENE, Łódź (2011)
- [13] 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)
- [14] Rubanowicz T., *Budowa modelu prognostycznego farmy wiatrowej w środowisku MATLAB*, XXII Seminarium Zastosowanie Komputerów w Nauce i Technice, Oddział Gdański PTETiS, Gdańsk (2012)
- [15] Landberg L., *Short-term prediction of the power production from wind farms*,

- PII: S0167-6105(98)0012-5, Elsevier Science Ltd. (1999)
- [16] 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)
- [17] Nielsen T.S., *Online prediction and control in nonlinear stochastic systems*, Technical University of Denmark, Ph.D. Thesis No. 84, (2002)
- [18] Saint-Drenan Y-M., *Wind power predictions analysis*, Part 2, Economical analysis, ECN-I-02-011 (2002)
- [19] Rubanowicz T., Bogalecka E., *Warunki wiatrowe na rozleglej farmie wiatrowej*, Mechanik Nr 7/2011, s. 29-36, PL ISSN 0025-6552, Warszawa (2011)
- [20] 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)
- [21] 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)
- [22] Holttinen H., *Optimal electricity market for wind power*, Energy Policy 33 (2005) 2052–2063, Elsevier (2005)
- [23] Waldl I., Kariniotakis G.N., *The Anemos wind power forecasting platform technology – techniques and experiences*, EWEC (2006)
- [24] 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)
- [25] Parkers J.; Tindal A., *Forecasting Short Term Wind Farm Production in Complex Terrain*, Garrard Hassan and Partners Ltd, [www.gl-garradhassan.com](http://www.gl-garradhassan.com), (2006)
- [26] Jursa R., *Wind power prediction with different artificial intelligence models*, IEEE (2006)
- [27] Lichota A., *Prognozowanie krótkoterminowe na lokalnym rynku energii elektrycznej*, Rozprawa doktorska, Akademia Górniczo-Hutnicza, Kraków (2006)
- [28] Centrum Informacji o Rynku Energii, [www.cire.pl](http://www.cire.pl)