

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH W MODELOWANIU PRĘDKOŚCI WIATRU JAKO JEDNEJ Z DETERMINANT POBORU ENERGII W BUDYNKACH

Tomasz JASIŃSKI*

Politechnika Łódzka, Wydział Organizacji i Zarządzania, Instytut Nauk Społecznych i Zarządzania Technologiami, email: tomasz.jasinski@p.lodz.pl

Streszczenie: Celem pracy była analiza możliwości wykorzystania narzędzia z obszaru sztucznej inteligencji, jakim są sztuczne sieci neuronowe (ANN) w zagadnieniach związanych z prognozowaniem poboru energii elektrycznej w budynkach. W wielu opracowaniach wykazano, że głównym źródłem popytu na energię są systemy klimatyzacji oraz systemy grzewcze (HVAC). Z tego też powodu jednym z podstawowych determinant zapotrzebowania na energię są czynniki atmosferyczne, w tym prędkość wiatru. W pracy oprócz badań literaturowych przeprowadzono również badania empiryczne w obszarze przewidywania prędkości wiatru przy użyciu ANN wykorzystujących dane archiwalne pochodzące ze stacji meteorologicznej usytuowanej na lotnisku Lublinek w Łodzi. Testom zostały poddane sieci pracujące w oparciu o architekturę perceptronu wielowarstwowego (MLP), sieci realizujące regresję uogólnioną (GRNN) oraz sieci o radialnych funkcjach bazowych (RBF). Modelowanie objęło prędkości wiatru w latach 2008-2016. Dane zostały podzielone na trzy zbiory: uczący, walidacyjny i testowy. Takie podejście umożliwiło minimalizację ryzyka przeuczenia ANN. Jednocześnie użycie jedynie najnowszych informacji w charakterze danych testowych umożliwiło opracowanie modelu, który może zostać wykorzystany w praktyce biznesowej. W pracy nie ograniczono się do poszukiwania optymalnego zbioru zmiennych objaśniających jedynie wśród danych pozyskanych bezpośrednio ze stacji meteorologicznej, lecz analizie poddano także zmienne wejściowe powstałe poprzez zastosowanie narzędzi analizy technicznej.

Słowa kluczowe: sztuczne sieci neuronowe, energia elektryczna, prognozowanie, wiatr

1. WPROWADZENIE

Rozwój przemysłu, który miał miejsce w ciągu ostatniej dekady, przyniósł gwałtowny wzrost zapotrzebowania na energię, w tym na energię elektryczną. Pociągnęło to za sobą procesy mające na celu zarówno ograniczanie jej


zużycia, jak i poszukiwanie alternatywnych, szczególnie odnawialnych, jej źródeł. Co prawda w wielu krajach obserwuje się obecnie spadek zapotrzebowania na energię związany z postępującym procesem deindustrializacji wywołanym przenoszeniem produkcji do krajów o niższych cenach czynników wytwórczych, w tym przede wszystkim kosztach pracy, to jednak zmiany w jakości życia mieszkańców bogatszej części świata w znacznym stopniu podnoszą – szczególnie okresowo – zapotrzebowanie na energię elektryczną. Jest to związane przede wszystkim ze wzrostem w ostatnich latach popularności wszelkiego rodzaju urządzeń związanych z techniką chłodniczą, przede wszystkim klimatyzatorów. Brak w wielu elektrowniach chłodzenia kominowego, a zatem używanie wodnego chłodzenia powoduje w okresie letnim konieczność ograniczenia ilości generowanej przez nie energii. Jest to również widoczne na terenie Polski, gdzie przykładowo 10 sierpnia 2015 roku konieczne okazało się wprowadzenie 20 stopnia zasilania, a tym samym ograniczeń w poborze mocy przez firmy. Wydarzenia te zintensyfikowały dyskusje na temat stanu oraz perspektyw zmian krajowego systemu generowania oraz dystrybucji energii, szczególnie w kontekście inwestycji. Te z kolei są ściśle związane z modelem funkcjonowania rynku energii (więcej w [1]). Celem niniejszego opracowania jest przedstawienie możliwości modelowania poboru energii w budynkach za pomocą sztucznych sieci neuronowych (ANN – ang. Artificial Neural Networks) z uwzględnieniem modelowania takich czynników atmosferycznych jak np. prędkość wiatru. Praca przedstawia różne aspekty wykorzystania ANN wraz z metodami optymalizacji ich funkcjonowania opartymi o pozostałe narzędzia z obszaru sztucznej inteligencji (AI – ang. Artificial Intelligence), takie jak symulatory algorytmów genetycznych (GA –

* Autor korespondencyjny, e-mail: tomasz.jasinski@p.lodz.pl

ang. Genetic Algorithms), czy strategii ewolucyjnych (ES – ang. Evolutionary Strategies).

2. RAMY KOCEPTUALNE SZTUCZNYCH SIECI NEURONOWYCH

ANN stanowią próbę stworzenia sztucznych komórek nerwowych funkcjonujących w sposób analogiczny do modelu biologicznego. Definicję pojedynczej komórki nerwowej prezentuje rys. 1. Sygnały wejściowe są mnożone przez odpowiadające im wagi, a następnie tak powstałe iloczyny biorą udział w operacji sumowania. Powstałe tzw. całkowite pobudzenie neuronu jest na kolejnym etapie przekształcane za pomocą tzw. funkcji aktywacji, a następnie opuszcza komórkę nerwową stanowiąc albo odpowiedź sieci, albo sygnał wejściowy kolejnych neuronów. Wspomniane wagi są liczbami rzeczywistymi. Właśnie za ich pomocą komórka nerwowa może zyskiwać „inteligencję”. Wagi w procesie nauki sieci ulegają licznym modyfikacjom, dzięki którym odpowiedź sieci jest obciążona coraz to mniejszym błędem. Budowa pojedynczego neuronu jest powszechnie omawiana w literaturze przedmiotu, m.in. w [2] i nie będzie ona przedmiotem dalszych rozważań w niniejszym opracowaniu.



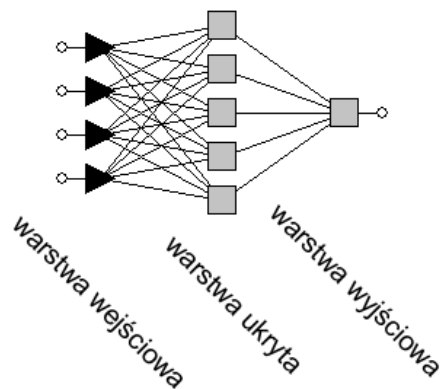
Rys. 1. Schemat budowy sztucznego neuronu [3]
Fig. 1. A scheme of an artificial neuron [3]

Komórki nerwowe mogą zostać ze sobą połączone na wiele różnych sposobów. W zależności od rodzaju tych połączeń wprowadza się podział ANN na liczne podgrupy. W opracowaniu został położony nacisk na jedno z najbardziej popularnych rodzajów ANN – tak zwane sieci jednokierunkowe wielowarstwowe, zwane również perceptronami wielowarstwowymi (MLP – ang. MultiLayer Perceptron). Budowa pozostałych rodzajów ANN jest powszechnie dostępna w literaturze przedmiotu (między innymi w [2]).

2.1. Sieć jednokierunkowa wielowarstwowa

Sieć jednokierunkowa wielowarstwowa jest zbudowana z neuronów pogrupowanych w tzw. warstwy. Jak sama nazwa wskazuje sygnały przepływają przez sieć w jednym kierunku – od wejścia do wyjścia. Pierwsza z warstw – wejściowa – służy do pobrania danych i rozprowadzenia ich wśród dalszych struktur ANN. Neurony tej warstwy nie biorą czynnego udziału w procesie uczenia. Ich wagi nie ulegają w trakcie treningu modyfikacjom. Następnie sygnały

są kierowane do komórek nerwowych zgrupowanych w pierwszej warstwie ukrytej. Neurony tej warstwy potrafią zdobywać wiedzę poprzez zachodzące w nich zmiany wartości wag sprzężonych z wejściami tych komórek. MLP mogą być wyposażone w więcej niż jedną warstwę ukrytą. W praktyce ich ilość najczęściej nie przekracza dwóch, a w wyjątkowych sytuacjach trzech. Za warstwami ukrytymi znajduje się ostatnia, pojedyncza warstwa wyjściowa. Jej neurony także biorą aktywny udział w procesie zdobywania wiedzy.



Rys. 2. Przykład sieci jednokierunkowej wielowarstwowej
Fig. 2. An example of multilayer perceptron

Rys. 2 prezentuje przykładowy MLP o czterech neuronach w warstwie wejściowej, pięciu w pojedynczej warstwie ukrytej oraz pojedynczym neuronie w warstwie wyjściowej. Sygnały wejściowe sieci stanowią zmienne objaśniające. Dane pojawiające się na wyjściach ANN to zmienne objaśniane.

3. MODELOWANIE POBORU ENERGII W BUDYNKACH

Możliwości praktycznego użycia ANN w celu modelowania zagadnień związanych z poborem energii w budynkach są, jak wskazuje literatura przedmiotu, niezwykle szerokie.

3.1. Prognozowanie zapotrzebowania na energię

Zapotrzebowanie na energię w budynkach powiązane jest z wieloma czynnikami. Jednym z głównym jest pobór prądu przez systemy klimatyzacji oraz systemy grzewcze (HVAC – ang. Heating, Ventilation and Air Conditioning). Nie należy jednak zapominać o poborze energii w pozostałych celach, np. oświetleniowych. Wśród czynników mających istotny wpływ na pobór energii wskazuje się w literaturze przedmiotu czynniki pogodowe (przede wszystkim temperaturę, wiatr oraz wilgotność powietrza), konstrukcję budynku (więcej na ten temat można odnaleźć w [4]) oraz jego kształt, liczbę mieszkańców i ich zwyczaje, stopień wykorzystania urządzeń klasy RTV-AGD, a także ich klasę

energetyczną.[5][6][7] W literaturze przedmiotu można odnaleźć badania, w których prognozy są dokonywane w rozbiu na poszczególne rodzaje popytu. Więcej na temat popytu na energię cieplną znajduje się między innymi w [8]. R. Mena et al. dokonali prognozy zapotrzebowania na energię dla budynku znajdującego się w kampusie Uniwersytetu Almeria w Hiszpanii. Badania obejmowały dwa horyzonty prognozy – jeden o wielkości pojedynczej próbki, drugi na sześćdziesiąt próbek do przodu (dane stanowiły szeregi czasowe o interwale jednej minuty). [5] W obu przypadkach prognozowanie miało zatem charakter krótkoterminowy. Oznacza to konieczność użycia danych wejściowych modelu dostosowanych do krótkiego horyzontu predykcji. Więcej na temat ich doboru odnaleźć można w: [9].

Również badania autorstwa R. Kumar et al. potwierdzają możliwość prognozy zapotrzebowania na energię z godzinowym wyprzedzeniem. Autorzy zastosowali podobnie jak w [8] między innymi dane pogodowe, uzupełniając je informacjami o parametrach technicznych nieruchomości, takich jak np. powierzchnia pomieszczeń. [10]

3.2. Modelowanie solarnych systemów chłodniczo-grzewczych

Zyskującymi w ostatnim czasie na popularności są systemy klimatyzacji funkcjonujące w oparciu o energię słoneczną. Ich niezaprzeczalną zaletą jest pokrywanie się szczytowego zapotrzebowania na energię z największą jej dostępnością. Badania autorstwa S. Rosiek i F.J. Batlles [11] potwierdziły możliwość precyzyjnego określenia wydajności systemów solarnego zasilania urządzeń klimatyzacyjnych i grzewczych za pomocą ANN. Autorzy za cel postawili sobie stworzenie modelu prognostycznego bazującego na możliwie niewielkiej liczbie zmiennych wejściowych. Jako zmienne wyjściowe zostały zastosowane m.in. następujące szeregi czasowe: (i) współczynnik wydajności zdefiniowany jako iloraz ciepła pobranego przez parownik do ciepła dostarczonego przez generator, (ii) wydajność systemu obliczona jako iloraz zdolności chłodzenia i użytecznej energii kolektorów.

4. PROGNOZOWANIE CZYNNIKÓW ATMOSFERYCZNYCH

Jak zostało to omówione w rozdziale 3.1 jednymi z głównych czynników określających zapotrzebowanie na energię są temperatura oraz wiatr. Również i one stają się przedmiotem modelowania za pomocą ANN.

4.1. Modelowanie prędkości wiatru

Przewidywaniu prędkości wiatru jest poświęcona między innymi praca [12], w której autorzy za pomocą ANN

dokonali godzinowej prognozy jego średniej prędkości. Użyty model jako zmienne objaśniające wykorzystywał czternaście opóźnionych wartości prędkości wiatru. Uzyskany w badaniu błąd średniokwadratowy wyniósł dla zbioru testowego 1.341 m/s (z oczywistych względów był on zauważalnie mniejszy w przypadku zbioru uczącego, dla którego jego wartość wyniosła 1.288 m/s). Zastosowana ANN miała budowę MLP o trzech warstwach. Testom poddano ANN zawierające 5, 10, 15, 20, 30 oraz 50 neuronów w pojedynczej warstwie ukrytej. Najlepsza okazała się być ANN o 15 omawianych komórkach nerwowych uczona w czasie 2000 epok (jedna epoka to prezentacja ANN wszystkich danych z danego zbioru – w tym przypadku uczącego). [12]

Przykładem udanego modelowania siły wiatru o charakterze średnioterminowym jest praca S. Kalogirou et al. [13] Horyzont predykcji wyniósł jeden miesiąc. Taka też była częstotliwość użytych szeregów czasowych. Badania objęły dane pochodzące ze stacji pomiarowych umieszczonych na wysokości 2 oraz 7 m. Maksymalne rozbieżności między wartościami rzeczywistymi a prognozowanymi nie przekraczały 1.8%. Na podkreślenie zasługuje fakt, że autorzy użyli co prawda MLP o jednej warstwie ukrytej, to jednak nie miała ona typowej budowy. Składała się bowiem z trzech osobnych sekcji komórek nerwowych, z których każda sekcja pracowała wykorzystując inne funkcje aktywacji (były to odpowiednio: funkcja Gaussa, dopełnienie funkcji Gaussa, tangens hiperboliczny). [13] Pewną wadą badań jest niewykorzystanie przez autorów tzw. zbioru walidacyjnego (tą nazwą w omawianym opracowaniu jest określany zbiór testowy spełniający inne zadanie). Jego użycie pozwoliłoby wyeliminować ryzyko przeuczenia się ANN w wyniku zbyt długotrwałego treningu.

Prognozowanie przy użyciu ANN w oparciu o informacje z wielu stacji pogodowych zostało zaprezentowane w pracy M. Bilgili et al. [14] Autorzy wykorzystując dane godzinowe z ośmiu stacji pomiarowych obliczyli dla każdej z nich średnie miesięczne wartości prędkości wiatru. Wszystkie stacje dokonywały pomiarów na tej samej wysokości – 10 m. Kolejnym krokiem było wyznaczenie współczynników korelacji między danymi z poszczególnych stacji. Ich wartość jest związana bezpośrednio z morfologią terenu między stacjami oraz w ich okolicy. Jako zmienne objaśniające modelu wybrano informacje o sile wiatru pochodzącej ze stacji o wysokich wartościach współczynników korelacji ze stacją modelowaną. W zależności od jej wyboru ilość stacji dostarczających zmienne wejściowe wahała się od dwóch do pięciu. Dodatkowo zbiór zmiennych objaśniających został rozszerzony o informację o numerze miesiąca, w którym zostały odczytane wartości prędkości wiatru. Zastosowana została sieć typu MLP o dwóch warstwach ukrytych. Ilość użytych w nich komórek nerwowych oscylowała w przedziałach od 6 do 12 oraz od 3 do 6 odpowiednio dla pierwszej i drugiej warstwy ukrytej.

Neurony zostały zbudowane na bazie logistycznej oraz liniowej funkcji aktywacji. Poprawność modelu została oszacowana za pomocą średniego bezwzględnego błędu procentowego, którego wartość wyniosła 4.49% dla najlepszego przypadku oraz 14.13% dla najgorszego. Należy zauważyć, że o ile otrzymane wyniki są wysoce zadowalające, to jednak podobnie jak w [13] autorzy nie zastosowali w procesie treningu sieci zbioru walidacyjnego, co mogło skutkować albo przeuczeniem ANN albo spowodowanym chęcią jego uniknięcia zbyt krótkim treningiem. Obie sytuacje oznaczają iż potencjał ANN mógł nie zostać w pełni wykorzystany.


W przypadku korzystania z funkcjonujących już stacji pomiaru prędkości wiatru pewnym problemem może okazać się wysokość, na której usytuowane są czujniki pomiarowe. W oczywisty sposób powinna ona korespondować z wysokością budynku, a tym samym jego ekspozycją na czynnik wiatru. W przypadku niskich budynków zazwyczaj nie stanowi to istotnego problemu, jednak w przypadku budownictwa wysokościowego pomiar dokonywany na wysokości kilku metrów może nie być reprezentatywny. Instalowanie stacji pomiaru na większej wysokości byłoby rozwiązaniem optymalnym. Jeśli jednak takie jej umiejscowienie nie jest uzasadnione ze względów ekonomicznych sugeruje się dokonanie kilku pomiarów na niższych wysokościach i stworzenie profilu pionowego wiatru. [15]

4.2. Przewidywanie temperatury powietrza

Jak wskazują badania ANN sprawdzają się w roli systemu predykcyjnego wartości temperatury. W badaniach opisanych w [16] autorzy zaprezentowali model MLP używający w roli zmiennych objaśniających szeregi czasowe z roku 2009 w postaci: (i) temperatury powietrza, (ii) punktu rosy, (iii) wilgotności, (iv) ciśnienia na poziomie morza, (v) widoczności, (vi) prędkości wiatru, (vii) prędkości wiatru w porywach, (viii) wielkości opadów. Wyniki badań nie tylko potwierdziły możliwość dokonania skutecznej prognozy wartości temperatury powietrza, lecz również wykazały że jej jakość jest porównywalna, a często nawet wyższa niż w przypadku tradycyjnych prognoz. Ten sam rodzaj ANN został użyty w badaniach Kumar Abhishek et al. [17] Dodatkowo autorzy użyli około 20% losowo pobranych danych celem stworzenia tak zwanego zbioru walidacyjnego, którego użycie zapobiega sytuacji przeuczenia się ANN (więcej na temat zasad podziału danych na zbiory: uczący, walidacyjny i testowy można odnaleźć między innymi w [18]). Analogiczne podejście (25% danych tworzyło zbiór walidacyjny) zostało zaprezentowane w [19]. Autorzy stworzyli precyzyjny model prognostyczny funkcjonujący na podstawie danych godzinowych. Podobnie jak w poprzednio przywołanych opracowaniach została użyta architektura MLP.

5. EMPIRYCZNE MODELOWANIE PRĘDKOŚCI WIATRU NA PRZYKŁADZIE DANYCH ZE STACJI METEOROLOGICZNEJ LOTNISKA LUBLINEK W ŁODZI

Celem badania empirycznego było stworzenie modelu ANN prognozującego prędkość wiatru z półgodzinnym wyprzedzeniem. Dane meteorologiczne pochodziły ze stacji pomiarowej zlokalizowanej na terenie lotniska Lublinek w Łodzi i obejmowały zakres czasowy od 1 stycznia 2008 roku do 11 sierpnia 2016 roku (interwał 30 minutowy). Podczas symulacji wykorzystano między innymi zmienne wejściowe powstałe poprzez wykorzystanie narzędzi zaadaptowanych z analizy technicznej. Wiązało się to z koniecznością użycia opóźnionych wartości zmiennych wejściowych. Niezbędnym było zatem zredukowanie ilości danych wprowadzanych do symulatora o 48 próbek wymaganych do stworzenia wspomnianych zmiennych objaśniających. Powstałe dane zostały podzielone na trzy zbiory – uczący (70%), walidacyjny (15%) oraz testowy (15%). Dobór zmiennych wejściowych modeli w wysokim stopniu przeprowadzony został w sposób doświadczalny w oparciu zarówno o badania literaturowe jak i 20-letnie doświadczenie autora w budowie i optymalizacji ANN.




Rys. 3. Histogram błędu procentowego dla prognozy danych ze zbioru testowego – model nr 1 (MLP 10-11-1)

Fig. 3. Percentage error histogram of the prediction for data from the test set – the model no. 1 (MLP 10-11-1)

Rys. 3 przedstawia histogram błędu procentowego prognozy prędkości wiatru o horyzoncie 30 minut dokonanej dla danych ze zbioru testowego przez MLP o architekturze 10-11-1 (liczba neuronów kolejno w warstwach: wejściowej, ukrytej, wyjściowej). Neurony warstwy ukrytej zostały zbudowane przy użyciu funkcji aktywacji w postaci tangensa hiperbolicznego. Pojedynczy neuron wyjściowy wyposażony był w funkcję wykładniczą. Jako zmiennych objaśniających użyto sześciu opóźnionych wartości szeregu czasowego (o interwale 30 minut) zawierającego prędkość

wiatru, wartości opóźnionej o 30 minut temperatury powietrza, kierunku wiatru (sprzed 30 minut) reprezentowanego jako liczby od 1 do 16 (17 w przypadku wiatru zmiennego oraz 0 przy jego braku), numeru dnia roku oraz wartości liczbowej (zmiennoprzecinkowej) reprezentującej godzinę i minutę (0 – godzina 0:00, 1 – godzina 24:00). Uzyskane wyniki wskazują, że zdecydowanie najbardziej liczny jest przedział błędu prognozy od -5% do 0%. Na kolejnych miejscach znajdują się kolejno przedziały błędu od 0% do 5% oraz od -10% do -5%. Można zatem przyjąć, że błąd związany ze znaczną liczbą prognoz mieści się w przedziale od -10% do 5%, co w przypadku średniej wartości wiatru wynoszącej dla zbioru testowego 3.13 m/s oznacza niedokładność w przedziale od -0.31 m/s do 0.16 m/s. Niestety w przypadku znacznej ilości prognoz błąd dochodzi do wartości +/- 25%, a to oznacza już niedokładność prognozy sięgającą nawet 0.78 m/s.



Rys. 4. Histogram błędu procentowego dla prognozy danych ze zbioru testowego – model nr 2 (MLP 10-11-1)


Fig. 4. Percentage error histogram of the prediction for data from the test set – the model no. 2 (MLP 10-11-1)

Dalszą optymalizację modelu udało się osiągnąć poprzez modyfikację zbioru zmiennych objaśniających. Oprócz – tak jak poprzednio – sześciu opóźnionych wartości prędkości wiatru oraz wartości liczbowej reprezentującej godzinę i minutę zastosowano zmianę ciśnienia między 30, a 60 minutami przed prognozowaną chwilą, średnią wartość prędkości wiatru w ciągu 24 godzin poprzedzających moment prognozy oraz średnią prędkość wiatru w ciągu ostatnich 3 godzin. Nowe zbiory danych wejściowych podobnie jak w poprzednio opisanym modelu zawierały dziesięć zmiennych. Uzyskany rozkład błędu procentowego przedstawia rys. 4.

W stosunku do poprzedniego modelu zmniejszeniu uległa liczba prognoz obarczonych błędem większym niż 25%. Szczególnie jest to widoczne w przypadku niedoszacowania przez ANN rzeczywistej prędkości wiatru. Liczba prognoz o najwyższej precyzji pozostała na zbliżonym poziomie.

W badaniach testom poddano liczne zbiory zmiennych wejściowych bazujące na innych, niż opisane, wskaźnikach wywodzących się z analizy technicznej. W szczególności użyte zostały oscylatory mające za zadanie określenie tempa zmian zmiennych wejściowych. Nie spowodowały one jednak podwyższenia jakości predykcji.

Wszystkie testowane modele ujawniły problem z przewidywaniem wiatru o wysokich wartościach, zdecydowanie wykraczających poza średnie. Na rys. 5 zaprezentowano wykres rozrzutu dla drugiego z opisanych modeli. Widoczne są dwa punkty reprezentujące wiatr o prędkości powyżej 35 m/s. Sytuacje te nie zostały prawidłowo przewidziane przez ANN. Przedstawione modele sieci funkcjonują poprawnie przy typowych warunkach wiatrowych, natomiast sytuacje ekstremalne nie są prognozowane z oczekiwaną precyzją (co szczególnie widoczne jest na rys. 5 – dwa punkty w prawym, dolnym rogu nieposiadające swoich „odpowiedników” w lewym, górnym rogu wykresu). Może to wynikać z wielu powodów, lecz przede wszystkim należy zwrócić uwagę że w zbiorze danych uczących tak ekstremalne wartości prędkości wiatru występują sporadycznie, a co za tym idzie nie istnieje wystarczająca liczba wzorców umożliwiająca poprawę naukę ANN w tym zakresie. Problem zatem wydaje się wynikać nie z wysokiej prędkości wiatru, co z rzadkości tego zjawiska.



Rys. 5. Wykres rozrzutu – model nr 2 (MLP 10-11-1)

Fig. 5. Scatter diagram – the model no. 2 (MLP 10-11-1)

6. WNIOSKI

Przeprowadzone badania, zarówno o charakterze literaturowym, jak i empirycznym, potwierdziły możliwość dokonania prognozy prędkości wiatru za pomocą ANN z wysoką precyzją. Jak wykazały symulacje przeprowadzone przez autora na podstawie danych meteorologicznych pochodzących ze stacji pomiarowej zlokalizowanej na terenie lotniska Lublinek w Łodzi wykorzystanie wybranych wskaźników pochodzących z analizy technicznej (której pierwotnym celem jest analizowanie zmian cen na rynkach

finansowych) przyczynia się do poprawy jakości prognoz. W szczególności przydatne okazały się być proste średnie ruchome. Jednocześnie zostały potwierdzone omawiane w literaturze przedmiotu problemy z przewidywaniem skrajnych wartości prędkości wiatru. Przy prędkościach przekraczających 35 m/s prognozy posiadały nieakceptowalny poziom precyzji.

ANN stanowią także precyzyjne narzędzie przewidujące zapotrzebowania na energię w budynkach. Jako źródło danych mogą zostać użyte prognozy meteorologiczne uzyskane za pomocą ANN. Kompleksowy system modelujący pobór energii elektrycznej w budynkach może być zbudowany z kilku współpracujących ze sobą sieci. Zarówno badania własne autora, jak i analiza literatury przedmiotu potwierdziły potencjał tkwiący w sieciach o architekturze MLP. Uzyskane przez nie wyniki były nieznacznie lepsze niż w przypadku sieci typu RBF oraz GRNN. Dalszej optymalizacji prognoz należy poszukiwać w obszarze modyfikacji zbioru zmiennych objaśniających, szczególnie poprzez zastosowanie kolejnych zmiennych wskaźnikowych.

APPLICATION OF NEURAL NETWORKS IN MODELING WIND SPEED AS A DETERMINANT OF ENERGY CONSUMPTION IN BUILDINGS

Summary: The paper presents possibilities to use ANN as a model predicting both – demand for energy in buildings and meteorological parameters affecting that demand such as wind speed. Empirical studies included wind speed forecasts using weather data from a meteorological station located at Lublinek Airport in Lodz. Numerous ANN types such as MLP, RBF and GRNN were tested during simulations.

Literatura

- [1] Jasiński T. *Niezawodność oraz metody jej zwiększania w różnych modelach rynku* [w:] A.T. Szablewski, M. Martin (red.) Ekonomiczne, regulacyjne, strukturalne i technologiczne uwarunkowania bezpieczeństwa energetycznego. Monografie Politechniki Łódzkiej, Łódź 2011, 199-219
- [2] Jasiński T. *Przegląd architektur sztucznych sieci neuronowych wykorzystywanych w ekonomii do przewidywania szeregów czasowych*, Studia i prace Kolegium Zarządzania i Finansów, SGH, zeszyt naukowy 35 (2003) 166-177
- [3] Jasiński T., Ścianowska A. *Security Assessment and Optimization of Energy Supply*, Oeconomia Copernicana, vol. 6, issue 2 (2015) 129-141
- [4] Aydinalp M., Ugursal V.I., Fung A.S. *Modeling of the space and domestic hot water heating energy consumption in the residential sector using neural networks*, Applied Energy, nr 79 (2004) 159-178
- [5] Mena R., Rodríguez F., Castilla M., Arahal M.R. *A prediction model based on neural networks for the energy consumption of a bioclimatic building*, Energy and Buildings 82 (2014) 142-155
- [6] Eriksson N. *Predicting demand in district heating systems. A neural network approach*, School of Engineering and Department of Physics and Astronomy, Uppsala University, Uppsala, Sweden, UPTec F12015 (2015)
- [7] Geletka V., Sedlakova A. *Impact of Shape Of Buildings on Energy Consumption*, Czasopismo Techniczne Budownictwo, zeszyt 3, r. 109 (2012) 123-129
- [8] Jasiński T. *Prognozowanie zapotrzebowania na energię ciepłą przy użyciu sztucznych sieci neuronowych* [w:] A.T. Szablewski (red.) Rynkowe i technologiczne oraz regulacyjne uwarunkowania rozwoju krajowego sektora ciepłowniczego. Dom Wydawniczy ELIPSA, Warszawa 2016, 196-203
- [9] Jasiński T. *Dane wejściowe sztucznych sieci neuronowych prognozujących krótkoterminowe zapotrzebowanie na energię*, Logistyka, nr 6 (2014)
- [10] Kumar R., Aggarwal R.K., Sharma J.D. *Estimation of Total Energy Load of Building Using Artificial Neural Network*, Energy and Environmental Engineering 1(2) (2013) 25-35
- [11] Rosiek S., Battles F.J. *Modelling a solar-assisted air-conditioning system installed in CIESOL building using an artificial neural network*, Renewable Energy 35 (2010) 2894-2901
- [12] Fonte P.M., Silva G.X., Quadrado J.C. *Wind Speed Prediction using Artificial Neural Networks*, Proceedings of the 6th WSEAS Int. Conf. on Neural Networks, Lisbon, Portugal, June 16-18 (2005) 134-139
- [13] Kalogirou S.A., Neocleous C., Paschiardis S., Schizas C. *Wind Speed Prediction Using Artificial Neural Networks*, Proceedings of the European Symposium on Intelligent Techniques ESIT'99 na CD-ROM, Crete, Greece (1999)
- [14] Bilgili M., Sahin B., Yasar A. *Application of artificial neural networks for the wind speed prediction of target station using reference stations data*, Renewable Energy 32 (2007) 2350-2360
- [15] Jąderko A., Kowalewski M.K. *Wyznaczanie parametrów wiatru w energetyce odnawialnej*, Przegląd Elektrotechniczny, r. 91, nr 1 (2015) 148-151
- [16] Santhosh Baboo S., Kadar Shereef I. *An Efficient Weather Forecasting System using Artificial Neural Network*, International Journal of Environmental Science and Development, Vol. 1, nr 4, October (2010) 321-326
- [17] Kumar Abhishek, Singh M.P., Saswata Ghosh, Abhishek Anand *Weather forecasting model using Artificial Neural Network*, Procedia Technology 4 (2012) 311-318
- [18] Leszczyński Z., Jasiński T. *Inżynieria kosztów*, ODDK, Gdańsk (2015)
- [19] Kadu P.P., Wagh K.P., Chatur P.N. *Temperature Prediction System Using Back propagation Neural Network: An Approach*, International Journal of Computer Science & Communication Networks, Vol 2(1) (2012) 61-64