

Analiza zastosowań sztucznych sieci neuronowych do krótkoterminowego prognozowania mocy oraz produkcji energii elektrycznej w systemach fotowoltaicznych

Streszczenie. W tekście przedstawiono przegląd metod prognozowania krótkoterminowego generacji mocy oraz produkcji energii elektrycznej przez system fotowoltaiczny z zastosowaniem sztucznych sieci neuronowych. Przedstawiono zbiorczy zestaw potencjalnych zmiennych objaśniających do modeli prognostycznych. Wykonano przykładowe prognozy oraz sformułowano wnioski końcowe.

Abstract. The paper presents the comprehensive review of short-term power and electric energy forecasting methods of photovoltaic systems using artificial neural networks. The collective set of potential explaining variables for predictive models have been showed. Examples of predictions have been executed and the final conclusions have been presented. (The analysis of artificial neural networks applications for short-term power output and electric energy production forecasting of photovoltaic systems)

Słowa kluczowe: prognozowanie krótkoterminowe mocy, system fotowoltaiczny, dobór zmiennych, sztuczne sieci neuronowe.

Keywords: short-term power forecasting, photovoltaic system, variables selection, artificial neural networks.

Wstęp

W przypadku prognozowania mocy w systemach fotowoltaicznych stosowane są trzy kategorie metod [1]: metody statystyczne, metody fizyczne oraz metody wykorzystujące sztuczną inteligencję (najczęściej sztuczne sieci neuronowe). Artykuł prezentuje przegląd wyników badań prognostycznych wykorzystujących różne typy sieci neuronowych oraz sugestie odnośnie wyboru zmiennych objaśniających.

Prognozy krótkoterminowe (typowo horyzont od 5 minut do 7 dni) wykorzystywane są w elektroenergetyce do procesów bieżącego sterowania oraz planowania pracy prognozowanego systemu. W przypadku prognozowania zapotrzebowania na energię elektryczną i ciepło oraz prognozowania mocy i produkcji energii w mikroźródłach opartych na nośnikach odnawialnych (OZE) na potrzeby mikrosieci, wysoka jakość prognoz krótkoterminowych ma duże znaczenie dla zapewnienia właściwej pracy mikrosieci, a dokładnie jak najbardziej skutecznego sterowania mikrosiecią. W procesie sterowania pracą mikrosieci ważną rolę odgrywają: centralny sterownik mikrosieci oraz sterowniki lokalne [2]. Do sterowników lokalnych należą: sterowniki mikroźródeł, sterowniki zasobników energii oraz sterowniki odbiorów. Generalnie wyróżnia się dwie strategie sterowania pracą mikrosieci: sterowanie scentralizowane oraz sterowanie rozproszone. Mikrosieć zawierająca mikroźródła, zasobniki energii oraz odbiory sterowalne wymaga przyjęcia odpowiedniej strategii zarządzania mocą (SZM) i strategii zarządzania energią (SZE). Do modułu zarządzania mocą (energiją) w czasie rzeczywistym podawane są informacje o zapotrzebowaniu odbiorców na energię elektryczną i ciepło (prognozy, dane bieżące), generacji energii w mikroźródłach opartych na nośnikach odnawialnych (OZE) (prognozy, dane bieżące) oraz cenach energii elektrycznej w poszczególnych przedziałach czasowych doby. Te informacje służą do efektywnego sterowania m.in.: importem/eksportem mocy z/do spółki dystrybucyjnej, wytwarzaniem energii przez źródła dysponowane oraz poborem mocy odbiorów sterowalnych. Najczęściej zadanie optymalizacji pracy mikrosieci jest rozpatrywane jako problem optymalizacji jednokryterialnej o charakterze ekonomicznym (minimalizacja kosztów związanych z dostawą energii elektrycznej do odbiorców, maksymalizacja przychodów uzyskiwanych ze sprzedaży energii elektrycznej). W przypadku optymalizacji wielokryterialnej celem może być

minimalizacja kosztów dostawy energii elektrycznej do odbiorców oraz maksymalizacja stopnia wykorzystania odnawialnych źródeł energii. Funkcja celu zadania optymalizacyjnego ma wiele zmiennych i należą do nich również prognozy - wartości przewidywanego zapotrzebowania na moc w węzłach odbiorowych oraz mocy generowanych w mikroźródłach opartych na odnawialnych nośnikach energii. Do rozwiązania zadania optymalizacyjnego (np. algorytm ewolucyjny) można w pierwszym kroku wykorzystać prognozy daną metodą zapotrzebowania na moc oraz generacji mocy uzyskując wartość koszt pokrycia zapotrzebowania na moc w mikrosieci. Następnie w kroku drugim można w funkcji celu zastąpić (bez ponownego rozwiązywania zadania optymalizacyjnego) wartości prognoz wartościami rzeczywistymi (realizacjami) i uzyskać nową (inną) wartość kosztu pokrycia zapotrzebowania na moc w mikrosieci. Można dzięki temu sprawdzić o ile zmieni się koszt pokrycia zapotrzebowania na moc w mikrosieci gdy do funkcji celu zamiast prognoz wykorzysta się ich realizacje. Taką samą dwukrokową procedurę można wykonać dla innej metody prognostycznej. Dzięki temu możliwe byłoby porównanie dwóch metod prognostycznych, a dokładnie zysku z wykorzystania metody prognozowania lepszej (kryterium np. błąd MAPE prognoz) w stosunku do gorszej. Szczegółowo zastosowania prognoz zapotrzebowania na energię i moc oraz produkcję energii w mikroźródłach (OZE) do celów sterowania w mikrosieciach zostały opisane w [2].

Sztuczne sieci neuronowe do prognozowania mocy w systemach fotowoltaicznych

Sieci neuronowe są bardzo popularnym narzędziem prognostycznym we wszelkiego typu prognozach krótkoterminowych w elektroenergetyce [3,4,5,6]. Wykorzystanie sztucznych sieci neuronowych do prognozowania generacji mocy w systemach fotowoltaicznych jest również bardzo popularne. Być może jest to nawet najczęściej stosowane narzędzie prognostyczne w tym zadaniu. Stosowane są różne typy sieci neuronowych, także w połączeniu z logiką rozmytą. Bardzo często implementowany jest w sieci neuronowej nieliniowy model statystyczny NARX (Nonlinear Autoregressive Exogenous Model) [7]. Model wykorzystuje zarówno zmienne opóźnione endogeniczne (szereg czasowy produkcji mocy) jak i dodatkowe zmienne

egzogeniczne opóźnione oraz ich wartości z okresu prognozy (zmienne egzogeniczne to najczęściej zmienne wybrane z danych mających wysoką korelację z mocą prognozowaną) [8]. Model NARX opisać można równaniem (1):

$$(1) P_t = F(P_{t-1}, P_{t-2}, P_{t-3}, \dots, u_t, u_{t-1}, u_{t-2}, u_{t-3}, \dots) + \varepsilon_t$$

gdzie: ε_t - składnik losowy w okresie t , P_t - wartość mocy w okresie t , u_t - wartość zmiennej egzogenicznej w okresie t , F - funkcja nieliniowa np. sztuczna sieć neuronowa

Najwięcej badań dotyczących prognozowania krótkoterminowego generacji mocy w systemach fotowoltaicznych wykorzystuje sieć neuronowa typu MLP (Multilayer Perceptron) [1,9,10]. Ponadto wykorzystuje się m.in.: sieci neuronowe typu SVM (Support Vector Machine) [11], sieci neuronowe rekurencyjne RNNs (Recurrent Neural Networks) np. sieć Elmana [10], sieci neuronowe typu RBF (Radial Base Function) [10], sieci neuronowe dynamiczne typu FTDNN (Focused Time Delay NN) [12] oraz sieci neuronowe dynamiczne typu DTDNN [12].

W opracowaniu [7] wykorzystano sieć neuronową typu MLP do prognoz o horyzoncie 24 godziny (15-minutowe wartości). Danymi wejściowymi do prognozy mocy były wartości historyczne poziomu nasłonecznienia oraz godziny prognoz. Model nie wykorzystywał prognoz NWP. Sieć neuronowa stanowiła funkcję F modelu NARX. Do uczenia sieci neuronowej wykorzystano algorytm Levenberga-Marquardta (LM). Jako funkcję aktywacji w warstwie ukrytej wykorzystano tangh, natomiast w warstwie wyjściowej zastosowano funkcję liniową. Sieć neuronowa miała jedno wyjście. Prognozy na kolejne godziny wykonywane były metodą krokową. Przykładowo prognozy na okresy $t+1$, $t+2$, $t+3$ (optymalne opóźnienie szeregu czasowego wynosiło 3 - testowano do 10) stanowiły dane wejściowe dla prognozy na okres $t+4$. W ten sposób generowano prognozy do horyzontu 24 godzin. Badania wykonane na terenie Włoch wykazały dużą sezonowość wielkości błędów prognoz (najmniejsze błędy wystąpiły w maju a największe błędy w sierpniu). Średni błąd procentowy nie przekraczał 5%.

Porównanie modelu fizycznego oraz modelu sieci neuronowej przedstawiono w [1]. Model fizyczny wykorzystujący konwersję poziomu nasłonecznienia (prognoza z modelu NWP) do wartości mocy prognozowanej uzyskał błąd nRMSE% od 11% do 17% w zależności od miesiąca. Im bardziej niebo było bezchmurne tym jakość prognoz była wyższa. Jakość prognoz mocy była silnie uzależniona od jakości prognoz z NWP. Stwierdzono, że błąd prognoz jest znacząco wyższy (około dwukrotnie) w przypadku wykorzystania w modelu fizycznym danych z prognoz (nasłonecznienie) zamiast danych rzeczywistych. Wskazuje to na dużą rolę precyzyjnych prognoz nasłonecznienia dla tej metody prognozowania mocy. Wpływ temperatury w modelu fizycznym był pomijalny. W przypadku wykorzystania sieci neuronowej typu MLP błędy nRMSE% były niższe (około 10,5%). Wynikało to wg autorów opracowania z możliwości auto-adaptacji sieci neuronowej (proces nauki na danych treningowych z przeszłości). Autorzy zwracają uwagę na bardzo wysoką korelację pomiędzy poziomem nasłonecznienia oraz mocą. Ponadto uważają, że trudno jest zbudować model wielosezonowy – łatwiej podzielić zadanie na kilka modeli osobnych np. dla każdej z pór roku.

W opracowaniu [13] wykorzystano sieć neuronową typu MLP stanowiącą funkcję F modelu NARX do prognoz o horyzoncie do 12 godzin. Wykorzystano algorytm uczący

Levenberga-Marquardta. Dane wejściowe sieci neuronowej stanowiły: 12 wartości nasłonecznienia (wynik prognozy modelu fizycznego obliczającego nasłonecznienie dla bezchmurnego nieba), prognoza najniższej oraz najwyższej temperatury na dzień prognozy, wskaźnika typu dnia określony na podstawie prognozy pogody na dzień prognozy (rodzaj pogody: wartość 0,9 oznacza bezchmurne niebo, 0,7 oznacza częściowe zachmurzenie, 0,3 oznacza pochmurno lub/i mgliście, 0,1 oznacza deszczowo, śnieżnie). Sieć neuronowa stanowiąca funkcję F modelu NARX uzyskała błąd MAPE 16,47%, w porównaniu do błędu 30,72% dla sieci neuronowej typu MLP nie wykorzystującej danych z prognoz NWP.

Połączenie sieci neuronowej z wnioskowaniem rozmytym zaproponowano w opracowaniu [14]. Prognozy mocy dotyczyły wartości dobowych. Wykorzystano sieć neuronową typu MLP z algorytmem uczenia propagacji wstecznej błędu. Optymalna sieć neuronowa miała 2 warstwy ukryte. Liczba wejść była równa 16. Stanowiły je trzy pakiety danych tego samego rodzaju dla rana (godz. 6.00), południa (godz.12.00) oraz wieczoru (godz.18.00). Były to następujące dane: kod dnia roku (liczba z zakresu 1 do 366), nasłonecznienie, temperatura powietrza, szybkość wiatru, wilgotność powietrza oraz ciśnienie atmosferyczne. Dana wejściowa – nasłonecznienie obliczana była z wykorzystaniem preprocesingu z wykorzystaniem logiki rozmytej. Nasłonecznienie było obliczane na podstawie indeksu UV, indeksu zachmurzenia oraz godziny.

Dynamiczne sieci neuronowe typu FTDNN oraz DTDNN zostały wykorzystane do prognoz wartości 10 minutowych mocy w systemie fotowoltaicznym z horyzontem do 1 godziny [12]. Prognozy wykonywane były metodą krokową wykorzystując tylko dane historyczne o wielkości mocy. Dla obu sieci neuronowych wykorzystano algorytm uczący Levenberga-Marquardta. Nieco lepsze wyniki uzyskano siecią neuronową typu FTDNN.

W opracowaniu [10] problem prognoz mocy z horyzontem 24 godziny podzielono na 12 osobnych zadań prognostycznych (dla każdego miesiąca osobny model). Sieć neuronowa na wejściu wykorzystywała tylko dane meteorologiczne (prognoza nasłonecznienia oraz prognoza temperatury). Testowano sieć neuronową typu MLP, sieć neuronową typu RBF oraz sieć neuronową rekurencyjną typu Elmana. W zależności od miesiąca prognozy najlepsze wyniki uzyskiwały różne sieci neuronowe. Autorzy w podsumowaniu stwierdzili jednak nieznacznie słabsze wyniki sieci neuronowej typu MLP. Ponadto wykazali, że możliwe jest prognozowanie mocy systemu fotowoltaicznego wykorzystując jako zmienne tylko objaśniające dane meteorologiczne.

Wykorzystanie sieci typu SVM opisano w [11]. W fazie wstępnej dokonywano klasyfikacji warunków pogodowych w dniu prognozy, a następnie wykorzystując sieć typu SVM wykonywano prognozy mocy dla systemu fotowoltaicznego z horyzontem 24 godzin dla okresów 15-minutowych. Danymi wejściowymi były prognozy meteorologiczne oraz dane historyczne mocy. Na podstawie danych historycznych dokonywano klasyfikacji pogody na dzień prognozy (słonecznie, mgliście, deszczowo, pochmurno). Metoda prognostyczna zawierała 4 osobne modele sieci typu SVM dla każdej z kategorii pogody. Na podstawie danych historycznych oraz danych meteorologicznych następował wybór jednego z 4 modeli, który prognozował następnie moc systemu fotowoltaicznego. Dane wejściowe stanowiły: prognoza mocy oszacowana dla danej kategorii dnia (uzyskana z analizy danych historycznych), minimalna, średnia oraz maksymalna temperatura w dniu prognozy uzyskana z prognozy NWP. Najmniejsze błędy RMSE (czego można było się spodziewać) uzyskał model dla dni

typu „słonecznie” – 1,57%. Natomiast największe błędy RMSE generował model dla dni typu „mgliście” – 2,52%. Łącznie dla 4 modeli błęd RMSE% był równy 2,10%.

Sieć neuronowa typu RBF do prognoz poziomu nasłonecznienia z horyzontem do 24 godzin opisano w [15]. Na podstawie prognoz meteorologicznych sieć neuronowa generowała prognozy poziomu nasłonecznienia. Prognozy te wykorzystywano następnie w modelu fizycznym do prognozy mocy w systemie fotowoltaicznym.

Sieć rekurencyjną typu Elmana oraz sieć neuronową typu MLP wykorzystano do prognoz dobowej produkcji energii w systemie fotowoltaicznym [16]. Danymi wejściowymi sieci były dane historyczne: całkowite nasłonecznienie dobowe oraz średnia dobowa temperatura powietrza. Do nauki sieci neuronowej wykorzystano dane z okresu 4 lat a do testowania sieci z okresu 1 roku. Sieć neuronowa typu MLP generowała korzystniejsze wyniki w porównaniu z siecią neuronową rekurencyjną gdy założono, że niedostępne są dane historyczne wartości mocy. Nieznaczna przewaga drugiej sieci neuronowej wystąpiła gdy moce mogły być wykorzystane na wejściu sieci.

Sugestie dotyczące wyboru zmiennych objaśniających do modeli prognostycznych

Z analizy literatury wynika, że jako potencjalne dane do prognoz krótkoterminowych mocy systemu fotowoltaicznego warto brać pod uwagę [5] wymienione poniżej dane. Wybór konkretnej danej powinien nastąpić na podstawie dostatecznie wysokiej korelacji z mocą prognozowaną oraz zgodnie z innymi zasadami doboru zmiennych objaśniających do modeli prognostycznych.

- Moc (dane historyczne). Wysokie autokorelacje występują typowo z kilkoma godzinami wstecz oraz dla wartości dokładnie sprzed $n * 24$ godzin.
- Nasłonecznienie (dane historyczne oraz prognozy). Warto zwrócić uwagę na fakt, że często występują duże rozbieżności w generacji mocy i produkcji energii dla danego poziomu nasłonecznienia.
- Temperatura (dane historyczne oraz prognozy).
- Wilgotność względna (dane historyczne oraz prognozy).
- Zachmurzenie (dane historyczne oraz prognozy).
- Ciśnienie atmosferyczne (dane historyczne oraz prognozy).
- Prawdopodobieństwo opadów (prognoza) Według niektórych źródeł np. [17] korzystnie jest podzielić prawdopodobieństwo opadów w danej godzinie na kilka kategorii. Kodowaniu podlegałaby wtedy kategoria (liczba z zakresu od 1 do 5). Przykład zawarto w tabeli 1.

Tabela 1. Podział prawdopodobieństwa opadów na kategorie.

Kategoria	Stan nieba	Prawdopodobieństwo opadów deszczu
1	Czyste	0-10%
2	Czyste oraz częściowo chmury	11-20%
3	Chmury	21-30%
4	Chmury oraz lekkie opady	31-60%
5	Opady	61-100%

- Pora prognozy (np. godzina). Występuje silna dobową okresowość generacji mocy. Kodowanie np. godziny może być zrealizowane z wykorzystaniem wartości ciągłych (wartości od 1 do 24 jako 1 wejście sieci neuronowej) lub binarnych (4 wejścia zero-jedynkowe).
- Miesiąc prognozy. Z uwagi na dużą sezonowość wielkości nasłonecznienia rozważyć można kodowanie miesiąca prognozy (liczba z zakresu od 1 do 12). Alternatywnie, niektóre źródła sugerują dekompozycję problemu prognostycznego na poszczególne miesiące w roku (osobne modele).

- Pozycja słońca na niebie w okresie prognozy. Parę danych stanowić może kąt wzniesienia słońca czyli jego wysokość nad linią horyzontu oraz azymut czyli kąt odchylenia słońca w płaszczyźnie poziomej od kierunku odniesienia (kierunek północny). Przykładowo latem w centralnej części Polski w godzinach południowych kąt wzniesienia wynosi 65°, natomiast zimą tylko 11°. Alternatywna dana dla pary danych: godzina prognozy oraz miesiąc.
- Dzień roku (liczba z zakresu od 1 do 366). Wymaga niestety danych historycznych z okresu co najmniej kilkunastu lat.
- Długość dnia w dniu prognozy. Z analiz statystycznych wynika, że istnieje korelacja o wartości około 0,3 pomiędzy długością dnia a wartością mocy. Alternatywa dla kodowania dnia roku.
- Dzień czy noc – wskaźnik możliwości produkcji energii elektrycznej (1 - okres pomiędzy wschodem a zachodem słońca, 0 – okres od zmroku do świtu) [9].

Badania autorskie godzinowej produkcji energii elektrycznej w systemie fotowoltaicznym z wyprzedzeniem 1 godziny

Wykonane przykładowe prognozy dotyczyły systemu fotowoltaicznego o mocy 19,5 kW znajdującego się w Centrum Fotowoltaiki Wydziału EiTl Politechniki Warszawskiej. Wykorzystano do badań dane z okresów: 15.01.2010 - 9.03.2010, 6.07.2010 - 16.08.2010 oraz 5.09.2010 - 31.12.2010. Z całości danych do weryfikacji jakości prognoz wykorzystano 24 dni. Każda z testowanych metod prognostycznych z wyjątkiem metody naiwnej wykorzystywała 13 zmiennych objaśniających. Zmienne egzogenne stanowiły: godzina prognozy (liczba z zakresu od 1 do 24), kod pory dnia (1 - okres pomiędzy wschodem a zachodem słońca, 0 – okres od zmroku do świtu), opady (prognoza), szybkość wiatru (prognoza), ciśnienie atmosferyczne (prognoza), temperatura (prognoza), zachmurzenie (prognoza), nasłonecznienie (prognoza) oraz długość dnia w dniu prognozy (liczba z zakresu od 0 do 1 określająca jaką część całego dnia stanowi okres pomiędzy wschodem a zachodem słońca). Zmienne endogeniczne stanowiły wartości produkcji energii elektrycznej w okresach od t-1 do t-3 oraz t-24. Jako podstawową miarę błędu przyjęto znormalizowany pierwiastek średniokwadratowego błędu – nRMSE. W tabeli 2 przedstawiono przykładowe wyniki prognoz uzyskanych wybranymi metodami. W metodzie naiwnej prognozę stanowiła wartość produkcji energii w okresie t-1. Zespół czterech sieci neuronowych 1” to metoda, w której przyjęto za prognozy średnie wartości z 4 prognoz wykonanych przy wykorzystaniu 3 różnych algorytmów uczących sieci typu MLP oraz jednej sieci typu RBF (sieci 1,2,3,4 w tabeli 2). „Zespół czterech sieci neuronowych 2 z wagami” to metoda, w której przyjęto za prognozy wartości tych samych czterech sieci neuronowych ale z odpowiednimi wagami. Do doboru właściwych wag wykorzystano algorytm optymalizacyjny Newtona, w którym minimalizacji podlegał błąd nRMSE obliczany dla prognoz z zakresu estymacji z przypisanymi wagami. Konkurencyjny algorytm optymalizacji - gradienty sprzężony generował niemal identyczne wartości wag. Największa wartość wagowa (co jest nieco zaskakujące) została przypisana sieci neuronowej typu RBF. Nieoczekiwanie również zwykła średnia z wyników prognoz z 4 sieci neuronowych wygenerowała niższe wartości błędów niż przypisanie wag poszczególnym prognozom z 4 sieci neuronowych. Wszystkie testowane metody okazały się lepsze od metody naiwnej stanowiącej punkt odniesienia. Statystyczna metoda regresji wielorakiej była znacząco gorsza niż sieci neuronowe. W przypadku sieci neuronowych wyniki były

bardzo zbliżone i trudno jednoznacznie wskazać metodę priorytetową. Sugerowane jest raczej wykorzystanie wyników zespołu sieci neuronowych.

Tabela 2. Wybrane wyniki prognoz produkcji energii elektrycznej przez system fotowoltaiczny z horyzontem 1 godziny.

Metoda prognostyczna	Miara błędu	Zakres estymacji	Zakres weryfikacji
Metoda naiwna	nRMSE [%]	6,930	7,633
	wsp.korelacji	0,915	0,928
Regresja wieloraka	nRMSE [%]	4,732	4,405
	wsp.korelacji	0,960	0,976
Sieć neuronowa 1 - MLP (alg uczyć: Quasi-Newtona)	nRMSE [%]	4,276	3,707
	wsp.korelacji	0,967	0,983
Sieć neuronowa 2 - MLP (alg uczyć: Levenberga-Marquardta)	nRMSE [%]	3,957	3,750
	wsp.korelacji	0,972	0,983
Sieć neuronowa 3 MLP (alg uczyć: szybka propagacja)	nRMSE [%]	4,180	3,778
	wsp.korelacji	0,969	0,982
Sieć neuronowa 4 RBF	nRMSE [%]	3,651	4,014
	wsp.korelacji	0,976	0,980
Zespół czterech sieci neuronowych 1	nRMSE [%]	3,858	3,612
	wsp.korelacji	0,973	0,984
Zespół czterech sieci neuronowych 2 z wagami	nRMSE [%]	3,642	3,926
	wsp.korelacji	0,976	0,981

Wnioski

Zdecydowana większość opracowań zwraca uwagę, że największe znaczenie dla uzyskania wysokiej jakości prognozy mocy w systemie fotowoltaicznym ma jakość prognoz czynników meteorologicznych (prognozy NWP) stanowiących zmienne egzogeniczne w modelach, a w szczególności precyzyjne prognozy poziomu nasłonecznienia [1]. Ponadto większość opracowań wskazuje na istotną rolę dużej liczby danych wejściowych systemu prognostycznego na jakość prognoz generacji mocy w systemach fotowoltaicznych. Im więcej, wysokiej jakości różnych informacji stanowić będą dane wejściowe, tym lepszej jakości prognoz można się spodziewać.

Autorskie badania opisane w [8] wykazały, że nawet dane ze stosunkowo niskim współczynnikiem korelacji do produkcji energii/mocy bywają pomocne w procesie prognozowania. Najważniejszą daną jest oczywiście prognoza poziomu nasłonecznienia na okres prognozy.

Wykorzystanie metod statystycznych typu regresja wieloraka wydaje się mniej celowe niż sztuczne sieci neuronowe, co potwierdziły przykładowe badania autorskie.

Najczęściej wykorzystywaną siecią neuronową w prognozowaniu krótkoterminowym generacji mocy w systemach fotowoltaicznych jest sieć neuronowa typu MLP. Wykorzystanie innych typów sieci neuronowych np. sieci RBF wydaje się również celowe, co wykazały autorskie badania. Bardzo obiecujące wyniki dają metody wykorzystujące kilka modeli sieci neuronowych (kilka odmiennych algorytmów uczyć) do uzyskania końcowej prognozy. Potwierdziły to wykonane autorskie badania z wykorzystaniem zespołu 4 sieci neuronowych.

Niektóre opracowania zwracają uwagę na konieczność integracji kilku prognoz lokalnych w celu poprawy jakości prognoz. Ponadto sugeruje się, również korzystać z podziału zadania prognostycznego na osobne modele dla poszczególnych miesięcy w roku lub pór roku [1]. Istnieją również opracowania np. [11] sugerujące, że korzystnie jest budować osobne modele dla kilku kategorii pogody na dzień prognozy.

LITERATURA

- [1] Yuehui H. et al.: "Comparative study of power forecasting methods for PV stations", International Conference on Power System Technology (POWERCON), 2010,
- [2] Baczyński D., Księżyk K., Parol M., Piotrowski P., Wasilewski J., Wójtowicz T.: „Mikrosieci niskiego napięcia”, Praca zbiorowa pod redakcją M. Parola, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2013,
- [3] Dudek G.: „Systemy uczące się oparte na podobieństwie obrazów do prognozowania szeregow czasowych obciążeń elektroenergetycznych”. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2012,
- [4] Piotrowski P.: „Prognozowanie w elektroenergetyce w różnych horyzontach czasowych”, Monografia, Prace Naukowe Politechniki Warszawskiej „Elektryka”, z. 144, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2013,
- [5] Piotrowski P.: „Analiza implementacji sztucznych sieci neuronowych w zadaniu prognozowania ultrakrótkoterminowego oraz sformułowanie wytycznych dotyczących prognozowania”, praca na zlecenie Globema Sp. z o.o., Warszawa, 2012,
- [6] Dobrzańska I., Dąsal K., Łyp J., Poptawski T., Sowiński J.: „Prognozowanie w elektroenergetyce. Zagadnienia wybrane”, Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2002,
- [7] Cococconi M., et al.: "24-hour-ahead forecasting of energy production in solar PV systems", 11th International Conference on Intelligent Systems Design and Applications (ISDA), 2011,
- [8] Piotrowski P.: „Analiza doboru zmiennych w zadaniu prognozowania ultrakrótkoterminowego produkcji energii elektrycznej w systemach fotowoltaicznych”, Przegląd Elektrotechniczny (Electrical Review), (ISSN 0033-2097), nr.4/2014, R.90, s.5-9,
- [9] Baczyński D., Wasilewski J.: „Krótkoterminowe prognozowanie produkcji energii elektrycznej w systemach fotowoltaicznych”, Rynek Energii, 96 (2011), nr 5, 47-51,
- [10] Yona A., et al.: "Application of neural network to 24-hour-ahead generating power forecasting for PV system", Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE,
- [11] Jie Shi, et al.: "Forecasting power output of photovoltaic system based on weather classification and support vector machine", Industry Applications Society Annual Meeting (IAS), 2011 IEEE, Orlando 2011,
- [12] Al-Messabi N., et al.: "Forecasting of photovoltaic power yield using dynamic neural networks", The 2012 International Joint Conference on Neural Networks (IJCNN),
- [13] Tao Cai, et al.: "Forecasting power output for grid-connected photovoltaic power system without using solar radiation measurement", Power Electronics for Distributed Generation Systems (PEDG), 2010 2nd IEEE International Symposium,
- [14] Grimaccia F., et al.: "Neuro-fuzzy predictive model for PV energy production based on weather forecast", Fuzzy Systems (FUZZ), 2011 IEEE International Conference,
- [15] Ciabattoni L., et al.: "Solar irradiation forecasting using RBF networks for PV systems with storage", Industrial Technology (ICIT), 2012 IEEE International Conference,
- [16] Adel Mellit: "Recurrent neural network-based forecasting of the daily electricity generation of a photovoltaic power system", Ecologic Vehicles - Renewable Energies (EVER), Monaco 26-29 march 2009,
- [17] Min-Cheol Kang, et al.: "Development of algorithm for day ahead PV generation forecasting using data mining method", Circuits and Systems (MWSCAS), 2011 IEEE 54th International Midwest Symposium.

Autor: dr hab. inż. Paweł Piotrowski, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: pawel.piotrowski@ien.pw.edu.pl