

## KRÓTKOTERMINOWE PROGNOZOWANIE DYNAMICZNEJ OBCIĄŻALNOŚCI LINII Z WYKORZYSTANIEM TECHNIKI SZTUCZNEJ INTELIGENCJI

Adam BABS<sup>1</sup>, Tomasz SAMOTYJAK<sup>2</sup>

1. Instytut Energetyki Oddział Gdańsk  
tel.: +48 602 639 079 e-mail: a.babs@ien.gda.pl
2. Instytut Energetyki Oddział Gdańsk  
tel.: 58 3498102 e-mail: t.samotyjak@ien.gda.pl

**Streszczenie:** W referacie przedstawiono sposób prognozowania parametrów pogodowych takich jak temperatura, prędkość i kierunek wiatru oraz natężenie promieniowania słonecznego, które są podstawą do wyznaczania dynamicznej obciążalności linii napowietrznych. Do krótkoterminowej prognozy warunków pogodowych wykorzystano jedną z metod technik sieci neuronowych tj. dynamiczną nieliniową autoregresyjną sieć neuronową (NAR). Przykład obliczeniowy prognoz warunków pogodowych wykorzystuje rzeczywiste dane z kilku stacji pogodowych ze zbioru ponad 350 stacji mierzących dane pogodowe na terenie kraju. Przyjmując symetryczny bezwzględny błąd procentowy (SMAPE) oszacowano dokładność prognozy oraz porównano ją z pomiarami rzeczywistymi oraz z prognozą pozyskiwaną od podmiotu komercyjnego.

Obliczenia i symulacje przeprowadzono w środowisku MATLAB, umożliwiając wykorzystanie opisanej metody prognozowania w istniejących systemach Dynamicznej Obciążalności Linii (DOL).

**Słowa kluczowe:** dynamiczna obciążalność linii, prognozowanie parametrów pogodowych, sztuczne sieci neuronowe.

### 1. WPROWADZENIE

Pobór mocy przez odbiorców, wielkość generacji ze źródeł odnawialnych, zwłaszcza turbin wiatrowych i paneli fotowoltaicznych, czy też dopuszczalna obciążalność linii przesyłowych są w dużym stopniu zależne od parametrów pogodowych takich jak temperatura zewnętrzna, prędkość i kierunek wiatru oraz natężenie promieniowania słonecznego. Krótkoterminowa prognoza tych warunków jest niezbędna przy planowaniu prowadzeniu ruchu systemu energetycznego, mającego na celu zbilansowanie systemu przy spodziewanych warunkach pogodowych oraz przy uwzględnieniu ograniczeń przesyłu wynikających z dopuszczalnych poziomów napięć i dopuszczalnej obciążalności elementów sieci, w tym głównie linii najwyższych napięć. Dokładność prognozy warunków pogodowych przekłada się na dokładność prognozowania obciążenia, generacji a zwłaszcza dopuszczalnej obciążalności linii, która jest nieliniową funkcją wszystkich wyżej wymienionych parametrów pogodowych.

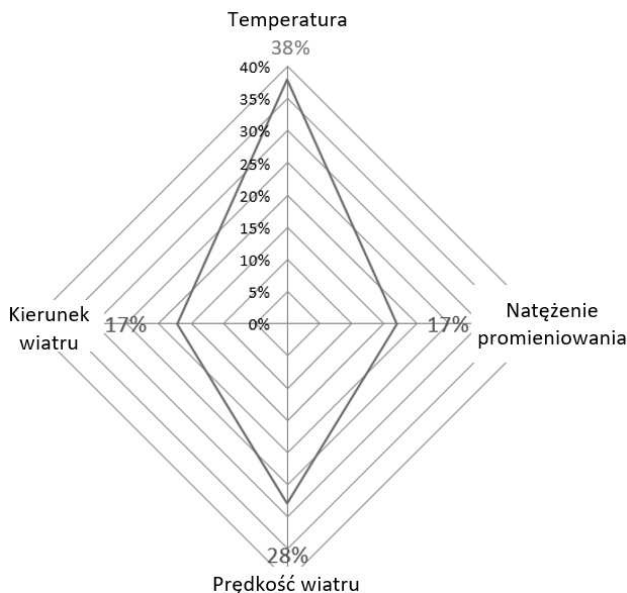
### 2. WPŁYW WARUNKÓW POGODOWYCH NA DOPUSZCZALNE OBCIĄŻANIE LINII

Dopuszczalne obciążanie linii jest maksymalną wartością prądu płynącego w linii, który w warunkach pogodowych występujących w każdym z przeseł linii nie spowoduje przekroczenia dopuszczalnej, wynikającej z norm, wartości zbliżenia przewodu do ziemi lub obiektu krzyżowanego.

Wartość zwisu a tym samym zbliżenia do ziemi lub obiektu krzyżowanego zależy od temperatury rdzenia przewodu, której wartość wynika z bilansu cieplnego tj. równowagi pomiędzy grzaniem a chłodzeniem przewodu. Grzanie przewodu jest głównie funkcją rezystancji przewodu i wielkości płynącego prądu, chłodzenie natomiast zależy od temperatury zewnętrznej oraz prędkości i kierunku wiatru [1].

Obliczenia wykonane z wykorzystaniem modelu cieplnego dla linii 220 kV z przewodami AFL-8 525 mm<sup>2</sup> wskazują, że wpływ poszczególnych czynników pogodowych na zmianę dopuszczalnego obciążania linii jest zróżnicowany. Zmiana dopuszczalnego obciążenia linii o 100 A może być spowodowana zmianą temperatury zewnętrznej o 10 °C, zmianą prędkości wiatru o 1 m/s i kierunku wiatru o 30 stopni oraz zmianą natężenia promieniowania słonecznego o 600 W/m<sup>2</sup>.

Przyjmując 10% zmiany wartości dla każdego z parametrów pogodowych w stosunku do warunków ustalonych takich jak temperatura otoczenia 30 °C, natężenie promieniowania 800 W/m<sup>2</sup>, prędkość wiatru 2 m/s i kierunek wiatru w stosunku do przewodu 45 stopni, obliczono udział procentowy każdej z tych zmian w obciążalności przewodu wywołanej wszystkimi zmianami łącznie, bez uwzględnienia faktu, że dwa z tych czynników oddziałują na chłodzenie a dwa na grzanie przewodu. Przy powyższych założeniach największy wpływ na zmniejszenie obciążalności przewodu ma zmiana temperatury zewnętrznej oraz zmiana prędkości wiatru powodująca zwiększenie obciążalności. Wartości tych udziałów rysunek 1 mogą być wskazówką, co wielkości błędu prognozy dopuszczalnego obciążenia linii spowodowanego błędem prognozy poszczególnych czynników pogodowych.



Rys. 1. Wpływ zmian warunków pogodowych na obciążalność linii

### 3. PROGNOZOWANIE WIELKOŚCI POGODOWYCH

#### 3.1. Dostępność pomiarów warunków pogodowych

Jakość krótkoterminowej prognozy warunków pogodowych o horyzoncie od kilku do kilkudziesięciu godzin jest zależna od ilości i jakości danych o pogodzie zebranych przed momentem prognozy tj. danych historycznych. Dane te są dostępne z kilku źródeł zarówno profesjonalnych, udostępnianych przez Instytut Meteorologii i Gospodarki Wodnej Państwowego Instytut Badawczy [2], jak i amatorskich [3]. Lokalizacja tych pomiarów nie jest uwarunkowana potrzebami wyznaczania generacji ze źródeł odnawialnych ani monitorowaniem dopuszczalnego obciążenia linii.

W krajowej energetyce źródłem danych o warunkach pogodowych, zarówno historycznych jak i aktualnych, są pomiary warunków pogodowych dokonywane na bieżąco dla potrzeb monitorowania i wyznaczania dopuszczalnej obciążalności linii z wykorzystaniem infrastruktury sprzętowej i oprogramowania systemu Dynamicznej Obciążalności Linii (DOL). Systemy te w latach 2014-2018 zostały wdrożone w sieciach 110 kV wszystkich Operatorów Systemu Dystrybucyjnego (OSD), przy czym w trzech OSD wdrożenia dotyczą całej sieci 110 kV. Łącznie zainstalowanych zostało ponad 350 stacji pogodowych, z których na bieżąco, co 15 minut, do dyspozycji przesyłane są pomiary temperatury, prędkości i kierunku wiatru oraz natężenia promieniowania słonecznego. W wielu miejscach mierzone jest również ciśnienie i punkt rosy, co pozwala na określenie prawdopodobieństwa wystąpienia szadzi. Rozmieszczenie punktów pomiaru warunków pogodowych na słupach linii 110 kV zapewnia monitorowanie dopuszczalnego obciążenia poprzez obliczanie dopuszczalnych prądów w miejscach szczególnie narażonych na przekroczenie granicznej wartości odległości do ziemi tj. w przęsłach krytycznych linii [4].

#### 3.2. Wykorzystanie sztucznej sieci neuronowej (SSN) do prognozowania warunków pogodowych

Działanie sztucznych sieci neuronowych naśladuje działanie biologicznych sieci neuronowych, które zawierają połączone ze sobą adaptacyjne węzły lub jednostki przetwarzania. Cecha ta pozwala na adaptację sposobu działania tych sieci do zmieniających się warunków wejściowych, poprzez uczenie się sieci i odwzorowanie złożonych zależności pomiędzy kolejnymi wartościami szeregu czasowego.

Istotną cechą wyróżniająca prognozowanie warunków pogodowych jest fakt, że dane historyczne, które są podstawą do prognozy dostępne są w postaci szeregów czasowych tj. wielkości mierzonych z jednakowym odstępem czasu a zależności pomiędzy poszczególnymi wielkościami są silnie nieliniowe.

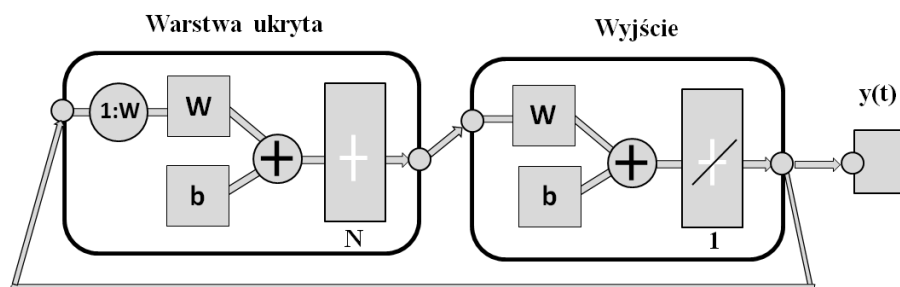
Analiza obszernej literatury dotyczącej metod krótkoterminowego prognozowania, [5], [6], [7], [8] wskazuje, że sztuczne sieci neuronowe są najbardziej rozpowszechnioną i zalecaną metodą prognozowania parametrów pogodowych, zarówno prognozowania jednego z elementów pogodowych (np. wiatru) jak i wielu parametrów pogodowych prognozowanych wspólnie.

W pracy [5] przedstawiono analizę porównawczą skuteczności różnych typów sieci neuronowych w zastosowaniu do prognozowania warunków pogodowych. Z analizy tej wynika, że nieliniowa autoregresyjna sieć z egzogennymi wejściami (sieć typu NARX) lub bez wejść zewnętrznych - sieć typu NAR (Nonlinear Autoregressive Neural Network) ma istotne zalety w porównaniu do innych metod zwłaszcza pod względem szybkości działania i jakości prognozy. W metodach tych dla prognozowania przyszłych wartości szeregu czasowego korzysta się z wcześniejszych wartości określonej zmiennej oraz wykorzystuje się efekt regresji tj. korekcji sposobu prognozowania na podstawie wcześniej wyznaczonych wartości prognozy i jej trafności.

#### 3.3. Charakterystyka sieć neuronowej typu NAR

Dla prognozowania krótkoterminowego parametrów pogodowych zastosowano nieliniowy, dynamiczny, autoregresyjny model sieci neuronowej ze sprzężeniem zwrotnym bez wejść zewnętrznych tj. sieć neuronową NAR. Wykorzystanie zewnętrznych danych (szeregów czasowych) innych niż wielkości prognozowane jest celowe wówczas, gdy zachodzi korelacja pomiędzy wartością prognozowaną a innymi zmiennymi, a tym samym zmienne zewnętrzne mogą wpływać na jakość prognozy. Przyjęto, że prognozowane zmienne pogodowe są od siebie niezależne, dlatego prognoza jest jednowymiarowa, tj. dotyczy tylko jednej zmiennej bez uwzględnienia innych zmiennych.

Zastosowany do prognozowania warunków pogodowych schemat sieci NAR przedstawiono na rysunku 2. W zależności od prognozowanego parametru pogodowego i pomiarów historycznych (szeregu czasowego) dostępnych w danej lokalizacji dobierana jest liczba wejść modelu  $W$  oraz liczba węzłów (neuronów)  $N$  w warstwie ukrytej. Wartością wyjściową  $y(t)$  w modelu NAR jest przewidywana, następna wartość szeregu czasowego wyliczona na podstawie przeszłych wartości tego przebiegu lub przewidywań z przeszłości.



Rys. 2 Schemat sieci NAR do prognozowania parametrów pogodowych

### 3.4. Mierniki dokładności prognozy

Zarówno podczas uczenia się sieci neuronowej jak i dla wyznaczania prognozy, wykorzystuje się miernik jakości działania sieci który opisuje zależność pomiędzy wartościami prognozowanymi a rzeczywistymi. Zależność ta jest wykorzystywana dla wyboru zarówno liczby wejść jak i liczby węzłów ukrytych, które to liczby definiują strukturę modelu sieci.

Wykorzystywane są mierniki dokładności takie jak: średni bezwzględny błąd procentowy MAPE (*mean absolute percentage error*) definiowany jako (1)

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (1)$$

oraz symetryczny średni bezwzględny błąd procentowy SMAPE (*symmetric mean absolute percentage error*) definiowany jako (2)

$$SMAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{|A_t - F_t|}{(|A_t| + |F_t|)} \quad (2)$$

gdzie:  $A_t$  – wartość rzeczywista,  $F_t$  – wartość prognozowana  $t$  atrybutu pogody.

Zastosowanie miernika dokładności prognozy SMAPE zamiast miernika dokładności MAPE prowadzi do około dwukrotnego zmniejszenia wartości liczbowej błędu prognozy, przy czym zmniejszenie to jest większe dla wartości prognozy przekraczających dane rzeczywiste niż dla wartości mniejszych niż dane rzeczywiste.

Dla lepszego zobrazowania dokładności prognozy, wartość błędu zastępuję się jej uzupełnieniem do 100%. Wartość 100% świadczy o zgodności prognozy z wartościami rzeczywistymi (3)

$$Acc(\%) = 100 - SMAPE(\%) \quad (3)$$

Używa się również pojęcia dopuszczalności prognozy przyjmując, że jeżeli względny miernik dokładności prognozy jest mniejszy od 10% to prognoza jest dopuszczalna, natomiast jeśli jest mniejszy niż 3% to prognoza jest bardzo dokładna.

## 4. PRZYKŁAD OBLICZENIOWY PROGNOZY WARUNKÓW POGODOWYCH

### 4.1. Zakres danych wejściowych

Pośród ponad 350 lokalizacji, w których od kilku lat mierzone są dla potrzeb systemów DOL wielkości pogodowe wybrano dane z 5 lokalizacji oddalonych od siebie kilkadziesiąt kilometrów. Do obliczeń i analiz porównawczych przyjęto dane z rzeczywistych pomiarów za okres 3 miesiące jesienno-zimowych w 2018 roku, kiedy

zazwyczaj występuje największa zmienność warunków pogodowych. Prognozy były wyznaczane w horyzoncie 24 godzinnym i dotyczyły prognoz dla czterech parametrów pogodowych: temperatura, prędkość i kierunek wiatru oraz natężenie promieniowania dla 5 lokalizacji. W procesie uczenia się sieci neuronowej dobierano jej najwłaściwszą dla każdej lokalizacji strukturę sieci, wykorzystując dane historyczne za okres 3 miesięcy.

Punktem odniesienia dla jakości prognoz wyznaczanych z wykorzystaniem SSN były prognozy pogody generowane przez podmiot komercyjny dla tych samych lokalizacji. Prognozy te miały rozdzielczość czasową jednej godziny i były aktualizowane co 6 godzin. Porównanie zatem dotyczyło prognoz 24 godzinnych, przy czym prognoza komercyjna była aktualizowana 4 razy na dobę (co 6 godzin).

### 4.2. Opis procesu modelowania i obliczeń

Obliczenie wartości prognozowanych warunków pogodowych wykonano za pomocą pakietu obliczeniowego Matlab i biblioteki Neural Network Toolbox implementując sieć typu NAR. Do uczenia sieci NAR zastosowano algorytm Levenberga-Marquardta a wagi początkowe wygenerowano przy użyciu funkcji losowej.

Etapem wstępnym jest uczenie się sieci polegające na wyborze parametrów sieci najbardziej właściwych dla prognozowanego szeregu czasowego. Proces ten wykorzystuje dane historyczne, które dzieli się na trzy zbiory: zbiór uczący, zbiór sprawdzający oraz zbiór testujący. Liczebność poszczególnych zbiorów wynosi zazwyczaj odpowiednio: 70%-15%-15%. Uczenie następuje do momentu, gdy średni błąd kwadratowy prognozy (MSE) dla kolejnych iteracji błąd przestaje maleć. Istotnym jest również, aby łączna liczebność tych zbiorów była wielokrotnie np. 30 krotnie większa niż liczebność zbioru prognozowanego. Wykorzystanie sieci neuronowej do prognozowania wymaga uprzedniego skonfigurowania modelu sieci. Należy określić następujące zmienne:


1. Horyzont czasowy prognozy tj. liczba kolejnych, prognozowanych wartości danej zmiennej. W analizowanych prognozach przyjęto horyzont 24 godzinny tj. 96 wartości prognozy z rozdzielczością 15 minut.
2. Liczba wartości wejściowych do prognozy będących w istocie liczbą wartości historycznych danej wielkości przed momentem prognozy oraz jeśli liczba wartości wejściowych jest mniejsza niż liczba punktów prognozy to również obejmuje już wyznaczone wartości prognozy (autoregresja).
3. Liczba węzłów ukrytych w modelu (neuronów), pomiędzy którymi zachodzą oddziaływania.

Kryterium doboru liczby wejść i liczby węzłów ukrytych była minimalizacja wartości miernika jakości

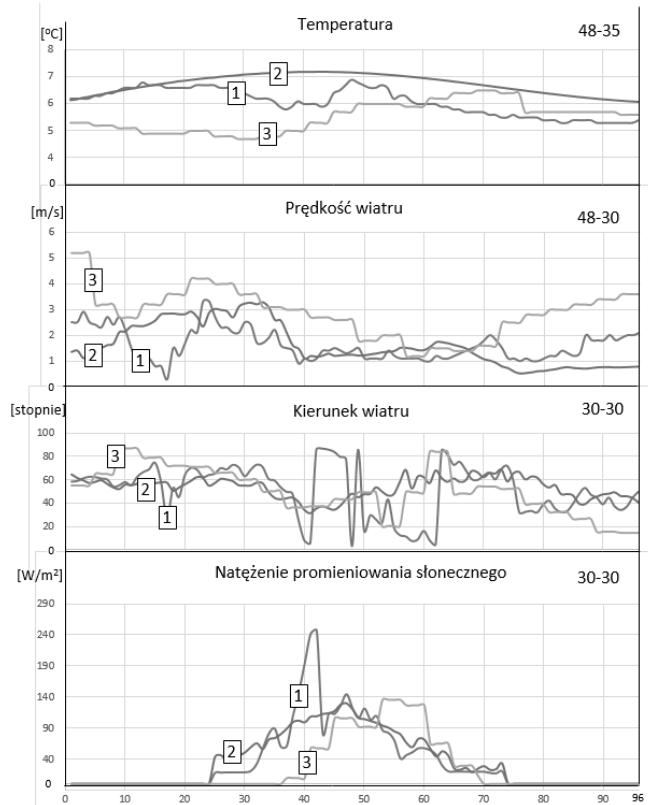
prognozy 24 godzinnej obliczanej dla 96 wartości szeregu czasowego. Miernik jakości wyznaczano dla każdego z zastosowaniem sieci NAR z prognozami komercyjnymi dla prognozowanego parametru pogody, przyjmując 9 wartości wszystkich lokalizacji dla czterech parametrów pogodowych liczby wejść od 6 do 52, odpowiadających wartościom przedstawiono w tablicy 1. Dla większości lokalizacji prognoza historycznym za okres od 1,5 do 13 godzin przed prognozą wykorzystaniem sieci SSN ma większą dokładność niż oraz 6 wartości liczby węzłów: 10, 20, 25, 30, 35 i 40. prognoza firmowa, przy czym prognoza firmowa była

Przykładowe wyniki doboru liczby wejść i liczby węzłów wyznaczana (aktualizowana) co 6 godzin. Zastosowanie takiego węzłów ukrytych dla modelu prognozowania prędkości samego horyzontu czasowego dla prognozy SSN wiatru w wybranej lokalizacji przedstawiono na Rys. 3, spowodowałyby jeszcze lepszą dokładność prognozy. Świadczą gdzie optymalnym okazał się model z 18 wejściami oraz 400 tym przebiegi porównawcze prognoz warunków pogodowych węzłami ukrytymi dający dokładność prognozy 93,68%. Dla przedstawione na rysunku 4, gdzie w początkowym okresie innej lokalizacji dla prognozy natężenia promieniowania prognozy wyniki otrzymane z sieci SSN są zbliżone danymi wybrano model z 30 wejściami i 30 węzłami dającymi rzeczywistymi w stopniu znacznie większym niż wyniki dokładność prognozy powyżej 80%.

Optymalna liczba wejść i węzłów w modelach prognozy temperatury dla poszczególnych lokalizacji jest zróżnicowana a dokładność prognozy 24 godzinnej wynosi od 92% do 97% (tablica 1).



Rys. 3 Dokładność 24 godzinnej prognozy prędkości wiatru dla zmiennej liczby wejść i węzłów ukrytych



Rys. 4. Porównanie wyników 24 godzinnej prognozy SSN z prognozą firmową i danymi rzeczywistymi

- 1 - dane rzeczywiste
- 2 - prognoza z wykorzystaniem SSN
- 3 - prognoza firmowa

### 4.3. Ocena jakości prognozy warunków pogodowych

Dokładność prognozy wyznaczonej z użyciem SSN należy uznać za wystarczającą dla celów, które opisano w rozdz. 2 tj. dla prognozowania dopuszczalnego obciążenia linii. Dotyczy to zwłaszcza prognozy temperatury i prędkości wiatru, których wpływ na dopuszczalną obciążalność linii jest największy, większy niż wpływ kierunku wiatru i natężenia promieniowania słonecznego (rysunek 1).

Tablica 1. Porównanie wyników prognozy SSN i prognozy firmowej dla różnych lokalizacji

Lokalizacja	Temperatura			Wiatr			Kierunek wiatru			Natężenie promieniowania		
	Liczba wejść-węzłów	Prognoza		Liczba wejść-węzłów	Prognoza		Liczba wejść-węzłów	Prognoza		Liczba wejść-węzłów	Prognoza	
		SSN	firmowa		SSN	firmowa		SSN	firmowa		SSN	firmowa
A	48-35	96,5	92,2	48-35	84,5	71,6	30-30	80,5	77,7	30-30	80,2	49,2
B	48-35	92,4	93,0	48-30	88,4	59,3	52-30	68,2	72,6	30-30	63,4	48,6
C	6-20	97,6	97,6	30-30	94,0	86,4	52-30	90,3	85,8	30-30	46,8	40,2
D	48-35	94,6	94,5	18-40	89,7	77,0	42-30	68,4	54,6	48-30	60,8	39,5
E	24-30	94,2	95,8	48-30	92,5	80,8	52-30	73,6	71,4	52-30	78,3	46,0

## 5. WNIOSKI

1. Przedstawione w referacie wyniki prognozy wartości pogodowych z wykorzystaniem SSN wskazują na wystarczającą dokładność tak wyznaczonej prognozy dla wykorzystania tych wyników dla obliczenia prognozowanego obciążenia linii w krótkim horyzoncie czasowym. Osiągnięte rezultaty są lepsze niż prognoza pogody dla danej lokalizacji wykonana przez podmiot komercyjny. Najmniej dokładną prognozę tj. o dokładności od 60% do 80% otrzymano dla natężenia promieniowania słonecznego, jednakże wpływ tego parametru na dopuszczalną obciążalność linii nie jest decydujący.
2. Ze względu na sezonowość zmian pogody dla poprawy dokładności prognozy celem jest aktualizacja modelu sieci neuronowej w odstępach ok. 30 dniowych. Aktualizacja ta dokonana na podstawie najnowszych danych historycznych pozwoli na optymalny dobór modelu sieci tj. liczby wejść i liczby węzłów.
3. Poprawę jakości prognoz warunków pogodowych można osiągnąć poprzez uwzględnienie korelacji tych samych parametrów pogodowych, ale pochodzących z sąsiednich geograficznie lokalizacji. Dotyczyć to może zwłaszcza prognozy natężenia promieniowania słonecznego, które jest zależne w dużym stopniu od przemieszczania się zachmurzenia.
4. W przypadku, gdy za względów ruchowych wystarczające są prognozy dopuszczalnej obciążalności linii w horyzoncie 24 godzinnym wydaje się celem opracowywanie tych prognoz na podstawie bieżących pomiarów w danej lokalizacji.

### Podziękowanie

W niniejszym referacie wykorzystano wyniki obliczeń wykonanych w ramach pracy dyplomowej [9] autorstwa Michała Pietrzaka absolwenta Politechniki Gdańskiej. Autorzy niniejszego referatu sprawujący opiekę merytoryczną nad tą pracą dyplomową składają autorowi tej pracy podziękowanie za udostępnienie i przygotowanie wyników zamieszczonych w niniejszym referacie.

## 6. BIBLIOGRAFIA

1. Babś A., Samotyjak T.: Dynamic Rating of 110 kV Overhead Lines, Acta Energetica nr 3/28.
2. Strona internetowa IMGW: <https://danepubliczne.imgw.pl/>
3. Strona internetowa Amatorskie Stacje Meteo: <http://stacjapogody.waw.pl/index.php?id=mapastacji>.
4. Babs A.: Weather conditions based wide area Dynamic Line Rating system for 110 kV network monitoring and contingency analysis, CIGRÉ Canada Conference, Winnipeg, Manitoba, August 31-September 2, 2015
5. Saroj Kr. Biswas at al.: Weather prediction by recurrent neural network dynamics, Int. J. Intelligent Engineering Informatics, Vol. 2, Nos. 2/3, 2014
6. Kumar S., Lopez D.: Feature Selection used for Wind Speed Forecasting with Data Driven Approaches, Journal of Engineering Science and Technology Review 8 (5) (2015)
7. Boussaada Z. et al: A Nonlinear Autoregressive Exogenous (NARX) Neural Network Model for the Prediction of the Daily Direct Solar Radiation, Energies 2018, 11, 620
8. Cococcioni M. at al: "24-hour-ahead forecasting of energy production in solar PV systems", 11th International Conference on Intelligent Systems Design and Applications (ISDA), 2011
9. Pietrzak M.: Prognozowanie warunków pogodowych dla wyznaczania dynamicznej obciążalności linii 110 kV. Praca dyplomowa na Wydziale Elektrotechniki i Automatyki Politechniki Gdańskiej, luty 2019.

## THE DYNAMIC LINE RATING SHORT-TERM FORECASTING WITH THE USE OF ARTIFICIAL INTELLIGENCE TECHNIQUE

The paper presents the method of forecasting weather parameters such as temperature, wind speed and direction, as well as the solar irradiation, which are the basis for determining the dynamic load capacity of overhead lines. For the short-term forecast of weather conditions one of the methods of neural network techniques was used, i.e. a dynamic non-linear autoregressive neural network (NAR). The calculation example of weather forecasts uses real data from several weather stations from a set of over 350 stations measuring weather data across the country. Assuming a symmetrical absolute percentage error (SMAPE), the accuracy of the forecast was estimated and compared with the actual measurements and the forecast obtained from the commercial entity.

Calculations and simulations were carried out in the MATLAB environment, enabling the use of the described prediction method in the existing Dynamic Line Rating systems (DOL).

**Keywords:** dynamic line rating, weather forecasting, artificial neural networks.