

doi:10.15199/48.2019.10.42

## Prognozowanie zapotrzebowania na moc w KSE z zastosowaniem grupowania rozmytego

**Streszczenie.** W artykule przedstawiona została metoda prognozowania zapotrzebowania dobowego na moc w Krajowym Systemie Elektroenergetycznym (KSE) z dowolnym wyprzedzeniem czasowym przy zastosowaniu grupowania rozmytego, zrealizowanego przy użyciu algorytmu C-means. Do badań numerycznych posłużyły dane godzinowe zapotrzebowania na moc w KSE z lat: 2014-2018. Na podstawie kilku ostatnich lat użytych w uczeniu systemu rozmytego przeprowadzono predykcję zapotrzebowania na moc dla każdego dnia roku 2018.

**Abstract.** The paper shows the method of 24-hour load forecasting in National Power System in Poland with unlimited time advance and with application of fuzzy sets and C-means algorithm. The hourly load data in KSE from the period of 2014-2018 have been used in experiments. The first 4 years data have been used in learning fuzzy system and data of the last year - 2018 have been used only in testing of the learned system. **The method of 24-hour load forecasting with application of fuzzy sets and C-means algorithm**

**Słowa kluczowe:** prognozowanie obciążeń, logika rozmyta, algorytm C-means.

**Keywords:** load forecasting, fuzzy logic, C-means algorithm.

### Wprowadzenie

Prognozowanie obciążeń w systemie elektroenergetycznym odgrywa istotną rolę - nie tylko w ekonomice kraju, ale także ze względu na bezpieczeństwo i niezawodność pracy systemu elektroenergetycznego. Prognozy są niezbędne do planowania pracy systemu i bieżącego prowadzenia ruchu, planowania remontów itp. W związku z tym powstało wiele prac poświęconych tej tematyce [1], [2], [3], [4]. Dotyczą one zarówno prognozowania ultrakrótkoterminowego (do 30 minut) [12], krótkoterminowego (np. z dnia na dzień) [13], jak i z dowolnym wyprzedzeniem czasowym. Wiele rozwiązań, np. [8], [9], stosuje sztuczne sieci neuronowe jako główne narzędzie predykcji, w tym również podejście rozmyte [10], które jest szczególnie interesujące, ze względu na obserwowaną rozmytość obciążeń odpowiadających różnym dniom roku. Zaletą sieci neuronowych jest możliwość nieliniowego dopasowania modelu do złożonych zależności występujących w analizowanym procesie zmian obciążeń godzinnych.

W pracy badaniu podlegać będzie metoda prognozowania 24-godzinowego zapotrzebowania na moc elektryczną w KSE wykorzystująca teorię zbiorów rozmytych do wykrywania skupisk w danych [6], [11]. Stosując algorytm C-means rozmytego grupowania danych zaproponowana zostanie metoda prognozy zapotrzebowania na moc elektryczną z dowolnym wyprzedzeniem czasowym. Jest to główna zaleta, w stosunku do klasycznego zastosowania sztucznych sieci neuronowych w rozwiązaniu problemu prognozowania.

### Problem badawczy

Do analizy rozwiązania posłużyły dane KSE - Krajowego Systemu Elektroenergetycznego [7], określające zapotrzebowanie na moc elektryczną całego kraju w konkretnych godzinach doby. Dane zapotrzebowania na moc dotyczą przedziału czasowego od 1 stycznia 2014 roku do 31 grudnia 2018 roku, obejmują zatem 5 lat. Łączna liczba dni w tym przedziale czasowym wynosi 1826, co stanowi 43824 godziny. Do każdej godziny doby przyporządkowana jest liczba określająca rzeczywiste zapotrzebowanie na moc, wyrażone w megawatach [MW]. Dane liczbowe zostały znormalizowane według wartości maksymalnej [1].

Na rysunku 1 przedstawiono znormalizowane zapotrzebowanie na moc w KSE w analizowanym przedziale czasowym, z zaznaczonym (za pomocą białej linii kropkowanej) rosnącym trendem liniowym.

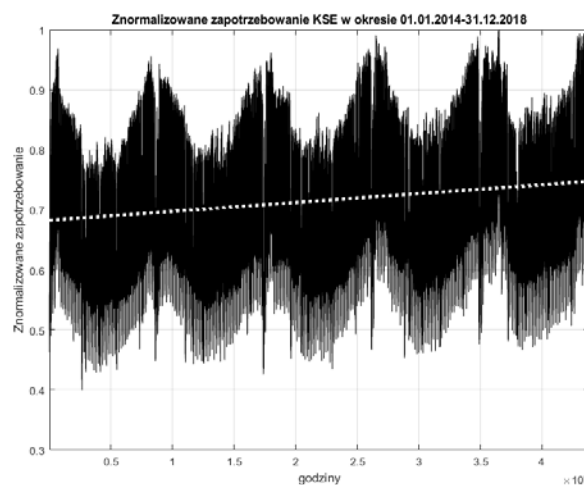
Normalizacja według wartości maksymalnej polega na zawężeniu zakresu danych do przedziału, w którym wartość 1 oznacza maksymalne zapotrzebowanie na moc w całym badanym 5-letnim okresie. Normalizacja danych dla potrzeb prognozowania przy użyciu grupowania rozmytego jest wskazana ze względu na dokładność obliczeń numerycznych.

Trend liniowy został uzyskany za pomocą metod numerycznych BasicFitting w środowisku Matlab. Za pomocą tej samej funkcji można uzyskać także trendy nieliniowe – kwadratowe, sześciennic i wyższych rzędów. Dodanie linii trendu do wykresu na rysunku 1 ma charakter wyłącznie ilustracyjny i daje informację o ogólnym wzroście zapotrzebowania na moc w KSE. W badaniach uwzględniono 2 przypadki: prognozowanie na danych oryginalnych, bez eliminacji trendu, oraz na danych po usunięciu trendu. Wyniki prognozowania dla danych oryginalnych zestawiono w tabelach 3 i 4, a po usunięciu trendu w tabeli 5. Średnie zapotrzebowanie na moc w latach: 2014-2017 wzrosło o 4,9%.

Trend liniowy dla analizowanych danych uzyskany w obliczeniach opisuje następująca funkcja

$$(1) \quad y_T = 1,4767 \cdot 10^{-6}x + 0,6826$$

gdzie  $x$  to kolejna godzina szeregu czasowego poddanego badaniom, od 1 do 43824.



Rys. 1. Znormalizowane zapotrzebowanie na moc w KSE w okresie od 01.01.2014 do 31.12.2018

Po przeliczeniu na megawaty można stwierdzić na podstawie trendu, że średnie zapotrzebowanie na moc w KSE wzrasta o 1000 MW co około 25760 godzin (czyli ok. 1073 dni).

W tabeli 1 przedstawione zostały podstawowe parametry statystyczne analizowanego szeregu czasowego takie jak: wartość minimalna mocy, wartość maksymalna, średnia, mediana, odchylenie standardowe oraz zakres zmian, zarówno wyrażone w MW, jak i znormalizowane według wartości maksymalnej.

Tabela 1. Zestawienie parametrów statystycznych dla badanego szeregu czasowego zapotrzebowania na moc w KSE w latach 2014-2018

Parametr	Dane znormalizowane	Dane w [MW]
Wartość minimalna	0,399	10 494,0
Wartość maksymalna	1,000	26 297,2
Średnia	0,715	18 801,4
Mediana	0,723	19 012,6
Odchylenie standardowe	0,118	3 112,8
Zakres zmian	0,601	15 803,2

Badany szereg czasowy charakteryzuje się stosunkowo dużym zakresem zmian, który jest większy o 50,6% od wartości minimalnej i dużym odchyleniem standardowym, stanowiącym 29,7% wartości minimalnej. Czynniki te świadczą o skali trudności w prognozowaniu badanego szeregu czasowego, zważywszy na fakt, że badany szereg czasowy nie jest regularny. Występują w nim nieregularności wynikające zarówno ze zmiennych warunków pogodowych, mających wpływ na zapotrzebowanie, jak również zmienną specyfikę dużego obszaru odbiorców jakim jest Krajowy System Elektroenergetyczny, obejmujący zarówno odbiorców indywidualnych jak i przemysłowych.

### Metoda badawcza

W zastosowanej metodzie badawczej każdy wektor danych, reprezentujący zapotrzebowanie na moc w konkretnym dniu, składający się z 24 elementów reprezentujących godziny, przynależy do różnych grup (klastrow), na które podzielony został zbiór uczący danych. Liczba klastrow i wpływ tej liczby na dokładność prognozy poddana została badaniom eksperymentalnym. W odróżnieniu od grupowania ostrego (np. K-means), w podejściu rozmytym każdy wektor  $\mathbf{x}_j$ , reprezentujący obciążenie 24-godzinne, przynależy jednocześnie do wszystkich klastrow reprezentowanych przez centra  $\mathbf{c}_i$  w stopniu  $\mu_{ij}$ , gdzie  $0 \leq \mu_{ij} \leq 1$ . Sumaryczny stopień przynależności każdego wektora  $\mathbf{x}_j$  do wszystkich  $M$  klastrow musi spełniać relację:

$$(2) \quad \sum_{i=1}^M \mu_{ij} = 1$$

Funkcja błędu  $E$ , która w toku uczenia podlega minimalizacji, równa się sumie błędów cząstkowych przynależności wszystkich wektorów  $\mathbf{x}_j$  do centrów  $\mathbf{c}_i$  z uwzględnieniem stopnia przynależności  $\mu_{ij}$ , zgodnie ze wzorem:

$$(3) \quad E = \sum_{i=1}^M \sum_{j=1}^p \mu_{ij}^m \|c_i - x_j\|^2$$

gdzie  $m$  jest wykładnikiem wagowym, przyjmującym wartości z przedziału  $[1, \infty)$ , a  $p$  liczbą dni biorących udział w obliczeniach. Jest to problem minimalizacji funkcji nieliniowej (3) z  $p$  ograniczeniami typu (2). Rozwiązanie problemu można sprowadzić do minimalizacji funkcji Lagrange'a zdefiniowanej następująco [11]:

$$(4) \quad J = \sum_{i=1}^M \sum_{j=1}^p \mu_{ij}^m \|c_i - x_j\|^2 + \sum_{j=1}^p \lambda_j \left( \sum_{i=1}^M \mu_{ij} - 1 \right)$$

gdzie:  $\lambda_j$  ( $j = 1, 2, \dots, p$ ) są mnożnikami Lagrange'a,  $p$  jest liczbą ograniczeń. Zostało udowodnione, że rozwiązanie problemu (4) można zapisać w postaci [6], [11]:

$$(5) \quad c_i = \frac{\sum_{j=1}^p \mu_{ij}^m x_j}{\sum_{j=1}^p \mu_{ij}^m}$$

$$(6) \quad \mu_{ij} = \frac{1}{\sum_{k=1}^M \left( \frac{d_{ij}}{d_{kj}} \right)^{\frac{2}{m-1}}}$$

w której  $d_{ij}$  jest odległością euklidesową między centrum  $\mathbf{c}_i$  a wektorem  $\mathbf{x}_j$ ,  $d_{ij} = \|\mathbf{c}_i - \mathbf{x}_j\|$ .

W badaniach zastosowano ten algorytm przy wykorzystaniu programu Matlab [5]. Stosując algorytm C-means, otrzymano macierz reprezentującą przynależności poszczególnych dni, stanowiących dane uczące, do  $M$  klastrow. Macierz ta dla  $M = 12$  ma wymiary  $12 \times 1461$ , gdzie 1461 stanowi liczbę dni uczących z czterech lat (od 01.01.2014 do 31.12.2017). W tabeli 2 przedstawionych zostało 7 pierwszych kolumn tej macierzy, reprezentujących 7 pierwszych dni roku 2014.

Tabela 2. Macierz przynależności kolejnych dni (od 01.01.2014 do 07.01.2014) do klastrow dla  $M = 12$

kl	dane uczące, początek - 01.01.2014						
	01.01	02.01	03.01	04.01	05.01	06.01	07.01
1	5,79E-08	0,00309	0,00173	0,00259	5,61E-10	1,87E-07	4,59E-09
2	0,76689	7,50E-09	7,83E-12	3,82E-12	1,98E-09	0,00067	4,97E-15
3	0,00065	1,32E-05	1,33E-08	4,81E-07	0,99999	0,28307	2,51E-12
4	3,17E-06	0,0012	4,01E-06	0,9974	1,53E-06	5,65E-05	1,43E-10
5	1,72E-09	0,00486	0,74061	3,61E-08	2,46E-12	2,55E-09	5,86E-06
6	1,62E-11	4,31E-07	5,02E-08	1,66E-12	4,01E-15	9,95E-12	4,29E-10
7	6,81E-06	2,93E-05	7,17E-08	1,61E-06	7,93E-07	5,86E-05	8,94E-12
8	7,52E-10	0,06118	0,12416	3,33E-09	7,65E-13	1,05E-09	0,99999
9	5,48E-08	0,84246	0,00051	1,18E-05	5,07E-10	2,16E-07	3,50E-08
10	9,22E-09	0,08711	0,13287	1,50E-06	3,11E-11	2,06E-08	6,49E-07
11	0,23245	1,74E-07	1,59E-10	2,63E-10	4,81E-06	0,71614	6,89E-14
12	1,66E-10	6,76E-05	0,00012	1,65E-10	8,96E-14	1,54E-10	6,79E-07

Analizując wartości liczbowe zawarte w tabeli 2 można stwierdzić, że dzień 01.01.2014 został przyporządkowany w największym stopniu (wynoszącym 0,7668) do klastra 2, w stopniu 0,2324 do klastra 11, w stopniu 0,00065 do klastra 3 itd. Z uwagi na to, że jest to dzień świąteczny (Nowy Rok) nie uzyskano dużej (większej niż 0,99) przynależności tylko do jednego klastra, zatem stopień rozmycia jest znaczny. Podobna sytuacja występuje dla dnia 06.01.2014 (również jest to dzień świąteczny – Święto Trzech Króli). Dzień ten został przyporządkowany w stopniu 0,7161 do klastra 11, w stopniu 0,2830 do klastra 3, itd. Przynależność do pozostałych klastrow jest mniejsza o kilka rzędów wielkości. Przynależność tego dnia do klastra 6 wyniosła zaledwie  $9,95 \cdot 10^{-12}$ . Natomiast znacznie mniejszy stopień rozmycia można zaobserwować dla dnia 07.01.2014, jest to dzień powszedni, wtorek. Występuje tutaj duża przynależność do klastra 8, wynosząca 0,9999. Przynależność do kolejnego

(pod względem wielkości stopnia przynależności) klastra 5 wynosi  $5,86 \cdot 10^{-6}$  jest, zatem ponad 170000 razy mniejsza od przynależności do klastra 8. W związku z tym stopień przynależności jest niski, przy czym za niski stopień przynależności (wartość współczynnika przynależności do określonego zbioru) można przyjąć stopień mniejszy niż 0,5. Podobna sytuacja występuje dla dnia 05.01.2014 i, mimo że nie jest to dzień powszedni (niedziela), został przyporządkowany w stopniu  $>0,99$  do klastra 3.

Duża rozpiętość przynależności krzywej obciążenia dla specyficznych różnych dni świątecznych jest czynnikiem świadczącym o znacznej rozmytości tych danych, co dowodzi trudności prognozy dla tych szczególnych dni.

Prognozowanie wektora 24-godzinnych obciążeń (wektor 24-elementowy oznacza jedną dobę) na konkretny dzień w roku polega na wagowym uśrednieniu centrów wszystkich klastrów do których przynależy dany dzień tygodnia określonego miesiąca (np. wszystkie wtorki w miesiącu maju). Wagi uwzględniają wartość przynależności konkretnego dnia do odpowiedniego klastra. W związku z tym, wektor 24-godzinnych obciążeń  $P_k$  na dzień  $k$ -ty w roku będzie uśrednioną sumą ważoną wektorów  $c_j$  reprezentujących klastry z wagą równą współczynnikowi przynależności rozważanego dnia tygodnia i miesiąca do danego klastra, co można zapisać wzorem:

$$(7) \quad P_k = \frac{1}{N} \sum_{i=1}^M \sum_{j=1}^N c_j \mu_{ik}^{(j)}$$

w którym  $N$  oznacza liczbę lat branych pod uwagę w uczeniu systemu, a  $M$  – liczbę klastrów. Do predykcji brane pod uwagę były tylko dni odległe od prognozowanego dnia o całkowitą liczbę lat. Uśrednianiu podlegają zatem te same dni tygodnia (np. poniedziałki), co dzień prognozowany. Umiejscowione są w tym samym miejscu cyklu rocznego, co dzień prognozowany. Zaimplementowano to w modelu poprzez wykorzystanie w prognozie danych odległych od dnia prognozowanego o całkowitą liczbę lat. Prognozę przeprowadzono z horyzontem 4-letnim (dane testujące są odległe od najdalszych danych uczących o 4 lata).

Tabela 3. Zestawienie błędów MAPE dla danych testujących z roku 2018, dla hiperparametrów:  $m = 2,0$ , gradient minimalny  $10^{-5}$ .

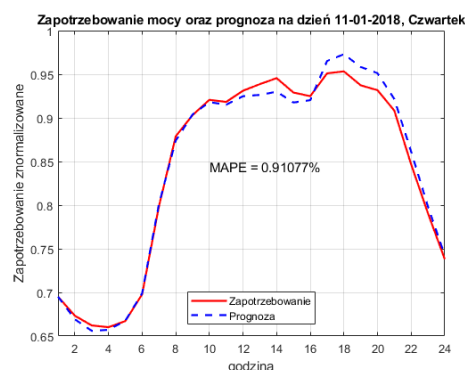


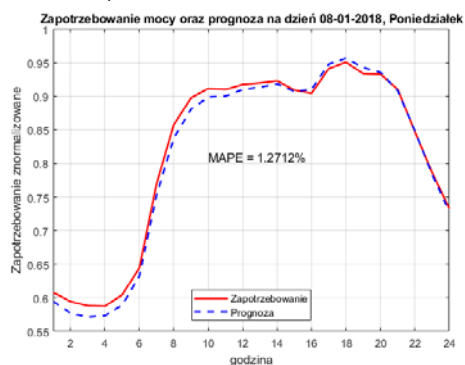
Miesiąc	Błąd MAPE testowania [%]			
	$M=12$	$M=52$	$M=104$	$M=365$
styczeń	3,77	3,69	3,45	3,79
luty	4,34	4,11	4,15	4,15
marzec	4,99	4,81	5,37	4,77
kwiecień	4,70	4,32	4,41	4,02
maj	6,51	6,38	6,15	6,25
czerwiec	2,88	2,55	2,69	2,56
lipiec	2,64	2,29	2,18	2,23
sierpień	3,70	3,60	3,65	3,58
wrzesień	2,41	2,28	2,25	2,16
październik	3,18	2,96	3,02	2,86
listopad	6,29	6,25	5,89	6,20
grudzień	7,48	7,58	7,24	7,54
<b>Średnia</b>	<b>4,41</b>	<b>4,24</b>	<b>4,21</b>	<b>4,18</b>
<b>Średnia bez dni świątecznych</b>	<b>3,58</b>	<b>3,42</b>	<b>3,39</b>	<b>3,35</b>


### Wyniki statystyczne prognozowania

W zależności od hiperparametrów dobieranych metodą eksperymentalną, takich jak: wykładnik wagowy  $m$ , liczba iteracji, liczba klastrów  $M$  oraz wartość minimalnego gradientu zastosowanego w algorytmie optymalizacyjnym, otrzymać można wiele modeli numerycznych prognozy. Dla wykładnika wagowego  $m = 2,0$ , liczby iteracji równej 100 oraz gradientu minimalnego  $10^{-5}$ , średni błąd MAPE dla całego roku 2018 poddanej testowaniu kształtował się na

poziomie 4,18%, przy liczbie klastrów  $M = 365$ . Wartości błędów MAPE dla danych testujących z roku 2018, przy zastosowaniu wartości hiperparametrów wymienionych powyżej, dla różnej liczby klastrów zostały przedstawione w tabeli 3. Wartości hiperparametrów były dobierane na zbiorze walidacyjnym wyszczególnionym ze zbioru treningowego (około 20% danych treningowych).

W przypadku pominięcia specyficznych, pod względem kształtu krzywej obciążenia, dni świątecznych, dokładność prognozy wzrosła, a błąd MAPE zmalał do 3,35%. Dni, które zostały pominięte w prognozie całościowej to w szczególności: 1, 6 stycznia; 1, 2 kwietnia (Wielkanoc); 1, 2, 3 maja, 31 maja (Boże Ciało); 15 sierpnia (Święto Wojska Polskiego); 1, 11 listopada; 24, 25, 26 grudnia (Wigilia i Boże Narodzenie).





Rys. 2. Zapotrzebowanie mocy wraz z prognozą dla wybranego tygodnia roku 2018

Na rysunku 2 przedstawiono znormalizowane wykresy zapotrzebowania na moc w KSE, wraz z krzywymi progностycznymi oraz błędem MAPE testowania dla każdego dnia w wybranym tygodniu (8.01.2018÷14.01.2018 roku).

Najlepsze dopasowanie krzywej prognozy do krzywej obciążenia rzeczywistego można zaobserwować dla środy i czwartku (wartość błędu MAPE wyniosła odpowiednio 0,80% i 0,91%). Natomiast najmniej dokładne dopasowanie występuje w przypadku piątku – błąd MAPE wyniósł tu 3,70%, co oznacza ponad 4-krotnie gorszą dokładność prognozy niż dla środy.

Dalsze badania dotyczyły, między innymi, wpływu wykładnika wagowego  $m$  na dokładność prognozy. W badaniach podlegał on modyfikacjom od wartości 1 do 2, przy czym najlepsze wyniki otrzymano dla  $m = 1,15$ , liczby iteracji równej 500 oraz gradientu minimalnego  $10^{-12}$ . Jak podano w tabeli 4, średni błąd MAPE testowania, dla liczby klastrów  $M = 365$ , wyniósł w tym przypadku 3,78%, a przy pominięciu dni świątecznych spadł do wartości 3,04%. Badania numeryczne dla mniejszej liczby klastrów niż 365 wykazały nieznaczne pogorszenie dokładności prognozy.

Wyniki uzyskane po zmodyfikowaniu hiperparametrów do wartości wymienionych powyżej, zostały przedstawione w tabeli 4.

Zaobserwowano względny wzrost dokładności o około 10%, mierzony spadkiem błędu MAPE testowania z poziomu 3,35% do 3,04%. Można zauważyć tu pewne nasycenie poziomu dokładności, ponieważ zarówno dla liczby klastrów  $M=52$ ,  $M=104$ ,  $M=365$  błąd MAPE oscyluje w przedziale (3,04÷3,06)%, zatem rozrzut wartości jest dość mały, na poziomie 0,02%. Jest to znacznie mniej niż analogiczny rozrzut dla wartości MAPE w tabeli 3, gdzie rozrzut ten wyniósł 0,07%.

Tabela 4. Zestawienie błędów MAPE dla roku 2018, dla hiperparametrów:  $m = 1,15$ , gradient minimalny  $10^{-12}$  przy różnej liczbie klastrów

Miesiąc	Błąd MAPE testowania [%]			
	$M=12$	$M=52$	$M=104$	$M=365$
styczeń	3,21	2,74	2,85	2,91
lut	3,54	3,27	3,24	3,23
marzec	5,18	5,24	5,27	5,19
kwiecień	4,29	3,86	3,73	3,79
maj	6,02	5,81	5,82	5,83
czerwiec	2,77	2,57	2,57	2,61
lipiec	2,00	1,74	1,74	1,81
sierpień	3,74	3,55	3,54	3,48
wrzesień	1,83	1,52	1,49	1,41
październik	3,14	2,95	2,95	2,87
listopad	5,58	5,51	5,42	5,32
grudzień	6,99	6,82	6,76	6,79
<b>Średnia</b>	<b>4,04</b>	<b>3,81</b>	<b>3,79</b>	<b>3,78</b>
<b>Średnia bez dni świątecznych</b>	<b>3,32</b>	<b>3,05</b>	<b>3,06</b>	<b>3,04</b>

Interesujące jest porównanie błędów prognozy przy uwzględnieniu (wylimitowaniu) trendu liniowego. W tabeli 5 przedstawiono statystyczne wartości średnich błędów MAPE uzyskane dla danych z roku 2018 przy różnej liczbie klastrów uwzględnionych w grupowaniu danych. Zastosowano identyczne wartości parametrów algorytmu.

Tabela 5. Zestawienie błędów MAPE dla roku 2018 z uwzględnieniem trendu liniowego (1) przy różnej liczbie klastrów

Rok 2018	Błąd MAPE testowania [%]			
	$M=12$	$M=52$	$M=104$	$M=365$
<b>Średnia roczna</b>	<b>3,61</b>	<b>3,62</b>	<b>3,62</b>	<b>3,61</b>
<b>Średnia bez dni świątecznych</b>	<b>2,85</b>	<b>2,87</b>	<b>2,87</b>	<b>2,86</b>

Można zauważyć istotne zmniejszenie wartości błędu MAPE dla każdej liczby klastrów. Wartość roczna MAPE wyniosła tym razem w najlepszym przypadku 3,61% oraz 2,85% (przy nieuwzględnieniu specyficznych dni świątecznych). Interesujące jest, że po wylimitowaniu trendu błąd MAPE pozostawał na podobnym poziomie niezależnie od liczby zastosowanych klastrów.

Porównanie uzyskanych wyników z innymi prezentowanymi w literaturze światowej jest trudne przy zachowaniu pełnej obiektywności, gdyż dotyczą różnych systemów i stosowanych metod. Podamy przykładowo dwa rozwiązania stosujące technikę rozmytą przetwarzania danych. Przykładowo, średnie błędy MAPE prognozy w modelu prezentowanym w [14] i opartym również na grupowaniu C-means oraz sieci RBF są rzędu 3÷5%, przy czym dotyczyły prognozowania krótkoterminowego. Praca [15] przedstawia modele długoterminowe przy zastosowaniu techniki zbiorów rozmytych. Najlepsze wyniki w postaci błędu MAPE = 5,73% uzyskano dla modelu rozmytego współpracującego z siecią MLP. Dotyczą one rzeczywistych danych wziętych z bazy ISO New England market. Ze względu na zupełnie inną specyfikę badanego obszaru elektroenergetycznego, trudno jest jednak o obiektywną ocenę uzyskanych wyników.

## Wnioski

Przeprowadzone badania grupowania rozmytego, a w szczególności algorytmu C-means w roli głównej predyktora wykazały, że grupowanie rozmyte stanowi dobre narzędzie do prognozowania obciążeń z dowolnym wyprzedzeniem czasowym w Krajowym Systemie Elektroenergetycznym.

W przypadku prognozowania długoterminowego w którym wykorzystano do uczenia modelu prognozy dane z lat 2014-2017 a prognozę przedstawiono dla całego roku 2018 (wyprzedzenie od 1 dnia do 1 roku) uzyskano wysoką dokładność, mierzoną błędem MAPE na danych testujących nie uczestniczących w uczeniu (dla całego roku 2018), na poziomie 3,78%. W przypadku pominięcia czternastu specyficznych dni świątecznych możliwa była dalsza redukcja tego błędu do poziomu MAPE=3,04%.

Przebadano wpływ liczby klastrów rozmytych na dokładność prognozy. Najlepsze wyniki w sensie dokładności osiągnięte zostały dla liczby odpowiadającej liczbie dni w prognozowanym roku.

**Autorzy:** dr inż. Tomasz Ciechulski, Wojskowa Akademia Techniczna, Instytut Systemów Elektronicznych, Zakład Systemów Informacyjno-Pomiarowych, ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa, E-mail: [tomasz.ciechulski@wat.edu.pl](mailto:tomasz.ciechulski@wat.edu.pl);  
prof. dr hab. inż. Stanisław Osowski, Wojskowa Akademia Techniczna, Instytut Systemów Elektronicznych, Zakład Systemów Informacyjno-Pomiarowych, ul. gen. Sylwestra Kaliskiego 2, 00-908 Warszawa, E-mail: [sto@iem.pw.edu.pl](mailto:sto@iem.pw.edu.pl).

## LITERATURA

- [1] Ciechulski T., Osowski S., *Prognozowanie zapotrzebowania mocy w KSE z horyzontem dobowym przy zastosowaniu zespołu sieci neuronowych*, Przegląd Elektrotechniczny, nr 9/2018, ss. 108-112
- [2] Pappadimitis E., Sapatinas T., *Short-term load forecasting: the similar shape functional time-series predictor*, IEEE Transactions on Power Systems, vol. 28, no. 4, ss. 3818-3825, 2013
- [3] Marzecki J., *Metody prognozowania obciążeń terenowych stacji SN/nn*, Przegląd Elektrotechniczny, nr 4/2017, ss. 26-29
- [4] Viegas J.L., Vieira S.M., Sousa J.M.C., *Fuzzy clustering and prediction of electricity demand based on household characteristics*, 16<sup>th</sup> World Congress of the International Fuzzy Systems Association, 2015
- [5] MathWorks, *Matlab manual user's guide*, Natick, 2018
- [6] Osowski S., *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2013
- [7] Polskie Sieci Elektroenergetyczne, Dane systemowe <https://www.pse.pl/dane-systemowe>
- [8] Wan H., *Load forecasting via deep neural network*, Procedia Computer Science, 2017, vol. 122, ss. 308-314
- [9] Shah S., Nagaraja H. N., Chakravorty J., *Short term load forecasting model for UGVCL, MGVCCL, DGVCL and PGVCL using ANN*, International Journal of Recent Trends in Electrical & Electronics Eng., 2017, vol. 5, pp. 21-30.
- [10] Anuar N., Zakaria Z., *Electricity load profile determination by using fuzzy C-means and probability neural network*, Energy Procedia 14 (2012) 1861-1869.
- [11] Jang J.S.R., Sun C.T., Mizutani E., *Neuro-fuzzy and soft computing*, 1997, Prentice Hall, New York.
- [12] Parol M., *Prognozowanie ultrakrótkoterminowe mocy generowanej w odnawialnych źródłach energii z wykorzystaniem logiki rozmytej*, Przegląd Elektrotechniczny, nr 6/2014, ss. 265-268
- [13] Baczyński D., Piotrowski P., *Prognozowanie dobowej produkcji energii elektrycznej przez turbinę wiatrową z horyzontem 1 doby*, Przegląd Elektrotechniczny, nr 9/2014, ss. 113-117
- [14] Zhu Y, He Y., *Short-term load forecasting model using fuzzy C means based radial basis function network*, Sixth International Conference on Intelligent Systems Design and Applications, IEEE Xplore, vol.12, 2006.
- [15] Daneshi H.; Shahidehpour M; Choobbari A. L., *Long-term load forecasting in electricity market*, 2008 IEEE International Conference on Electro/Information Technology, Ames, IA, USA.