

Krótkoterminowe prognozowanie bazowego obciążenia odbiorcy komunalno-bytowego z wykorzystaniem danych historycznych

Short-term forecasting of the baseline load of the residential customer using historical data

Streszczenie. W artykule omówiono metodę prognozowania dobowego przebiegu obciążenia odbiorcy komunalno-bytowego. Opisana metoda bazuje na założeniach metody naiwnej i wykorzystuje historyczne dane dotyczące zużycia energii elektrycznej przez analizowanego odbiorcę. Zaproponowany model prognostyczny może zostać zastosowany do wyznaczenia prognozy obciążenia bazowego, wykorzystywanej przez system zarządzania energią w budynku wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Abstract. This paper discusses a method for forecasting the daily load profile of a residential consumer. The method described is based on the assumptions of the persistence (naive) method and uses historical data on the electricity consumption by the analyzed customer. The proposed forecasting model can be applied to determine the consumer's baseline load forecast, used by the energy management system in a building equipped with a photovoltaic source, energy storage and shiftable (controllable) loads.

Słowa kluczowe: odbiorca komunalno-bytowy, obciążenie bazowe, krótkoterminowe prognozowanie obciążenia, metoda naiwna
Keywords: residential load, baseline load, short-term load forecasting, persistence (naive) method

Wprowadzenie

Prosumenckie źródła fotowoltaiczne (PV), wraz z domowymi magazynami energii oraz odbiornikami o elastycznym czasie załączania, umożliwiając budowę lokalnych (budynkowych) systemów bilansowania zapotrzebowania odbiorców komunalno-bytowych. Funkcję tę realizują układy określane jako Home Energy Management System (HEMS) [1]. Do prawidłowego zaplanowania pracy poszczególnych urządzeń, oprócz prognozy generacji źródła PV [2], konieczne jest dysponowanie prognozą bazowego obciążenia odbiorcy. Uwzględniając tę prognozę, system HEMS określa moce oraz okresy ładowania i rozładowania magazynu, a także momenty włączenia odbiorników o znanych profilach poboru energii i sterowanym czasie załączania [3].

Horyzont czasowy prognozy obciążenia może być różny. Pierwszym rodzajem prognoz są prognozy długoterminowe [4], obejmujące zwykle okres od roku do kilkudziesięciu lat. Tego typu prognozy są wykorzystywane w procesie strategicznego planowania rozwoju systemu elektroenergetycznego. Drugim rodzajem prognoz są prognozy średnioterminowe [5], przygotowywane na okres od tygodnia do roku. Znajdują one zastosowanie m.in. przy planowaniu zabiegów eksploatacyjnych. Kolejną grupę prognoz stanowią prognozy krótkoterminowe [6], przygotowywane najczęściej w rozdzielczości godzinowej dla okresu od kilku do kilkudziesięciu godzin. Właśnie tego typu prognozy są wykorzystywane do planowania operacyjnego w kolejnej dobie. Niekiedy wyróżnia się jeszcze prognozy o krótszym horyzoncie czasowym i wyższej rozdzielczości (ultrakrótkoterminowe) [7], stosowane w bieżącym bilansowaniu zapotrzebowania.

Kolejnym czynnikiem różnicującym rodzaje prognoz jest poziom agregacji, dla którego są one opracowywane [8]. Można tutaj wyróżnić prognozy systemowe, sporządzane dla całego systemu połączonego (np. europejskiego) lub poszczególnych systemów krajowych, prognozy regionalne, wykonywane dla obszarów działania pojedynczych operatorów systemów dystrybucyjnych, prognozy grupowe dla odbiorców o podobnym charakterze zużycia oraz prognozy indywidualne, opracowywane dla pojedynczych odbiorców.

Z punktu widzenia tematyki niniejszego artykułu przedmiotem zainteresowania są indywidualne prognozy krótkoterminowe (dobowe w rozdzielczości godzinowej), sporządzane dla odbiorców komunalno-bytowych.

Prawidłowe prognozowanie obciążenia odbiorcy komunalno-bytowego jest trudnym zadaniem ze względu na znaczną zmienność tego obciążenia. Do typowych czynników mających istotny wpływ na zapotrzebowanie odbiorcy komunalno-bytowego należą: tryb życia i nawyki mieszkańców [9], w tym różne wydarzenia medialne [10], pory roku determinujące m.in. dostępność światła dziennego [11] oraz warunki pogodowe, wpływające na komfort cieplny w budynku [12]. Oprócz tego wpływ na zużycie energii przez gospodarstwa domowe mogą mieć różnego typu programy promujące oszczędność energii [13], a także wzrastająca świadomość ekologiczna społeczeństwa [14]. Obecnie pojawiają się również dodatkowe czynniki wpływające na zapotrzebowanie tej grupy odbiorców. Można do nich zaliczyć m.in. rozwój infrastruktury umożliwiającej zautomatyzowane zarządzanie energią w budynkach [15], dynamiczne ceny energii [16] lub zalecane przez operatorów okresy, w których należy zwiększyć lub zmniejszyć zużycie energii elektrycznej [17].

W literaturze przedmiotu można znaleźć propozycje metod krótkoterminowego prognozowania obciążenia odbiorców komunalno-bytowych, w których uwzględnia się wpływ niektórych z wymienionych wyżej czynników. Przykładowo w pracy [18] uwzględniono wpływ warunków pogodowych, w artykule [19] wpływ pór roku, a w pracy [20] nawyki mieszkańców w połączeniu z charakterystyką używanych urządzeń gospodarstwa domowego. Z kolei w artykule [21] opisano metodę prognozowania dla budynków niskoemisyjnych, a w pracy [22] dla budynków z rozbudowaną automatyką sterującą urządzeniami. Wymienione metody wykorzystują zaawansowane techniki obliczeniowe, takie jak sieci neuronowe [18, 21, 22], uczenie maszynowe [20] lub optymalizację metaheurystyczną [19], w związku z tym są one zbyt skomplikowane, aby można było je łatwo zaimplementować w systemie HEMS. Zatem w tym obszarze zastosowań potrzebne jest opracowanie znacznie prostszej metody, która pozwoli na wyznaczenie krótkoterminowej prognozy bazowego obciążenia odbiorcy komunalno-bytowego cechującej się zadowalającą dokładnością, przy jednoczesnej minimalizacji zasobów obliczeniowych niezbędnych do jej sporządzenia. Jest to główny cel niniejszego artykułu.

Zaproponowana w artykule metoda prognozowania opiera się na założeniach metody naiwnej, przy czym w metodzie tej – oprócz wartości średniej obciążenia z kilku dni poprzedzających – do przygotowania prognozy


wykorzystano również inne sposoby opisu zmienności obciążenia (obciążenie „typowe” i statystycznie najczęstsze), omówione w dalszej części artykułu. Do kalibracji i walidacji metody wykorzystano dane pomiarowe pochodzące z liczników energii zainstalowanych u odbiorców z grupy taryfowej G11. Uzyskane wyniki prognoz porównano z wynikami otrzymanymi przy zastosowaniu metody naiwnej w wersji podstawowej (obciążenie średnie z kilku poprzednich dni). Finalnie, zaproponowany model prognostyczny zastosowano do wyznaczenia prognozy obciążenia bazowego wybranego odbiorcy.

Metoda naiwna w prognozowaniu obciążenia


Metoda naiwna nazywana jest również w literaturze angielskiej „persistence method” [23], co można przetłumaczyć jako „metoda trwałości”. To określenie dobrze odzwierciedla podstawę metody, którą jest założenie, że wszystko pozostanie bez zmian, czyli wartość prognozowana będzie taka sama jak ostatni pomiar. Zgodnie z tym założeniem obciążenie odbiorcy w godzinie h dnia n będzie takie samo jak obciążenie w tej samej godzinie w dniu poprzednim (wariant $n - 1$) lub w takim samym dniu tydzień temu (wariant $n - 7$). W innym wariantcie metody naiwnej wykorzystuje się kilka dni poprzedzających (kolejnych lub kolejnych takich samych), dla których obliczana jest wartość średnia obciążenia w poszczególnych godzinach, stanowiąca prognozę zapotrzebowania w analizowanym dniu n .

Propozycja metody prognozowania obciążenia odbiorcy komunalno-bytowego bazująca na metodzie naiwnej


Ponieważ obciążenie odbiorcy komunalno-bytowego jest silnie skorelowane z obecnością domowników i zwykle wykazuje pewną powtarzalność tygodniową, w niniejszym artykule zastosowane zostanie podejście oparte na wykorzystaniu kilku kolejnych takich samych dni poprzedzających (dni $n - 7$, $n - 14$, $n - 21$...). Na rys. 1 ÷ 4 dla wybranego odbiorcy komunalno-bytowego przedstawiono dobowe grafiki obciążenia dla czterech kolejnych wtorków. Dane te zostaną wykorzystane do zilustrowania zaproponowanej w artykule metody prognozowania zapotrzebowania.




Rys. 1. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 28$ (wtorek, 21.05.2019, zużycie dobowe 6,86 kWh)



Rys. 2. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 21$ (wtorek, 28.05.2019, zużycie dobowe 8,32 kWh)




Rys. 3. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 14$ (wtorek, 04.06.2019, zużycie 5,57 kWh)



Rys. 4. Obciążenie odbiorcy w poszczególnych godzinach w dniu $n - 7$ (wtorek, 11.06.2019, zużycie dobowe 6,89 kWh)

W pierwszym kroku proponowanej metody, na podstawie zarejestrowanych profili obciążenia odbiorcy (rys. 1 ÷ 4), wyznacza się wartości średnie zużycia w poszczególnych godzinach doby, co ilustruje rys. 5.



Rys. 5. Średnie obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 6,91 kWh)

W metodzie naiwnej obliczone średnie obciążenia godzinowe stanowiłyby wprost prognozę zapotrzebowania w analizowanym dniu (w dniu n , czyli w tym przypadku we wtorek, 18.06.2019), co można wyrazić wzorem:


$$E_{np}(h) = E_{sr}(h) = \frac{1}{N} \sum_{i=1}^N E_{n-7i}(h), \quad (1)$$

gdzie:


- $E_{np}(h)$ - prognozowane zużycie energii w dniu n w godzinie h ,
- $E_{sr}(h)$ - średnie zużycie energii w godzinie h ,
- $E_{n-7i}(h)$ - zużycie energii w godzinie h w kolejnych takich samych dniach poprzedzających, $i = 1, 2, \dots, N$,
- N - liczba kolejnych takich samych dni poprzedzających, dla których wyznaczane jest zużycie średnie.

W niniejszym artykule do wyznaczenia prognozy zapotrzebowania proponuje się natomiast zastosowanie również innych niż grafik średni, sposobów opisu zmienności obciążenia odbiorcy. W tym celu wykorzystany zostanie tzw. grafik „typowy” oraz grafik statystycznie najczęstszy.

Metoda tworzenia „typowego” grafiku obciążenia odbiorcy została zaproponowana w pracy [24]. Polega ona na tym, że w pierwszej kolejności godzinowe zużycie energii w analizowanych N dniach, np. dla czterech wtorków pokazanych na rys. 1 ÷ 4, porządkuje się od wartości największej do najmniejszej. Następnie z tak uporządkowanych wartości oblicza się średnie dla poszczególnych godzin. W kolejnym kroku, obliczone średnie z wartości uporządkowanych przypisuje się do odpowiednich przedziałów czasowych, wykorzystując wyznaczone wcześniej średnie obciążenie odbiorcy dla wartości chronologicznych (rys. 5). Przypisanie polega na tym, że największą wartość średnią z uporządkowanych wartości obciążeń godzinowych przypisuje się do przedziału czasowego, w którym wystąpiła największa wartość średnia z obciążeń chronologicznych. Drugą największą wartość średnią z obciążeń uporządkowanych przypisuje się do godziny, w której wystąpiła druga z kolei największa wartość średnia z obciążeń chronologicznych, trzecią do trzeciej, itd., co zilustrowano na rys. 6. W efekcie otrzymuje się tzw. grafik „typowy” przedstawiony na rys. 7.




Rys. 6. Ilustracja metody tworzenia „typowego” grafiku obciążenia odbiorcy komunalno-bytowego



Rys. 7. „Typowe” obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 6,91 kWh)

W trzecim kroku proponowanej metody prognozowania zapotrzebowania tworzony jest grafik obciążeń statystycznie najczęściej występujących w poszczególnych godzinach doby (grafik statystycznie najczęstszy). W tym celu dla N analizowanych takich samych dni poprzedzających najpierw określa się maksymalną wartość godzinowego zużycia energii ($E_{max}(h)$), jakie wystąpiło w tym okresie. Następnie obliczane są granice poszczególnych przedziałów zużycia równe (mniejsza szerokość dwóch pierwszych przedziałów umożliwia zróżnicowanie bardzo niskich obciążeń): $(0, 0,05E_{max}(h)]$, $(0,05E_{max}(h), 0,1E_{max}(h)]$, $(0,1E_{max}(h), 0,2E_{max}(h)]$, $(0,2E_{max}(h), 0,3E_{max}(h)]$, ..., $(0,9E_{max}(h), E_{max}(h)]$. Dla tak zdefiniowanych przedziałów sprawdza się, ile razy obciążenie w danej godzinie w ciągu N analizowanych dni zawierało się w poszczególnych przedziałach i wyszukuje się przedział z największą liczbą zliczeń. Środek tego przedziału przyjmowany jest jako obciążenie statystycznie najczęściej występujące w danej godzinie doby w ciągu N analizowanych dni. Rysunek 8 przedstawia grafik statystycznie najczęstszy utworzony opisaną metodą dla czterech wtorków, dla których dobowe przebiegi obciążenia zostały zilustrowane na rys. 1 ÷ 4.



Rys. 8. Statystycznie najczęstsze obciążenie odbiorcy komunalno-bytowego w poszczególnych godzinach wyznaczone dla czterech kolejnych wtorków (zużycie dobowe 7,08 kWh)

Opracowane grafiki: średni (rys. 5), „typowy” (rys. 7) i statystycznie najczęstszy (rys. 8), określone dla N analizowanych takich samych dni poprzedzających, w kolejnym kroku są wykorzystywane do wyznaczenia prognozy zapotrzebowania dla rozpatrywanego dnia n . W tym celu dokonuje się odpowiedniego „złożenia” tych grafików z uwzględnieniem wag, co wyraża wzór:


$$E_{np}(h) = w_1 E_{sr}(h) + w_2 E_{typ}(h) + w_3 E_{st}(h), \quad (2)$$

gdzie:

- $E_{typ}(h)$ - „typowe” zużycie energii w godzinie h ,
- $E_{st}(h)$ - statystycznie najczęstsze zużycie energii w godzinie h ,

w_1, w_2, w_3 - wagi poszczególnych składników prognozy (należy pamiętać, że dla $w_1 = 1$ i $w_2 = w_3 = 0$ otrzymuje się model naiwny wyrażony wzorem (1)).

Na rys. 9 przedstawiono prognozę wygasła zapotrzebowania odbiorcy w dniu n (wtorek, 18.06.2019), określoną zaproponowaną metodą dla czterech kolejnych wtorków poprzedzających, przy założeniu jednakowych wag ($w_1 = w_2 = w_3 = 1/3$) poszczególnych składników prognozy.



Rys. 9. Prognoza wygasła zapotrzebowania na energię elektryczną w dniu n (wtorek, 18.06.2019) określona zaproponowaną metodą (zużycie rzeczywiste 8,44 kWh, zużycie prognozowane 6,97 kWh)

Zależność (2) definiuje, oparty na założeniach metody naiwnej, hybrydowy model prognostyczny, wykorzystujący historyczne dane pomiarowe. Model ten należy poddać odpowiedniej kalibracji, polegającej na określeniu optymalnej liczby kolejnych takich samych dni poprzedzających (N) oraz wag poszczególnych składników prognozy (w_1, w_2, w_3).

Kalibracja modelu prognostycznego

Do kalibracji (a następnie do walidacji) zaproponowanego modelu prognostycznego (2) wykorzystano roczne dane pomiarowe dotyczące zużycia energii dla dziesięciu wybranych odbiorców z obszaru miejsko-wiejskiego zlokalizowanych w promieniu 30 km. Wykorzystane dane miały rozdzielczość godzinową i pochodziły z liczników rozliczeniowych energii elektrycznej zainstalowanych w tych odbiorców. W tabeli 1 podano najważniejsze dane charakteryzujące rozpatrywanych odbiorców. Wybrani odbiorcy zostali losowo podzieleni na dwie równoliczne grupy. Dane pomiarowe dla odbiorców z grupy pierwszej (O1, O3, O4, O7 i O9) zostały wykorzystane do kalibracji modelu, natomiast dane dla odbiorców z grupy drugiej (O2, O5, O6, O8 i O10) do jego walidacji, co opisano w kolejnej części artykułu.

Tabela 1. Dane charakteryzujące odbiorców wykorzystanych do kalibracji i walidacji zaproponowanego modelu prognostycznego (2)

Odbiorca	Moc umowna, kW	Moc szczytowa (godzinowa), kW	Roczne zużycie energii, kWh
O1	6	3,21	3 978
O2	16	3,73	3 812
O3	20	5,54	3 737
O4	14	3,40	3 719
O5	15	3,58	3 649
O6	21	5,32	3 625
O7	17,3	3,54	3 537
O8	15	3,16	2 886
O9	5,7	3,28	2 720
O10	17,3	2,39	2 313

Kalibracja zaproponowanego modelu prognostycznego (2) polegała na dobraniu liczby kolejnych takich samych dni poprzedzających (N) oraz wartości wag (w_1, w_2, w_3) w taki sposób, aby zminimalizować błędy prognozy zapotrzebowania w dniu n , w stosunku do rzeczywistego zużycia, jakie wystąpiło w tym dniu. Poszukując optymalnych wartości N oraz w_1, w_2 i w_3 obliczano błędy zdefiniowane zależnościami:

$$MAE = \frac{1}{24} \sum_{h=1}^{24} |E_{nr}(h) - E_{np}(h)|, \quad (3)$$

$$RMSE = \sqrt{\frac{1}{24} \sum_{h=1}^{24} (E_{nr}(h) - E_{np}(h))^2}, \quad (4)$$

$$MAPE = \frac{1}{24} \sum_{h=1}^{24} \left| \frac{E_{nr}(h) - E_{np}(h)}{E_{nr}(h)} \right| \cdot 100\%, \quad (5)$$

gdzie:

$E_{nr}(h)$ - rzeczywiste zużycie energii w dniu n w godzinie h .

Kalibracja modelu (2) została wykonana dwuetapowo. W pierwszym etapie poszukiwano optymalnej liczby dni poprzedzających (N), przy przyjęciu jednakowych wartości wag poszczególnych składników prognozy ($w_1 = w_2 = w_3 = 1/3$). Obliczenia wykonano dla pięciu odbiorców, dla których losowo wybierano różne dni tygodnia (dni n) w różnych okresach roku. Prognozy dla tych dni były wyznaczane dla $N = 2, 3, \dots, 10$. Przykładowe wyniki obliczeń przedstawiono w tabeli 2 (wyłuszczone liczbę dni poprzedzających, dla których uzyskano najmniejszą wartość błędu $MAPE$). Otrzymane wyniki wskazują, że liczba takich samych dni poprzedzających (N), dla których uzyskano najmniejsze wartości błędów określonych zależnościami (3) ÷ (5) wynosi zwykle od 3 do 5.

Tabela 2. Błędy prognozy uzyskane modelem prognostycznym (2) dla różnej liczby takich samych dni poprzedzających N

Odbiorca	Dzień prognozy (dzień n)	Liczba dni poprzedzających (N)	Błędy prognozy		
			MAE kWh	RMSE kWh	MAPE %
O3	08.08	2	0,13	0,25	30,17
		3	0,13	0,26	32,21
		4	0,13	0,25	29,82
		5	0,12	0,24	27,70
		6	0,13	0,25	33,93
		7	0,13	0,25	33,47
		8	0,14	0,26	34,55
		9	0,14	0,25	34,17
O4	12.06	10	0,14	0,26	34,68
		2	0,14	0,23	37,85
		3	0,12	0,20	33,33
		4	0,14	0,28	36,30
		5	0,16	0,28	37,48
		6	0,16	0,28	35,62
		7	0,16	0,28	37,46
		8	0,16	0,27	36,72
O9	02.11	9	0,16	0,26	38,51
		10	0,16	0,28	40,50
		2	0,19	0,23	34,95
		3	0,17	0,21	28,93
		4	0,16	0,22	25,43
		5	0,17	0,21	27,17
		6	0,15	0,21	25,62
		7	0,17	0,22	27,71
		8	0,17	0,21	26,64
		9	0,18	0,22	27,12
		10	0,19	0,24	28,90

W drugim etapie kalibracji wyznaczono optymalne wartości współczynników w_1 , w_2 i w_3 , przyjmując, że liczba takich samych dni poprzedzających N jest równa 3, 4 lub 5. Obliczenia wykonano przy zastosowaniu algorytmu optymalizacyjnego PSO (Particle Swarm Optimization) [25], przy założeniu, że funkcją celu jest minimalizacja błędu $MAPE$ (5), a wartości wag spełniają następujące ograniczenia: $w_1, w_2, w_3 \in [-1, 1]$, $w_1 + w_2 + w_3 = 1$. Przykładowe wyniki obliczeń zestawiono w tabeli 3. Analiza pełnego zbioru uzyskanych wyników wykazała, że dla większości przypadków $w_1 = 1$, a wartości w_2 i w_3 zawierają się zwykle w przedziale od -0,3 do 0,3 i mają taką samą wartość bezwzględną, ale przeciwne

znaki (w_2 częściej jest dodatni). Dla zoptymalizowanych wartości wag błędy $MAPE$ (tabela 3) osiągają niższe wartości, w porównaniu z wartościami uzyskanymi dla jednakowych współczynników wagowych (tabela 2).

Tabela 3. Wartości wag poszczególnych składników prognozy modelu (2) minimalizujące błąd $MAPE$

Odbiorca	Dzień prognozy (dzień n)	Liczba dni poprzedzających (N)	Wagi poszczególnych składników prognozy			MAPE %
			w_1	w_2	w_3	
O3	01.08	3	1,00	0,07	-0,07	23,16
		4	1,00	-0,11	0,11	23,49
		5	1,00	0,11	-0,11	21,97
	08.08	3	1,00	-0,05	0,05	28,43
		4	1,00	-0,07	0,07	27,86
		5	1,00	-0,05	0,05	25,54
O4	12.06	3	-0,04	1,00	0,04	25,64
		4	1,00	-0,07	0,07	32,77
		5	-0,10	1,00	0,10	32,45
	12.10	3	1,00	0,39	-0,39	29,54
		4	0,62	0,38	0,00	25,32
		5	0,27	0,60	0,13	27,80
O9	02.11	3	0,00	0,89	0,10	26,76
		4	-0,26	1,00	0,26	22,55
		5	0,10	0,96	-0,06	26,00
	07.12	3	1,00	-0,08	0,08	26,75
		4	1,00	0,17	-0,17	30,73
		5	1,00	-0,20	0,20	25,90

Walidacja modelu prognostycznego

Uwzględniając wyniki otrzymane podczas kalibracji modelu prognostycznego (2), przy jego walidacji przyjęto, że liczba takich samych dni poprzedzających (N) wynosi od 3 do 5, a współczynniki wagowe są równe $w_1 = 1$, $w_2 = 0,3$, $w_3 = -0,3$. Dla takich parametrów modelu wyznaczono prognozy dla odbiorców z drugiej grupy (O2, O5, O6, O8 i O10). Wartości błędów prognozy dla wybranych przypadków zestawiono w tabeli 4, przy czym, dla porównania, podano również wartości błędów uzyskane przy zastosowaniu metody naiwnej (1). W większości przeanalizowanych przypadków błędy prognozy uzyskane za pomocą zaproponowanego modelu (2), w szczególności błąd $MAPE$, były niższe niż błędy uzyskane dla metody naiwnej (1). Pozwala to wnioskować o przydatności zaproponowanego modelu do prognozowania bazowego obciążenia odbiorców komunalno-bytowych.

Tabela 4. Porównanie dokładności prognoz uzyskanych metodą naiwną (1) z prognozami uzyskanymi zaproponowanym modelem (2)


Odbiorca	Dzień prognozy n	Liczba dni poprzedzających N	Metoda naiwna (1)			Model prognostyczny (2)		
			MAE kWh	RMSE kWh	MAPE %	MAE kWh	RMSE kWh	MAPE %
O2	25.03	3	0,12	0,18	39,34	0,12	0,18	38,35
		4	0,11	0,17	34,39	0,11	0,17	32,72
		5	0,11	0,17	30,98	0,12	0,20	35,84
O5	29.05	3	0,17	0,28	34,62	0,20	0,35	35,47
		4	0,13	0,21	25,97	0,14	0,26	23,86
		5	0,10	0,17	20,77	0,08	0,11	17,15
O10	13.11	3	0,11	0,18	30,59	0,11	0,19	28,43
		4	0,11	0,18	30,30	0,11	0,19	29,68
		5	0,10	0,17	27,06	0,10	0,17	25,93

Zastosowanie zaproponowanego modelu prognostycznego do określania bazowego obciążenia odbiorcy komunalno-bytowego

W omówionych dotychczas badaniach korzystano z pomiarów zarejestrowanych przez liczniki rozliczeniowe należące do OSD. Wykorzystane pomiary stanowiły więc całkowite obciążenie analizowanych odbiorców, obejmujące zarówno ich obciążenia bazowe, na które składają się odbiorniki o niesterowanym czasie załączania (np. oświetlenie, lodówki, telewizory, komputery, kuchenki, drobny sprzęt AGD,

pompy obiegowe CO i CWU, itp.), jak i obciążenia dodatkowe (potencjalnie sterowalne), na które składają się odbiorniki, których czas załączenia można zaprogramować (pralki, zmywarki, suszarki do ubrań, bojler i grzejniki elektryczne, klimatyzatory, itp.). Dla takich pomiarów przeprowadzono kalibrację i walidację zaproponowanego modelu prognostycznego (2). Celem niniejszego artykułu jest opracowanie metody prognozowania bazowego (nie całkowitego) obciążenia odbiorcy komunalno-bytowego. W tej części przedstawiono wyniki działania zaproponowanego modelu prognostycznego (2) w tym zastosowaniu.

Do weryfikacji przydatności modelu (2) do prognozowania obciążenia bazowego wykorzystano wyniki pomiarów zarejestrowanych przez dedykowany system pomiarowy zainstalowany w budynku mieszkalnym należącym do jednego z autorów artykułu. System ten umożliwia rejestrację całkowitego obciążenia budynku, jak również rejestrację obciążenia odbiorników przeznaczonych do zdalnego załączania przez system HEMS (odbiorniki o sterowanym czasie załączania obejmują: zmywarkę, pralkę, suszarkę do ubrań oraz ładowarkę roweru elektrycznego). Zatem na podstawie takiego zbioru pomiarów można określić bazowe obciążenie budynku w poszczególnych dniach poprzedzających N , stanowiące podstawę do opracowania prognozy obciążenia bazowego w analizowanym dniu n . Przykładowe wyniki pomiarów, zarejestrowanych w sobotę, 31 sierpnia 2024 r., przedstawiono na rys. 10. W tym dniu obciążenie całkowite budynku wyniosło 19,32 kWh, a obciążenie bazowe było równe 15,94 kWh. Na obciążenie dodatkowe (3,38 kWh) złożyła się energia zużyta przez: zmywarkę (1,15 kWh), pralkę (0,5 kWh), suszarkę do ubrań (0,65 kWh) oraz ładowarkę roweru elektrycznego (1,05 kWh).



Rys. 10. Obciążenie bazowe oraz obciążenie dodatkowe (odbiorniki o sterowanym czasie załączania) analizowanego odbiorcy komunalno-bytowego w sobotę, 31 sierpnia 2024 r.


Efekty działania modelu prognostycznego (2) w zastosowaniu do prognozowania bazowego obciążenia odbiorcy komunalno-bytowego zostaną przedstawione na przykładzie prognoz wyznaczonych dla trzech kolejnych, takich samych dni roboczych (dni prognozy n obejmują środy: 3, 10 i 17 lipca 2024 r.). W obliczeniach przyjęto parametry modelu (2) podane w poprzedniej części artykułu. Prognozy wykonano dla $N = 3, 4, 5$ kolejnych takich samych dni poprzedzających. Wyniki podsumowujące przeprowadzone obliczenia zaprezentowano w tabeli 5. Z kolei na rys. 10 ÷ 13 porównano dobowe przebiegi zmierzzonego (rzeczywistego) obciążenia bazowego z przebiegami wyznaczonymi za pomocą modelu (2), dla $N = 5$ kolejnych takich samych dni poprzedzających.

Analizując uzyskane wyniki można zauważyć, że maksymalna różnica między rzeczywistym a prognozowanym bazowym zużyciem energii elektrycznej w rozpatrywanych dniach wynosi od 1 kWh do 1,6 kWh (około 10% zużycia dobowego). Z kolei błędy $MAPE$ zawierają się w przedziale od 20% do 30%. Otrzymana dokładność prognozy jest porównywalna z dokładnością, którą inni autorzy uzyskali dla tego rodzaju zadania prognostycznego (prognozowanie zapotrzebowania pojedynczego odbiorcy komunalno-bytowego) z wykorzystaniem znacznie bardziej zaawansowanych metod, opartych na sztucznych sieciach neuronowych. Przykładowo, błędy $MAPE$ dla prognoz dobowych dla okresu


rocznego, uzyskane dla 42 przeanalizowanych odbiorców przy wykorzystaniu metody zaproponowanej w artykule [26], zawierały się zwykle w granicach od 30% do 50%. Z kolei analizy wykonane w artykule [27] dla 1181 odbiorców wskazują, że dla odbiorców o największej zmienności obciążenia w tej grupie dobowe błędy $MAPE$ w miesiącu o najwyższym zapotrzebowaniu w ciągu roku kształtowały się na poziomie od kilkunastu do nawet 100%. Zatem dokładność prognoz bazowego obciążenia odbiorcy uzyskiwana z wykorzystaniem zaproponowanego modelu (2) jest zadowalająca, aby zaproponowana metoda mogła zostać zastosowana w systemie HEMS, służącym do zarządzania energią elektryczną w budynku mieszkalnym wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Tabela 5. Rzeczywiste i prognozowane bazowe zużycie energii oraz błędy prognoz obciążenia bazowego odbiorcy komunalno-bytowego uzyskane przy zastosowaniu zaproponowanego modelu (2)


Dzień prognozy n	Liczba dni poprzedzających N	Bazowe zużycie energii		Błędy prognozy		
		rzeczywiste, kWh	prognozowane, kWh	MAE kWh	RMSE kWh	MAPE %
03.07	3	11,79	10,92	0,13	0,18	25,34
	4		10,87	0,14	0,21	24,89
	5		10,84	0,12	0,19	22,30
10.07	3	12,49	11,89	0,11	0,16	23,00
	4		11,18	0,11	0,15	20,73
	5		10,88	0,10	0,14	18,14
17.07	3	12,39	12,36	0,16	0,24	29,80
	4		11,88	0,15	0,23	27,19
	5		11,29	0,16	0,25	27,25



Rys. 11. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 3 lipca 2024 r.



Rys. 12. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 10 lipca 2024 r.



Rys. 13. Rzeczywiste i prognozowane bazowe zużycie energii analizowanego odbiorcy komunalno-bytowego w środę, 17 lipca 2024 r.

Podsumowanie

Dobowe profile zapotrzebowania na energię elektryczną indywidualnych odbiorców komunalno-bytowych charakteryzują się dużą zmiennością, wynikającą z różnorodności zachowań tych odbiorców, stymulowanych dodatkowo przez szeroką gamę czynników zewnętrznych. W efekcie prognozowanie tego rodzaju przebiegów z odpowiednio wysoką dokładnością jest zadaniem skomplikowanym, wymagającym

często wykorzystania zaawansowanych metod obliczeniowych, bazujących na szerokim zakresie danych wejściowych. To sprawia, że tak rozbudowane metody mogą stwarzać problemy w zastosowaniu w budynkowych systemach zarządzania energią HEMS. Istnieje zatem konieczność poszukiwania prostszych rozwiązań, które jednocześnie będą cechowały się odpowiednią, do tego zastosowania, jakością generowanych prognoz.

W artykule zaproponowano metodę prognozowania zapotrzebowania odbiorcy komunalno-bytowego opartą na idei metody naiwnej, która do obliczeń wykorzystuje godzinowe pomiary zużycia energii z kilku takich samych dni poprzedzających. Na podstawie takiego zestawu pomiarów wyznaczane są przebiegi opisujące w różny sposób dobowe obciążenie analizowanego odbiorcy: grafik średni, tzw. grafik „typowy” i grafik statystycznie najczęstszy, a prognoza wyznaczana jest przez zsumowanie powyższych grafików, z uwzględnieniem odpowiednich wag.

Zaproponowany model prognostyczny został skalibrowany przy wykorzystaniu rzeczywistych danych pomiarowych pochodzących z liczników rozliczeniowych odbiorców należących do grupy taryfowej G11. Liczba takich samych

dni poprzedzających, dla których uzyskano największą dokładność prognozy wynosi od 3 do 5. Wagi, z którymi sumowane są poszczególne składniki prognozy, wyznaczone przy użyciu metody optymalizacji PSO, są niejednakowe. Największą wagę ma grafik średni. Wagi dwóch pozostałych składników – grafiku „typowego” i statystycznie najczęstszego – są niższe oraz mają jednakową wartość bezwzględną, ale przeciwne znaki. Tak skalibrowany model dał błędy porównywalne z innymi, bardziej zaawansowanymi modelami. Dzięki prostocie opracowanego modelu prognostycznego istnieje możliwość jego praktycznej implementacji w systemie HEMS, zarządzającym energią w budynku wyposażonym w źródło fotowoltaiczne, magazyn energii i sterowane odbiorniki.

Autorzy: mgr inż. Tomasz Naczyński, Politechnika Śląska, Wspólna Szkoła Doktorów, ul. Akademicka 2a; dr hab. inż. Roman Korab, prof. PŚ, Politechnika Śląska, Wydział Elektryczny, Katedra Elektroenergetyki i Sterowania Układów, ul. Krzywoustego 2, 44-100 Gliwice, E-mail: roman.korab@polsl.pl; dr inż. Marcin Połomski, Politechnika Śląska, Wydział Automatyki, Elektroniki i Informatyki, Katedra Algorytmiki i Oprogramowania, ul. Akademicka 16, 44-100 Gliwice, E-mail: marcin.polomski@polsl.pl

LITERATURA

- [1] Zafar U., Bayhan S., Sanfilippo A.: Home Energy Management System: Concepts, Configurations, and Technologies for the Smart Grid. IEEE Access, 8/2020, doi:10.1109/ACCESS.2020.3005244
- [2] Korab R., Kandzia T., Naczyński T.: Short-term forecasting of photovoltaic power generation. Przegląd Elektrotechniczny, 9/2023, doi:10.15199/48.2023.09.06
- [3] Korab R., Połomski M., Naczyński T.: Optimal Scheduling of Energy Storage and Shiftable Loads in Grid-Connected Residential Buildings with Photovoltaic Micro-Installations. Energies 2024, 17, 5264, doi:10.3390/en17215264
- [4] Esteves G., Bastos B., Cyrino F., Calili R., Souza R.: Long Term Electricity Forecast: A Systematic Review. Procedia Computer Science, vol. 55, 2015, doi:10.1016/j.procs.2015.07.041
- [5] Khuntia S., Rueda J., van der Meijden M.: Forecasting the load of electrical power systems in mid- and long-term horizons: a review. IET Gener. Transm. Distrib., vol. 10, 2016, doi:10.1049/iet-gtd.2016.0340
- [6] Rodrigues F., Cardeira C., Calado J., Melicio R.: Short-Term Load Forecasting of Electricity Demand for the Residential Sector Based on Modelling Techniques: A Systematic Review. Energies 2023, 16, doi:10.3390/en16104098
- [7] Jiang Y., Gao T., Dai Y., Si R., Hao J., Zhang J., Gao D.: Very short-term residential load forecasting based on deep-autoformer. Applied Energy, vol. 328, 2022, doi:10.1016/j.apenergy.2022.120120
- [8] Pinheiro M., Madeira S., Francisco A.: Short-term electricity load forecasting – A systematic approach from system level to secondary substations. Applied Energy, vol. 332, 2023, doi:10.1016/j.apenergy.2022.120493
- [9] Tran L., Cai G., Gao W.: Determinants and approaches of household energy consumption: A review. Energy Reports, 10/2023, doi:10.1016/j.egyr.2023.08.026
- [10] Daśal K., Popławski T., Starczynowska E.: Badanie wpływu czynników pozapogodowych na zmiany obciążenia w KSE. Rynek Energii, 2/2010
- [11] Kang J., Reiner D.: What is the effect of weather on household electricity consumption? Empirical evidence from Ireland, Energy Economics, vol. 111, 2022, doi:10.1016/j.eneco.2022.106023
- [12] Yang L., Yan H., Lam J.: Thermal comfort and building energy consumption implications – A review. Applied Energy, vol. 115, 2014, doi:10.1016/j.apenergy.2013.10.062
- [13] Abrahamse W., Steg L., Vlek C., Rothengatter T.: A review of intervention studies aimed at household energy conservation. Journal of Environmental Psychology, vol. 25, 3/2005, doi:10.1016/j.jenvp.2005.08.002
- [14] Steg L., Vlek C.: Encouraging pro-environmental behavior: An integrative review and research agenda. Journal of Environmental Psychology, 3/2009, doi:10.1016/j.jenvp.2008.10.004
- [15] Tuomela S., de Castro Tomé M., Iivari N., Svento R.: Impacts of home energy management systems on electricity consumption. Applied Energy, vol. 299, 2021, doi:10.1016/j.apenergy.2021.117310
- [16] Hofmann M., Lindberg K.: Residential demand response and dynamic electricity contracts with hourly prices: A study of Norwegian households during the 2021/22 energy crisis. Smart Energy, vol. 13, 2024, doi:10.1016/j.segy.2023.100126.
- [17] www.pse.pl/jak-funkcjonuje-krajowy-system-elektroenergetyczny/wsparcie-bilansowania-systemu
- [18] Wang Y., Zhang N., Chen X.: A Short-Term Residential Load Forecasting Model Based on LSTM Recurrent Neural Network Considering Weather Features. Energies 2021, 14, doi:10.3390/en14102737
- [19] Barman M., Dev Choudhury N.: Season specific approach for short-term load forecasting based on hybrid FA-SVM and similarity concept. Energy, vol. 174, 2019, doi:10.1016/j.energy.2019.03.01
- [20] Wang S., Deng X., Chen H., Shi Q., Xu D.: A bottom-up short-term residential load forecasting approach based on appliance characteristic analysis and multi-task learning. Electric Power Systems Research, vol. 196, 2021, doi:10.1016/j.epsr.2021.107233
- [21] Alanazi M., Saeed A., Islam M., Habib S., Sherazi H., Khan S., Shees M.: Enhancing Short-Term Electrical Load Forecasting for Sustainable Energy Management in Low-Carbon Buildings. Sustainability 2023, 15, 16885, doi:10.3390/su152416885
- [22] Su Y., He Q., Chen J., Tan M.: A residential load forecasting method for multi-attribute adversarial learning considering multi-source uncertainties. International Journal of Electrical Power & Energy Systems, vol. 154, 2023, doi:10.1016/j.ijepes.2023.109421
- [23] Kychkin A., Chasparis G.: Feature and model selection for day-ahead electricity-load forecasting in residential buildings. Energy and Buildings, vol. 249, 2021, doi:10.1016/j.enbuild.2021.111200
- [24] Berent-Żesławska J., Smajek L., Sobieszkański S.: Katalog odbiorców nN i SN. Opracowanie Zakładu Sieci Rozdzielczych Instytutu Energetyki, Katowice, 1995
- [25] Korab R., Połomski M., Naczyński T., Kandzia T.: A dynamic thermal model for a photovoltaic module under varying atmospheric conditions. Energy Conversion and Management, vol. 280, 2023, doi:10.1016/j.enconman.2023.116773
- [26] Yang W., Shi J., Li S., Song Z., Zhang Z., Chen Z.: A combined deep learning load forecasting model of single household resident user considering multi-time scale electricity consumption behavior. Applied Energy, vol. 307, 2022, doi:10.1016/j.apenergy.2021.118197
- [27] Acharya S.K., Wi Y.-M., Lee J.: Short-Term Load Forecasting for a Single Household Based on Convolution Neural Networks Using Data Augmentation. Energies 2019, 12, 3560, doi:10.3390/en12183560