

Przegląd metod wykorzystywanych do średnioterminowego prognozowania obciążeń elektroenergetycznych

Streszczenie. W artykule dokonano przeglądu metod i modeli prognostycznych dedykowanych średnioterminowemu prognozowaniu obciążeń elektroenergetycznych. Opisano metody modelowania warunkowego i autonomicznego, modele klasyczne, modele inteligencji obliczeniowej i uczenia maszynowego oraz modele oparte na podobieństwie obrazów.

Abstract. The article reviews the methods and models of the medium-term load forecasting. Methods of conditional and autonomous modeling, classic models, computational intelligence and machine learning models are described, as well as pattern similarity-based models. (**Medium-term load forecasting models - a review**).

Słowa kluczowe średnioterminowe prognozowanie zapotrzebowania na energię elektryczną, modele inteligencji obliczeniowej i uczenia maszynowego, modele oparte na podobieństwie obrazów.

Keywords: mid-term load forecasting, computational intelligence and machine learning models, pattern similarity-based models.

Wstęp

Prognozowanie obciążeń systemów elektroenergetycznych jest integralnym działaniem wbudowanym w procesy planowania pracy systemu w dłuższym horyzoncie oraz w procesy bieżącego sterowania jego pracą. Funkcjonowanie systemu bez dokładnych prognoz jest niemożliwe. Wynika to z faktu, że energii elektrycznej nie można magazynować w większych ilościach. Zapotrzebowanie musi być pokryte na bieżąco produkcją, przy ograniczeniach wynikających z elastyczności pracy jednostek wytwórczych i wymogów niezawodności i bezpieczeństwa pracy systemu. Trafność prognoz przekłada się na koszty wytwarzania i przesyłu oraz stopień niezawodności dostaw energii elektrycznej do odbiorców. Zawyżone prognozy prowadzą do utrzymywania w ruchu zbyt dużej liczby jednostek wytwórczych w celu dotrzymania wymogów bezpieczeństwa – zapewnienia odpowiedniego marginesu mocy rezerwowej. Prognozy zaniżone przynoszą przeciwny skutek – zaplanowanie zbyt małej liczby jednostek wytwórczych, które nie są w stanie pokryć rzeczywistego zapotrzebowania. W takiej sytuacji do ruchu włącza się interwencyjnie dodatkowe jednostki o szybkim rozruchu, które generują dodatkowe koszty operacyjne.

Dokładne prognozy zapotrzebowania na energię elektryczną wymagane są również na konkurencyjnych rynkach energii elektrycznej. Prognozy dla różnych horyzontów czasowych i obszarów terytorialnych determinują strategie inwestycyjne przedsiębiorstw energetycznych i pozwalają optymalizować pozycje rynkowe podmiotów działających na rynku energii. Dokładność prognoz wprost przekłada się na wyniki finansowe uczestników konkurencyjnego rynku energii.

Potrzeba sporządzania prognoz miesięcznego zapotrzebowania na energię elektryczną, które są przedmiotem tej pracy, wynika z trzech przesłanek [1]:

- techniczno-eksploatacyjnych – związanych z planowaniem poziomu produkcji i zakupów paliwa, planowaniem inwestycji sieciowych oraz ustalaniem harmonogramu remontów,
- ekonomicznych – związanych z negocjowaniem kontraktów pomiędzy podmiotami działającymi na rynku energii oraz zawieraniem umów z odbiorcami,
- prawnych – związanych z obowiązkiem sporządzania prognoz dla różnych horyzontów czasowych narzuconych przez ustawę Prawo Energetyczne.

Prognozowanie krótkoterminowego i średnioterminowego zapotrzebowania na energię elektryczną z wysoką dokładnością jest trudnym zadaniem, ponieważ szereg czasowy zapotrzebowania na energię elektryczną jest niestacjonarny, charakteryzuje się występowaniem cyklu dobowego, tygodniowego i rocznego. Dużą rolę odgrywa w nim komponent losowy i zakłócenia spowodowane występowaniem świąt i nagłych zmian pogody.

Szeregi czasowe miesięcznego zapotrzebowania na energię elektryczną, które są przedmiotem prognozowania średnioterminowego w elektroenergetyce, wyrażają zwykle tendencję wzrostową skorelowaną z poziomem rozwoju ekonomicznego danego państwa. Zmiany sezonowe odzwierciedlają cykl roczny związany z czynnikami klimatycznymi i zmiennością pór roku. Wśród czynników zakłócających zarówno trend jak i wahania sezonowe tych szeregów wymienia się decyzje polityczne i czynniki ekonomiczne wpływające na rozwój gospodarczy. Do analizy i wstępnej obróbki takich szeregów czasowych często stosuje się metody różnicowania [2, 3, 4], dopasowania krzywej [5, 6] i techniki wygładzania [7, 8]. Mają one na celu dekompozycję szeregu, odfiltrowanie trendu i sprowadzenie szeregu do postaci stacjonarnej. Następnie prognozuje się uzyskane szeregi za pomocą popularnych modeli prognostycznych, takich jak regresja liniowa, ARIMA, sieci neuronowe lub systemy rozmyte.

Metody średnioterminowego prognozowania obciążeń systemów elektroenergetycznych można podzielić na dwie ogólne kategorie [9]: metody modelowania warunkowego (conditional modeling approach) oraz metody modelowania autonomicznego (autonomous modeling approach). Inny podział dotyczy modeli stosowanych jako części wykonawcze tych metod. Można wyodrębnić modele statystyczne oraz modele wykorzystujące uczenie maszynowe i inteligencję obliczeniową. Modele generują prognozy najczęściej dla jednego punktu czasowego, tzn. zadaniem modelu jest zaprognozowanie w chwili t prognozy dla chwili $t + l$, zazwyczaj $l = 1$. Aby dokonać prognozy dla więcej niż jednego kroku do przodu, stosuje się podejście rekurencyjne lub bezpośrednie. W podejściu rekurencyjnym najpierw wykonuje się prognozę jeden krok do przodu. Aby wykonać prognozę dla $l = 2$ na wejście modelu wprowadza się prognozę otrzymaną dla $l = 1$. Prognoza dla $l = 2$ zostaje wprowadzona na wejście modelu generującego prognozę dla $l = 3$ itd. Zaletą podejścia rekurencyjnego jest to, że model skonstruowany dla $l = 1$ wykorzystuje się do prognoz kolejnych elementów szeregu czasowego. W metodzie

bezpośredniej buduje się odrębne modele dla każdej chwili $t + 1, t + 2, \dots, t + h$. Tworzy się także modele wielowyjściowe, które jednocześnie prognozują h kolejnych wartości szeregu czasowego. Takie modele opisano w pracy [10, 11].

W kolejnych punktach przedstawiono podejścia i modele stosowane do prognozowania średnioterminowego obciążeń systemów elektroenergetycznych.

Metody modelowania warunkowego i autonomicznego

Zapotrzebowanie na energię elektryczną jest silnie uzależnione od warunków społecznych, gospodarczych i pogodowych, dlatego czynniki te mogą zostać uwzględnione w procesie prognozowania w celu poprawy dokładności przewidywania. Podejście oparte na modelowaniu warunkowym koncentruje się na analizie ekonomicznej i długoterminowym planowaniu i prognozowaniu polityki energetycznej. Uwzględnia się tu warunki społeczno-ekonomiczne, które wpływają na zapotrzebowanie na energię w danym regionie oraz migrację ludności. Wzrost gospodarczy opisywany jest wskaźnikami ekonomicznymi, które stanowią dodatkowe wejścia modelu prognostycznego. Do takich wskaźników zalicza się [9, 12]: produkt narodowy brutto, wskaźnik cen towarów i usług konsumpcyjnych, kursy walutowe czy poziom przeciętnego wynagrodzenia. Ponadto jako dane wejściowe wprowadza się zmienne opisujące system elektroenergetyczny i infrastrukturę sieciową, takie jak liczba i długość linii przesyłowych czy liczba stacji najwyższych napięć. Zmienne ekonomiczne mają największy wpływ na trend, natomiast zmienne pogodowe z uwagi na ich sezonową naturę – na zachowanie periodyczne szeregu czasowego zapotrzebowania na energię elektryczną [13].

W pracy [14] wykazano, że w przypadku szybko rozwijających się regionów klasyczne metody prognostyczne zawodzą. Autorzy opracowali system ekspercki, który wspomaga wybór najbardziej odpowiedniego modelu prognostycznego i kluczowych zmiennych wejściowych. Zmienne te są zapisywane w regułach decyzyjnych i przechowywane w bazie wiedzy. Inny model dedykowany dla szybko rozwijających się systemów opisano w [15]. Model prognozuje obciążenia szczytowe na podstawie funkcji logistycznej zależnej m.in. od poziomu aktywności społecznej związanej ze świętami religijnymi. Model opisany w [16] bazuje na zmiennych pogodowych (wybieranych na podstawie analizy korelacyjnej) oraz zmiennej reprezentującej liczbę połączeń sieciowych. W [17] modele regresji wielorakiej i model ARIMA zasilane są zmiennymi ekonomicznymi (wskaźnik cen towarów i usług oraz wskaźnik produkcji przemysłowej), zmiennymi pogodowymi (wilgotność, poziom opadów deszczu, prędkość wiatru oraz poziom nasłonecznienia) oraz historycznymi wartościami obciążeń szczytowych. Bardziej oszczędny model, jeśli chodzi o informacje wejściowe, zastosowano w [18], gdzie obciążenie systemu prognozuje się na podstawie obciążeń historycznych oraz poziomu PKB. Kilku autorów zauważyło, że niedokładność w przewidywaniu zmiennych pogodowych, nieunikniona w przypadku prognozowania na kilka miesięcy wprzód, prowadzi do zauważalnego wzrostu błędów prognozowania obciążenia [19].

W modelowaniu autonomicznym do prognozowania obciążeń elektroenergetycznych wykorzystuje się przede wszystkim obciążenia historyczne i informacje o warunkach pogodowych. To podejście jest bardziej odpowiednie dla stabilnych gospodarek, bez gwałtownych zmian wpływających na zapotrzebowanie na energię elektryczną. Dobór zmiennych pogodowych, takich jak [9]: temperatura

atmosferyczna, wilgotność powietrza, czas nasłonecznienia, prędkość wiatru itp., zależy od lokalnych warunków klimatycznych i pogodowych [16, 20, 21, 22]. W tworzeniu modeli należących do tej kategorii wykorzystuje się informacje o zmianach sezonowych warunków pogodowych oraz występowaniu wydarzeń cyklicznych takich jak okresy świąteczne [21, 22]. W [21] przedstawiono modele prognozowania miesięcznych obciążeń szczytowych wykorzystujące podejście klasyczne (ARIMA) oraz sieci neuronowe. Zmienne wejściowe zawierają profile obciążeń, czynniki pogodowe (temperaturę i wilgotność) oraz indeks czasu. Model opisany w [22], bazujący na sieci neuronowej, jako zmiennych wejściowych używa historycznego zapotrzebowania oraz temperatur atmosferycznych. Wprowadza się także zmienne sezonowe wyrażające pory roku.

W wielu przypadkach modele autonomiczne upraszcza się stosując jako informację wejściową jedynie dane historyczne obciążenia. Takie podejście zastosowano w [13], gdzie trend szeregu miesięcznych obciążeń systemu prognozuje się jedynie na podstawie obciążeń z dwunastu poprzedzających miesięcy. Składową sezonową natomiast modeluje się szeregiem Fouriera. Na uwagę zasługuje duża dokładność tego modelu: MAPE na poziomie 2%. W [23] zastosowano model sieci neuronowo-rozmytej bazujący jedynie na zmiennych pogodowych (ciśnienie, temperatura, prędkość wiatru, itp.), bez uwzględnienia obciążeń historycznych jako zmiennych wejściowych.

Modele klasyczne

Do prognozowania zapotrzebowania na energię elektryczną początkowo wykorzystywano głównie techniki klasyczne. Szeroko stosowane były metody ARIMA, wygładzanie wykładnicze oraz regresja liniowa. Ograniczone zdolności adaptacyjne tych metod oraz problemy z modelowaniem nieliniowych zależności spowodowały wzrost zainteresowania technikami sztucznej inteligencji [13]. Do najprostszych modeli klasycznych zalicza się modele naiwne, które jako prognozę przyjmują wybraną historyczną wartość obciążenia. W szeregach wykazujących sezonowość, takich jak szeregi obciążeń miesięcznych, jest to wartość przesunięta o dwanaście miesięcy. Losowe fluktuacje i trend mogą negatywnie wpływać na wyniki prognozy.

Modele regresji liniowej pozwalają uwzględnić trend (jedynie liniowy), ale implementacja cykli sezonowych w modelu wymaga dodatkowych operacji, np. dekompozycji szeregu na poszczególne miesiące. Przykład zastosowania modelu liniowego do średnio i długoterminowego prognozowania obciążeń systemów elektroenergetycznych można znaleźć w pracy [24]. W modelu wykorzystuje się silne korelacje dobowe (24 h) oraz roczne (52 tygodni) do prognozowania dobowych profili obciążeń w horyzoncie od kilku tygodni do kilku lat. Wyniki prognoz są korygowane o roczne przyrosty obciążenia. Dla prognozowania z horyzontem rocznym uzyskano błędy MAPE o wartościach nie większych niż 3,8%.

W [17] porównano działanie modelu regresji liniowej i modelu ARIMA w zadaniu prognozowania miesięcznych obciążeń szczytowych z wyprzedzeniem do 12 miesięcy. Modele zasilane są tym samym zestawem zmiennych wejściowych obejmującym dane o historycznym obciążeniu szczytowym, dane pogodowe i ekonomiczne. Eksperymentalnie wykazano około dwukrotnie większą dokładność modelu ARIMA. Do niestacjonarnych szeregów czasowych z nieregularnym trendem periodycznym w [5] zaproponowano model regresji liniowej rozbudowany o składowe periodyczne realizowane przez funkcję sinus o różnych częstotliwościach.

Przestrzenny model autoregresji do średnioterminowego prognozowania obciążeń opisano w [18]. Autorzy zauważają silną zależność pomiędzy obciążeniem systemu a PKB w analizowanych trzydziestu chińskich prowincjach. Do prognozy obciążenia w danej prowincji wykorzystują nie tylko lokalną zależność obciążenia od PKB, ale także zależności zidentyfikowane dla prowincji sąsiednich. Pozwala to zredukować błędy prognoz z 5,2-5,4% do niecałych 3,5-3,9%.

Znana od lat 60-tych ubiegłego stulecia sezonowa metoda wygładzania wykładniczego (metoda Holta-Wintersa) z powodzeniem stosowana jest do prognozowania średnioterminowego w elektroenergetyce od wielu lat. Idea wygładzania wykładniczego polega na przypisaniu obserwacjom z poprzednich okresów wykładniczo zanikających wag. Obserwacje z ostatnich okresów mają dzięki temu większy wpływ na prognozę. Model Holta-Wintersa opiera się na trzech równaniach wygładzających, które reprezentują poziom zmiennej prognozowanej, jej trend i sezonowość. Istnieją dwa rodzaje metody Holta-Wintersa, które zależą od sposobu modelowania sezonowości. Wersja addytywna metody Holta-Wintersa jest stosowana, gdy wahania sezonowe nie są zależne od trendu. Natomiast wersję multiplikatywną stosuje się, gdy występuje proporcjonalna zależność pomiędzy wahaniami sezonowymi i trendem [25].

Do metod klasycznych zalicza się również szeregi Fouriera. W [13] użyto ich do modelowania składnika sezonowego szeregów czasowych obciążeń miesięcznych. Na podstawie analizy spektralnej zidentyfikowano sześć częstotliwości podstawowych i utworzono dla nich szereg Fouriera. Prognozę składowej sezonowej obliczoną za pomocą szeregu Fouriera dla danego horyzontu dodaje się do prognozy trendu.

W [26] wykorzystano łańcuchy Markowa do analizy danych wejściowych i wyboru najlepszego modelu prognostycznego. Podejście to jest szczególnie przydatne, gdy tendencja wzrostowa szeregu czasowego jest niestabilna. Do modeli klasycznych można zaliczyć także model opisany w [15], który bazuje na prostej funkcji logistycznej. Zmiennymi wejściowymi są: czas, maksymalna temperatura atmosferyczna oraz czynnik społeczny uwzględniający święta religijne (model opracowano dla państw arabskich). Na podstawie analizy danych historycznych dobiera się sześć parametrów modelu.

Modele inteligencji obliczeniowej i uczenia maszynowego

Do analizy i prognozowania szeregów czasowych obciążeń systemów elektroenergetycznych w ostatnich latach często sięga się po narzędzia sztucznej inteligencji takie jak: sieci neuronowe [27, 28], systemy eksperckie, metody hybrydowe, np. połączenie sieci neuronowych z logiką rozmytą [29], transformację falkową [30] i algorytmy genetyczne. Sztuczne sieci neuronowe są najpopularniejszym przedstawicielem tej grupy. Sieci neuronowe oferują następujące zalety w porównaniu z modelami zbudowanymi w oparciu o metody statystyczne: mogą zidentyfikować i modelować nieliniowe funkcje, uczą się odpowiednich zależności na podstawie danych, potrafią uogólniać wiedzę na dane spoza zbioru uczącego, nie wymagają konstruowania złożonych modeli matematycznych, równoległe przetwarzają dane oraz są odporne na błędy w danych.

Sieci neuronowych w [13] używa się do prognozy trendu szeregu czasowego obciążeń miesięcznych. Składową sezonową prognozuje się przy użyciu szeregów Fouriera. Obie prognozy, trendu i fluktuacji sezonowych, agreguje się. Do prognozy trendu autorzy użyli wielowarstwowego

perceptronu oraz sieci z radialnymi funkcjami bazowymi. Długość wektora wejściowego ustalono na dwanaście, co ma związek z roczną cyklicznością czynników pogodowych i społecznych. Dzięki dekompozycji zadania uzyskano znaczne uproszczenie modeli neuronowych. Sieci zawierały tylko dwa neurony, co przełożyło się na redukcję czasu uczenia.

W pracy [31] szereg czasowy zapotrzebowania miesięcznego jest dekomponowany na trend i wahania sezonowe. Do ich prognozy używa się dwóch niezależnych sieci neuronowych. Uzyskana prognoza okazała się bardziej dokładna, niż prognoza generowana przez jedną sieć neuronową. Do identyfikacji trendu autorzy użyli średniej ruchomej i splajnów kubicznych.

W [32] zaproponowano sztuczne sieci neuronowe uczone za pomocą różnych algorytmów heurystycznych, takich jak: algorytm wyszukiwania grawitacyjnego (Gravitational Search Algorithm) i algorytm optymalizacji kukułkowej (Cuckoo Optimization Algorithm). Sieć prognozuje miesięczne obciążenia systemu. Dane wejściowe obejmują obciążenia historyczne i zmienne pogodowe.

W pracy [16] zastosowano dwie sieci neuronowe: jedną do predykcji całkowitej energii miesięcznej, drugą do predykcji miesięcznych obciążeń szczytowych. Zmienne wejściowe obejmują czynniki pogodowe oraz liczbę połączeń sieci, opisującą rozmiar systemu. Przykład użycia sieci Kohonena do prognozowania średnioterminowego można znaleźć w [12]. Autorzy zbudowali 12 sieci do prognozowania na każdy miesiąc roku. Wektory wejściowe zawierają obciążenia historyczne i wskaźniki mikroekonomiczne. Sieci prognozują godzinowe profile obciążeń.

Sieci neuronowe zaproponowane w [22] wspomagane są logiką rozmytą. Zmienne sezonowe definiuje się w postaci trapezoidalnych wskaźników pory roku. Autorzy trenują zbiór sieci neuronowych o tej samej architekturze lecz innych wagach startowych. Odpowiedzi sieci są agregowane, co w efekcie daje dokładniejsze prognozy. Autorzy stosują różne techniki regularyzacji, aby zapobiec przeuczeniu sieci.

W pracy [33] pokazano przykład połączenia sieci neuronowych i algorytmów genetycznych. Do prognozowania obciążeń w horyzoncie od 45 do 49 dni wykorzystuje się wielowarstwowo perceptron, którego architektura jest optymalizowana przy użyciu algorytmu genetycznego. W [34] rozważa się sieci neuronowe prognozujące obciążenia w trybie rekurencyjnym. W sieci neuronowej opisanej w [9] adaptacyjnie dobiera się liczbę warstw ukrytych przy ograniczonej do czterech liczbie neuronów w każdej warstwie. Sieć używana jest do prognoz obciążeń miesięcznych. Autorzy zauważają, że włączenie zmiennych pogodowych poprawia dokładność prognoz, ale z uwagi na ich niską dokładność, eliminują je ze swojego modelu. Wyniki eksperymentów wykazały niższe błędy dla proponowanej metody w porównaniu z błędami generowanymi przez konkurencyjne modele: regresji liniowej, ARIMA i klasycznej sieci neuronowej.

Do prognoz obciążeń miesięcznych w [23] zaproponowano ważoną ewoluującą rozmytą sieć neuronową. Reguły rozmyte implementowane w neuronach wprowadzane są tu addytywnie w procesie treningu. Nowością tej pracy jest zastosowanie mechanizmu ważenia zmiennych wejściowych przy obliczaniu odległości wektora wejściowego do reguły rozmytej. W [35] do prognoz średnioterminowych obciążeń zastosowano maszynę wektorów nośnych. Wejściami modelu są prognozy obciążeń wykonane za pomocą prostych modeli: wielomianowego, wykładniczego, logarytmicznego,

wygładzania wykładniczego i logistycznego. Maszyna wektorów nośnych przekształca nieliniowo te prognozy i generuje prognozę zagregowaną.

Innym przykładem modeli kwalifikujących się do grupy inteligencji obliczeniowej są metody oparte na podobieństwie. Stanowią one podstawę wielu metod uczenia maszynowego i rozpoznawania obrazów. Wspólna zasada działania tych metod brzmi: nieznanne cechy obiektu można zaprognozować na podstawie zbioru obiektów podobnych, dla których te cechy są znane. Obiekty widziane są poprzez swoje obrazy (zbiory mierzalnych parametrów). Definicja obrazów oraz definicja miary podobieństwa są tutaj kluczowe. W modelach prognostycznych wykorzystuje się podobieństwo pomiędzy fragmentami szeregów czasowych [11]. Oporają się one na założeniu: jeśli fragmenty szeregu czasowego (lub ich obrazy) są do siebie podobne, to fragmenty następujące bezpośrednio po nich (lub ich obrazy) również są do siebie podobne.

Pierwsze prace dotyczące metod opartych na podobieństwie pojawiły się w połowie lat 90 ubiegłego wieku. W [36] autorzy definiują kilka charakterystyk (obrazów) wyrażających lokalne cechy szeregów czasowych: lokalne ekstrema, trend i sezonowość. Przy wyszukiwaniu podobnych obrazów z historii wymagana jest pełna zgodność tych charakterystyk z obrazem wejściowym (prototypem). Miary podobieństwa bazują na podobieństwie wartości średniej, odchylenia standardowego, kształtu i fazy (położenia w cyklu). Bardziej podobne obrazy uzyskują większe wagi i mają większy wpływ na tworzoną prognozę, którą wyznacza się jako kombinację liniową obrazów historycznych. W [37] zaproponowano reprezentację szeregu czasowego za pomocą binarnych sekwencji informujących o kierunku zmian szeregu czasowego: wzrostu lub spadku. Za pomocą trójwymiarowego binarnego wzorca wyszukiwana jest sekwencja w historii szeregu pasująca do prototypu, która następnie jest skalowana i przyjmowana jako prognoza.

Modele wykorzystujące podobieństwo do prognozy średnioterminowej obciążeń elektroenergetycznych

Zastosowanie metod opartych na podobieństwie obrazów jest bardzo obiecujące w prognozowaniu obciążeń miesięcznych, ponieważ te szeregi czasowe charakteryzują się wyraźnymi cyklami rocznymi, które wykazują duże podobieństwo. Jako przykłady modeli prognostycznych miesięcznych obciążeń systemu elektroenergetycznego można podać: [38], gdzie wykorzystano prosty model k najbliższych sąsiadów, [39], gdzie wagi obrazów wyznaczano za pomocą zbiorów rozmytych, [40], gdzie użyto modelu regresji nieparametrycznej, czy [41], gdzie zależności modelowano za pomocą sieci neuronowo-rozmytej.

W artykułach [38, 39, 40] autorzy prognozują średnie miesięczne zapotrzebowanie na energię elektryczną w kilku krajach europejskich. Prognozy generowane są dla jednego roku, w dwóch wariantach:

A) prognoza tworzona jest jednocześnie dla 12 miesięcy wprzód (horyzont $h = 12$),

B) prognoza tworzona jest oddzielnie dla każdego z 12 miesięcy ($h = 1$).

Autorzy testują jakość modeli w przypadku zastosowania kilku metod definicji obrazów wejściowych. Wartości szeregów czasowych zostały pobrane z repozytorium ENTSO-E (www.entsoe.eu) dla czterech państw europejskich: Polski, Niemiec, Hiszpanii i Francji. Autorzy porównują osiągnięte wyniki z metodami klasycznymi ARIMA i wykładniczego i na podstawie obliczanych błędów wnioskują, że występuje

poprawa jakości prognoz w odniesieniu do metod klasycznych. Błędy na poziomie kilku procent można uznać za konkurencyjne w stosunku do innych doniesień literaturowych. Ponadto autorzy podają inną zaletę modeli wykorzystujących podobieństwo, jaką niewątpliwie jest ich szybkość.

Podsumowanie

Średnioterminowe prognozowanie w elektroenergetyce stawia przed modelami prognostycznymi wyzwania związane z niestacjonarnością szeregów czasowych, nieliniowym trendem, cyklami sezonowymi o zmiennej wariancji i wysokim poziomem zakłóceń losowych. Obok metod klasycznych, które mają silne podstawy teoretyczne, coraz częściej używa się modeli sztucznej inteligencji. Modele te aproksymują zależności nieliniowe, uczą się odpowiednich funkcji z danych i wykazują adaptacyjność. Modele oparte na podobieństwie obrazów wyróżnia prostota: mają czytelną strukturę, niewielką liczbę parametrów do estymacji i zrozumiałą zasadę działania.

Autor: Paweł Pelka, Politechnika Częstochowska, Instytut Informatyki, al. Armii Krajowej 17, 42-200 Częstochowa, E-mail: p.pelka@el.pcz.czest.pl.

LITERATURA

- [1] Piotrowski P.: Prognozowanie w elektroenergetyce w różnych horyzontach czasowych. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2013
- [2] Mbamalu G.A.N., El-Hawary M.E.: Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation, IEEE Trans Power Systems, 8 (1993), nr 1, 343–7
- [3] Charytoniuk W., Chen M.S.: Very short-term load forecasting using artificial neural networks. IEEE Trans Power Systems 15 (2000), nr 1, 263–8
- [4] Abdel-Aal R.E., Al-Garni A.Z.: Forecasting monthly electric energy consumption in Eastern Saudi Arabia using univariate time-series analysis. Energy, 22 (1997), nr 11, 1059–69.
- [5] Barakat E.H.: Modeling of nonstationary time-series data. Part II. Dynamic periodic trends. Electr Power Energy Systems 23 (2001), 63–8
- [6] Barakat E.H., Al-Qasem J.M.: Methodology for weekly load forecasting. IEEE Trans. Power System 13 (1998), nr 4, 1548–55
- [7] Saab S., Badr E., Nasr G.: Univariate modeling and forecasting of Energy consumption: the case of electricity in Lebanon. Energy 26 (2001), nr 1, 1–14
- [8] Ringwood J.V., Bofelli D., Murray F.T.: Forecasting electricity demand on short, medium and long time scales using neural networks. J Intel Robot Systems 31 (2001), 129–47
- [9] Ghiassi M., Zimbra D. K., Saidane H.: Medium term system load forecasting with a dynamic artificial neural network model, Electric Power Systems Research 76 (2006), 302–316
- [10] Dudek G.: Analiza podobieństwa obrazów sekwencji szeregów czasowych obciążeń elektroenergetycznych, Przegląd Elektrotechniczny 85 (2009), nr 3, 149–152
- [11] Dudek G.: Systemy uczące się oparte na podobieństwie obrazów do prognozowania szeregów czasowych obciążeń elektroenergetycznych, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2012
- [12] Gavrilas M., Ciutea I., Tanasa C.: Medium-term load forecasting with artificial neural network models, 16th International Conference and Exhibition on Electricity Distribution, 2001, IEEE Conf. Elec. Dist. Pub. No. 482, 383.
- [13] González-Romera E., Jaramillo-Morán M. A., Carmona-Fernández D.: Monthly electric energy demand forecasting with neural networks and Fourier series, Energy Conversion and Management 49 (2008), 3135–3142.
- [14] Kandil M.S., El-Debeiky S.M., Hasanién N.E.: Long-term load forecasting for fast developing utility using a knowledge-based expert system, IEEE Trans. Power Syst. 17 (2002), nr 2, 491–496

- [15] Barakat E.H., Al-Rashed S.A.: Long range peak demand forecasting under condition of high growth, *IEEE Trans. Power Syst.* 7 (1992), nr 4, 1483–1486.
- [16] Islam S.M., Al-Alawi M., Ellithy K.A.: Forecasting monthly electric load and energy for a fast growing utility using an artificial neural network, *Electric Power Syst. Res.*, 34 (1995), 1–9
- [17] Bunnoon P., Chalermyanont K., Limsakul C.: Mid Term Load Forecasting of the Country Using Statistical Methodology: Case study in Thailand, 2009 International Conference on Signal Processing Systems, 924-928
- [18] Cai G., Yang D., Jiao Y., Pan C.: The Characteristic Analysis and Forecasting of Mid-Long Term Load Based on Spatial Autoregressive Model, *Proc. 2009 International Conference on Sustainable Power Generation and Supply*, Nanjing, China
- [19] Chen B.J., Chang M.W., Lin C.J.: Load forecasting using support vector machines: a study on EUNITE competition 2001, *IEEE Trans Power Systems* 19 (2004), nr 4, 1821–30
- [20] Ranaweera D.K., Karady G.G., Farmer R.G.: Economic impact analysis of load forecasting, *IEEE Trans. Power Syst.* 12 (1997), nr 3, 1388–1392
- [21] Elkateb M. M., Solaiman K., Al-Turki Y.: A comparative study of medium-weather-dependent load forecasting using enhanced artificial/fuzzy neural network and statistical techniques, *Neurocomputing* 23 (1998), 3–13
- [22] Doveh E., Feigin P., Hyams L.: Experience with FNN models for medium term power demand predictions, *IEEE Trans. Power Syst.*, 14 (1999), nr 2, 538-546
- [23] Pei-Chann C., Chin-Yuan F., Jyun-Jie L.: Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach, *Electrical Power and Energy Systems*, 33 (2011), 17–27
- [24] Al-Hamadi H.M., Soliman S.A.: Long-term/mid-term electric load forecasting based on short-term correlation and annual growth, *Electric Power Syst. Res.*, 74 (2005), 353–361.
- [25] Zagdański A., Suchwałko A.: *Analiza i prognozowanie szeregów czasowych. Praktyczne wprowadzenie na podstawie środowiska R*, Wydawnictwo naukowe PWN SA, Warszawa 2016
- [26] Dong-Liang Z., Yanjian, Wei-Hua W., Xiu-Lan Y.: Mid-long term load forecasting of the unstable growth sequence based on Markov chains screening combination forecasting models, 2016 China International Conference on Electricity Distribution (CICED 2016), Xi'an, 10-13 Aug, 2016
- [27] Peng T.M., Hubele N.F., Karadi G.G.: Advancement in the application of neural networks for short-term load forecasting. *IEEE Trans Power Systems*, 7 (1992), nr. 1, 250–7
- [28] Park D.C., El-Sharkawi M.A., Marks II R.J., Atlas L.E., Damborg M.J.: Electric load forecasting using an artificial neural network. *IEEE Trans Power Systems* 6 (1991), nr. 2, 442–9
- [29] Padmakumari K., Mohandas K.P., Thiruvengadam S.: Long term distribution demand forecasting using neuro fuzzy computations. *Electr Power Energy Systems*, 21 (1999), 315–22
- [30] Gao R., Tsoulakas L.H.: Neural-wavelet methodology for load forecasting. *J Intel Robot Systems* 31 (2001), 149–57
- [31] González-Romera E., Jaramillo-Morán M.A., Carmona-Fernández D.: Monthly electric energy demand forecasting based on trend extraction. *IEEE Trans. Power System*, 21 (2006), nr 4, 1935–46
- [32] Chen J.F., Lo S.K., Do Q.H.: Forecasting Monthly Electricity Demands: An Application of Neural Networks Trained by Heuristic Algorithms, *Information*, 31 (2017), nr 8
- [33] Aquinode R. R. B, Neto O. N., Lira M. M. S., Ferreira A. A., Carvalho Jr. M.A., Silva G. B., Oliveirade J. B.: Development of an Artificial Neural Network by Genetic Algorithm to Mid-Term Load Forecasting, *Proceedings of 2007 International Joint Conference on Neural Networks*, Orlando, Florida, USA, August 12-17, 2007
- [34] Borlea I., Buta A., Lustrea B.: Some Aspects Concerning Mid Term Monthly Load Forecasting Using ANN, *EUROCON 2005 - The International Conference on "Computer as a Tool"*, Belgrade, November 22-24, 2005
- [35] Zhao W., Wang F., Niu D.: The Application of Support Vector Machine in Load Forecasting, *JOURNAL OF COMPUTERS*, 7 (2012), nr. 7, 1615-1622
- [36] Sket Motnikar B., Pisanski T., Cepar D.: Time-series forecasting by pattern imitation, *OR Spektrum*, Springer-Verlag, 18 (1996), 43-49
- [37] Singh S., Stuart E.: A Pattern Matching Tool for Time-Series Forecasting, *Proc. Fourteenth International Conference on Pattern Recognition*, 20-20 Aug. 1998
- [38] Dudek G., Pełka P.: Forecasting monthly electricity demand using k nearest neighbor method, *Przegląd Elektrotechniczny*, 93 (2017) ,nr.4, 62-65.
- [39] Pełka P., Dudek G.: Prediction of Monthly Electric Energy Consumption using Pattern-Based Fuzzy Nearest Neighbour Regression. *Proc. 2nd Int. Conf. Computational Methods in Engineering Science (CMES'17)*, ITM Web Conf., 15 (2017), 1-5
- [40] Dudek G., Pełka P.: Medium-term electric energy demand forecasting using Nadaraya-Watson estimator. *Proc. 18th Int. Scientific Conf. on Electric Power Engineering 2017 (EPE'17)*, 1-6
- [41] Pełka P., Dudek G.: Neuro-Fuzzy System for Medium-term Electric Energy Demand Forecasting. In: Borzemski L., Świątek J., Wilimowska Z. (eds) *Information Systems Architecture and Technology: Proceedings of 38th International Conference on Information Systems Architecture and Technology – ISAT 2017*, *Advances in Intelligent Systems and Computing*, Springer, Cham, 655 (2018), 38-47