

Badania algorytmów predykcyjnych na potrzeby zarządzania mikro siecią prądu stałego z instalacją fotowoltaiczną

Streszczenie. Artykuł przedstawia wybrane zagadnienia dotyczące zastosowania algorytmów predykcyjnych sztucznej inteligencji w zarządzaniu energią w lokalnych inteligentnych mikro sieciach prądu stałego, których efektem może być pozytywny wpływ na stabilność całego systemu elektroenergetycznego oraz efektywne zarządzanie energią w celu osiągnięcia korzyści finansowych wynikających z dynamicznych cen energii elektrycznej na towarowej giełdzie energii lub w nadchodzących dynamicznych systemach rozliczeń z prosumentami.

Abstract. The paper presents selected issues regarding the application of predictive algorithms of artificial intelligence in energy management within local smart DC microgrids, aiming to positively influence the overall stability of the power system and efficient energy management to achieve financial benefits derived from dynamic electricity prices on the Electricity - Day-Ahead Market or in the upcoming dynamic tariffs for prosumers. (Research on predictive algorithms for the energy management of a DC microgrid with a photovoltaic installation).


Słowa kluczowe: system zarządzania energią, mikro sieć prądu stałego, algorytmy predykcyjne, odnawialne źródła energii.

Keywords: Energy management system (EMS), DC microgrid, predictive algorithms, renewable energy sources.

Wstęp

Obserwowana obecnie szybka transformacja krajowego systemu elektroenergetycznego w kierunku odnawialnych źródeł energii (OZE) powoduje zagrożenia dla stabilności tego systemu. Związane jest to z dużą zmiennością produkcji energii z instalacji fotowoltaicznych (PV) i farm wiatrowych [1]. Istnieje wiele rozwiązań wychodzących naprzeciw tym wyzwaniom, począwszy od rozwiązań konwencjonalnych, jak elektrownie szczytowo-pompowe czy gazowe, skończywszy na lokalnych elektrochemicznych magazynach energii elektrycznej, podłączanych bezpośrednio do sieci prądu przemiennego. W najbliższej perspektywie, obiecującym rozwiązaniem tego typu problemów mogą być również inteligentne mikro sieci prądu stałego [2], których idea została przedstawiona na rysunku 1. Tego typu systemy mogą być sterowane przez algorytmy sztucznej inteligencji, wspomagające zarządzanie energią i realizację różnych strategii i celów lokalnych, np. zwiększenia autokonsumpcji energii z OZE czy maksymalizacji zysków wynikających z wymiany energii z siecią prądu przemiennego (AC) z wykorzystaniem dynamicznych cen energii, oraz globalnych, takich jak kompensacja mocy biernej czy wpływ na bilans energii w krajowym systemie dystrybucji energii elektrycznej [3]. W szczególności, kluczową rolę odgrywają w tym zakresie algorytmy predykcyjne. Dzięki nim możliwe jest przewidywanie wartości sygnałów istotnych z punktu widzenia efektywnej pracy systemu.

Ze względu na dużą zmienność energii pochodzącej z OZE, wynikającą z bezpośredniej zależności od warunków pogodowych, bardzo trudne jest zarządzanie energią lokalnie, a tym bardziej w ujęciu globalnym. W celu zwiększenia skuteczności zarządzania bilansem energii, w mikro sieci można wykorzystać algorytmy sztucznej inteligencji oferujące możliwość predykcji ilości energii pochodzącej z OZE, ale także w wielu innych aspektach [4]. W dalszej perspektywie powinno to również poprawić kontrolę nad bilansem energii w systemie elektroenergetycznym. W artykule przedstawiono wyniki badań wybranych algorytmów predykcyjnych, mające na celu wybranie najlepszego dla polskich realiów oraz dokonano analizy wpływu warunków pogodowych na modelowanie produkcji energii elektrycznej z instalacji PV.



Rys. 1. Graficzna prezentacja idei mikro sieci prądu stałego

Zarządzanie energią w mikro sieci prądu stałego

W celu zapewnienia optymalnego działania algorytmu zarządzania energią w mikro sieci prądu stałego o funkcjonalności podanej we wstępie, potrzebna jest dokładna predykcja trzech wielkości – produkcji energii przez instalację PV, zużycia energii przez podłączone do mikro sieci urządzenia oraz cen energii na Towarowej Giełdzie Energii (TGE). Wprawdzie ten ostatni czynnik jest aktualnie znany z wyprzedzeniem 14-38 godzinowym (ceny są podawane o godzinie 10, zakres zawiera informacje o kolejnej dobie), jednak, zgodnie z przyjętą ustawą, planowane jest przejście na krótsze terminy. Bardziej szczegółowe informacje nie są jeszcze znane, niemniej w momencie wprowadzenia takiej zmiany kluczowe będzie posiadanie przygotowanych algorytmów do predykcji cen, które będą mogły zostać szybko dostosowane do nowej sytuacji na giełdzie energii.

Z uwagi na szeroki zakres możliwych konfiguracji, modeli i przebiegów, eksperymenty opisane w niniejszej pracy zostały przeprowadzone na specjalnie w tym celu opracowanym modelu symulacyjnym. Odzworowuje on strukturę mikro sieci oraz umożliwia przeprowadzenie symulacji z różnymi przebiegami sygnałów odwzorowujących rzeczywiste scenariusze działania sieci.

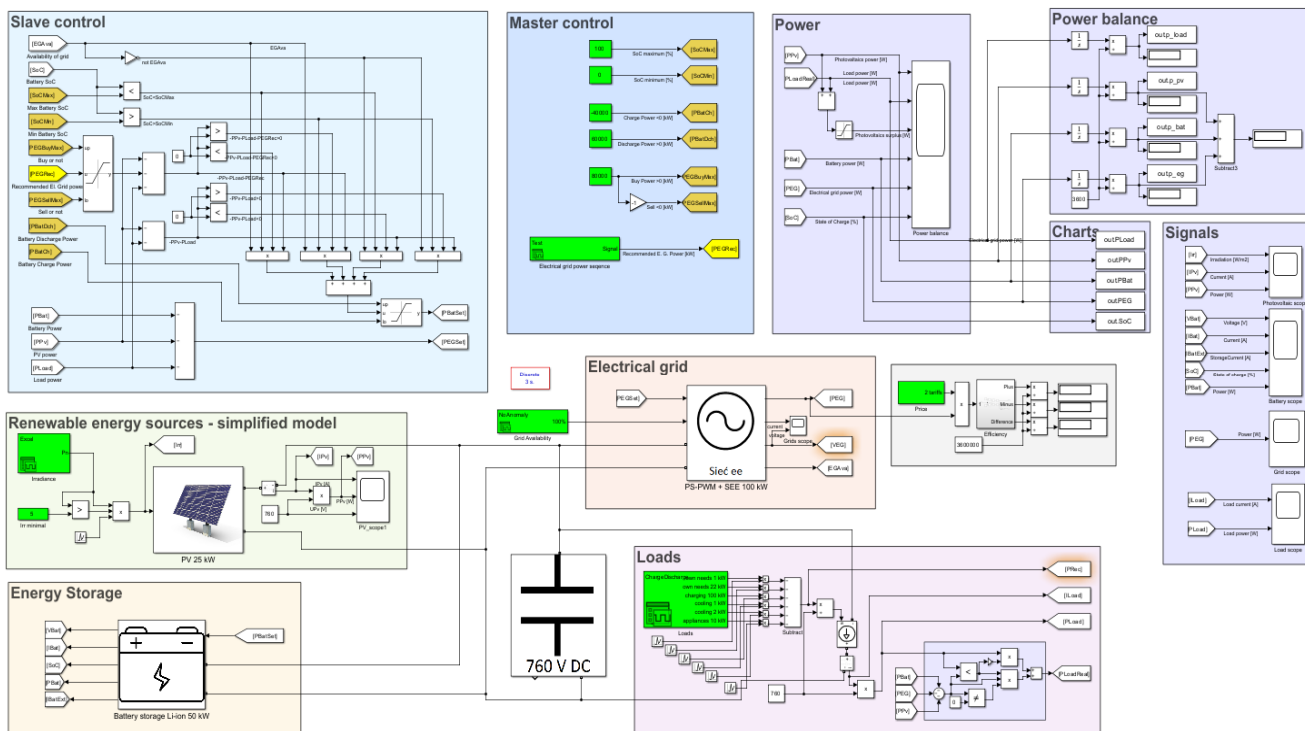
Ze względu na zmiany cen energii co godzinę oraz czasy ładowania i rozładowania baterii akumulatorów zdecydowano się na wykorzystanie modelu z horyzontem czasowym 12- lub 24-godzinowym i adaptacją predykcji oraz sterowania w okresie godzinowym, który będzie obejmował okresowość występującą zarówno w produkcji energii ze źródeł PV, jak i w zmienności cen energii elektrycznej na

giełdzie TGE w obecnej postaci [5]. Na podstawie porównania z dostępnymi rzeczywistymi danymi pozwoliło to przygotować algorytm do pracy w chwili, gdy nastąpi przejście na krótsze terminy ogłaszania kontraktów na TGE.

Przygotowanie modeli symulacyjnych

W trakcie prac badawczych przygotowano szereg modeli eksperymentalnych pracy mikro sieci prądu stałego z podłączonymi źródłami fotowoltaicznymi oraz definiowanymi obciążeniami, a parametry ostatecznej wersji przedstawiono w tabeli 1. Modele zostały przygotowane w środowisku Matlab i umożliwiają szczegółowe badania zachowania mikro sieci, jej dynamiki i potrzeb, także na potrzeby predykcji zachowań anomalnych lub

wykraczających poza możliwości dwóch instalacji PV, z których pochodziły dane (rys. 2). Wyniki symulacji z użyciem modeli zostały porównane z działaniem rzeczywistych komponentów. W efekcie uzyskano bardzo wysokie współczynniki odwzorowania – dla 102 przebiegów testowych osiągnięto różnicę między przebiegami nie przekraczającą 2,5% dla 99. centyli oraz średnią błędów 0,57%. Dodatkowo, większość różnic pomiędzy sygnałami znajdowała się w skrajnych granicach zakresu działania, które w rzeczywistych sytuacjach rzadko występują. Biorąc to pod uwagę, jak również liczbę i stopień komplikacji modelowanych elementów, należy uznać, że uzyskane modele są bardzo dokładne i pozwalają na skuteczne ich wykorzystanie w dalszej części prac.



Rys. 2. Model symulacyjny mikro sieci w Matlabie


Tabela 1. Parametry modelu symulacyjnego mikro sieci prądu stałego

	Nazwa parametru	Wartość	Jednostka
1	Napięcie obwodu DC	760	V
2	Moc sprzęgu AC/DC	100	kW
3	Pojemność magazynu energii	50	kWh
4	Moc instalacji fotowoltaicznej	25	kW
5	Maksymalna moc odbiorników DC	125	kW


Przykładowe wykresy przebiegu prądu oraz stopnia naładowania magazynu (SoC) otrzymane w symulatorze oraz rzeczywiste pokazano na rysunkach 3 i 4. Magazyn był kilkakrotnie ładowany i rozładowywany prądem, którego wartość była zmieniana podczas prowadzonych badań. Zgodność symulacji z danymi rzeczywistymi jest bardzo wysoka. Współczynnik determinacji R^2 zarówno dla prądu, jak i SoC wyniósł ponad 0,99, zaś różnice pomiędzy sygnałem rzeczywistym, a symulowanym dla różnych centyli pokazano w tabeli 2.

Tabela 2. Błędy przebiegów prądu i SoC dla wybranych centyli

Centyli	90	95	98	99	100
Prąd	1,61	1,83	2,06	2,22	3,20
SoC	0,852	0,999	1,26	1,40	1,75



Rys. 3. Wykres przebiegu prądu w magazynie energii



Rys. 4. Wykres przebiegu stopnia naładowania magazynu energii

Badania algorytmów predykcyjnych

Do prawidłowego funkcjonowania mikrosieci, z zapewnieniem optymalnego jej sterowania, niezbędna jest informacja w zakresie przewidywanych wartości wybranych sygnałów. W szczególności kluczowa jest predykcja ceny zakupu energii elektrycznej w horyzoncie czasowym niezbędnym do sterowania przepływami energii. Na potrzeby zbadania możliwości prognozowania produkcji energii elektrycznej z instalacji fotowoltaicznych zaproponowano i przetestowano rozwiązania wykorzystujące wybrane algorytmy predykcyjne.

W związku z tym, że mikrosieć prądu stałego stanowi kompletny ekosystem, sama prognoza produkcji energii elektrycznej musi zostać wzbogacona o dodatkowe elementy w celu zapewnienia całościowego rozwiązania i umocowania predykcji w warunkach ekonomicznych. Dlatego też przygotowano również prognozę obciążeń mikrosieci, prognozę cen energii w sytuacji ich uwolnienia oraz algorytmy sterujące działaniem mikrosieci i transferem energii. Takie komplementarne rozwiązania umożliwiają optymalne wykorzystanie wyprodukowanej energii elektrycznej ze źródeł fotowoltaicznych.

Każda z wymienionych wielkości wymaga odrębnego modelu predykcyjnego, przy czym każdy z tych modeli – z uwagi na charakterystykę sygnału – cechuje się innym poziomem złożoności. Najbardziej przewidywalne i najłatwiejsze do zbudowania są dobowe profile obciążeń (choć szczegóły zależą od charakterystyki użytkownika instalacji).

W większości przypadków, wiarygodne predykcje obciążeń mogą zostać zbudowane na podstawie modelu opartego o trzy podstawowe profile: dane historyczne o obciążeniach z ostatniego tygodnia, miesiąca i roku. Największy wpływ na profil mają najnowsze dane, pozostałe wykorzystywane są głównie do nauczania modelu rozróżniania wpływu sezonowości (oraz uwzględnienia np. dni wolnych od pracy). Ze względu na niski poziom skomplikowania modeli oraz dużą powtarzalność dziennych charakterystyk obciążenia zastosowano klasyczne sieci neuronowe rekurencyjne typu RNN – GRU i LSTM oraz modele autoregresyjne, które uzyskały zadowalające rezultaty (w badaniu profili obciążeń uzyskano w najgorszym przypadku współczynnik determinacji $R^2 = 0,84$).

Predykcja cen, przy założeniu ich uwolnienia, jest bardziej skomplikowanym problemem. Z uwagi na zmiany cen wynikające z działania rynku, inflacji oraz związane z wprowadzaniem regulacji prawnych, model predykcyjny jest w tym przypadku niestacjonarny. W tym przypadku, przetestowano rozwiązania takie jak: drzewa decyzyjne, lasy losowe, SVM, LSTM, modele bazujące na wzmocnieniu, jak XGB czy autoregresyjne. Ostatecznie wybrano model autoregresji z sezonowością. Zastosowane rozwiązanie bardzo dobrze modeluje przyszłe ceny na Towarowej Giełdzie Energii. Przy próbie 6000 obserwacji z horyzontem 24h uzyskano współczynnik determinacji $R^2 =$

0,95, a średnie odchylenie wartości predykcji ceny energii wyniosło 7,13%.

W przypadku sterowania mikrosiecią prądu stałego i predykcją kupna/sprzedaży energii elektrycznej oraz wewnętrznego transferu energetycznego najlepsze rezultaty uzyskano dla modelu sterowania opartego o algorytm optymalizacyjny roju cząstek PSO (ang. particle swarm optimization). Zbliżone rezultaty zostały uzyskane również z zastosowaniem modelu wykorzystującego algorytm genetyczny z ograniczonym elitaryzmem [6] i nałożonymi ograniczeniami na zachowanie ciągłości pomiędzy poszczególnymi genami (AG). Oba modele znajdowały w krótkim czasie (2-10 minut, w zależności od parametrów) akceptowalne suboptymalne rozwiązania. Różniły się one od rozwiązania optymalnego (znalezionego przy pomocy czasochłonnej metody typu *brute force*) o 2-9%, gdzie kryterium była maksymalizacja zysku z handlu energią w ciągu 24h (tab. 3). Każde osiągnięte w ten sposób rozwiązanie spełniało podstawowe kryterium zachowania nałożonych na model ograniczeń i uzyskania określonego (punktowo lub przedziałem) poziomu energii pod koniec cyklu.

Tabela 3. Porównanie skuteczności działania algorytmów zarządzania transferem energetycznym mikrosieci prądu stałego dla małej sieci testowej

Algorytm	Czas obliczeń [s]	Bilans [PLN]	Wydajność algorytmu [%]
Brak sterowania predykcyjnego	n/d	-4,26	0
Scenariusz optymalny	n/d	8,84	100
AG	15	7,34	89
	132	8,18	93
	180	8,54	98
PSO	100	7,35	89
	360	8,17	95
	720	8,62	98

Do uzyskania wiarygodnej predykcji produkcji energii przez instalację PV skorzystano z dostępnych danych dotyczących licznych niewielkich instalacji PV, których charakterystyki i związane z nimi niedokładności są bardziej zbliżone do docelowych źródeł wykorzystywanych w mikrosieciach, niż dane dotyczące dużych farm PV. Uzupełniono je o dane pogodowe pochodzące z serwisów OpenMeteo i SolCast, oraz lokalne dane pogodowe pochodzące ze stacji pogodowej umieszczonej obok jednego z paneli PV. W celu ustalenia wag poszczególnych czynników dokonano analizy zależności pomiędzy danymi pogodowymi a produkcją energii elektrycznej. Po wstępnym przetworzeniu, usunięciu anomalii, ich wzajemnych korelacji ustalono, że najistotniejszym parametrem pogodowym jest całkowite natężenie napromienienia na powierzchni poziomej (GHI) oraz współczynnik przejrzystości powłoki chmur. Wykorzystując drzewo regresyjne i las losowy uzyskano modele osiągające w najgorszych przypadkach współczynnik determinacji $R^2 = 0,87$.

Na podstawie przetworzonych danych pogodowych przygotowano zestaw modeli predykcyjnych. W trakcie badań przetestowano skuteczność 6 algorytmów (drzewo regresyjne [9], las losowy [10], SVM [11], regresor XGB [12], AdaBoost [13], CatBoost [14]) w różnych konfiguracjach. W celu uniknięcia nadmiernego dopasowania modelu do danych, zastosowano 10-krotną walidację krzyżową z podziałem 75-25 i przemieszaniem. Po wykryciu anomalii w zbiorach danych (zarówno pochodzących z serwisów meteorologicznych, jak i instalacji fotowoltaicznej) i uodpornieniu algorytmów na nie, osiągnięto model precyzyjnie przewidyujący produkcję

energii ze źródeł PV w horyzoncie 24-godzinnym. Wyniki przedstawiono w tabeli 4 – prognoza krótkoterminowa dotyczy okresu 3h w czasie produkcyjnym, czas działania wycznaczonych modeli był krótszy niż minuta.

Analiza pokazała, że wprowadzenie lokalnych danych pogodowych znacząco poprawiło zdolności predyktoryjne modelu. Dane te często były uznawane za dużo bardziej istotne od pochodzących z serwisów pogodowych, wskazując na ich większą dokładność. W szczególności hierarchia cech według ich istotności w procesie predykcji jest w naturalny sposób zawarta w drzewie regresyjnym. Jak widać na rysunku 5, na czterech pierwszych poziomach drzewa regresyjnego znajdują się aż cztery lokalne parametry pogodowe (DCI_R, DCI_S, GFCI, EnvTemp), jeden pochodzący z inwertera (liczba próbek w ciągu godziny), jeden niezależny (godzina) i jeden pochodzący z danych globalnych (shortwave_radiation).

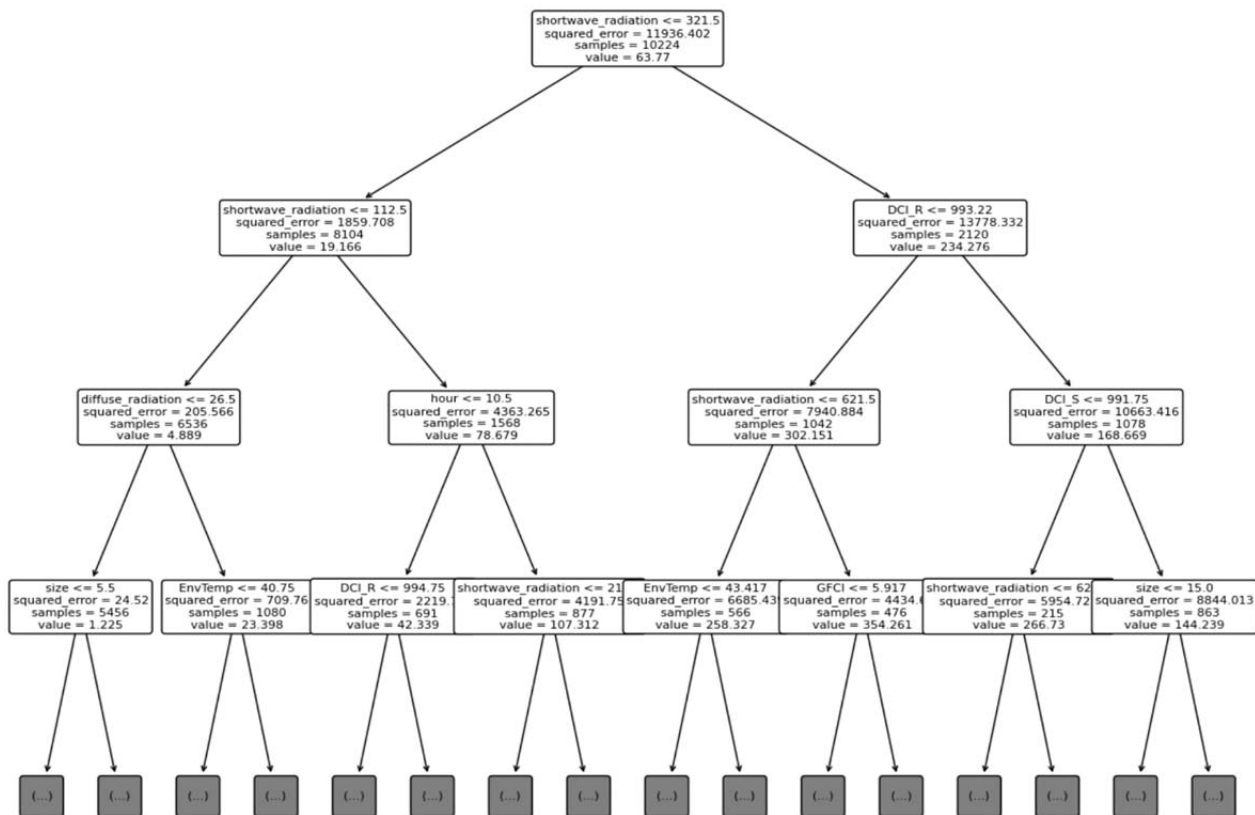
Tabela 4. Porównanie algorytmów do predykcji produkcji energii fotowoltaicznej dla małej mikro sieci testowej.

Model	R ² prognozy krótkoterminowej	R ² prognozy 24h
Drzewo regresyjne	0,9	0,93
Las losowy	0,95	0,85
SVM	0,94	0,89
XGB	0,98	0,95
AdaBoost	0,98	0,95
CatBoost	0,98	0,95

W przypadku wykorzystania lokalnych danych pogodowych pochodzących z niewielkiej stacji pogodowej umieszczonej obok instalacji PV, do prognozy krótkoterminowej (horyzont czasowy 3h) produkcji energii

elektrycznej osiągnięto dużo lepsze wyniki. Współczynnik determinacji wyniósł R² = 0,999. Dane te nie pozwalają jednak na bezpośrednie wykorzystanie w predykcji 24h, z uwagi na niedostępność prognoz. Można je jednak wykorzystać pośrednio do szacowania niedokładności (i korekcji) prognoz pogody pochodzących z SolCast i OpenMeteo dla lokalizacji instalacji.

Spośród sześciu użytych modeli regresyjnych, na szczególną uwagę zasługuje model XGB. W przypadku prognoz 24h bez bezpośredniego wykorzystania lokalnych danych pogodowych, ale uodpornionych na lokalne anomalie (przesłanianie słońca przez stałe obiekty, odłączenia inwertera, niedokładności serwisu pogodowego, itd.) i wytrenowanych na zbiorze pozwalającym odkryć sezonowość (tj. obejmujących swoim zakresem więcej niż 1 rok, w tym przypadku prawie 2 lata obserwacji) XGB potrafi bardzo dobrze przewidzieć produkcję energii elektrycznej osiągając R² = 0,99 i RMSE = 0,37 (rys. 6). Przy nauce na zbiorze danych niepozwalającym na określenie sezonowości i bez odfiltrowania anomalii (rys. 7) osiągnięto wiarygodną predykcję z R² = 0,95 i RMSE = 2,72. O ile predykcja energii w godzinach produkcyjnych była dokładna, o tyle z racji na brak możliwości nauczenia się sezonowości (do eksperymentu użyto danych z okresu marzec-listopad) model nauczył się, że godziny 6 i 7 są również godzinami produkcyjnymi. Dodatkowo, model oparty o XGB potrafi generować ujemne wartości w związku z anomaliami występującymi w danych przesyłanych z instalacji PV. Jedną z pierwszych modyfikacji algorytmu było uodpornienie modelu na tego typu dane.




Rys. 5. Górna część drzewa regresyjnego zbudowanego na podstawie całości danych

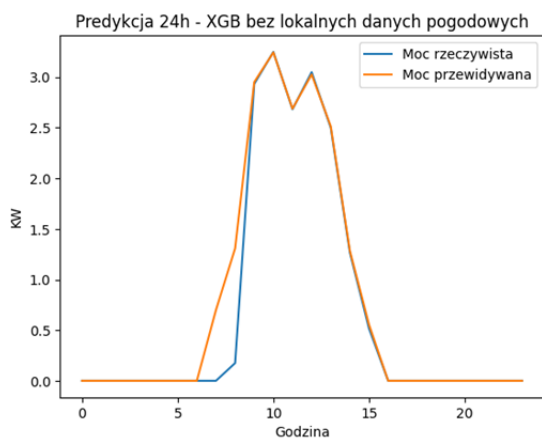
W uodpornionym algorytmie największe różnice w predykcji występowały zazwyczaj w okresie świtu i zmierzchu (rys. 6), niespodziewane przesłanianie przez

chmury w okresie szczytowej produkcji nie miało dużego wpływu przez zastosowanie okresu godzinowego i powodowało tylko nieznaczne odchylenia.

Zgodnie z przypuszczeniami, problematyka sterowania siecią DC w zmieniającym się środowisku rynkowym wymagała modeli niestacjonarnych, z uwagi na niemożliwe do wcześniejszego wprowadzenia zmiany regulacyjne, jak również skomplikowane zależności i liczne czynniki, od których zależy cena energii elektrycznej w Polsce. Wobec tego, w celu uwzględnienia niestacjonarności środowiska i możliwości skokowych zmian, przygotowano modele zdolne do szybkiego dostosowania się do nowych danych (douczenia). Wszystkie przygotowane rozwiązania są w stanie przejść do dokładnej pracy po nastąpieniu skokowej zmiany w czasie krótszym niż doba (w większości przypadków nawet w czasie kilkudziesięciu minut).



Rys. 6. Predykcja produkcji energii elektrycznej przy pomocy modelu opartego o XGB uodpornionego na lokalne anomalie (pomarańczowy) oraz rzeczywista produkcja energii (niebieski).



Rys. 7. Predykcja produkcji energii elektrycznej przy pomocy modelu opartego o XGB (pomarańczowy) oraz rzeczywista produkcja energii (niebieski). Zbiór uczący nie pozwalający na ustalenie sezonowości i bez uodpornienia algorytmu na lokalne anomalie.

Podsumowanie

Optymalne sterowanie przepływami energii w mikro sieci prądu stałego, niezależnie od kryterium optymalizacji wymaga predykcji pewnych sygnałów w najbliższym horyzoncie czasowym. W pracy opisano wyniki eksperymentów polegających na zastosowaniu wybranych modeli predykcyjnych do przewidywania produkcji energii oraz modeli pomocniczych predykcji obciążeń mikro sieci przy znanych cenach energii elektrycznej.

Zaproponowane rozwiązania pozwalają dokonać kompleksowej predykcji produkcji energii elektrycznej ze źródeł PV, obciążenia mikro sieci DC oraz cen energii elektrycznej w horyzoncie 24h. Zastosowane algorytmy

predykcyjne znacząco wspomagają sterowanie procesem ładowania i rozładowywania systemu baterii i transferu energii elektrycznej z siecią przesyłową. Opracowane modele predykcji i sterowania pozwalają również na sprawne zarządzanie mikro siecią DC w horyzoncie czasowym 24h, umożliwiając zapewnienie jej wymaganych przez użytkownika parametrów i maksymalizację zysku z wymiany handlowej z siecią przesyłową.

Autorzy: dr inż. Krzysztof Hryniów; dr inż. Grzegorz Sarwas; dr inż. Piotr Grzejszczak; dr inż. Mariusz Zdanowski; dr hab. inż. Marcin Iwanowski; dr inż. Maciej Sławiński; dr inż. Witold Czajewski; dr inż. Waldemar Graniszewski; Politechnika Warszawska, Instytut Sterowania i Elektroniki Przemysłowej, ul. Koszykowa 75, 00-662 Warszawa, E-mail: [Imię.Nazwisko]@pw.edu.pl

Projekt współfinansowany przez Unię Europejską ze środków Europejskiego Funduszu Rozwoju Regionalnego w ramach Programu Operacyjnego Inteligentny Rozwój. Projekt realizowany w ramach konkursu Narodowego Centrum Badań i Rozwoju: Szybka ścieżka - Innowacje cyfrowe.

LITERATURA

- [1] Raczkowski R., Robak S., System magazynowania energii elektrycznej jako środek poprawy elastyczności systemu elektroenergetycznego z dużym udziałem generacji OZE. *Przegląd Elektrotechniczny*, 2021, 97, 1–8
- [2] Rahbar K., Chai C. C., Zhang R., Energy Cooperation Optimization in Microgrids with Renewable Energy Integration, *IEEE Transactions on Smart Grid*, 2018, 9, 2, 1482-1493
- [3] Grzejszczak P., Koszel M., Barlik R., Nowatkiewicz B., SIMES - Smart Integrated Modular Energy System for DC Microgrids with Energy Storages, *Progress in Applied Electrical Engineering (PAEE)*, Koscielisko, Poland, 2023, 1-5
- [4] Graniszewski W. i inni, DC Microgrid Power Flow Management System – Proof of Concept, *Progress in Applied Electrical Engineering (PAEE)*, Koscielisko, Poland, 2023, 1-4
- [5] Ziel F., Weron R., Day-ahead electricity price forecasting with high-dimensional structures: Univariate vs. multivariate modeling frameworks, *Energy Economic*, 2018
- [6] Viana MS, Morandin Junior O, Contreras RC., A Modified Genetic Algorithm with Local Search Strategies and Multi-Crossover Operator for Job Shop Scheduling Problem, *Sensors (Basel)*. 2020 Sep 22;20(18):5440. doi: 10.3390/s20185440. PMID: 32971959; PMCID: PMC7571099
- [7] Hochreiter, S., Schmidhuber, J., Long Short-Term Memory. *Neural Computation*, 9(8), 1997, 1735-1780
- [8] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y., Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014, pp. 1724-1734
- [9] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J., Classification and Regression Trees. Belmont, CA: Wadsworth International Group., 1984
- [10] Breiman, L., Random Forests. *Machine Learning*, 45(1), 2001, pp. 5-32
- [11] Drucker, H., Burges, C.J.C., Kaufman, L., Smola, A., & Vapnik, V., Support Vector Regression Machines. In M.C. Mozer, M.I. Jordan, & T. Petsche (Eds.), *Advances in Neural Information Processing Systems 9*, 1997, pp. 155-161, Cambridge, MA: MIT Press
- [12] Chen, T., Guestrin, C., XGBoost: A Scalable Tree Boosting System, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*, San Francisco, CA, USA, 2016, pp. 785-794, ACM
- [13] Freund, Y., Schapire, R. E., A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 1997, pp. 119-139.
- [14] Dorogush, A. V., Ershov, V., Gulin, A., CatBoost: gradient boosting with categorical features support, *Workshop on ML Systems at NIPS 2017*, 2018, arXiv:1810.11363.