



Akademia Górniczo-Hutnicza
im. Stanisława Staszica
w Krakowie

Wydział Energetyki i Paliw

ZWIĘKSZENIE EFEKTYWNOŚCI ENERGETYCZNEJ DZIĘKI ZAAWANSOWANYM MODELOM PROGNOZOWANIA

KAMIL MISIUREK, TADEUSZ OLKUSKI, JANUSZ ZYŚK

Streszczenie


Wzrost kosztów energii i globalne cele zrównoważonego rozwoju sprawiają, że zwiększenie efektywności energetycznej staje się priorytetem. Poster ten, prezentuje, jak zaawansowane modele prognozowania, oparte na uczeniu maszynowym (ML) i głębokim uczeniu (DL), umożliwiają optymalizację pracy systemów energetycznych i redukcję strat. Analiza obejmuje szerokie spektrum metod, od klasycznych modeli statystycznych, takich jak ARIMA i regresja, po nowoczesne algorytmy sztucznej inteligencji, w tym sieci neuronowe (LSTM, CNN-LSTM) i transformery. Modele te są dostosowywane do różnych horyzontów czasowych – od prognoz bardzo krótkoterminowych, po długoterminowe. Przedstawione studia przypadków demonstrują praktyczne zastosowanie tych modeli w czterech kluczowych obszarach: zarządzaniu energią w budynkach biurowych, optymalizacji produkcji w fabrykach, inteligentnym zarządzaniu siecią energetyczną (Smart Grid) oraz integracji odnawialnych źródeł energii z prognozowaniem na poziomie indywidualnych odbiorców.

Wprowadzenie: Problem i cel

Wyzwanie: Rosnące koszty energii, niestabilność rynku i globalne cele zrównoważonego rozwoju wymuszają poszukiwanie innowacyjnych rozwiązań do optymalizacji zużycia energii.

Rozwiązanie: Zaawansowane modele prognostyczne, oparte na uczeniu maszynowym, oferują możliwość precyzyjnego przewidywania zużycia i produkcji energii, co pozwala na jej efektywne zarządzanie

Cel pracy: Prezentacja, w jaki sposób wdrożenie modeli prognostycznych w różnych sektorach prowadzi między innymi do wymiennych oszczędności finansowych lub lepszego przewidywania zapotrzebowania na import surowców (węgiel, gaz) (Singh i in. 2019).



Rys. 1 Kategorie prognozowania zużycia energii elektrycznej w oparciu o różne horyzonty czasowe i odpowiadające im obszary operacyjne (Azeem i in. 2021).

1. Zarządzanie energią w budynku biurowym

Problem: Zapotrzebowanie na energię w dużych budynkach, takich jak biurowce, jest bardzo zmienne i zależy od wielu czynników, w tym od liczby osób, pory dnia, czy warunków pogodowych. Tradycyjne metody planowania mogą być uzupełnione o nowoczesne narzędzia analityczne, co pozwala lepiej dostosować pracę systemów grzewczych i klimatyzacyjnych (HVAC) oraz ograniczyć zużycie energii.

Zastosowany model: Sztuczne Sieci Neuronowe (ANN). Model ten wykorzystuje dane historyczne o zużyciu energii, harmonogramie dnia, temperaturze zewnętrznej i wilgotności, aby dynamicznie dostosowywać się do złożonych wzorców zużycia.

Wynik: Model ANN znacznie przewyższył tradycyjne metody, takie jak regresja liniowa czy średnia ruchoma, osiągając błąd MAPE na poziomie 3,9%, co jest znaczącą poprawą. W efekcie możliwe jest bardziej precyzyjne prognozowanie zapotrzebowania na energię, co pomaga obniżyć koszty (Lee i in. 2018).

3. Inteligentne zarządzanie siecią energetyczną (Smart Grid)

Problem: Rosnące włączenie odnawialnych źródeł energii (OZE), takich jak wiatr czy słońce, do sieci energetycznej powoduje jej niestabilność i większe ryzyko przeciążeń, ponieważ ich produkcja jest zmienna. Konieczne jest precyzyjne prognozowanie, aby bilansować podaż i popyt.

Zastosowany model: Hybrydowy model głębokiego uczenia CNN-LSTM oraz ConvLSTM. Modele te łączą konwolucyjne sieci neuronowe (CNN), które wyodrębniają cechy przestrzenne, z sieciami LSTM, które analizują zależności czasowe. Do prognozowania wykorzystano dane z elektrowni PV, wzbogacone o dane pogodowe (np. temperatura, prędkość wiatru, zachmurzenie).

Wynik: Modele hybrydowe znacznie przewyższyły standardowe modele LSTM, uzyskując niższą wartość błędu prognozy. Potwierdza to, że integracja CNN z LSTM zwiększa dokładność prognoz, co jest kluczowe dla stabilności sieci (Agga i in. 2021).

Podsumowanie

Zaawansowane modele prognostyczne są kluczowym narzędziem w kontekście współczesnych wyzwań energetycznych, takich jak rosnące koszty i globalne cele zrównoważonego rozwoju. Ich zastosowanie umożliwia optymalizację pracy systemów energetycznych i redukcję strat. Do prognozowania zużycia energii elektrycznej wykorzystuje się szerokie spektrum metod, od klasycznych modeli statystycznych (jak ARIMA czy regresja), po nowoczesne algorytmy sztucznej inteligencji, w tym uczenie maszynowe i głębokie uczenie. Modele te są dostosowywane do różnych horyzontów czasowych – od bardzo krótkoterminowych po długoterminowe. Coraz częściej stosuje się również modele hybrydowe, które łączą zalety różnych podejść. Praktyczną wartość tego podejścia demonstrują cztery studia przypadków, które prezentują zastosowanie tych modeli w kluczowych obszarach: zarządzaniu energią w budynkach biurowych, optymalizacji produkcji w fabrykach, inteligentnym zarządzaniu siecią energetyczną (Smart Grid) oraz integracji odnawialnych źródeł energii z prognozowaniem na poziomie indywidualnych odbiorców. Wnioskiem jest, że zaawansowane prognozowanie nie tylko wspiera oszczędności finansowe i redukcję strat, ale także jest niezbędnym elementem planowania zrównoważonego i stabilnego systemu energetycznego przyszłości.

Literatura

Singh, P.; Dwivedi, P.; Kant, V. A hybrid method based on neural network and improved environmental adaptation method using Controlled Gaussian Mutation with real parameter for short-term load forecasting. Energy 2019, 174, 1–12.

Azeem, A.; Ismail, I.; Jameel, S.M.; Harindran, V.R. Electrical Load Forecasting Models for Different Generation Modalities: A Review. IEEE Access 2021, 9, 142239–142263.

Lee, Y.W.; Tay, K.G.; Choy, Y.Y. Forecasting Electricity Consumption Using Time Series Model. Int. J. Eng. Technol. 2018, 7, 218–223.


Laayati, O.; Bouzi, M.; Chebak, A. Smart Energy Management System: Design of a Monitoring and Peak Load Forecasting System for an Experimental Open-Pit Mine. Appl. Syst. Innov. 2022, 5, 18.

Agga, A.; Abbou, A.; Labbadi, M.; El Houm, Y. Short-term self consumption PV plant power production forecasts based on hybrid CNN-LSTM, ConvLSTM models. Renew. Energy 2021, 177, 101–112.

Kong, W.; Dong, Z.Y.; Jia, Y.; Hill, D.J.; Xu, Y.; Zhang, Y. Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network. IEEE Trans. Smart Grid 2019, 10, 841–851.

Metodologia: Modele i dane

Prognozowanie zużycia energii elektrycznej opiera się na analizie różnorodnych danych wejściowych, takich jak historyczne pomiary zużycia energii, czynniki sezonowe, warunki pogodowe oraz wskaźniki ekonomiczne. W badaniach stosuje się zarówno klasyczne metody statystyczne (ARIMA, SARIMA, regresja, Holt-Winters), jak i nowoczesne algorytmy sztucznej inteligencji (LSTM, CNN-LSTM, RNN, transformery). Coraz częściej wykorzystywane są również modele hybrydowe, łączące zalety obu podejść. Dobór metody zależy od horyzontu czasowego prognozy.



Rys. 2 Schemat danych wejściowych i modeli wykorzystywanych w prognozowaniu zużycia energii elektrycznej, opracowanie własne.

2. Optymalizacja produkcji w fabryce

Problem: W przedsiębiorstwach o ciągłym cyklu produkcyjnym, takich jak kopalnie odkrywkowe, kluczowe jest efektywne zarządzanie energią w godzinach szczytowego obciążenia. Brak precyzyjnych prognoz może prowadzić do wysokich kosztów operacyjnych.

Zastosowany model: Model regresji kwantylowej Fast Forest (FFQR). Algorytm ten umożliwia dokładne przewidywanie zużycia energii w różnych scenariuszach operacyjnych. Do jego działania wykorzystano dane dotyczące zużycia energii, godzin pracy maszyn i wskaźników produkcyjnych.

Wynik: Model FFQR okazał się wysoce skuteczny w prognozowaniu obciążeń szczytowych, co pozwala na lepsze zarządzanie siecią energetyczną i minimalizację kosztów operacyjnych (Laayati i in. 2022).

4. Integracja OZE i prognozowanie na poziomie indywidualnych odbiorców

Problem: Prognozowanie zużycia energii na poziomie pojedynczych gospodarstw domowych jest bardzo trudne z powodu wysokiej zmienności i nieprzewidywalności wzorców zachowań. Wzrost popularności fotowoltaiki na dachach (prosumenci) wymaga dokładnego przewidywania zarówno produkcji, jak i zużycia energii w czasie rzeczywistym.

Zastosowany model: Sieć neuronowa LSTM. Model ten został wytrenowany na danych z inteligentnych liczników, rejestrujących zużycie energii co 30 minut, co pozwala na dokładne modelowanie wzorców zużycia.

Wynik: Model LSTM osiągnął lepsze wyniki niż inne testowane metody (np. sieci neuronowe BPNN czy K-Nearest Neighbors), co potwierdza jego zdolność do uczenia się skomplikowanych zależności czasowych w zużyciu energii w gospodarstwach domowych. Dzięki temu możliwe jest efektywne zarządzanie energią na poziomie prosumenckim (Kong i in. 2019).