

PAWEŁ MORKISZ *

Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie, Polska

MARTYNA WIĄCEK *

Akademia Górniczo-Hutnicza im. St. Staszica w Krakowie, Polska

Agorithmics sp. z o.o., Kraków, Polska

IRENEUSZ WOCHLIK *

Agorithmics sp. z o.o., Kraków, Polska

Fundacja AI Law Tech, Warszawa, Polska



WYKORZYSTANIE METOD OBLICZENIOWYCH I SZTUCZNEJ INTELIGENCJI W BEZPIECZEŃSTWIE ENERGETYCZNYM

APPLICATION OF COMPUTATIONAL METHODS AND ARTIFICIAL INTELLIGENCE IN ENERGY SECURITY



ABSTRAKT: Możliwości zastosowania sztucznej inteligencji w sektorze energetycznym są dziś szerokie. Ogromna ilość danych przechodzących przez ten sektor stwarza potrzebę wdrażania automatycznej, inteligentnej analizy oraz potencjał rozwoju tych technologii. Chcąc zapewnić bezpieczeństwo energetyczne rozumiane jako zapewnienie ciągłości dostaw energii i paliw, należy mieć pełną kontrolę nad ich dystrybucją i możliwymi zagrożeniami. Korzyści płynące z kontroli nad danymi, prognozowania kluczowych w tym sektorze wartości czy optymalizacji działań i operacji na sieci są nieocenione.

Celem niniejszego artykułu jest przegląd konkretnych obszarów energetyki, w których metody obliczeniowe i sztuczna inteligencja mają największy potencjał. Ponadto, wskazanie konkretnych metod, które sprawdzone w innych sektorach lub zbadane w nauce mają zastosowanie również tutaj.



***dr Paweł Morkisz**, AGH University of Science and Technology, Krakow, Poland

 <https://orcid.org/0000-0002-4734-966X>  morkiszp@agh.edu.pl

***Martyna Wiącek**, AGH University of Science and Technology, Krakow, Poland & Agorithmics sp z o.o., Krakow, Poland

 <https://orcid.org/0000-0002-3933-6287>  martynawiacek@agh.edu.pl

***dr inż. Ireneusz Wochlik**, Agorithmics sp z o.o., Krakow, Poland & AI Law Tech Foundation, Warsaw, Poland

 <https://orcid.org/0000-0002-2003-7551>  ireneusz.wochlik@agorithmics.com

Copyright (c) 2023 Paweł Morkisz & Martyna Wiącek & Ireneusz Wochlik. This work is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.

SŁOWA KLUCZOWE: bezpieczeństwo energetyczne, sztuczna inteligencja, prognoza, optymalizacja, transformacja cyfrowa

ABSTRACT: The possibilities for using artificial intelligence in the energy sector are vast today. The massive amount of data passing through this sector creates the need to implement automatic, intelligent analysis and the potential for developing these technologies. In order to ensure energy security, understood as ensuring the continuity of energy and fuel supplies, it is necessary to have complete control over their distribution and possible threats. The benefits of controlling data, forecasting critical values in this sector, or optimizing activities and operations on the network are invaluable.

The purpose of this article is to review specific areas of the energy sector where computational methods and artificial intelligence have the most significant potential. In addition, specific methods that have been proven in other sectors or studied in science are indicated to apply here.

KEYWORDS: energy security, artificial intelligence, forecasting, optimization, digital transformation

WPROWADZENIE

W XXI wieku bezpieczeństwo energetyczne jest ściśle powiązane ze sprawnym funkcjonowaniem państwa. Jesteśmy uzależnieni od surowców energetycznych oraz energii elektrycznej, na których opiera się nasze codzienne życie. Dziś większość z nas używa komputera jako narzędzia pracy, nauki, rozrywki, rezygnujemy z gotówki na rzecz transakcji kartą, korzystamy z transportu opartego na ropie naftowej oraz energii elektrycznej, a w domu potrzebujemy prądu i gazu aby przygotować obiad, kawę, czy ogrzać mieszkanie. Wszelkie niedobory i zakłócenia grożą chaosem i paraliżem. Wizja blackoutu to czarny scenariusz, który zupełnie uniemożliwiłby nam wykonywanie codziennych obowiązków. Coraz częściej jednak słyszymy o nadchodzącym kryzysie klimatycznym, w szczególności energetycznym. Ten ostatni zapewne został przyspieszony przez aktualnie trwającą wojnę, wywołaną agresją Rosji na Ukrainę. Te wydarzenia wywołały ogromne podwyżki cen energii dla konsumentów i przedsiębiorstw i w dalszej perspektywie najpewniej przyspieszą transformację energetyczną i odejście od importowanych paliw kopalnych na rzecz produkowanej lokalnie energii odnawialnej. Wielu decydentów i przywódców państw boleśnie uświadomiło sobie, jak niebezpieczne jest uzależnienie od paliw kopalnych z Rosji. Już w marcu 2022 Międzynarodowa

Agencja Energetyczna (IEA)¹ opublikowała dziesięciopunktowy plan obejmujący strategię redukcji tego uzależnienia dla państw Unii Europejskiej. W ogólności obejmuje on rozsądne gospodarowanie energią i dywersyfikację z uwzględnieniem alternatywnych źródeł.

Nie mamy wpływu na konflikty zbrojne, pandemie, awarie sieci czy inne wydarzenia tak mocno zaburzające rutynowe funkcjonowanie społeczeństwa. Mamy jednak wpływ na strategię i politykę energetyczną państwa czy poziom przygotowania na tzw. "czarne łabędzie". Celem artykułu jest przegląd możliwości wykorzystania metod sztucznej inteligencji i modelowania matematycznego w celu analizy dostępnych danych i możliwych scenariuszy i umożliwienia decydom podejmowania złożonych decyzji w oparciu o matematykę.

DANE I ICH POTENCJAŁ

Żyjemy w czasach, gdzie każdego dnia generowane są potężne ilości danych - każda firma instynktownie gromadzi masę informacji o zleceniach czy klientach, a w przemyśle bez przerwy prowadzone są odczyty z urządzeń zapisywane w bazach. Mapy Google stale aktualizują informacje o namierzonych pojazdach, a aplikacje monitorujące nasze zdrowie co chwilę zapisują, ile zrobiliśmy kroków czy jakie mamy tętno. To oczywiście tylko niektóre z przykładów, mamy jednak świadomość, że każdy sektor po swojemu te dane gromadzi i przetwarza. Prowadzi to do koncepcji Big Data - ilości danych, których nie jesteśmy w stanie przetworzyć manualnie. Ponieważ umiejętna ich analiza prowadzi do cennej wiedzy, nieocenione okazują się metody sztucznej inteligencji, które potrafią te wolumeny danych poukładać, odkryć w nich zależności, wzorce czy anomalie i przetworzyć na informację użyteczną dla człowieka.

Sektor energetyczny nie jest tu wyjątkiem. Ogromne ilości danych kumulowanych przez przeróżne systemy w tej branży, stwarzają potrzebę wdrażania rozwiązań opartych na sztucznej inteligencji oraz potencjał do rozwoju tych technologii. Korzystanie np. z rozwiązań predykcji zapotrzebowania na energię elektryczną daje dziś firmom przewagę konkurencyjną, a w przyszłości najpewniej będzie standardem, bez którego ciężko będzie firmom w ogóle funkcjonować.

¹ IEA (2022), *A 10-Point Plan to Reduce the European Union's Reliance on Russian Natural Gas*, IEA, Paris
<https://www.iea.org/reports/a-10-point-plan-to-reduce-the-european-unions-reliance-on-russian-natural-gas>,
(dostęp: 6.02.2023)

ROZWÓJ SZTUCZNEJ INTELIGENCJI

Sztuczna inteligencja (ang. artificial intelligence, AI) znana jest w zasadzie od lat 50. XX wieku, kiedy to amerykański informatyk i matematyk John McCarthy pierwszy raz użył tego terminu, określając że jest to „konstruowanie maszyn, o których działaniu dałoby się powiedzieć, że są podobne do ludzkich przejawów inteligencji”. Wtedy też odbyło się pierwsze seminarium poświęcone tej tematyce, a także powstały dwa pierwsze laboratoria AI (na Uniwersytecie Carnegie Mellon oraz na MIT). Warto też wspomnieć o Alanie Turingu, który prowadził pierwsze badania nad możliwością uczenia się i tworzenia nowych konceptów przez komputery. Do dziś często nazywany jest ojcem sztucznej inteligencji, a test nazwany jego nazwiskiem wykorzystywany był wielokrotnie, do weryfikacji zdolności maszyny do posługiwania się językiem naturalnym i pośrednio mającym dowodzić opanowania przez nią umiejętności myślenia².

W drugiej połowie XX wieku w zakresie sztucznej inteligencji badano głównie systemy ekspertowe oparte na rachunku symbolicznym, czy sieci neuronowe oparte na wynikach badań mózgu. W tym czasie entuzjazm środowisk naukowych wokół sztucznej inteligencji na zmianę rósł i opadał. Oczekiwano wielkich przełomów i szybkiej rewolucji, jednak nie następowało to szybko. Różniły się wizje naukowców w zakresie jej rozwoju i często napotykali oni ścianę ze względu na koszty czy brak mocy obliczeniowej, aby dalej rozwijać systemy. Mówi się wręcz o “zimach AI”, kiedy to następowała redukcja wydatków i zastój w badaniach nad nowymi koncepcjami.

Obecnie, kategorią sztucznej inteligencji która znalazła najszerze wykorzystanie i najlepsze rezultaty jest uczenie maszynowe. Podejście to polega na samodzielnym odkrywaniu wzorców, anomalii i zależności przez model, aby skutecznie rozwiązać postawiony problem. Dla przykładu, jeżeli chcemy nauczyć model rozpoznawać kota na zdjęciu, to pokazujemy mu wiele zdjęć z oznaczeniem o prawidłowej odpowiedzi w formie “to jest kot”, “to nie jest kot”. Model sam uczy się odróżniać go od innych zwierząt, a my nie dajemy mu żadnych wskazówek. Mówimy wtedy o zbiorze treningowym, w którym gromadzimy jak najwięcej przykładów, i o zbiorze testowym, na którym sprawdzamy nasz model (podajemy mu przykłady, których nie widział wcześniej). Sprawdzamy, czy model “nauczył się”, tzn. czy umie uogólnić swoją wiedzę na nowe przypadki. Gdybyśmy chcieli napisać taki program bez uczenia maszynowego,

² A.M. Turing, *Computing machinery and intelligence*. Mind 59, October 1950:433-60.

musielibyśmy jasno opisać parametry, które miałyby być sprawdzane (np. proporcje uszu, dopuszczalne kolory, opis konturu), a to jest w przypadku opisu obrazu niezwykle trudne. Nic dziwnego, że rozpoznawanie obrazu tą metodą odnosi takie sukcesy.

Początek XXI wieku jest dla sztucznej inteligencji prawdziwą rewolucją. Obecnie, to właśnie uczenie maszynowe jest najszerzej eksploatowanym obszarem AI. Idąc dalej - poddziedziną uczenia maszynowego która obecnie daje tak dobre rezultaty jest głębokie uczenie, czyli wykorzystanie sieci neuronowych o wielu warstwach. W latach 2010 - 2014 zastosowanie sieci neuronowych nastąpiło w zupełnie nowej skali i jakości. Złożyły się na to czynniki takie jak dostęp do ogromnych ilości danych, dostępu do mocy obliczeniowej i opracowania zupełnie nowych algorytmów trenowania sieci.

Warto wspomnieć 2012 rok, kiedy to zespół kierowany przez profesora Geoffrey'a Hinton'a z Uniwersytetu w Toronto osiągnęła przełomowy wynik w konkursie rozpoznawania obrazów – 2012 ImageNet Large Scale Visual Recognition Challenge (ILSVRC). Wykorzystując głębokie sieci neuronowe (znacznie bardziej skomplikowane od tych rozważanych przed kilkudziesięciami laty) uzyskali doskonałe wyniki dla zagadnienia przetwarzania obrazów. Powstała publikacja "ImageNet Classification with Deep Convolutional Neural Networks"³, która na dzień dzisiejszy ma ponad 125 tysięcy cytowań. Przedstawiono w niej architekturę konwolucyjnej sieci neuronowej: 8 warstw, 60 milionów parametrów i 650 000 neuronów. Dzięki wykorzystaniu akceleratorów graficznych (GPU) uzyskano odpowiednią moc obliczeniową, aby taką sieć wytrenować i skutecznie klasyfikować obrazy ze zbioru ImageNet.

WYKORZYSTANIE AI W SEKTORZE ENERGETYCZNYM

Konkretne obszary zastosowań sztucznej inteligencji w sektorze energetycznym (według⁴) to:

- a) Prognozowanie,
- b) Optymalizacja działań i operacji na sieci,
- c) Optymalizacja zasobów i strategiczne decyzje biznesowe,
- d) Predictive maintenance,
- e) Konserwacje i naprawy,

³ A. Krizhevsky, I. Sutskever, G. Hinton, *ImageNet Classification with Deep Convolutional Neural Networks*, 2012

⁴ dena German Energy Agency, *Artificial Intelligence – from Hype to Reality for the Energy Industry*, Deutsche Energie-Agentur GmbH (dena), 2020

- f) Pomiar bezpieczeństwa,
- g) Ułatwienia dla aktywnych konsumentów,
- h) Dostosowywanie produktów i środków marketingowych,
- i) Automatyzacja procesów w zakresie pomiarów, rachunków i ogólnej dystrybucji.

Jako najbardziej obiecujące miejsca wykorzystania sztucznej inteligencji w raporcie wyróżniono prognozowanie, optymalizację działań i operacji na sieci oraz optymalizację zasobów i strategiczne decyzje. Z naszej perspektywy, kluczowe są również punkty d) - f). Dysponując danymi telemetrycznymi i procesowymi które każdego dnia są zbierane w ogromnych ilościach, warto wdrożyć inteligentne metody ich analizy i wnioskowania o przyszłych wartościach. W poniższych sekcjach krótko omówimy, w jaki sposób konkretne metody mogą wspierać te obszary. Naturalny dla analityków podział opiera się na podejściu do modelowania - pierwsza część metod opiera się na założeniu że możemy dokładnie prognozować, natomiast druga na założeniu, że mamy dostęp do danych o stanie technicznym sieci.

PROGNOZOWANIE PRZYSZŁYCH WARTOŚCI

Prognozowanie, czy też predykcja (ang. forecasting) stanowi ważną metodę analizy rzeczywistości. Pozwala nam "spojrzeć w przyszłość" w sposób naukowy i oparty na aktualnie obserwowanych trendach. Mówimy o prognozowaniu szeregów czasowych, tj. zbioru danych, w którym mamy obserwacje rejestrowane w odpowiednich odstępach czasu (na przykład szereg dziennych cen akcji konkretnej firmy w ciągu ostatnich dwóch lat). Na podstawie historycznych trendów, wahań, obserwowanych zależności możemy stworzyć model, który przewidzi nam przyszłą wartość (np. cenę akcji na dzień kolejny). Dzięki temu uzyskujemy przybliżone wartości, które pozwolą nam na lepsze planowanie i zarządzanie zasobami.

W zakresie prognozowania mamy ogromny potencjał dla AI i modeli matematycznych. To zagadnienie jest szeroko eksploatowane w wielu branżach i daje wymierne korzyści biznesowe. Na przykład, prognozując sprzedaż produktu na kolejny sezon otrzymujemy informacje jak mamy zaopatrzyć magazyny, aby uniknąć zarówno nadprodukcji i jak i niezaspokojenia popytu na produkt. W sektorze energetycznym, możemy np. prognozować zapotrzebowanie na energię elektryczną z punktu widzenia rynku regionalnego, aby lepiej rozdystrybuować zasoby i uniknąć strat podczas przesyłu nadmiernej ilości energii, a w efekcie wpłynąć na sytuację ekonomiczną przedsiębiorstw działających w sektorze elektroenergetycznym.

Samo zagadnienie niesie ze sobą bardzo dużo możliwości i wyzwań - można przewidywać wspólnie dla dużego regionu, posiadać dużą granulację na obszary, a nawet pojedynczych odbiorców czy producentów. Tak samo dużo możliwości niesie ze sobą kwestia horyzontu czasowego - można przewidywać całe zapotrzebowanie na kolejną dobę / tydzień / miesiąc, a można przewidywać zapotrzebowanie na każdą godzinę. Oczywiście od wyboru zadania drastycznie zależy jego trudność zarówno od strony modelowania jak również implementacji. W szczególności w przypadku, w którym chcemy przewidywać szczegółowo zapotrzebowania na odbiorcę dla każdego z użytkowników niezależnie, z granulacją na każdą godzinę, jest bardzo trudne. Wymaga wygenerowania bardzo dużej liczby modeli oraz ich utrzymywania w systemie. Tak samo ważne jest też już na etapie modelowania by określić właściwy sposób liczenia błędów. Często pomyłka przeszacowania i niedoszacowania niosą ze sobą zupełnie inne koszty, w szczególności jak przeszacujemy zapotrzebowanie na energię, to poniesiemy pewną stratę z wyprodukowania za dużo. Z kolei gdy niedoszacujemy, może zabraknąć energii dla odbiorcy, co często może się wiązać z poważnymi konsekwencjami, a co najmniej karami umownymi.

METODY PROGNOZOWANIA

Analiza szeregów czasowych jest dziedziną od lat rozwijaną przez ekonomistów i matematyków. Dużym powodzeniem cieszą się proste modele badające stacjonarność czy autokorelację, takie jak np. modele autoregresyjne (oznaczone stosownie do stopnia ich komplikacji symbolami AR, ARMA, ARIMA). Często korzysta się z podejścia polegającego na dekompozycji szeregu czasowego i wyodrębnieniu czynnika trendu i sezonowości, a czasem też losowości (tzw. szumu).^{5,6}

Innymi modelami matematycznymi, które pomagają w analizie obserwowanych procesów są metody analizy stochastycznej. Mówimy o analizie procesów stochastycznych, które w przeciwieństwie do funkcji wykazują pewnego rodzaju nieprzewidywalność (jak np. ceny akcji, prądu), a "stochastyczny" oznacza właśnie "losowy". Stochastyczne równania różniczkowe (SRR) znalazły wiele praktycznych zastosowań m.in. w matematyce finansowej, inżynierii czy też biologii. Pozwalają na uwzględnienie losowych zaburzeń występujących w modelowanych zjawiskach. Jako przykład można podać szeroko wykorzystywany model Blacka-Scholesa do

⁵ Ho, Siu Lau, and Min Xie. *The use of ARIMA models for reliability forecasting and analysis*. Computers & industrial engineering 35.1-2 (1998): 213-216.

⁶ Ediger, Volkan Ş., Sertac Akar. *ARIMA forecasting of primary energy demand by fuel in Turkey*. Energy policy 35.3 (2007): 1701-1708.

wyceny opcji europejskich.⁷ W przypadku cen energii, bazujemy na takich komponentach jak: sezonowość, powrót do średniej, występowanie istotnych skoków, czy heteroskedastyczność, czyli wariancja zmienna w czasie. Na tej podstawie konstruujemy modele oparte np. o konkretny proces z własnością powrotu do średniej (tzw. Mean Reversion Jump Diffusion)⁸. Dla zagadnienia prognozowania cen energii szczegółowe zestawienie obecnie wykorzystywanych metod i ich rezultatów znaleźć można w monografii Rafała Werona⁹.

Powyższe metody dają dobre rezultaty, jednak są skomplikowane konceptualnie - potrzeba zaangażować matematyka, który rozumie dane podejście, potrafi dobrać odpowiedni model a następnie na podstawie rzeczywistych danych wyestymować współczynniki. Kluczową kwestią dla odpowiedniego dopasowania modelu jest właśnie jego odpowiednia kalibracja, tzn. estymacja konkretnych wartości parametrów z danych rzeczywistych. Najczęściej tego typu algorytmy wykorzystują dobrze znane metody statystyczne jak MNW (metoda największej wiarygodności) czy MNK (metody najmniejszych kwadratów).¹⁰

Zupełnie nowe możliwości daje nam sztuczna inteligencja, którą możemy "nakarmić" odpowiednimi danymi i wytrenować model, uzyskując prognozę. Chcąc wykorzystać do tego metody uczenia maszynowego, możemy skorzystać np. z sieci neuronowych typu LSTM, które mają zdolność do wykorzystywania wcześniej zaobserwowanych zależności występujących w zbiorze danych. To również są metody, które są konceptualnie złożone, jednak dzięki ich popularności w ostatnich latach powstało bardzo wiele bibliotek (tzw. frameworków) np. dla języka Python, które ułatwiają skorzystanie z tych algorytmów. Włączając do tego wiedzę ekspercką (doświadczonego Data Scientista, osób z branży i wiedzą dziedzinową), możemy otrzymać bardzo skuteczne modele, które doskonale dopasowują się do zmienności obserwowanych danych i potrafią zwracać trafne prognozy. Szczegółowe zestawienie metod uczenia głębokiego dla prognozowania szeregów czasowych można znaleźć w publikacji omawiającej aktualny state-of-the-art tego zagadnienia.¹¹

⁷ M. Capiński, and Ekkehard Kopp. *The Black–Scholes Model*. Cambridge University Press, 2012.

⁸ S. Deng, *Stochastic models of energy commodity prices and their applications: Mean-reversion with jumps and spikes*. Berkeley: University of California Energy Institute, 2000.

⁹ R. Weron, *Electricity price forecasting: A review of the state-of-the-art with a look into the future*, International journal of forecasting 30 (4), 1030-1081, 2014

¹⁰ E. Allen. *Modeling with Itô Stochastic Differential Equations*, Springer, 2007.

¹¹ X. Huang, G. C. Fox, S. Serebryakov, A. Mohan, P. Morkisz, D. Dutta, *Benchmarking Deep Learning for Time Series: Challenges and Directions*, 2019 IEEE International Conference on Big Data (Big Data), Los Angeles, CA, USA, 2019, pp. 5679-5682, <https://doi.org/10.1109/BigData47090.2019.9005496>

Prognoza może być celem samym w sobie, bo wiedza o tym “co czai się za rogiem” jest cenna dla decydentów i managerów. Jednakże, często prognoza jest tylko bazą dla dalszych analiz. Jako przykład można wskazać analizę typu what-if, w której korzystając z modeli predykcyjnych możliwe jest symulowanie nowych scenariuszy i sprawdzanie jak wówczas zachowa się prognoza. Możemy na przykład dodać dane o nowym osiedlu czy fabryce, zwiększyć zapotrzebowanie dwukrotnie, i sprawdzić, na co powinniśmy być przygotowani. Pozwala to zidentyfikować potencjalne przyszłe problemy i słabe ogniwa, ale też znaleźć najbardziej korzystny scenariusz. Innym przykładem, gdzie korzystamy z wyników prognoz jest optymalizacja przepływu, czyli wykorzystanie prognozy do możliwie lokalnego bilansowania. Uzyskanie informacji z modeli o dokładnych prognozach produkcji i zużycia pozwala na ustalenie jak wygląda bilans i minimalizację strat na przesyle.

Podsumowując, umiejętność prognozy przyszłych wielkości sprzedaży, zapotrzebowania rynku oraz zmian w trendach ma fundamentalne znaczenie w planowaniu procesu produkcji oraz strategii sprzedażowej. Uzyskiwane wyniki wspierają proces świadomego planowania i zarządzania przedsiębiorstwem. Na podstawie uzyskanych przez modele prognostyczne informacji planowane są nie tylko inwestycje ale i wielkość produkcji, koszty, wielkość zamówień czy struktury zatrudnienia. Przewidywanie przyszłych zachowań rynku stanowi klucz do efektywnego zarządzania w wielu dziedzinach gospodarki - w szczególności energetyki. Dokładność tej prognozy może w istotny sposób wpływać na sytuację ekonomiczną przedsiębiorstw działających w sektorze energetycznym.

OPYTYMALIZACJA DZIAŁAŃ I OPERACJI DZIĘKI MODELOWANIU SIATKI POŁĄCZEŃ SIECI

Zagadnienie to polega na opracowaniu modelu cyfrowego całej siatki połączeń energetycznych. Najczęściej reprezentuje się sieć dystrybucyjną jako graf, gdzie krawędzie stanowią przewody trakcyjne, a wierzchołki to odbiorcy, producenci lub rozdzielnie. Wówczas można dla każdego z odbiorców określić średnie oraz maksymalne zużycie energii, a dla każdego z dostawców maksymalną moc produkcyjną. Posiadając taki model, możliwa jest rzetelna odpowiedź na wiele pytań i analiza pod kątem słabych punktów oraz możliwych inwestycji. Dodatkowo, model taki ma możliwość przechowywania wielu typów informacji, np. maksymalnej przepustowości, maksymalnej wielkości produkcji, zakontraktowanej minimalnej deklarowanej mocy, ale także informację dotyczącą stanu technicznego czy przewidywanego czasu życia.

Kolejnym zastosowaniem takiego uproszczonego modelu rzeczywistości jest modyfikowanie go i przeprowadzanie symulacji w celu sprawdzania reakcji całego układu. Dla przykładu, możemy usuwać pojedynczy element i sprawdzać, czy system nadal jest wydajny, co odpowiada realizacji scenariusza, gdzie wyłączona zostaje jedna elektrownia, czy przerwany zostanie jeden fragment sieci dystrybucyjnej. Dzięki temu możemy zidentyfikować słabe ogniwa czy elementy kluczowe dla zapewnienia ciągłości dostaw. Ponadto, możliwe jest uruchomienie algorytmu, który odpowie na pytania - gdzie należy wykonać kolejną inwestycję, by zmniejszyć prawdopodobieństwa braku dostawy prądu. Analogicznie można analizować scenariusze dodawania kolejnych osiedli, instalacji, nowych fabryk czy terenów przemysłowych i określić minimalne nowe źródła energii oraz ich optymalne rozmieszczenie.

Finalnie, za pomocą takiego modelu sieci dystrybucji, dysponując wcześniej wspomnianymi modelami prognostycznymi, możliwe jest zoptymalizowanie przesyłania i bilansowania energii, w szczególności określenie obszarów i bilansowanie w ich obszarze w celu możliwej minimalizacji strat w przesyśle. W ten sposób realnie można ograniczyć koszty energii elektrycznej dla odbiorców, bo dostawcy mogą obniżyć koszty przesyłowe.

ANALIZA DANYCH TELEMTRYCZNYCH I PROCESOWYCH

Bardzo ważnym zagadnieniem wykorzystywania zaawansowanej analizy danych oraz sztucznej inteligencji jest analiza danych telemetrycznych i procesowych. Możliwe jest to na wielu poziomach i wielu płaszczyznach. Możliwe jest monitorowanie poszczególnych maszyn w konkretnej elektrowni czy rozdzielni. Odbywa się to typowo poprzez analizę bieżących odczytów danych czujnikowych i integrację systemu analitycznego z systemem typu DCS czy SCADA. Ze względu na fakt, że energetyka to sektor, w którym większość instalacji to infrastruktura krytyczna, systemy akwizycji i przechowywania danych sensorowych i procesowych są bardzo dokładne i starannie nadzorowane. W związku z tym, zwykle dysponujemy dużą ilością danych historycznych wysokiej jakości. Dane te pozwalają na analizę danych oraz wytrenowanie różnych modeli sztucznej inteligencji.

Pierwszą, bardzo ważną możliwością zastosowania AI dla tych danych jest detekcja anomalii i wykrywanie wartości odstających - są to algorytmy dedykowane do wykrywania i alarmowania o zdarzeniach, które nie pojawiały się w danych wcześniej. Samo zagadnienie można potraktować na wiele sposobów. Najbardziej podstawowa jego wersja to śledzenie wartości czujników niezależnie i wykrywanie wartości, które są poza jakimś przedziałem - przedział ten

może być albo ustalony w oparciu o historyczne dane albo o dziedzinowe dane eksperckie (np. ekspert wie, że jeśli temperatura urządzenia przekroczyła ustaloną temperaturę, to należy od razu uruchomić alarm oraz wyłączyć urządzenie). Bardziej zaawansowane techniki to np. analiza szybkości zmian (przykładowo nie jest normalne, by temperatura rosła szybciej niż 5C/min, jeśli tak się dzieje, to jest to oznaka awarii). Systemy działające w ten sposób to właśnie albo detekcja anomalii dla zdarzeń nie spotykanych w przeszłości albo systemy typu Condition-Based Monitoring. Do tej grupy zaliczamy także systemy typu analizy wibracji. Potrafimy za ich pomocą wykryć, że coś niepożądanego dzieje się z maszyną o wiele wcześniej niż następuje realna awaria. Takie modele uczenia maszynowego

Warto tu przywołać jeszcze raz znane nam z poprzedniej sekcji modele predykcyjne. W tym kontekście budowane są w oparciu o historyczne dane i historyczne zdarzenia na tych konkretnych bądź podobnych maszynach czy obiektach. Modele te trenuje się w ten sposób, że znany jest moment historycznej awarii oraz stan czujników i danych procesowych wcześniej. Możliwe jest więc nauczenie modelu, że jeśli podobne symptomy pojawiają się w danych, jest zwiększone prawdopodobieństwo powtórzenia takiej samej awarii jak historyczna, a dzięki temu przewidywanie nadchodzących awarii.

Kolejnym ważnym aspektem o ogromnym potencjale w przemyśle są cyfrowe bliźniaki (ang. digital twin), będące cyfrowym odpowiednikiem procesu, obiektu czy całego systemu. Modele te pozwalają na symulację zachowania się maszyn czy instalacji w wirtualnym świecie. Pozwala to na zarówno wykrywanie, że odczyty danych bieżących są daleko od oczekiwanych z cyfrowego oraz na symulacje dla nowych wartości procesowych czy optymalizacji procesów. Podejście to jest np. szeroko stosowane w automotive - BMW wraz z NVIDIA opracowało wszystkie fabryki także w wirtualnym świecie (NVIDIA Omniverse), co pozwala na optymalizację samego procesu wirtualnie, a następnie przenoszenie uzyskanych wyników do rzeczywistości.

Powyższe modele wspierają koncepcję systemów typu Predictive Maintenance (PdM), której celem jest wdrażania strategii umożliwiającej najbardziej optymalne wykorzystanie zasobów w firmie (maszyn, urządzeń). Dla przykładu, jeżeli jeden element linii produkcyjnej ulega uszkodzeniu, wtedy cała produkcja musi zostać zatrzymana do czasu naprawienia usterki, a to generuje spore koszty i problemy z dotrzymaniem terminowości dostaw. Wykorzystanie sztucznej inteligencji często pozwala wykryć sygnały zbliżającej się awarii które są w danych pomiarowych, a nie są widoczne dla człowieka. Dzięki temu rośnie bezpieczeństwo i efektywność całej produkcji. Jako praktyczny przykład możemy wskazać rozwiązanie wdrożone

w należącej do spółki TAURON Elektrowni Łagiasza w Będzinie przy współpracy ze spółką Reliability Solutions. Wdrożono system diagnostyki predykcyjnej, którego zadaniem jest inteligentne wspomaganie procesu zarządzania eksploatacją maszyn, ukierunkowane na zmniejszenie ilości awarii, podniesienie gotowości oraz bezpieczeństwa technicznego maszyn.^{12, 13} Taką analityką można objąć nie tylko elektrownie, lecz również stacje przesyłowe, fabryki czy sieci dystrybucyjne.

ROLA TRANSFORMACJI CYFROWEJ

Aby skutecznie wdrażać zaawansowane modele i podejmować decyzje w oparciu o dane niezbędna jest transformacja cyfrowa przedsiębiorstw, czyli przekrojowy i zorganizowany program zmiany ukierunkowany na wzrost wydajności i poprawę jakości struktur i procesów. Obejmuje on digitalizację, czyli przekształcenie analogowych procesów i obiektów fizycznych w ich cyfrowe odpowiedniki. Zastąpienie papierowych raportów czy ręcznych notatek cyfrową dokumentacją jest kluczowe, jeśli chcemy mówić o transformacji i wykorzystaniu nowych technologii w dowolnej organizacji. Idąc dalej, powinniśmy zadbać o nasze zasoby danych, będące dziś tak cennym aktywem. Należałoby ocenić wszechstronność i skalę posiadanych danych, opracować spójne procesy ich gromadzenia i archiwizowania, w końcu zaprojektować i wdrożyć oprogramowanie służące nam za bazę danych. Te działania składają się na tzw. Data Governance, dzięki któremu możemy usystematyzować i zrozumieć nasze dane, a w efekcie wdrożyć spersonalizowaną analitykę i wykorzystać ich potencjał.

Niestety, nasze doświadczenia pokazują, że większość dużych organizacji ma z tym poważny kłopot. Podjęcie decyzji o przeprowadzaniu transformacji cyfrowej jest odwlekane w czasie, gdyż jest to spory wysiłek i zaangażowanie wielu osób, szczególnie na początkowym etapie. Jednak korzyści z niej płynące są ogromne, poczynając od bieżącej kontroli nad głównymi parametrami biznesu, przez odpowiedzi na wymagania dostawców i klientów, po zwiększenie przychodów i zysków firmy. Ponadto, bez cyfryzacji trudno sięgać po rozwiązania oparte na sztucznej inteligencji czy inne metody analizy danych. Zazwyczaj jest to strata pieniędzy i czasu, gdyż dobre dane są podstawą budowania modeli.

¹² P. Jachymek, *Wykorzystanie analizy Big Data i metod predykcyjnych w utrzymaniu majątku produkcyjnego-na przykładzie Elektrowni Łagiasza*, 2019

¹³ J. Grochowalski, et al. *Towards application of machine learning algorithms for prediction temperature distribution within CFB boiler based on specified operating conditions*. Energy 237 (2021): 121538.

W 2022 roku podgrupa ds. energetyki w ramach działań Grupy Roboczej ds. Sztucznej Inteligencji (GRAI) przy współpracy z ośrodkiem THINKTANK przeprowadziła kompleksową analizę potencjału sztucznej inteligencji w sektorze energetycznym wraz z oceną dojrzałości spółek energetycznych w Polsce. W wyniku tych działań ukazał się raport "Ocena dojrzałości cyfrowej przedsiębiorstw rynku energii elektrycznej w Polsce" będący podsumowaniem przeprowadzonej ekspertyzy¹⁴.

Ponadto, ukazała się publikacja "Jak sztuczna inteligencja może przyspieszyć transformację sektora energetycznego" opracowana przez Obserwatorium Transformacji Cyfrowej THINKTANK przy współpracy z Accenture, Microsoft i Intel. Opracowanie to skierowane jest do liderów przedsiębiorstw związanych z energetyką, firm IT współpracujących z branżą energetyczną, a także decydentów zajmujących się polityką gospodarczą i energetyczną w naszym kraju. Ten strategiczny dokument porusza kwestie specyficzne dla branży energetycznej i polskiego rynku w kontekście transformacji cyfrowej i transformacji energetycznej, ponadto zawiera wyniki badania mającego na celu ocenę gotowości sektora energetycznego w Polsce do wdrożeń AI.

PODSUMOWANIE

Bezpieczeństwo energetyczne, rozumiane jako zapewnienie bieżącego i przyszłego zapotrzebowania odbiorców na paliwa i energię wprost zależy od możliwości monitorowania kluczowych parametrów infrastruktury. Liderzy przedsiębiorstw, kierownicy, inżynierowie i decydenci w sektorze energetycznym powinni mieć bieżącą kontrolę nad głównymi parametrami związanymi z dystrybucją. Energetyka to bardzo złożony i wielowymiarowy system, w którym zależności, powiązania, przyczyny i skutki są zbyt rozległe i niemożliwe do odczytania przez człowieka. Wykorzystanie metod obliczeniowych i sztucznej inteligencji pozwala na identyfikację wzorców i korelacji i zrozumienie posiadanych danych. Dzięki wdrożeniu inteligentnej i przemyślanej analityki, możliwe jest bardziej rzetelne podejmowanie decyzji w oparciu o dane, włączając w to analizę ryzyka i ograniczanie strat energii. Jak wskazano powyżej, sztuczna inteligencja w energetyce najczęściej wykorzystywana jest dwójako - do prognozowania i optymalizacji. Dzięki temu sektor energetyczny staje się wydajniejszy, a w przyszłości może

¹⁴ THINKTANK na zlecenie KPRM, Ocena dojrzałości cyfrowej przedsiębiorstw rynku energii elektrycznej w Polsce, 2023, <https://www.gov.pl/web/ai/ocena-dojrzalosci-cyfrowej-przedsiębiorstw-rynku-energii-elektrycznej-w-polsce>, (dostęp: 6.02.2023)

znacznie przyczynić się do zapewnienia samowystarczalności systemów, a w efekcie neutralności klimatycznej.

BIBLIOGRAFIA REFERENCES LIST

PIŚMIENNICTWO LITERATURE

Allen E., *Modeling with Itô Stochastic Differential Equations*, Springer, 2007.

Artificial Intelligence – from Hype to Reality for the Energy Industry, Deutsche Energie-Agentur GmbH (dena), 2020

Capiński, Marek, and Ekkehard Kopp. *The Black–Scholes Model*. Cambridge University Press, 2012.

Deng S., *Stochastic models of energy commodity prices and their applications: Mean-reversion with jumps and spikes*. Berkeley: University of California Energy Institute, 2000.

Ediger, Volkan Ş., and Sertac Akar. "ARIMA forecasting of primary energy demand by fuel in Turkey." *Energy policy* 35.3 (2007): 1701-1708.

Grochowalski J. i inni, "Towards application of machine learning algorithms for prediction temperature distribution within CFB boiler based on specified operating conditions." *Energy* 237 (2021): 121538.

Ho, Siu Lau, and Min Xie. "The use of ARIMA models for reliability forecasting and analysis." *Computers & industrial engineering* 35.1-2 (1998): 213-216.

Huang X., Fox G.C., Serebryakov S., Mohan A., Morkisz P. and Dutta D., "Benchmarking Deep Learning for Time Series: Challenges and Directions," 2019 IEEE International Conference on Big Data (Big Data), Los Angeles, CA, USA, 2019, pp. 5679-5682, <https://doi.org/10.1109/47090.2019.9005496>.

IEA (2022), *A 10-Point Plan to Reduce the European Union's Reliance on Russian Natural Gas*, IEA, Paris, <https://www.iea.org/reports/a-10-point-plan-to-reduce-the-european-unions-reliance-on-russian-natural-gas>,

Jachymek P., *Wykorzystanie analizy Big Data i metod predykcyjnych w utrzymaniu majątku produkcyjnego-na przykładzie Elektrowni Łagisza*, 2019

Krizhevsky A., Sutskever I., Hinton G., *ImageNet Classification with Deep Convolutional Neural Networks*, 2012

THINKTANK na zlecenie KPRM, *Ocena dojrzałości cyfrowej przedsiębiorstw rynku energii elektrycznej w Polsce*, 2023, <https://www.gov.pl/web/ai/ocena-dojrzalosci-cyfrowej-przedsiębiorstw-rynku-energii-elektrycznej-w-polsce>

Turing, Alan M. (1950). *Computing machinery and intelligence*. *Mind* 59 (October):433-60.

Weron R, *Electricity price forecasting: A review of the state-of-the-art with a look into the future*, *International journal of forecasting* 30 (4), 1030-1081, 2014



Copyright (c) 2023 Paweł Morkisz, Martyna Wiącek, Ireneusz Wochlik



This work is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.