

Analiza IPE nr 2/2020

Nowa era technologii w sektorze energii

Ewa Mataczyńska* , Cyprian Mataczyński**

Streszczenie

Współczesne przedsiębiorstwa energetyczne funkcjonują w otoczeniu przesyconym danymi niosącymi ogromne ilości przeróżnych informacji. Dane pochodzą zarówno z urzędów będących własnością samych firm, ale w przeważającej mierze z otoczenia w jakim działa firma. Ponadto za sprawą transformacji sektora energii, w którym pojawiają się nowe, zdecentralizowane zasoby energii, rosnące wymagania klientów, a presja regulacyjna na łagodzenie zmian klimatu jest większa niż kiedykolwiek, znaczenia nabiera kwestia możliwości pozyskiwania informacji oraz właściwego ich przetwarzania w ciągle zmieniającym się otoczeniu. Posiadając tak ogromne ilości danych, których skatalogowanie wydaje się niemożliwe, firma nie będzie funkcjonowała efektywnie bez wsparcia ze strony nowych technologii. Takie wsparcie z pewnością przyniosą techniki i algorytmy sztucznej inteligencji. Opracowanie uczących się modeli, ukierunkowanych na rozwiązanie konkretnych zagadnień, problemów można docelowo połączyć w jedną kompletną platformę, która w sposób automatyczny (również nadzany) będzie identyfikowała i rozwiązywała pojawiające się problemy. Poniższa analiza ma na celu przybliżenie zagadnień związanych z wykorzystaniem różnych metod uczenia maszynowego we wsparciu wybranych procesów funkcjonujących na rynku energii. Przedstawione w niej rozwiązania są w dużej części autorskimi przykładami tego, w jaki sposób można próbować podejść do istniejących w sektorze oczekiwań.

Abstract

Modern energy companies are overloaded with data, providing numerous insights into the systems. The data is collected not only from the devices which are the property of the enterprise, but mainly from the enterprises' environment. The need to collect this data and process it correctly comes from the transformation of the energy sector in which the new decentralized energy resources are more and more common, rise of the client requirements and the pressure on reducing the impact on the environment. Having such amount of data, without the aid of the new autonomous technologies, it seems impossible to effectively use it. The aid comes from the broad spectrum of artificial intelligence algorithms. Creation of learning models, set to solve specific problems might one day lead to single and unified platform, which autonomously (and on-line) will identify and solve appearing problems. This article's analysis aims to acquaint the reader with the aspects of the use of machine learning based methods used to aid a few chosen energy market processes. Shown solutions are mainly author's view on how the mentioned algorithms may be useful in sector's expectations of the future.

* dr Ewa Mataczyńska – ekspert Instytutu Polityki Energetycznej im. Ignacego Łukasiewicza

** Cyprian Mataczyński – Katedra Automatyki, Mechatroniki i Systemów Sterowania, Politechnika Wroclawska.

1. Wprowadzenie

Sztuczna inteligencja (AI - ang. *artificial intelligence*) to jeden z największych trendów technologicznych obecnych czasów, kształtujący przyszłe modele biznesowe we wszystkich sektorach gospodarki na całym świecie. Dzięki dużym postępom w rozwoju technologii komputerowej, sztuczna inteligencja osiąga coraz to nowe poziomy użyteczności i zastosowania, przekraczając wszelkie początkowe oczekiwania.

Wykorzystując zaawansowane algorytmy uczenia maszynowego (ML – ang. *machine learning*) oraz głębokiego uczenia (DL – ang. *deep learning*) jak również sztuczne sieci neuronowe (ANN – ang. *artificial neural networks*), AI może obsługiwać ogromne ilości danych zarówno nieustrukturyzowanych² jak i ustrukturyzowanych³, lub też częściowo ustrukturyzowanych, pochodzących z różnych źródeł. Może identyfikować wzorce i zależności pomiędzy tymi danymi, ale też próbować przewidywać możliwe do zaistnienia scenariusze, tworząc jednocześnie rekomendacje dla decydentów zarządzających danym procesem. Inteligentne aplikacje mogą również skutecznie podejmować decyzje w sposób autonomiczny oraz zautomatyzowany, bez interwencji człowieka.

Problem współczesnych przedsiębiorstw polega na tym, że funkcjonują w otoczeniu przesyconym danymi niosącymi ogromne ilości przeróżnych informacji. Dane pochodzą zarówno z urzędów będących własnością samych firm, ale w przeważającej mierze z otoczenia w jakim działa firma. Zdarza się, że potencjalnie nieistotne (niemające związku z prowadzoną przez firmę działalnością) informacje mogą w istotny sposób, poprzez różnego rodzaju powiązania (trudne do określenia przez człowieka) wpłynąć na realizację poszczególnych procesów biznesowych. Oznacza to, że pomimo świadomości o istnieniu tych informacji, firma nie potrafi skutecznie i efektywnie z nich korzystać. W takiej sytuacji kwestia sposobów

² Oznacza to, że dane nie pasują do żadnej bazy danych, ani nie mogą być elementem relacyjnego modelu danych w firmie. Dane nieustrukturyzowane prowadzą do wielu wyzwań związanych z zarządzaniem danymi w odniesieniu do uzyskania wartości dodanej z tych danych. Typowym przykładem danych nieustrukturyzowanych jest heterogeniczne źródło danych zawierające kombinację prostych plików tekstowych, obrazów, filmów. Przykładem danych nieustrukturyzowanych są wyniki wyszukiwania udostępniane przez wyszukiwarkę Google.

Według firmy analitycznej Gartner, średnio około 80% danych w firmach uznaje się za nieustrukturyzowane. <http://informacjebranzowe.pl/niewykorzystane-dane-w-naszyc-firmach>, dostęp 01.03.2020.

³ Są to wszystkie dane, które możemy przechowywać, konsultować i przetwarzać w postaci stałego formatu. BIG DATA: *Soorten, kenmerken en voordelen door Wim Hoogenraad*, 29.08.2017, <https://www.itpedia.nl/2017/08/29/big-data-soorten-kenmerken-en-voordelen/>, dostęp 01.03.2020.

pozyskiwania oraz właściwego przetwarzania informacji w ciągle zmieniającym się otoczeniu, zyskuje na wartości. Posiadając tak ogromne ilości danych, których skatalogowanie wydaje się niemożliwe, firma nie będzie funkcjonowała efektywnie bez wsparcia ze strony nowych technologii. Takie wsparcie z pewnością przyniosą techniki i algorytmy sztucznej inteligencji. Są one coraz częściej wykorzystywane w sektorze energetycznym. Ich zastosowanie skierowane jest na identyfikację zaawansowanych problemów, do których rozwiązania konieczna jest skomplikowana, analiza dużej ilości danych. Ponadto poszukiwane są metody takiego rozwiązywania problemów, które będą w stanie adaptować się do zmiennych w czasie warunków otoczenia rozumianego jako zmienność danych (generalizacja modelu).

Poniższy artykuł ma na celu przybliżenie możliwych do zastosowania technik uczenia maszynowego w celu opracowania modeli wspierających rozwiązania wybranych problemów w sektorze energii elektrycznej. Przy czym należy założyć, że za punkt startowy umożliwiający podjęcie tematu ewentualnego zastosowania wskazanych rozwiązań uznaje się punkt, w którym przedsiębiorstwo posiada:

- wystarczającą ilość danych niezbędnych do prawidłowego funkcjonowania modelu,
- adekwatne zaplecze technologiczne oraz techniczne, pozwalające na gromadzenie, przechowywanie oraz analizowanie danych,
- niezbędne zaplecze personalne w celu efektywnego wdrożenia i zarządzania nowymi modelami procesów, które ukształtują się po implementacji poszczególnych rozwiązań.

W artykule nie porusza się również kwestii finansowych ewentualnego uruchomienia i funkcjonowania analizowanych rozwiązań. Ze względu na brak aktualnych infrastruktur, danych oraz przeprowadzonych badań, jak i zaawansowanie przedstawionych problemów, materiał należy traktować jako wsparcie dla rozwoju przyszłych projektów, czy realizacji rozwiązań docelowych w sektorze energii. Przedstawione w niej rozwiązania są w dużej części autorskimi przykładami tego, w jaki sposób można próbować podejść do istniejących w sektorze oczekiwań.

2. Transformacja rynku energii jako główny czynnik rozwoju AI w sektorze

Od kilku lat trwają intensywne dyskusje na temat wykorzystania sztucznej inteligencji do wsparcia procesów związanych z funkcjonowaniem sektora energii, w tym zwłaszcza rynku energii elektrycznej. Na rynku tym rozpoczął się proces transformacji, której źródłem jest decentralizacja, dekarbonizacja oraz digitalizacja. Te trzy elementy ściśle powiązane ze sobą wyznaczają kierunki na przyszłość dla sektora. Elementów tych nie można traktować oddzielnie ponieważ, aby osiągnąć pewien poziom dekarbonizacji należy zaangażować zasoby zdecentralizowane, ale aby można było efektywnie korzystać z tych zasobów niezbędne są mechanizmy digitalizacji umożliwiające zarządzanie tymi zasobami w sposób pozwalający na osiągnięcie jak najwyższego poziomu efektywności energetycznej z jednej strony, a z drugiej umożliwić funkcjonowanie zdecentralizowanym zasobom w sposób gwarantujący zachowanie stabilnej i bezpiecznej pracy systemu elektroenergetycznego. Oczywiście jest to pewien uproszczony schemat, w głębi którego kryją się liczne zadania szczegółowe, które będzie należało wykonać, aby osiągnąć zamierzony cel. Ponadto to nie tylko zadania, ale również nowe modele biznesowe dla dużych przedsiębiorstw energetycznych, to nowe podmioty wchodzące na rynek, to zmiana zachowań odbiorców, która również nie pozostanie bez znaczenia. Wreszcie to zmiana potrzeb tych odbiorców, potrzeb dotyczących codziennego życia, które ewoluowało wraz z pojawianiem się nowych rozwiązań dla domu (ang. *smart home*). Tak szeroki wachlarz zachowań, zmian oraz potrzeb wskazuje na konieczność podejścia do zagadnienia transformacji w sektorze energii w sposób kompleksowy.

Opracowanie uczących się modeli, ukierunkowanych na rozwiązanie konkretnych zagadnień i problemów można docelowo połączyć w jedną kompletną platformę, która w sposób automatyczny (również nadążny) będzie identyfikowała i rozwiązywała pojawiające się problemy. Stworzenie architektury dla takiej platformy, która obejmie zarówno techniczne, jak i ekonomiczne perspektywy rozwoju sektora energii z obsługą AI wydaje się właściwym kierunkiem dla przyszłego rynku energii elektrycznej nasyconego źródłami rozproszonymi (źródła energii odnawialnej PV, turbiny wiatrowe, samochody elektryczne, magazyny energii, mikrosieci, pompy ciepła, odbiorcy zarządzający swoim zużyciem energii) o bardzo różnej charakterystyce, wpływającej na stabilność całego systemu elektroenergetycznego. Bez zmiany istniejących technologii informatycznych trudno będzie zarządzać dużą ilością zróżnicowanych

danych. Z tego też powodu w AI upatruje się ogromny potencjał dla projektowania przyszłego kształtu rynku energii.

3. Wybrane obszary zastosowań AI w sektorze energii

Typowe obszary zastosowania tego rodzaju technologii to handel energią elektryczną, inteligentne sieci czy *sector coupling* (łączenie energii elektrycznej, gazu, ciepła i transportu). Warunkiem wykorzystania AI w systemie energetycznym jest cyfryzacja sektora i odpowiednio gromadzony i przechowywany duży zestaw wiarygodnych danych. Do większości aktualnie stosowanych rozwiązań dane powinny być opisane przez człowieka (oetykietowane) w sposób umożliwiający wykonanie zadania, do którego dany algorytm ma być wykorzystany (czy to do zadania typu regresji, klasyfikacji czy jeszcze innych). W takim przypadku mówimy o uczeniu z nauczycielem, polegającym na podawaniu przykładów poprawnego działania, które właściwie skonfigurowany model, powinien umieć powtórzyć, a ponadto dobrze generalizować w przypadku otrzymania danych o innej dystrybucji niż dane uczące (np. pobrane z innych urządzeń). Stąd, w tym przypadku istotna jest wiarygodność danych, na podstawie których model będzie uczony.

Właściwa analiza danych pochodzących z urządzeń zainstalowanych w sieciach elektroenergetycznych może pomóc w przewidywaniu awarii, prognozowaniu zapotrzebowania na energię elektryczną oraz reagowaniu z odpowiednim wyprzedzeniem na pojawiające się problemy z niezbilansowaniem systemu. W zależności od przyczyny, która spowoduje awarię, specjalnie opracowane platformy będą zdolne do wykorzystania właściwych modeli analizujących i uruchamiających odpowiednie mechanizmy w celu eliminowania zagrożenia awariami. W tym przypadku do sterowania oprócz typowego podejścia optymalizacji klasycznej, przyszłościowo można próbować stosować modele uczenia ze wzmocnieniem, do których dane nie są tak bardzo potrzebne, a dużo bardziej potrzebne są precyzyjne symulacje systemów jako środowiska dla tych algorytmów. Najczęściej spotykanym zastosowaniem samouczących się modeli jest wykonywanie prognoz, które mogą być wykorzystywane również przez wytwórców, szczególnie tych, którzy zarządzają produkcją energii pochodzącej z instalacji źródeł energii odnawialnej (słońce, wiatr), jak i spółki zajmujące się sprzedażą energii elektrycznej. Te drugie niejednokrotnie wykorzystują

specjalistyczne modele nie tylko do prognozowania zapotrzebowania na energię, ale również do przewidywania zmienności cen na rynku energii.

Szczególne oczekiwania w zastosowaniu rozwiązań AI wiąże przemysł samochodowy. Wzrost liczby samochodów elektrycznych to z jednej strony możliwości (szczególnie przez wielu upatrywane jako wsparcie rozwiązań na rzecz klimatu) z drugiej wyzwania. Ładowanie samochodów elektrycznych (szczególnie przy wykorzystaniu dużych mocy) musi być skoordynowane na poziomie sieci elektroenergetycznej w sposób zapewniający po pierwsze efektywne korzystanie z ładowarki przez właściciela samochodu, a z drugiej gwarantujące stabilność pracy sieci elektroenergetycznej, szczególnie w ujęciu lokalnym. Niejednokrotnie samochód elektryczny definiuje się jako przyszłe źródło elastyczności dla systemu elektroenergetycznego, ze względu na techniczne możliwości korzystania z niego jako magazynu energii. Możliwość wykorzystania tego rodzaju zachowań na dużą skalę, będzie wymagało zaawansowanych modeli do zarządzania stabilnością sieci elektroenergetycznej.

Innym zastosowaniem rozwiązań AI jest wykrywanie anomalii w poborze energii, czyli wykrywanie nielegalnego poboru energii. Niektóre z tego rodzaju rozwiązań działają w oparciu o uczenie bez nauczyciela (samouczenie sieci neuronowej), czyli w oparciu jedynie o przykładowe dane wejściowe bez etykiet wprowadzanych przez nauczyciela. Odpowiednio zaprojektowana sieć neuronowa potrafi dostosować wagi algorytmu swojego działania tak, aby automatycznie wykrywać sygnały odmienne od tych, które charakteryzują standardowego konsumenta. Innymi słowy zidentyfikowanie potencjalnych partii sygnału, które są charakterystyczne dla nielegalnego poboru energii.

Ponadto koordynowanie prac konserwacyjnych i określanie optymalnych czasów utrzymania sieci z zastosowaniem AI pomaga zminimalizować koszty i utratę zysków, a także eliminuje niepotrzebne zakłócenia w pracy sieci.

4. Możliwości implementacji AI w sektorze energii – wybrane zagadnienia

4.1 Prognozowanie zapotrzebowania na energię elektryczną

Prognozowanie zapotrzebowania na energię elektryczną jest bardzo skomplikowanym procesem ze względu na konieczność analizy wielu różnych czynników, które mają oczywisty wpływ na osiągnięte wartości, ale też takich czynników, które potencjalnie mogą wpłynąć na

zachowanie odbiorców. Są to między innymi również zmiany związane z samowystarczalnością odbiorców (własna produkcja), zmiany pogody oraz inne zmiany zachowania otoczenia np. sezony letnie, kiedy szkoły nie pracują, dodatkowe wolne dni od pracy (niespodziewane), rozgrywki meczy, duże wydarzenia lokalne, bądź krajowe.

System prognostyczny umożliwiający analizowanie tego typu elementy powinien składać się z wielu pomniejszych modułów, które odpowiadałyby za zbieranie wszelkich danych, które mogłyby pomóc głównemu modułowi w dalszej estymacji. Warto początkowo eksplorować aktualne dane (choćby poprzez zmniejszenie ich wymiarowości przy pomocy algorytmów typu PCA (ang. *Principal Component Analysis*) oraz wraz z ekspertami w dziedzinie prognozowania znaleźć elementy procesu, na które powinna być zwrócona największa uwaga. A dopiero po odpowiednim przygotowaniu danych można próbować tworzyć narzędzie do estymacji zapotrzebowania na energię elektryczną. Biorąc pod uwagę posiadanie historycznych danych używanych do prognozowania, można założyć, że najlepszym z podejść będzie podejście uczenia z nauczycielem. Duża ilość oetykietowanych danych w czasie o dużej wymiarowości, podsuwa dalsze rozwiązanie tego zagadnienia poprzez użycie rekurencyjnych sieci neuronowych bądź *Time-lagged Auto Encoder*⁴, czyli modelu, który jako wejście otrzymuje dane z poprzednim stemplem czasowym, następnie redukuje ich wymiar poszukując w nich zależności, na podstawie których będzie mógł próbować przewidzieć kolejny rekord danych. Warstwę, w której przetwarzane są dane o zredukowanej wymiarowości, nazywa się *bottleneckiem*. W przypadku prognozowania, gdy kolejna prognoza zależy nie tylko od poprzedniej, ale również od danych zewnętrznych, można rozszerzyć go o te dodatkowe dane. Pomoże to modelowi w odpowiedniej estymacji prognozy. Obydwa modele przystosowane są do radzenia sobie z danymi rozłożonymi w stałych odstępach czasu. Tego typu modele musiałyby być lokalne – każdy z nich reprezentujący zależności między wejściem, a prognozą dla jednego, zdefiniowanego obszaru. Dodatkowo wraz ze zmianami zapotrzebowania na energię, dane mogą ulegać przedawnieniu – nie dawać miarodajnej informacji dla późniejszych estymacji. Problem ten można rozwiązać dwojako:

⁴ C. Wehmeyer, F. Noé, *Time-lagged autoencoders: Deep learning of slow collective variables for molecular kinetics*, The Journal of chemical physics 148.24 (2018): 241703.

- przez dostrajanie sieci neuronowej na nowych danych co pewien okres, najlepiej poprzez zamrożenie wag ekstraktorów cech⁵, a naukę jedynie warstw predykcyjnych (przy sieciach rekurencyjnych) bądź dekodera (przy autoenkoderze),
- utworzenie specjalnego współczynnika, który dodatkowo regulował będzie rezultaty na wyjściu sieci neuronowej, przekształcając je tak, aby jak najbardziej odpowiadały danym rzeczywistym.

Wykonane przykładowe badania pokazują, że część takiego systemu jest możliwa do stworzenia przy niewielkim nakładzie pracy⁶.

4.2 Predykcja cen energii elektrycznej

Nawiązując do powyższego przykładu, ideałem dla wielu firm energetycznych zajmujących się obrotem energią elektryczną jest posiadanie rozwiązań pozwalających przewidywać ceny energii elektrycznej, tworzyć optymalny portfel zakupowy w okresie nie tylko krótkoterminowym, ale również długoterminowym. Stworzenie tego rodzaju rozwiązań powinno uwzględniać przewidywane trendy na poziomie nie tylko krajowym, ale również międzynarodowym szczególnie w kontekście bieżących i przyszłych regulacji.

Analiza zagadnienia wymaga skonstruowania złożonego systemu, który weźmie pod uwagę wszelakie niezbędne czynniki wpływające na zmiany cen. Przewidywanie trendów możliwe jest jedynie wtedy, gdy dane wykazują pewnego rodzaju czasowe zależności. Przy tak złożonych zagadnieniach, długofalowe przewidywanie może być bardzo ciężkie do osiągnięcia. Pokazuje to jak ważny jest rozwój zagadnień związanych z teorią chaosu i jednocześnie łączenie osiągnięć tej dziedziny z uczeniem maszynowym⁷. Modele odpowiedzialne za przewidywanie systemów zależących od takiej ilości parametrów muszą być wystarczająco sensytywne na małe zmiany parametrów wejściowych, jednocześnie zachowując odpowiednią generalizację. Te dwa przeciwstawne sobie kryteria należałoby potraktować ze szczególną ostrożnością tak, aby system działał jak najlepiej.

⁵ Znaczy to tyle, że warstwy, które redukują wymiarowość w autoenkoderze nie są dodatkowo uczone, zmieniany jest jedynie sposób predykcji dalszych prognoz na ich podstawie. Znacznie przyspiesza to proces nauki.

⁶ K. Amarasinghe, D.L. Marino, M. Manic, *Deep neural networks for energy load forecasting*, 2017 IEEE 26th International Symposium on Industrial Electronics (ISIE). IEEE, 2017.

⁷ N. B. Harikrishnan, N. Nagaraj, *A novel chaos theory inspired neuronal architecture*, 2019 Global Conference for Advancement in Technology (GCAT), IEEE, 2019.

Aktualne osiągnięcia z dziedziny uczenia głębokiego, niestety nie są przystosowane do tak długofalowego przewidywania trendów o bardzo szerokim zasięgu. Optymalizacja portfela, posiadając wszystkie założonych danych jest możliwa do osiągnięcia już teraz, poprzez odpowiednio przygotowane systemy i algorytmy ewolucyjne⁸.

4.3 Przewidywanie zachowań użytkowników systemu elektroenergetycznego

Przewidywanie zachowań użytkowników systemu elektroenergetycznego w kontekście ich przyzwyczajen wpływających na zużycie energii elektrycznej jest jednym z podstawowych elementów prognozowania zapotrzebowania obszaru na energię elektryczną. Jednak przedsiębiorstwa obrotu energią elektryczną wykorzystują zachowania odbiorców również do tworzenia grup odbiorców oraz proponowanie im zestawu ofert cenowych lub dopasowanych dla potrzeb tych grup produktów.

Rozwiązanie proponowane przez S-V. Oprea, A. Bara⁹ pokazuje, że możliwe jest zastosowanie połączenia kilku słabszych modeli predykcyjnych, tak aby na podstawie danych z inteligentnych liczników, jak i stacji pogodowych, oszacować dzienne zużycie energii elektrycznej. Wspomniane rozwiązanie składało się z siedmiu różnych modeli, z których najlepiej sprawujący się w poprzednich przewidywaniach wybierany był dla stworzenia przewidywań zużycia energii na kolejne 24 godziny.

W przypadku, kiedy przedsiębiorstwo nie posiada wiedzy o możliwych do zaistnienia zależności od wybranych parametrów, czy grupach odbiorców, analizy uczenia maszynowego można oprzeć na metodach klastrowania, które umożliwiają określenie optymalnej, względem pewnego kryterium, ilości odrębnych grup odbiorców. Na podstawie otrzymanego podziału, można następnie analizować podobieństwa między członkami takich grup. Na podstawie takich badań można określić czego potrzebuje każda z grup i co warto przedstawiać w ofertach tak, aby jak najbardziej były dopasowane do potrzeb poszczególnych grup¹⁰.

⁸ J. Korczak, P. Lipinski, *Evolutionary approach to portfolio optimization*, Proceedings of Workshop on Artificial Intelligence for Financial Time Series Analysis, Porto, 2001.

⁹ S-V. Oprea, A. Bara, *Machine Learning Algorithms for Short-Term Load Forecast in Residential Buildings Using Smart Meters, Sensors and Big Data Solutions*, IEEE Access, Vol. 7, pp: 177874 – 177889, 09.12.2019, <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8928601>, dostęp: [05.04.2020].

¹⁰ J. Sala, R. Li, M. H. Christensen, *Clustering and classification of energy meter data: A comparison analysis of data from individual homes and the aggregated data from multiple homes. Building Simulation*, Tsinghua University Press, 2019

Producenci energii elektrycznej ze źródeł sezonowych są specjalnymi użytkownikami systemu elektroenergetycznego, dla których możliwość prognozowania generacji jest bardzo istotnym elementem, szczególnie w kontekście jej dużej zmienności związanej z czynnikami pogodowymi również w połączeniu z tworzeniem scenariuszy sprzedaży wyprodukowanej energii w najbardziej efektywnych pod względem kosztowym warunkach. Zgodnie z danymi zaprezentowanymi przez naukowców z Niemiec, modele opracowane dla fotowoltaiki (PV), czy generacji z wiatru wykazują bardzo dobre wyniki z dobrą korelacją godzinową, na poziomie 0,992 dla energii z wiatru, i niski błąd modelu (znormalizowany średni błąd kwadratowy 0,10). Natomiast modele popytu na energię elektryczną i modele cenowe wymagają dopracowania, aby uzyskać wyniki o akceptowalnej jakości¹¹.

Można wyobrazić sobie, że w przyszłości mechanizmy prognostyczne będą powiązane z uwarunkowaniami (możliwościami i potrzebami) sieci elektroenergetycznych, ale również zawartymi ewentualnych kontraktów na świadczenie usług elastyczności. Takie przyszłościowe modele prognostyczne powinny wskazywać najbardziej opłacalne dla producenta zachowanie zapewniające bezpieczeństwo energetyczne. Niemniej jednak zarówno poziom rozwoju sieci elektroenergetycznych spełniających wymagania sieci *smart grid* w powiązaniu z ciągle rozwijającymi się algorytmami uczenia maszynowego sprawia, że stworzenie systemów łączących powyższe elementy jest bardzo skomplikowanym zadaniem.

Dziedziną, która wykazuje największe możliwości w tego typu podejściu jest uczenie ze wzmocnieniem (ang. *reinforcement learning*), które jednak wymagałoby utworzenia bardzo dokładnej symulacji zachowań sieci energetycznej wraz z wieloma zmiennymi parametrami. Oprócz tego aktualny stan tego typu algorytmów wymaga niezwykle dużej mocy obliczeniowej oraz sieci neuronowych o ilości parametrów liczonej w dziesiątkach milionów, których nauka może trwać nawet kilka do kilkunastu miesięcy, w trakcie których całe zespoły analizują ich działanie oraz przeprowadzają „operacje”¹². Głównym problemem jest tu wielkość przedsięwzięcia, które wymagałoby bardzo długiego i drogiego w utrzymaniu prowadzenia projektu badawczego.

¹¹ J. Baumgartner, J. Schmidt, K. Gruber, *Using machine learning to predict renewable electricity generation, electricity demand, and electricity prices from climate data*, Geophysical Research Abstracts, 2019, Vol. 21, p1-1. 1p.

¹² J. Raiman, S. Zhang, C. Dennison, *Neural Network Surgery with Sets*, arXiv preprint arXiv:1912.06719, 2019.

4.4 Analiza wpływu ładowania samochodów elektrycznych na sieć elektroenergetyczną

Mechanizmy prognozowania połączone z topologią sieci elektroenergetycznej na wybranym obszarze nasyconym rozproszonymi źródłami energii, stacjami ładowania samochodów elektrycznych mogłyby efektywnie wesprzeć procesy zarządzania przepływem energii elektrycznej w sieci, np. poprzez dokonywanie automatycznych rekonfiguracji sieci lub uruchamianie dostępnych na wybranym terenie źródeł elastyczności (wraz z automatycznym dokonaniem rozliczenia przeprowadzonych transakcji). Próba rozwiązania tego zagadnienia wiąże się z elementami przewidywania przyszłości, które bez odpowiednich danych i dużego uproszczenia rzeczywistych procesów jest niemożliwe do osiągnięcia na dużym poziomie wiarygodności.

Niemniej jednak przewidywania związane z ładowaniem samochodów są możliwe do estymacji. W tym przypadku niezbędna jest współpraca pomiędzy twórcami samochodów elektrycznych, które powinny zapewnić wyposażenie samochodu w niezbędne technologie, a branżą energetyczną. Samochody takie mogłyby wysyłać do centralnego systemu dane dotyczące lokalizacji (dla bezpieczeństwa, podobne efekty powinny dać dane lokalizacji najbliższej ładowarki, bądź tej najczęściej uczęszczanej) oraz spersonalizowane dla danego samochodu prawdopodobieństwo tego, że będzie on ładowany w najbliższym czasie. Oszacowanie tego prawdopodobieństwa byłoby możliwe do osiągnięcia poprzez zastosowanie sieci neuronowych, które nazywane są uniwersalnymi aproksymatorami funkcji, czyli odpowiednia sieć neuronowa jest w stanie dopasować się do dowolnej funkcji w sensie matematycznym. Mając takie dane system grafowy, który ma informacje na temat topologii sieci elektroenergetycznej w formie grafu powiązań, byłby w stanie przewidywać i na bieżąco korygować zmiany w obciążeniu tej sieci. Pomóc w tym zadaniu mogłyby algorytmy uczenia maszynowego na grafach, takie jak sieci neuronowe grafowe bądź pokrewne im podejścia¹³.

¹³ W. Hamilton, L. Rex Ying, J. Leskovec. *Representation learning on graphs: Methods and applications*, arXiv preprint arXiv:1709.05584, 2017.

4.5 Określanie potencjalnych miejsc nielegalnego poboru energii elektrycznej.

W tym zakresie poczynione zostały już badania opisane między innymi przez A. Ghasemi¹⁴, H. Hao¹⁵ i S. Mandava¹⁶. Podejść jest kilka, dzielą się one na dwie główne kategorie. Jedna z nich wymaga sieci typu *smart grid*, a z pewnością liczników inteligentnych ze zdalnym dostępem, aby monitorować bieżące zmiany w poborze energii. To, co wydaje się istotne w tej kategorii, to zdalny dostęp do danych oraz możliwość pozyskiwania z danych o dobrej jakości. Jakość danych zależy w dużym stopniu od metody ich pozyskiwania. Dla rozwiązań funkcjonujących przez PLC, niejednokrotnie zakłócenia generowane przez inne urządzenia są na tyle duże, że poziom jakości pozyskanych danych nie zawsze będzie gwarantem dużej wiarygodności stosowanych modeli. Problem jakości danych jest jednak właściwy dla większości przeprowadzanych analiz, niezależnie od zastosowanej technologii przyjętej do opracowania modelu. Chcąc zniwelować zakłócenia powstające na sieci energetycznej, poza możliwością zastosowania standardowych procesów takich jak filtry o różnej przepustowości, można spróbować zastosować wspomniane wcześniej autoenkodery o odpowiednio zmodyfikowanym sposobie nauki, bądź rekurencyjne sieci neuronowe opisane w badaniu przeprowadzonym przez K. Antczak¹⁷.

Druga kategoria zaś stara się obejść ograniczenie braku liczników inteligentnych ze zdalnym odczytem, działając na dostępnych już danych, pochodzących z systemów bilingowych. W tej kategorii można wyróżnić dwa podejścia. Pierwsze z podejść polega na utworzeniu pewnego rodzaju szablonu (profilu) konsumpcji energii dla każdego z użytkowników i wykrywanie odchyłeń pomiędzy kolejnymi dniami użytkowania, znajdując punkty poboru potencjalnie podejrzane o nielegalny pobór. Druga z nich tworzy podobny model, jednak na danych dostępnych na fakturach, bez konieczności ciągłego, godzinnego dostępu do licznika. Przy czym wiarygodność drugiego rozwiązania zależy od sposobu prowadzenia fakturowania za energię elektryczną. Na dzień dzisiejszy w znacznej większości

¹⁴ A. Ghasemi, M. Gitizadeh, *Detection of illegal consumers using pattern classification approach combined with Levenberg-Marquardt method in smart grid*, International Journal of Electrical Power & Energy Systems 99, 2018, pp: 363-375.

¹⁵ H. Hao, S. Liu, K. Davis, *Energy Theft Detection Via Artificial Neural Networks*, IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), IEEE, 2018.

¹⁶ S. Mandava, J. Vanishree, V. Ramesh, *Automation of Power Theft Detection Using PNN Classifier*, International Journal of Artificial Intelligence and Mechatronics 3.4, 2014, pp: 118-122.

¹⁷ K. Antczak, *Deep recurrent neural networks for ECG signal denoising*, arXiv preprint arXiv:1807.11551, 2018.

fakturowanie oparte jest o system prognozowania zużycia, co oznacza, że rzeczywiste rozliczenia dokonywane są w różnych okresach dla różnych grup odbiorców, nie koniecznie miesięcznych. Stąd próba wykorzystywania tego rodzaju danych do stworzenia modeli dających wysoki poziom wiarygodności może nie przynieść spodziewanych efektów.

4.6 Zastosowanie dronów do prowadzenia ewidencji urządzeń

Cały system autonomicznego sterowania dronem można utworzyć na podstawie danych geograficznych samej sieci elektroenergetycznej, użytych do wyznaczania drogi poruszania się pojazdu. Odpowiednia interpretacja struktur, do których powinny takie drony podlatywać i identyfikować wybrane elementy może być użyta przez systemy analogiczne do systemów, które powstają w samochodach autonomicznych. Bardzo szybkie rozpoznawanie obiektów na klatkach filmu jest w zasięgu podstawowych modeli sieci neuronowych takich jak na przykład YOLOv3¹⁸ czy RetinaNet¹⁹. Rozpoznawanie obiektów wraz z lokalizacją ich punktów charakterystycznych daje możliwość dronowi na odpowiednie ustawienie się, tak aby wszelkie dane potrzebne do ewidencji mogły zostać odczytane z uzyskanego obrazu kamery przy pomocy pewnego rodzaju systemu OCR²⁰. Oddzielnie stworzenie każdego z tych systemów nie jest zbyt skomplikowane, jednak połączenie ich oznacza przebrnięcie przez fizyczne bariery, takie jak na przykład długość pracy baterii drona przy jednoczesnej obsłudze tak wielu systemów oraz stacje ładowania rozłożone optymalnie dla drona, bądź osoby, które będą nadzorować jego pracę i wymieniać akumulatory, gdy te będą wyczerpane. Przez takie ograniczenia wprowadzenie takiego rozwiązania wymagało będzie większego nadzoru ludzkiego.

4.7 Przewidywanie problemów ze stabilnością pracy sieci elektroenergetycznej

Temat stabilizacji pracy sieci elektroenergetycznej, czy inaczej mechanizmy zarządzania pracą tej sieci nie są nowym tematem, gdyż codzienna praca systemu elektroenergetycznego wymaga tego. Niemniej jednak charakterystyka przyłączonych odbiorników, czy źródeł zmienia się w dynamiczny sposób. System elektroenergetyczne

¹⁸ J. Redmon, A. Farhadi, *Yolov3: An incremental improvement*, arXiv preprint arXiv:1804.02767, 2018.

¹⁹ TY. Lin, et al., *Focal loss for dense object detection*, Proceedings of the IEEE international conference on computer vision, 2017.

²⁰ S. Stoliński, W. Bieniecki, *Application of OCR systems to processing and digitization of paper documents*, Information Systems in Management VIII, 2011, p: 102.

projektowany na przepływ energii w jednym kierunku, od producenta do odbiorcy, za sprawą rozproszonych źródeł energii przechodzi transformację, której jednym z efektów jest dwukierunkowy przepływ energii. Zmiany te następują w sposób dynamiczny, powodując, że sieć elektroenergetyczna w wielu miejscach „nie radzi sobie” ze stabilnością i jakością dostaw. Pomocą w zarządzaniu takimi sieciami elektroenergetycznymi mogą być modele oparte na uczeniu maszynowym, co zaprezentował portugalski operator sieci dystrybucyjnej w przeprowadzonym projekcie. Projekt koncentruje się na działaniu, kontroli i ochronie sieci dystrybucyjnej od szyn niskiego napięcia w podstacjach poprzez sieć niskiego napięcia do inteligentnego licznika. Założono, że jakości pracy sieci elektroenergetycznej można poprawić poprzez proaktywne zatrzymywanie zdarzeń związanych z utrzymaniem jakości dostarczanej energii, w oparciu o techniki wykorzystujące algorytmy sztucznej inteligencji sztuki. Kierując się tezą, że większość urządzeń elektrycznych jest zaprojektowana tak, aby działać prawidłowo, gdy są zasilane dopuszczalnymi napięciami, analizie poddano napięcia zarejestrowane na licznikach. Choć przeprowadzone badania nie dały wyniku na poziomie 100% wiarygodności osiągniętych rezultatów to zgodnie z zaprezentowanymi wnioskami, zarządzanie inteligentnymi licznikami jest istotną częścią kontroli i monitorowania sieć elektroenergetycznej, aby w przyszłości uzyskać pełną elastyczność i wydajność tej sieci²¹.

To właśnie dla sieci *smart grid* prowadzone są badania oparte na stworzenie systemu, który bierze pod uwagę nie tylko wskazania sensoryczne na analizowanym sprzęcie, ale dodatkowo bierze pod uwagę wyniki inspekcji danego urządzenia. Dla lepszego porozumienia między proponowaną siecią neuronową radialną, a inspektorem wykorzystany jest *Failure Mode and Effect Analysis*, czyli mierzalne określenie punktów krytycznych danych systemów. Na podstawie tych danych sieć neuronowa podejmuje decyzję o tym czy niedługo możliwe jest wystąpienie awarii danej części sieci elektroenergetycznej²².

²¹ T. M. Vazquez Sanchez, P. Pérez Núñez, J. Díez, J. Fernández-Lopez, Fault detection in low voltage networks with smart meters and machine learning techniques, 25th International Conference on Electricity Distribution, Madrid, 3-6 June 2019, Paper n° 851.

²² N. Nadai, et al., *Equipment failure prediction based on neural network analysis incorporating maintainers inspection findings*, Annual Reliability and Maintainability Symposium (RAMS), IEEE, 2017.

5. Wnioski końcowe oraz rekomendacje

Instytucje naukowe, spółki czy pojedyncze jednostki, które potrafią korzystać z informacji i danych jakie ich otaczają oraz mają umiejętność agregowania i pełni wykorzystywania tych informacji są już dzisiaj liderami zmian.

Chcąc otrzymać algorytmy i podejścia, w których nowoczesne technologie spotykałyby się z zapotrzebowaniem rynku, powinno się poza digitalizacją większości danych, udostępniać je (odpowiednio przygotowane i pozbawione danych sensytywnych) na otwartych licencjach, tak, aby społeczności naukowe mogły ich używać podczas prowadzenia projektów naukowych. Dodatkowo warto jest inwestować w ścisłą współpracę pomiędzy środowiskiem naukowym oraz przemysłem, wspierając projekty rozwojowe, które promują w zapisach umów poszukiwanie nowych rozwiązań niezależnie od poziomu osiągnięcia efektu końcowego. Oczywiście wiąże się to z ryzykiem nie ukończenia projektu, jednak pozwala osobom zaangażowanym w rozwój naukowy na eksperymenty, które mogą ten rozwój przyspieszyć.

Niezależnie od tego na temat jakiego zagadnienia trwa dyskusja, zwykle podstawą do osiągnięcia sukcesu dla obydwu stron tej dyskusji jest wzajemna współpraca, oznaczająca również niezbędne kompromisy. Tak jest również i w przypadku gromadzenia doświadczeń dotyczących tworzenia algorytmów samouczących się. Bowiem bez tych doświadczeń nie będzie możliwości wyeliminowania tych miejsc w algorytmach, które nie przynoszą zadowalających rezultatów.

Bibliografia

Amarasinghe K., Marino D.L., Manic M., *Deep neural networks for energy load forecasting*, 2017 IEEE 26th International Symposium on Industrial Electronics (ISIE). IEEE, 2017.

Antczak K., *Deep recurrent neural networks for ECG signal denoising*, arXiv preprint arXiv:1807.11551, 2018.

Baumgartner J., Schmidt J., Gruber K., *Using machine learning to predict renewable electricity generation, electricity demand, and electricity prices from climate data*, Geophysical Research Abstracts, 2019, Vol. 21, p1-1. 1p.

Ghasemi A., Gitizadeh M., *Detection of illegal consumers using pattern classification approach combined with Levenberg-Marquardt method in smart grid*, International Journal of Electrical Power & Energy Systems 99, 2018, pp: 363-375.

Hamilton W., Rex Ying L., Leskovec J., *Representation learning on graphs: Methods and applications*, arXiv preprint arXiv:1709.05584, 2017.

- Hao H., Liu S., Davis K., *Energy Theft Detection Via Artificial Neural Networks*, IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), IEEE, 2018.
- Harikrishnan N. B., Nagaraj N., *A novel chaos theory inspired neuronal architecture*, 2019 Global Conference for Advancement in Technology (GCAT), IEEE, 2019.
- Korczak J., Lipinski P., *Evolutionary approach to portfolio optimization*, *Proceedings of Workshop on Artificial Intelligence for Financial Time Series Analysis*, Porto, 2001.
- Lin TY, et al., *Focal loss for dense object detection*, Proceedings of the IEEE international conference on computer vision, 2017.
- Mandava S., Vanishree J., Ramesh V., *Automation of Power Theft Detection Using PNN Classifier*, International Journal of Artificial Intelligence and Mechatronics 3.4, 2014, pp: 118-122.
- Nadai N., et al., *Equipment failure prediction based on neural network analysis incorporating maintainers inspection findings*, Annual Reliability and Maintainability Symposium (RAMS), IEEE, 2017.
- Oprea SV., Bara A., *Machine Learning Algorithms for Short-Term Load Forecast in Residential Buildings Using Smart Meters*, Sensors and Big Data Solutions, IEEE Access, Vol. 7, pp: 177874 – 177889, 09.12.2019,
<https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8928601>, dostęp: [05.04.2020].
- Raiman J., Zhang S., Dennison C., *Neural Network Surgery with Sets*, arXiv preprint arXiv:1912.06719, 2019.
- Redmon J., Farhadi A., *Yolov3: An incremental improvement*, arXiv preprint arXiv:1804.02767, 2018.
- Sala J., Li R., Christensen M. H., *Clustering and classification of energy meter data: A comparison analysis of data from individual homes and the aggregated data from multiple homes*. Building Simulation, Tsinghua University Press, 2019
- Stoliński S., Bieniecki W., *Application of OCR systems to processing and digitization of paper documents*, Information Systems in Management VIII, 2011, p: 102.
- Wehmeyer C., Noé F., *Time-lagged autoencoders: Deep learning of slow collective variables for molecular kinetics*, The Journal of chemical physics 148.24 (2018): 241703.
- Vazquez Sanchez T. M., Pérez Núñez P., Díez J., Fernández-Lopez J., *Fault detection in low voltage networks with smart meters and machine learning techniques*, 25th International Conference on Electricity Distribution, Madrid, 3-6 June 2019, Paper n° 851.