

Wpływ czynników zewnętrznych na predykcję zużycia energii elektrycznej w budynku biurowym z panelami fotowoltaicznymi

Streszczenie. Planowanie zużycia energii elektrycznej ze względu na pojawiające się niespodziewanie przerwy w dostawie staje istotnym aspektem zarządzania utrzymaniem budynków. Analiza szeregów czasowych pozwala na predykowanie zużycia energii elektrycznej w kolejnych latach na podstawie danych historycznych. Celem badania jest weryfikacja wpływu czynników zewnętrznych na predykcję ilości zużycia energii elektrycznej. W badaniach zostały wykorzystane metody analizy szeregów czasowych: model naiwny z sezonowością, regresji liniowej oraz Facebook Prophet. Wyniki pokazują, że zaproponowane modele w zadawalający sposób są w stanie prognozować zapotrzebowanie na energię.

Abstract. Planning for electricity consumption due to power outages occurring unexpectedly is becoming an important aspect of building maintenance management. Time series analysis makes it possible to predict electricity consumption in future years based on historical data. The purpose of the study is to verify the influence of external factors on the prediction of the amount of electricity consumption. The study used time series analysis methods: naive model with seasonality, linear regression and Facebook Prophet. The results show that the proposed models are able to predict energy demand satisfactorily. (Impact of external factors on electricity consumption prediction in office building with photovoltaic supply).

Słowa kluczowe: predykcja, zużycie energii, analiza szeregów czasowych, metody predykcji danych

Keywords: prediction, energy consumption, time series analysis, methods of data predication

Wstęp

Energia elektryczna jest w dzisiejszych czasach potrzebna niemal do każdego urządzenia występującego w naszym otoczeniu: telefon, komputer, sprzęt gospodarstwa domowego, światła drogowe i wiele innych. Jednak coraz częściej mówi się o niedoborach energii elektrycznej. Zdarzają się przerwy w dostawie energii, co staje się dotkliwie zarówno dla odbiorców prywatnych jak i przedsiębiorstw, zwłaszcza w miastach, gdzie występuje większe zapotrzebowanie na pobór energii elektrycznej przez podmioty różnego typu. Elektrownie mają trudności w dostarczeniu wystarczającej ilości tego dobra przez cały czas, które wynikają z powodu wyczerpujących się złóż węgla czy braku budowy nowoczesnych elektrowni atomowych. Innym elementem są czynniki zewnętrzne i sytuacje losowe, które jeszcze bardziej zaburzają systemy zużycia energii elektrycznej oraz jej produkcję na rynek krajowy i światowy. Niespodziewane sytuacje jak wybuch epidemii COVID-19 czy wojna w państwie, który jest dostawcą surowca produkującego energię mogą wprowadzać pewne odchylenia od normy. Dodatkowo takie anomalie mogą niekorzystnie wpłynąć na cenę energii elektrycznej, powodując znaczny wzrost kosztu zużywanej energii. Może to negatywnie wpłynąć na plan finansowy przedsiębiorstwa związany z kosztem przeznaczonym na energię elektryczną.

Takie sytuacje powodują, że odbiorcy energii elektrycznej, zwłaszcza przedsiębiorstwa, muszą planować zużycie energii elektrycznej oraz ewentualnie starać się o alternatywne źródła energii. Takim rozwiązaniem może być montowanie paneli fotowoltaicznych. Jednak ważnym aspektem zarządzania jest predykowanie ilości zużycia energii, co pozwoli na planowanie zapotrzebowanie ilości zużycia energii, zaplanowanie redukcji ilości osób w biurze w wysokich momentach cenowych energii elektrycznej czy gromadzenie alternatywnych form dostarczania energii podczas niższego zużycia i niższych cen.

W artykule badamy czy czynniki zewnętrzne takie jak niespodziewany wybuch pandemii COVID-19 wpływają na zużycie energii w pewnym badanym budynku biurowym. Sprawdzamy czy metody predykcyjne przewidują prawidłowo zużycie energii podczas występowania anomalii związanej z sytuacjami losowymi. Badamy możliwość zastosowania w opisanej sytuacji trzech metod predykcji:

naiwna z sezonowością, regresja liniowa oraz Facebook Prophet. Dodatkowo zostaje przeprowadzona ocena prognoz. W tym celu wyznaczano są trzy podstawowe metryki związane z oceną uzyskanego wyniku względem wartości rzeczywistej. Pozwoliło to na dobranie odpowiedniej metody do predykcji zachowań z anomaliami.

Opis badanego zespołu budynków

Opisywany obiekt jest zespołem nieruchomości, na który składa się budynek biurowy i wielopiętrowy garaż. Budynek biurowy posiada 4 kondygnacje oraz podpiwniczenie. Powierzchnia zabudowy to 810 m², a powierzchnia użytkowa to 3230 m². Obiekt został oddany do użytku 2017 r. i jest zlokalizowany w Krakowie, w centrum miasta nieopodal rzeki.

Budynek wyposażony jest w system utrzymania komfortu cieplnego, na który składa się wentylacja, klimatyzacja oraz ogrzewanie. Powyższe systemy zarządzane są przez BMS (ang. Building Management System). System grzewczy bazuje na źródle ciepła systemowego zasilanego z miejskiej sieci ciepłowniczej. Ciepło sieciowe wykorzystywane jest do ogrzewania budynku z wykorzystaniem kaloryferów oraz do zasilania nagrzewnic w systemach wentylacyjnych. Mając na uwadze okresy przejściowe wiosną i jesienią, w których ciepło z miejskiej sieci ciepłowniczej może nie być już dostarczane do budynku, a temperatury zewnętrzne mogą powodować potrzebę podniesienia temperatury wewnętrznej, centrala wentylacyjna została wyposażona w 4-sekcyjną nagrzewnicę elektryczną o mocy 45 kW. Nagrzewnica ta może być używana w okresie grzewczym, jednak system BMS jest skonfigurowany w taki sposób, aby centrale wentylacyjne korzystały w pierwszej kolejności z systemowego ciepła ilość dostarczanego z ciepłowniczej sieci miejskiej. Wentylacja wyposażona jest w system rekuperacji oparty o wymienniki obrotowe. Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany jest w oparciu o pomiary dwutlenku węgla w pomieszczeniach przeznaczonych do obsługi zmiennej ilości osób oraz dla części biurowej, w której występują pomieszczenia do określonej liczby osób pracujących w trybie ciągłym zapotrzebowanie na powietrze dla tej powierzchni zostało określone na podstawie wymagań normatywnych.

Budynek wyposażony jest w sieć strukturalną, zasilaną z napięcia gwarantowanego umożliwiającego podtrzymanie pracy przez co najmniej 24 godziny z wykorzystaniem systemu ładowania akumulatorów oraz generatora zasilanego silnikiem diesla. Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w systemy zabezpieczenia technicznego obiektu, w tym CCTV, SKD, ppoż. Ponadto w części technicznej znajdują się stacje ładowania pojazdów dla 8 sztuk pojazdów elektrycznych. Jednak stacje te wykorzystywane są dla ładowania średnio jednego pojazdu dziennie.

Budynek biurowy posiada instalację fotowoltaiczną o mocy 40 kWp oraz wyposażony jest w instalacje służące minimalizacji wpływu na środowisko jak przykładowo system związany z wykorzystaniem wody szarej oraz system inteligentnego dozowania wody w instalacjach kanalizacyjnych. Obiekt w znacznej części wykorzystywany jest przez 24 h/dobę. W pozostałej części należy przyjąć, że pracownicy przebywają co najmniej przez 12h.

Pobór energii jest więc uzależniony od ilości działających standardowo urządzeń, a także konieczności użycia dodatkowych urządzeń, na przykład nagrzewnicy.



Rysunek 1. Badany zespół budynków - mapa i wizualizacja budynków.

Wybrane metody analizy szeregów czasowych i przykłady ich zastosowania

Do przewidywania zużycia energii elektrycznej można zastosować różne metody analizy danych dla szeregów czasowych. Do najbardziej popularnych aktualnie należą model naiwny z sezonowością, regresja liniowa oraz Facebook Prophet.

Model naiwny z sezonowością

Model naiwny uwzględniający sezonowość to proste podejście prognostyczne, które zakłada, że przyszłe wartości będą takie same, jak ostatnia zaobserwowana wartość w odpowiednim sezonie. Ta metoda ignoruje wszelkie podstawowe trendy, wzorce i czynniki zewnętrzne wpływające na dane. Jest to szczególnie przydatne w przypadku danych wykazujących powtarzające się wzorce lub sezonowość, gdzie wartości mają tendencję do podążania za stałym trendem w określonych odstępach czasu, takich jak tygodnie, miesiące lub kwartały. Naiwny model sezonowy jest łatwy do wdrożenia i wydajny obliczeniowo, ale może działać nieefektywnie, jeśli istnieją złożone wzorce lub znaczące różnice w danych. Zastosowanie tego modelu w predykcji zużycia energii wydaje się zasadne ze względu na pory roku występujące w badanym okresie.

Chociaż model ten należy do najprostszych modeli, to jest on używany w wielu dziedzinach życia codziennego takich jak predykcja pogody [16], w finansach i ekonomii do wyznaczenia ceny produktów [11] czy w analizie finansowej do określenia zysków przedsiębiorstwa [12]. Stosuje się go również do przewidywania wykorzystania energii, czego przykładem jest badanie wpływu użycia klimatyzatorów na całość zużycia energii we Włoszech. Model naiwny z sezonowością wykorzystano również do prognozy cen energii elektrycznej [14], [15].

Regresja liniowa

Regresja liniowa to metoda statystyczna stosowana do modelowania związku między zmienną zależną a jedną lub większą liczbą zmiennych niezależnych poprzez dopasowanie równania liniowego do obserwowanych danych. Celem jest znalezienie najlepiej dopasowanej linii, która minimalizuje różnicę między wartościami przewidywanymi a rzeczywistymi punktami danych. Linia ta przedstawia liniową zależność pomiędzy zmiennymi, gdzie zmiany zmiennych niezależnych prowadzą do proporcjonalnych zmian zmiennej zależnej. Równanie proste jest zwykle przedstawiane jako $Y = ax + b$, gdzie Y jest zmienną zależną, x jest zmienną niezależną, a jest nachyleniem, a b jest wyrazem wolnym. Regresja liniowa jest szeroko stosowana do prognozowania, rozumienia korelacji i identyfikowania trendów w danych.

Wykorzystanie modelu regresji liniowej jest opisane w wielu dziedzinach. Użyto go między innymi w aspekcie ekonomicznym, przykładowo do predykcji popytu na mieszkania w celu określenia możliwości budowlanych [18], do określenia cen akcji [21]. W medycynie regresja liniowa użyta została między innymi do wykrywania anomalii w medycznych sieciach [20], natomiast w badaniach diagnostycznych i terapeutycznych, w których wynik zależy od więcej niż jednego czynnika wykorzystywana jest analiza regresji wielokrotnej [19].

Oczywiście ważnym obszarem zastosowań jest wykorzystanie modelu regresji liniowej w zagadnieniach energetycznych. Wykorzystano ją przykładowo do prognozy zużycia energii elektrycznej w zależności od wielu zmiennych ekonomicznych [17].


Facebook Prophet

Prophet to procedura prognozowania danych szeregów czasowych oparta na modelu addytywnym, w którym nieliniowe trendy są dopasowane do sezonowości rocznej, tygodniowej i dziennej oraz efektów świątecznych. Algorytm ten działa najlepiej w przypadku szeregów czasowych, które mają silne efekty sezonowe i kilku sezonów danych historycznych. Prophet jest odporny na brakujące dane i zmiany trendu i zazwyczaj dobrze radzi sobie z wartościami odstającymi.

Facebook Prophet stała się bardzo popularną metodą prognozowania danych i jest wykorzystywany w wielu zagadnieniach. Przykładowo metoda została zastosowana w prognostyce cen akcji na wielu giełdach światowych [24], [25], [26], do określenia wielkości transportu węgla w transporcie kolejowym [23], do prognozowania przyszłej sprzedaży w branży detalicznej (retail) [22]. Natomiast w usługach informatycznych metoda została wykorzystana do przewidywania przyszłego wykorzystania zasobów w środowisku chmurowym [10], a w obszarze zdrowia do prognozowania epidemii medycznych [27], [28]. Facebook Prophet wykorzystywany jest również w przemyśle energetycznym przykładowo w celach predykcyjnych użytkowania energii elektrycznej czy wartości cen [9].

Badanie eksperymentalne

Badania eksperymentalne wykonano na zestawie danych uzyskanych z czujnika poboru energii umieszczonego w opisanym zespole budynków. Dane zebrano w okresie 4 lat, od 01.01.2018 do 31.12.2021. Odczyt danych następował (próbkiowanie) co 15 minut. Zbiór danych zawierał więc ponad 140 174 odczytów. Badany okres to dwa lata typowego zużycia energii, kolejne prawie dwa lata zawierają dane z okresu pandemii COVID-19 (marzec 2020- grudzień 2021).



Rys.2. Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie (oryginalne dane wejściowe).


Przygotowanie danych do predykcji

Przed zastosowaniem metod predykcji wykonano analizę danych wejściowych. W trakcie tej analizy zauważono, że kilkanaście zapisów wstępuje podwójnie (dla jednej godziny zarejestrowano dwie wartości poboru energii). Analiza dat występowania takiej sytuacji wskazała, że ma ona miejsce w przypadku zmiany czasu z letniego na czas zimowy. Następnie została wykonana wizualizacja szeregu czasowego, przy użyciu bibliotek matplotlib w Pythonie (Rys. 2). Zauważono nagłą wartość odstającą i przeanalizowano okres, w którym nastąpiła ta anomalia. Na podstawie uzyskanych dodatkowych informacji (znaczna wartość poboru energii wystąpiła w wyniku rozruchu po przerwie w dostawie energii) stwierdzono, że jest to sytuacja jednorazowa i nie ma wpływu na analiza w dłuższym okresie czasu. Nietypową wartość odczytu zastąpiono uśrednioną wartością odczytów z sąsiednich dni.

Wstępna obróbka danych została więc wykonana poprzez:

- usunięcie dodatkowych powielonych danych (zamiana czasu z letniego na zimowy - dodatkowa godzina),
- usunięcie anomalii (uśrednienie danych z sąsiednich dni).


Szereg czasowy zużycia energii elektrycznej po wstępnej obróbce danych przedstawiono na rysunku Rys.3.




Rys.3. Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie (po wstępnej obróbce danych wejściowych).

Analiza danych zużycia energii


Po wstępnej obróbce dane sprawdzono, jak kształtuje się zużycie energii w poszczególnych latach. Rozkłady zużycia energii w poszczególne miesiące w kolejnych czterech latach zostały przedstawione na rysunkach Rys. 4a-4d.




Rys. 4a. Rozkład wartości zużycia energii w miesiącach 2018 roku.



Rys. 4b. Rozkład wartości zużycia energii w miesiącach 2019 roku.



Rys. 4c. Rozkład wartości zużycia energii w miesiącach 2020 roku.




Rys. 4d. Rozkład wartości zużycia energii w miesiącach 2021 roku.

Jak można zauważyć na powyższych wykresach wykorzystanie energii elektrycznej w marcu 2020 znacznie zmalało. Można to powiązać z wybuchem pandemii COVID-19 oraz przejściem wielu osób na pracę zdalną, co zmniejszyło ilość osób zużywających energię elektryczną w badanym budynku biurowym. Dodatkowym elementem zauważalnym jest sezonowość zużycia energii w badanych latach. W miesiącach letnich mamy znacznie większe zużycie energii elektrycznej. Może to być związane przykładowo z używaniem klimatyzacji w pomieszczeniach roboczych przez pracowników badanego zespołu budynków. W roku 2021 można zauważyć duży rozrzut wykorzystywania energii elektrycznej, ale prawie we wszystkich miesiącach wartości najmniejsze są równomiernie rozłożone. Wyjątkiem są miesiąc lipiec i sierpień co może być spowodowane wyższymi temperaturami powietrza i utrzymaniem niższej temperatury wewnętrznej dla zapewniania komfortu cieplnego pracowników. Duży rozrzut zużycia energii elektrycznej może być spowodowany możliwością pracy hybrydowej, kiedy w poszczególnych dniach znacznie waha się liczba pracujących osób w budynku biurowym. Przy większej ilości pracowników pracującej w jednym dniu mamy znacznie większy pobór energii elektrycznej, ale mogą również występować dni, w których nie mamy żadnych pracowników lub ich liczba jest znacznie ograniczona.

Prognoza zużycia energii

Ze względu na różnice w wartościach odczytów w różnych porach dnia w ramach badań zostały przeprowadzone dwie analizy: dla uśrednionych danych w całym dniu oraz maksymalnej wartości z danego dnia.




Rys.5. Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie wraz z prognozą na rok 2021


Dane podzielono na zbiór treningowy i zbiór testowy. Zbiór treningowy zawierał dane z lat 2018-2020. Prognoza została wyznaczona na rok 2021 na podstawie danych ze zbioru treningowego. Na rysunku Rys. 5 zostało przedstawione zużycie energii elektrycznej badanego zespołu budynków w badanym okresie wraz z prognozą na rok 2021. Na wykresie niebieskim kolorem zostały

oznaczone dane z lat 2018-2020, na których modele były trenowane. Kolorem pomarańczowym przedstawiono dane testowe. Kolor zielony to dane predykcyjne dla roku 2021.


Na kolejnych rysunkach zostały pokazane dane tylko rok 2021, w którym porównano wyniki wartości testowych z prognozą danych. Na rysunkach Rys. 6 a-c pokazano wyniki prognozy dla wartości średnich z całego dnia, w szczególności wartości prognozy wyznaczonej za pomocą modelu naiwnego z sezonowością (Rys. 6a), modelu regresji (Rys. 6b) oraz modelu Facebook Prophet (Rys. 6c).



Rys.6a. Wyniki analizy prognozy dla wartości średnich przy użyciu modelu naiwnego z sezonowością.




Rys.6b. Wyniki analizy prognozy dla wartości średnich przy użyciu modelu regresji liniowej.




Rys.6c. Wyniki analizy prognozy dla wartości średnich przy użyciu modelu Facebook Prophet.


Na rysunkach 7 a-c pokazano wyniki prognozy dla wartości maksymalnej z całego dnia, w szczególności wartości prognozy wyznaczonej za pomocą modelu naiwnego z sezonowością (Rys. 7a), modelu regresji (Rys. 7b) oraz modelu Facebook Prophet (Rys. 7c).



Rys.7a. Wyniki analizy prognozy dla wartości maksymalnych przy użyciu modelu naiwnego z sezonowością.



Rys.7b. Wyniki analizy prognozy dla wartości maksymalnych przy użyciu modelu regresji liniowej.



Rys.7c. Wyniki analizy prognozy dla wartości maksymalnych przy użyciu modelu Facebook Prophet

Na podstawie przedstawionych wykresów można stwierdzić dobre dopasowanie krzywych prognozy do krzywych testowych dla metody regresji liniowej oraz Facebook Prophet. Ma to miejsca zarówno dla danych maksymalnych oraz uśrednionych. Wiele z uzyskanych wyników pokrywa się z danymi rzeczywistymi, zatem można stwierdzić, że są to odpowiednie metody do prognozowania zużycia wartości energii elektrycznej. Najlepiej dopasowana krzywa jest dla metody regresji liniowej.

Gorsze dopasowanie prognozy dla metody naiwnej z sezonowością uzyskano znaczną różnicę na początku roku, co spowodowane jest to zmianą użytkownika energii elektrycznej na początku pandemii a wynikami uzyskanymi rok później w tym samym miesiącu.

Ocena błędów wynikowego

Istnieje wiele sposobów określenia dokładności otrzymanej prognozy z rzeczywistym wynikiem. W celu określenia wybranych rozwiązań zostały wybrane trzy rodzaje metryk oceny prognozy:

MAE – jest to suma wartości bezwzględnych poszczególnych wartości podzielona przez jej ilość

$$MAE = \frac{\sum_{i=1}^n |y_i - x_i|}{n}$$

RMSE – jest to pierwiastek z sumy kwadratów błędów. Małe błędy "karzemy" małymi wartościami, natomiast duże błędy, otrzymują większą karę

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - x_i)^2}{n}}$$

MAPE – jest to suma błędów bezwzględnych podzielona przez sumę rzeczywistej wartości. Aby wynik był skalowalny, podaje się niniejsze wartości w procentach.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right|$$

W tabeli 1 oraz 2 zostały przedstawione wartości wynikowe dla poszczególnych metod odpowiednio dla uśrednionej wartości zużycia energii w dobie oraz wartości maksymalnej w ciągu dnia.

Tabela 1. Analiza prognozy dla wartości maksymalnych zużycia energii.

Nazwa metody	MAE	RMSE	MAPE
Naiwna sezonowość	0.501	0.619	4.303
Regresja liniowa	0.227	0.287	1.954
Facebook Prophet	0.215	0.272	1.844

Tabela 2. Analiza prognozy dla wartości średnich zużycia energii.

Nazwa metody	MAE	RMSE	MAPE
Naiwna sezonowość	0.423	0.513	3.864
Regresja liniowa	0.108	0.136	0.973
Facebook Prophet	0.113	0.150	1.017

Jak możemy zauważyć, najgorsze wyniki uzyskujemy w obu przypadkach dla modelu naiwnego z sezonowością. Nie jest to zaskoczeniem, ponieważ należy on do najprostszych z badanych algorytmów.

W przypadku pozostałych metod wyniki są zbliżone. Najlepsze rezultaty zostały uzyskane dla metody regresji liniowej dla uśrednionych wartości dziennego zużycia energii. Porównywalne do niego są wyniki otrzymane za pomocą metody Facebook Prophet. Różnica wynosi nie cały 0,1 punktu procentowego.

Wnioski

Na podstawie przeprowadzonych analiz i eksperymentów możemy zauważyć, że predykcja zużycia energii elektrycznej w budynku biurowym z panelami fotowoltaicznymi może stać się istotnym narzędziem zarządzania efektywnością energetyczną pomimo nieoczekiwanego wpływu czynników zewnętrznych jak pandemia COVID-19. Zgodnie z wynikami eksperymentów dotyczących predykcji zużycia energii elektrycznej na podstawie wartości maksymalnej i średniej widzimy, że zaproponowane modele w zadawalający sposób są w stanie prognozować zapotrzebowanie na energię. Oznacza to, że na ich podstawie możliwe będzie sporządzenie strategii zarządzania budynkami biorącymi udział w eksperymencie.

Opisane metody nie wyczerpują dyskusji na temat możliwych innych bardziej złożonych modeli predykcji, które wzięłyby pod uwagę na przykład warunków pogodowych mających także znaczenie na ogólne zużycia energii elektrycznej z sieci w budynkach z panelami fotowoltaicznymi. Dodatkowo można uwzględnić monitorowanie wydajności i skuteczność paneli fotowoltaicznych, które mogą stanowić wkład energii odnawialnej. Można także rozważyć szczegółowo dynamikę zużycia energii elektrycznej w ciągu dnia, które przez przewidywanie wzorców zużycia energii elektrycznej jest kluczowe dla optymalnego zarządzania energią z paneli fotowoltaicznych i sieci. Skuteczne zarządzanie i analiza danych z paneli fotowoltaicznych oraz zużycia energii są niezbędne do efektywnego zarządzania energią. Wszystkie wymienione aspekty będą rozwijane w następnych pracach.

Autorzy: mgr inż. Kazimierz Kawa Akademia Górniczo-Hutnicza, Katedra Automatyki i Robotyki, Al. Mickiewicza 30, 30-150 Kraków, Tauron Polska Energia S.A E-mail: kawa@agh.edu.pl; mgr inż. Rafał Mularczyk Akademia Górniczo-Hutnicza, Katedra Automatyki i Robotyki, Al. Mickiewicza 30, 30-150 Kraków, E-mail: mularczyk@agh.edu.pl; dr inż. Waldemar Bauer, Akademia Górniczo-Hutnicza, Katedra Automatyki i Robotyki, Al. Mickiewicza 30, 30-150 Kraków, E-mail: bauer@agh.edu.pl; dr hab. inż. Edyta Kucharska, Akademia Górniczo-Hutnicza, Katedra Automatyki i Robotyki, Al. Mickiewicza 30, 30-150 Kraków, E-mail: edyta@agh.edu.pl;

LITERATURA

- [1] Ray M., Samal P., Kumar Panigrahi C., *The influencing factors on efficacy enhancement of HVAC systems – A review*, Materials Today: Proceedings, (2021), ISSN 2214-7853, <https://doi.org/10.1016/j.matpr.2021.07.264>
- [2] Tsanas A., Xifara A., *Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools*, Energy and Buildings, Volume 49, (2012), 560-567, ISSN 0378-7788, <https://doi.org/10.1016/j.enbuild.2012.03.003>.
- [3] Yu Z., Haghight F., Fung B.C.M., Yoshino H., *A decision tree method for building energy demand modeling*, Energy and Buildings, Volume 42, Issue 10, (2010), 1637-1646, ISSN 0378-7788, <https://doi.org/10.1016/j.enbuild.2010.04.006>.
- [4] Dincer I., *On thermal energy storage systems and applications in buildings*, Energy and Buildings, Volume 34, Issue 4, (2002), 377-388, ISSN 0378-7788, [https://doi.org/10.1016/S0378-7788\(01\)00126-8](https://doi.org/10.1016/S0378-7788(01)00126-8).
- [5] Farouk N., Alhumaidi A. Alotaibi, Alshahri A.H., Almitani K. H., *Using PCM in buildings to reduce HVAC energy usage taking into account Saudi Arabia climate region*, Journal of Building Engineering, Volume 50, (2022), 104073, ISSN 2352-7102, <https://doi.org/10.1016/j.jobe.2022.104073>.
- [6] Hou J., Li X., Wan H., Sun Q., Dong K., Huang G., *Real-time optimal control of HVAC systems: Model accuracy and optimization reward*, Journal of Building Engineering, Volume 50, 2022, 104159, ISSN 2352-7102, <https://doi.org/10.1016/j.jobe.2022.104159>.
- [7] Belafi, Z., Hong, T., Reith, A. *Smart building management vs. intuitive human control—Lessons learnt from an office building in Hungary*. Build. Simul. 10, 811–828 (2017). <https://doi.org/10.1007/s12273-017-0361-4>
- [8] Bagheri-Esfeh H., Reza Dehghan M., *Multi-objective optimization of setpoint temperature of thermostats in residential buildings*, Energy and Buildings, Volume 261, (2022), 111955, ISSN 0378-7788, <https://doi.org/10.1016/j.enbuild.2022.111955>.
- [9] Guo, C., Ge, Q., Jiang, H., Yao, G., & Hua, Q. (2020). Maximum power demand prediction using fbprophet with adaptive Kalman filtering. IEEE Access, 8, 19236-19247., Chicago.
- [10] M. Daraghmeah, A. Agarwal, R. Manzano and M. Zaman, "Time Series Forecasting using Facebook Prophet for Cloud Resource Management," 2021 IEEE International Conference on Communications Workshops (ICC Workshops), Montreal, QC, Canada, 2021, pp. 1-6, doi: 10.1109/ICCWorkshops50388.2021.9473607.
- [11] Brandt, J. A., & Bessler, D. A. (1983). Price forecasting and evaluation: An application in agriculture. Journal of Forecasting, 2(3), 237-248.
- [12] Lacina, M., Brian Lee, B. and Zhaohui Xu, R. (2011), "An Evaluation of Financial Analysts and Naïve Methods in Forecasting Long-Term Earnings", Lawrence, K.D. and Klimberg, R.K. (Ed.) Advances in Business and Management Forecasting (Advances in Business and Management Forecasting, Vol. 8), Emerald Group Publishing Limited, Bingley, pp. 77-101.
- [13] De Felice, M., Alessandri, A., & Ruti, P. M. (2013). Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models. Electric Power Systems Research, 104, 71-79.
- [14] Jan F, Shah I, Ali S. Short-Term Electricity Prices Forecasting Using Functional Time Series Analysis. Energies. 2022; 15(9):3423. <https://doi.org/10.3390/en15093423>
- [15] Nogales, F. J., & Conejo, A. J. (2006). Electricity price forecasting through transfer function models. Journal of the Operational Research Society, 57(4), 350-356.
- [16] Svec, J., & Stevenson, M. (2007). Modelling and forecasting temperature based weather derivatives. Global Finance Journal, 18(2), 185-204., Chicago.
- [17] Mohamed, Z., & Bodger, P. (2005). Forecasting electricity consumption in New Zealand using economic and demographic variables. Energy, 30(10), 1833-1843.
- [18] Ng, S. T., Skitmore, M., & Wong, K. F. (2008). Using genetic algorithms and linear regression analysis for private housing demand forecast. Building and Environment, 43(6), 1171-1184.
- [19] Marill, K. A. (2004). Advanced statistics: linear regression, part II: multiple linear regression. Academic emergency medicine, 11(1), 94-102.
- [20] Salem, O., Guerassimov, A., Mehaoua, A., Marcus, A., & Furht, B. (2014). Anomaly detection in medical wireless sensor networks using SVM and linear regression models. International Journal of E-Health and Medical Communications (IJEHMC), 5(1), 20-45., Chicago,
- [21] . Peng and X. Li, "Application of a multifactor linear regression model for stock portfolio optimization," in 2018 International Conference on Virtual Reality and Intelligent Systems (ICVRIS) 2018, pp. 367-370
- [22] Zunic, E., Korjenic, K., Hodzic, K., & Donko, D. (2020). Application of facebook's prophet algorithm for successful sales forecasting based on real-world data. arXiv preprint arXiv:2005.07575.
- [23] Soloviev, V., Titov, N., & Smirnova, E. (2020, July). Coking coal railway transportation forecasting using ensembles of ElasticNet, LightGBM, and Facebook prophet. In International Conference on Machine Learning, Optimization, and Data Science (pp. 181-190). Cham: Springer International Publishing.
- [24] Garlapati, A., Krishna, D. R., Garlapati, K., Rahul, U., & Narayanan, G. (2021, April). Stock price prediction using Facebook Prophet and Arima models. In 2021 6th International Conference for Convergence in Technology (I2CT) (pp. 1-7). IEEE.
- [25] Kaninde, S., Mahajan, M., Janghale, A., & Joshi, B. (2022). Stock price prediction using facebook prophet. In ITM Web of Conferences (Vol. 44, p. 03060). EDP Sciences.
- [26] Saiktishna, C., Sumanth, N. S. V., Rao, M. M. S., & Thangakumar, J. (2022, May). Historical Analysis and Time Series Forecasting of Stock Market using FB Prophet. In 2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS) (pp. 1846-1851). IEEE.
- [27] Battineni, G., Chintalapudi, N., & Amenta, F. (2020). Forecasting of COVID-19 epidemic size in four high hitting nations (USA, Brazil, India and Russia) by Fb-Prophet machine learning model. Applied Computing and Informatics.
- [28] Satrio, C. B. A., Darmawan, W., Nadia, B. U., & Hanafiah, N. (2021). Time series analysis and forecasting of coronavirus disease in Indonesia using ARIMA model and PROPHET. Procedia Computer Science, 179, 524-532.