



AKADEMIA GÓRNICZO-HUTNICZA IM. STANISŁAWA STASZICA W KRAKOWIE

DZIEDZINA: NAUKI INŻYNIERYJNO-TECHNICZNE

DYSCYPLINA AUTOMATYKA, ELEKTRONIKA, ELEKTROTECHNIKA
I TECHNOLOGIE KOSMICZNE

ROZPRAWA DOKTORSKA

*Standaryzacja i optymalizacja zarządzania zespołem
rozproszonych heterogenicznych nieruchomości
komercyjnych*

Autor: mgr inż. Kazimierz Kawa

Promotor rozprawy: dr hab. inż. Edyta Kucharska, prof. AGH
Promotor pomocniczy: dr inż. Waldemar Bauer

Praca wykonana: Akademia Górniczo - Hutnicza im. Stanisława Staszica
w Krakowie,
Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej

Kraków 2024



FIELD OF SCIENCE ENGINEERING AND TECHNOLOGY

SCIENTIFIC DISCIPLINE AUTOMATION, ELECTRONICS, ELECTRICAL
TECHNOLOGY AND SPACE TECHNOLOGIES

DOCTORAL THESIS

*Standardization and optimization management
of a system of heterogenous, distributed commercial
facilities*

Author: mgr inż. Kazimierz Kawa

First supervisor: dr hab. inż. Edyta Kucharska, prof. AGH
Assisting supervisor: dr inż. Waldemar Bauer

Completed in: AGH University of Krakow, Faculty
of Electrical Engineering, Automatics, Computer Science and
Biomedical Engineering

Krakow, 2024

PREAMBUŁA

Badania te są wynikiem przemysłowego programu doktoranckiego, finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego (MNiSW) i realizowanego we współpracy z TAUTON DYSTRYBUCJA S.A. i Akademią Górniczo-Hutniczą, Wydziałem Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej.

Streszczenie

Praca koncentruje się na analizie metod predykcji zużycia energii oraz prognozowania awarii w kontekście automatyki budynkowej i systemów zarządzania nieruchomościami. Kluczowym celem jest opracowanie modułowych, zestandaryzowanych rozwiązań technologicznych, które usprawnią proces zarządzania nieruchomościami poprzez telesterowanie oraz automatyzację systemów komfortu cieplnego i zabezpieczeń technicznych.

Praca przeprowadza dogłębną analizę funkcjonalności systemów wspomagania decyzji oraz ich zastosowania w kontekście zarządzania rozproszonymi nieruchomościami. Badania eksperymentalne przeprowadzono na przykładach nieruchomości z niehomogeniczną infrastrukturą techniczną, a wyniki podkreślają opłacalność stosowania zaawansowanych metod predykcji. Opracowane modele mają za zadanie wspierać decyzje zarządcze w obszarze przewidywania awarii oraz prognozowania zużycia mediów, co ma na celu poprawę efektywności operacyjnej i redukcję kosztów utrzymania nieruchomości.

Praca wnosi istotny wkład w rozwój zarządzania budynkami, zwłaszcza w kontekście heterogenicznych, rozproszonych nieruchomości, proponując holistyczne podejście do zarządzania predykcją i optymalizacją procesów technicznych oraz kosztowych w nieruchomościach komercyjnych.

Abstract

The study focuses on the analysis of energy consumption prediction and failure forecasting methods in the context of building automation and property management systems. The main objective of this research is to develop modular, standardized technological solutions that will improve the property management process through telecontrol and automation of telecontrol and automation of thermal comfort systems and technical security.

The study conducts an in-depth analysis of the functionality of decision support systems and their application in the context of managing distributed real estate. Experimental research was carried out on examples of real estate with homogeneous technical infrastructure, and the results emphasize the profitability of using advanced prediction methods. The developed models are designed to support management decisions in the area of predicting failures and forecasting utility consumption, which is aimed at improving operational efficiency and reducing property maintenance costs.

This study makes a significant contribution to the development of building management, especially in the context of heterogeneous, dispersed real estate, by proposing a holistic approach to prediction management and optimization of technical and cost processes in commercial real estate.

Spis treści

Wprowadzenie.....	9
1. Systemy wspomaganie decyzji.....	12
1.1. Cel i znaczenie systemów wspomaganie decyzji.....	12
1.2. Historia rozwoju informatycznych systemów wspomaganie decyzji.....	13
1.3. Klasyfikacja systemów wspomaganie decyzji.....	14
1.4. Główne komponenty systemów wspomaganie decyzji.....	15
1.5. Metody i techniki wykorzystywane w systemach wspomaganie decyzji.....	15
1.6. Proces podejmowania decyzji wspomaganie przez SWD.....	16
1.7. Praktyczne zastosowania systemów wspomaganie decyzji.....	17
1.8. Przykładowy System Wspomaganie Decyzji w przedsiębiorstwie energetycznym	20
1.9. Przyszłość systemów wspomaganie decyzji.....	22
Podsumowanie.....	24
2. Konserwacja predykcjna: koncepcje, metody i narzędzia.....	27
2.1. Cechy i zastosowanie konserwacji predykcyjnej.....	28
2.2. Wytyczne dla konserwacji predykcyjnej.....	30
2.3. Potencjalne źródła danych w konserwacji predykcyjnej.....	31
2.4. Zalety konserwacji predykcyjnej.....	32
2.5. Wady i problemy w procesach konserwacji predykcyjnej.....	33
2.6. Stosowane modele i metody predykcji.....	34
2.7. Charakterystyka algorytmów klasy GBM.....	35
2.8. Mierniki jakości predykcji.....	59
2.9. Podsumowanie.....	61
3. Specyfika sterowania oraz zarządzania budynkami.....	63
3.1. Różnorodność rozwiązań w zakresie wyposażenia budynków na różnych etapach życia.....	63
3.2. Wpływ zmian przeznaczenia budynku na systemy zarządzania komfortem cieplnym	64
3.3. Administrowanie i serwisowanie zespołów budynków.....	66
3.4. Możliwość standaryzacji w zakresie budowy budynków lub ich części oraz ich wpływ na systemy automatyki budynkowej.....	78
3.5. Wpływ kolejności decyzji zarządczych dotyczących modernizacji zespołów budynków na korzyści finansowe.....	81
3.6. Wnioski.....	82
4. Badanie możliwości wykorzystania rozwiązań dla standaryzacji wymagań w zakresie automatyki budynkowej.....	83
4.1. Sterowanie sieciami cieplnymi.....	83
4.2. Środowisko użyte do budowy narzędzia do predykcji.....	97

4.3.	Narzędzie do gromadzenia danych oraz rozwoju w zakresie predykcji	98
4.4.	Model predykcji zużycia mediów	101
4.5.	Opis źródeł danych i przygotowanie do modelowania	102
4.6.	Badania predycyjne zużycia energii elektrycznej na zbiorach danych z odczytów liczników energii	102
4.7.	Badania predycyjne na pojedynczej nieruchomości z niehomogeniczną infrastrukturą techniczną	121
4.8.	Model predykcji zużycia wody	134
4.9.	Analiza przebiegów temperatury pompy ciepła i jej otoczenia	138
4.10.	Model predykcji uszkodzeń.....	145
4.11.	Sprzężenie Zwrotne Wyników Predykcji ze Sterowaniem Urządzeniami.....	153
5.	Podsumowanie	156
Bibliografia.....		160
Wykaz rysunków.....		175
Wykaz tabel.....		177
Załączniki		177

Lista skrótów

SWD, DSS - Systemy Wspomagania Decyzji, (Decision Support Systems)
AI – sztuczna inteligencja (Artificial intelligence)
ML – uczenie maszynowe (Machine Learning)
DBMS – Systemy Zarządzania Informacją (Database Management Systems)
UI – Interfejs Użytkownika (User Interface)
PCA – analiza głównych składowych (Principal Component Analysis)
NLP – przetwarzanie języka naturalnego (Natural Language Processing)
IoT – internet rzeczy (Internet of Things)
BMS – System Zarządzania Budynkiem (Building Management System)
HVAC – ogrzewanie, wentylacja, klimatyzacja (Heating, Ventilation, Air Conditioning)
SOA – architektura zorientowana na usługi (Service-Oriented Architecture)
GBM – model prognozowania szeregów czasowych (Gradient Boosting Machines)
SARIMA - model prognozowania szeregów czasowych (Seasonal Autoregressive Integrated Moving Average)
RF – algorytm uczenia maszynowego „las losowy” – (Random Forest)
DNN – głębokie sieci neuronowe (Deep Neural Networks)
RNN - rekurencyjne sieci neuronowe (Recurrent Neural Networks)
SGD - stochastyczny spadek gradientu (Stochastic Gradient Descent)
BPTT – propagacja wsteczna w czasie (Backpropagation Through Time)
LSTM – rekurencyjna sieć neuronowa (Long Short-Term Memory)
GRU – rekurencyjna sieć neuronowa (Gated Recurrent Units)
PI/PID – algorytmy wykorzystywane do sterowania systemami HVAC

Wprowadzenie

Opis problemu badawczego

Właściwe zarządzanie nieruchomościami jest kluczowe dla stabilnego i bezpiecznego realizowania celów biznesowych przedsiębiorstw. W tym kontekście kluczowe znaczenie mają sprawne monitorowanie stanu technicznego nieruchomości, odpowiednie planowanie i realizowanie przeglądów oraz eksploatacji infrastruktury, szybkie wykrywanie usterek, kompleksowa diagnostyka, skuteczne reagowanie na awarie, zapewnienie odpowiedniego poziomu bezpieczeństwa oraz organizacji ruchu.

Problem optymalnie kosztowego i energetycznego zarządzania nieruchomościami wzrasta wraz z ilością, rozłożeniem terytorialnym nieruchomości, ze zróżnicowaniem ich wielkości i realizowanych funkcji oraz zastosowanych w budynkach urządzeń technicznych. Z tego względu konieczne jest zastosowanie nowoczesnych metod analizy, monitorowania, diagnostyki oraz przygotowania rozwiązań, które umożliwią wybór efektywnych technicznie i kosztowo działań utrzymaniowych (Vijayan *et al.*, 2020; Durdyev *et al.*, 2022).

Tematyka niniejszej pracy jest bezpośrednio powiązana z aktualnymi potrzebami przedsiębiorstwa TAURON Dystrybucja S.A., które pełni rolę operatora elektroenergetycznego systemu dystrybucyjnego w południowej Polsce. Oprócz nieruchomości związanych z siecią dystrybucyjną, spółka zarządza blisko dwustoma nieruchomościami komercyjnymi, zróżnicowanymi pod względem wielkości i funkcji. Aby zapewnić efektywne zarządzanie tymi nieruchomościami, TAURON Dystrybucja S.A. wyodrębnił specjalne komórki administracyjne. Ich działania w zakresie zarządzania nieruchomościami mogą być wspierane przez nowoczesne metody optymalizacji procesów, oparte na wynikach najnowszych badań naukowych.

TAURON Dystrybucja S.A., w celu minimalizacji kosztów utrzymania nieruchomości niesieciowych, dąży do optymalizacji procesów zarządczych, jednak istnieją obszary wymagające dalszego doskonalenia, które związane są z następującymi niedoborami:

- brak wdrożenia narzędzi umożliwiających centralizację monitorowania systemów automatyki i zabezpieczeń oraz poprawę jakości danych zarządczych,
- brak standaryzacji wymagań dla systemów automatyki budynkowej i ochrony technicznej,
- brak systemowego podejścia do utrzymania budynków, z uwzględnieniem identyfikacji obszarów oszczędności i zarządzania zużyciem energii.

Literatura opisuje szereg metod przewidywania zdarzeń oraz zużycia energii i awarii urządzeń (Cheng *et al.*, 2020; Pham *et al.*, 2020; Wang, Lu and Feng, 2020; Bouabdallaoui *et al.*, 2021; Lei *et al.*, 2021; Olu-Ajayi *et al.*, 2022). Istnieje jednak potrzeba zbadania ich zastosowania w heterogenicznych, rozproszonych nieruchomościach o zróżnicowanych parametrach technicznych i użytkowych. Podczas gdy predykcja zużycia energii jest relatywnie dobrze opisana, budowa jednorodnego systemu predykcyjnego dla różnych, koherentnych nieruchomości pozostaje wciąż nie w pełni zdiagnozowana. W szczególności nie opracowano jeszcze dogłębnych badań dotyczących optymalizacji kosztów utrzymania rozproszonych terytorialnie oraz zabytkowych nieruchomości, zwłaszcza w kontekście współpracy narzędzi

do telesterowania z administratorami, którzy zdalnie regulują parametry komfortu cieplnego na podstawie analiz potrzeb użytkowników (Brandi *et al.*, 2020; Vijayan *et al.*, 2020; Esrafilian-Najafabadi and Haghghat, 2021; Gupta *et al.*, 2021; Halhoul Merabet *et al.*, 2021) oraz w zakresie przewidywania awarii tzw. automatyki budynkowej i systemów zabezpieczenia technicznego budynków.

Istotnym zagadnieniem do zbadania jest również potencjał redukcji zakresu danych pozyskiwanych z budynków do tych niezbędnych dla przeprowadzania predykcji, bez utraty ich dokładności. W kontekście heterogenicznych zespołów nieruchomości, które różnią się wielkością, konstrukcją, przeznaczeniem, okresem użytkowania czy etapem cyklu życia, takie zróżnicowanie techniczne, jak na przykład przenikalność cieplna przegród czy stosowane systemy automatyki budynkowej, stanowi wyzwanie dla implementacji uniwersalnych, zestandaryzowanych metod predykcji.

Cel pracy

Celem niniejszej pracy jest analiza możliwości zastosowania metod predykcji danych do wspomaganie zarządzania rozproszonych, heterogenicznych zespołów nieruchomości komercyjnych, wyposażonych w systemy o różnorodnych parametrach technicznych i eksploatacyjnych, zidentyfikowanie zakresu danych pozyskiwanych z budynków niezbędnych dla przeprowadzania predykcji oraz opracowanie odpowiednich procedur wdrożenia tych metod do sprawnego zarządzania obiektami oraz przewidywania zapotrzebowania na energię, kosztów utrzymania i ryzyka awarii.

Dla zrealizowania celu pracy konieczne było wykonanie badań dotyczących możliwości i efektywności stosowania metod predykcji w podejmowaniu decyzji zarządczych w zakresie:

- przewidywania awarii systemów automatyki budynkowej, w szczególności systemów HVAC oraz systemów zabezpieczeń technicznych budynków,
- prognozowania zużycia energii elektrycznej, zarówno dla pojedynczych nieruchomości, jak i całych ich zespołów,
- prognozowania zużycia wody,
- przewidywania obciążenia prądowego opomiarowanych obwodów oraz innych parametrów związanych z poborem energii elektrycznej,
- prognozowania pogody dla nieruchomości zlokalizowanych na obszarach o specyficznych warunkach mikroklimatycznych.

Niniejsza praca doktorska realizowana jest w formule doktoratu wdrożeniowego. Przeprowadzone badania stanowią próbkę, na której organizacja badawcza oprze swoje wnioski dotyczące możliwości, opłacalności oraz zakresu standaryzacji rozwiązań stosowanych w zarządzaniu nieruchomościami komercyjnymi.

Badania te mają nie tylko charakter aplikacyjny, lecz także stanowią wkład w rozwój wiedzy na temat zarządzania nieruchomościami komercyjnymi w kontekście inteligentnych budynków. Wskazanie, jak nowoczesne narzędzia predykcyjne mogą zintegrować się z bieżącymi procesami zarządczymi w sposób przynoszący korzyści ekonomiczne i operacyjne,

jest ważnym aspektem dalszego rozwoju metod zarządzania obiektami komercyjnymi. Dzięki takim badaniom możliwe będzie także lepsze zrozumienie i opisanie wyzwań, jakie stoją przed firmami zajmującymi się zarządzaniem dużymi portfelami nieruchomości, a także przyczynienie się do stworzenia nowych standardów w tej dziedzinie, które mogą zostać szeroko zaimplementowane w przyszłości.

Tezę pracy można sformułować następująco: ***Zastosowanie metod predykcyjnych w zarządzaniu heterogenicznymi zespołami nieruchomości komercyjnych zwiększa efektywność procesów zarządzania, przyczynia się do redukcji kosztów operacyjnych oraz pozwala na lepsze przewidywanie i zarządzanie ryzykiem awarii.***

Struktura pracy

Struktura pracy jest następująca.

Rozdział 1 opisuje niezbędne dla realizacji celu podstawy teoretyczne w zakresie systemów wspomagania decyzji odwołując się do najnowszych badań w tym zakresie.

Rozdział 2 charakteryzuje zakres niezbędnych dla przeprowadzenia badań metod predykcji, oceny wyników przeprowadzonych badań w zakresie predykcji.

Rozdział 3 przedstawia krótką charakterystykę systemów utrzymania komfortu cieplnego, zabezpieczeń technicznych budynków stosowanych w różnych okresach czasu dla budynków lub zespołów budynków. Przedstawia również czynniki wpływające na trudność optymalnego kosztowo zarządzania zespołami heterogenicznych nieruchomości komercyjnych przybliżając jednocześnie na przykładzie TAURON Dystrybucja S.A. powody powstawania zespołów nieruchomości heterogenicznych.

Rozdział 4 opisuje wyniki prac w zakresie możliwości obniżenia kosztów utrzymania zespołów heterogenicznych budynków poprzez zastosowanie telesterowania węzłami cieplnymi. Ponadto przedstawia badania w zakresie wyboru najlepszej metody predykcji wielkości okresowo zmiennych oraz opisuje przygotowane narzędzie.

Na przykładzie wybranej nieruchomości rozdział opisuje możliwość zastosowania narzędzia przygotowanego w postaci modułu rozszerzającego system nadzorujący lokalne systemy zabezpieczenia technicznego budynków o funkcje predykcyjne, korzystającego jednocześnie z dostępnych w systemie zabezpieczenia technicznego budynku danych związanych z jego użytkowaniem. Rozdział przedstawia także dobór wyposażenia pomiarowego, które może być stosowane w kolejnych nieruchomościach w celu prowadzenia badań predykcyjnych. Opiszano także zakres danych niezbędnych dla prowadzenia predykcji elementów systemu zabezpieczenia technicznego budynku oraz poziomu, na którym opłacalne jest dokonywanie predykcji uszkodzeń systemów zabezpieczenia technicznego budynku. Przedstawiono także wyniki przeprowadzonych badań w zakresie predykcji zużycia mediów oraz predykcji uszkodzeń.

W rozdziale 5 zawarto podsumowanie i kierunki badań rozwojowych.

1. Systemy wspomaganie decyzji

1.1. Cel i znaczenie systemów wspomaganie decyzji

W rozproszonych zespołach heterogenicznych nieruchomości komercyjnych systemy wspomaganie decyzji odgrywają kluczową rolę w integracji procesów zarządzania. Wykorzystują one centralną bazę danych dotyczącą eksploatacji budynków, opartą na rzeczywistych i szybko dostępnych danych. Dzięki temu wspierają nie tylko bieżącą diagnostykę zdarzeń, które zachodzą w zarządzanych obiektach i systemach automatyki budynkowej, lecz także umożliwiają optymalizację procesów utrzymania i monitorowania nieruchomości. Przydatność tych systemów jest niezastąpiona również z punktu widzenia ograniczania negatywnego wpływu budynków na środowisko naturalne (Aaltonen *et al.*, 2013; Y. Lu *et al.*, 2018; Alfalah and Zayed, 2020; Liang *et al.*, 2024). Systemy wspomaganie decyzji odpowiadają na prawne wymogi dotyczące redukcji zużycia energii, co przekłada się na realne korzyści w zakresie zrównoważonego zarządzania energią (Sztubecka *et al.*, 2020).

Z perspektywy ekonomicznej, wdrożenie systemów wspomaganie decyzji prowadzi do znacznego obniżenia kosztów operacyjnych poprzez optymalizację zużycia mediów i efektywniejsze zarządzanie infrastrukturą techniczną (Cheng *et al.*, 2020). Natomiast z punktu widzenia organizacji biznesowych, zapewniają one ciągłość funkcjonowania procesów, gwarantując utrzymanie stabilnych warunków pracy, co jest kluczowe dla niezakłóconej działalności przedsiębiorstw.

Współczesne organizacje stają przed rosnącą liczbą wyzwań, wynikających z dynamicznych zmian w otoczeniu biznesowym, rosnącej konkurencji oraz szybkiego rozwoju technologicznego. W tym złożonym kontekście proces podejmowania decyzji staje się coraz bardziej skomplikowany, wymagając nie tylko dostępu do aktualnych danych, ale również ich zaawansowanej analizy i szybkiej interpretacji. Systemy wspomaganie decyzji (SWD) zostały opracowane z myślą o spełnieniu tych potrzeb, oferując narzędzia umożliwiające efektywne zarządzanie danymi, co w efekcie prowadzi do podejmowania lepszych decyzji biznesowych (Arnott and Pervan, 2008).

Celem Systemów Wspomaganie Decyzji (SWD) jest ułatwienie procesu decyzyjnego poprzez dostarczanie menedżerom, analitykom oraz innym użytkownikom końcowym kompleksowych zestawów danych, narzędzi do ich analizy oraz mechanizmów oceny różnych scenariuszy i alternatywnych rozwiązań (Power, Burstein and Sharda, 2011). Dzięki temu proces podejmowania decyzji staje się nie tylko szybszy, ale również bardziej przemyślany, oparty na rzetelnych i dokładnych informacjach.

Znaczenie systemów wspomaganie decyzji wykracza poza samą pomoc w podejmowaniu decyzji. Przyczyniają się one do zwiększenia efektywności operacyjnej organizacji, podniesienia jakości oferowanych usług i produktów, a także lepszego zrozumienia potrzeb klientów oraz trendów rynkowych. Dzięki SWD organizacje mogą nie tylko reagować na bieżące wyzwania, ale również przewidywać przyszłe zmiany i adaptować się do nich

w sposób proaktywny, co staje się kluczowym elementem budowania przewagi konkurencyjnej (Power, 2008).

Rozwój SWD został napędzony postęпами w dziedzinach takich jak sztuczna inteligencja (AI), uczenie maszynowe (ML), analiza dużych zbiorów danych (big data) oraz nowoczesne technologie informatyczne. Te innowacje sprawiły, że systemy wspomaganie decyzji stały się bardziej wydajne, elastyczne i dostępne. Obecnie SWD są w stanie przetwarzać ogromne ilości danych w czasie rzeczywistym, dostarczając precyzyjnych i wartościowych informacji, co kilka lat temu było poza zasięgiem możliwości technologicznych (Razmak and Aoun i. 2015).

Dodatkowo, SWD odgrywają kluczową rolę w promowaniu kultury organizacyjnej opartej na danych, gdzie decyzje na wszystkich poziomach organizacji są podejmowane na podstawie analizy danych, a nie wyłącznie intuicji, doświadczenia czy tradycyjnych metod zarządzania (Chaudhuri *et al.*, 2021). Zachęcając do analizy informacji i podejmowania decyzji na podstawie faktów, systemy te wspierają racjonalne i obiektywne podejście do zarządzania. To z kolei pozwala podejmować lepiej uzasadnione decyzje, które są w stanie skuteczniej odpowiadać na zmieniające się wymagania biznesowe oraz oczekiwania klientów (Power, 2008).

W obliczu szybko zmieniającego się otoczenia biznesowego, systemy wspomaganie decyzji stają się nieocenionym narzędziem w rękach menedżerów, umożliwiającym zwiększenie efektywności operacyjnej, poprawę konkurencyjności oraz optymalizację procesów decyzyjnych. Ich zdolność do transformacji złożonych danych w przejrzyste i klarowne informacje decyzyjne sprawia, że stanowią one fundament nowoczesnego zarządzania i podejmowania decyzji (Soroudi and Amraee, 2013).

1.2. Historia rozwoju informatycznych systemów wspomaganie decyzji

Historia rozwoju informatycznych systemów wspomaganie decyzji (SWD) jest ściśle powiązana z postęпами w dziedzinie technologii informacyjnych oraz zmieniającymi się potrzebami zarządczymi w organizacjach. Początki tych systemów można umiejscowić w latach 60. i 70. XX wieku, kiedy to rozpoczęto systematyczne badania nad możliwościami wykorzystania komputerów do wspierania procesów decyzyjnych w przedsiębiorstwach (*A Brief History of Decision Support Systems*; Power, 2008).

Wczesne lata rozwoju SWD charakteryzowały się koncentracją na modelowaniu danych i tworzeniu systemów informacyjnych, które miały za zadanie dostarczać menedżerom informacji potrzebnych do podejmowania decyzji. Pionierskimi pracami w tej dziedzinie były badania nad systemami informacji zarządczej (Management Information Systems - MIS), które skupiały się na automatyzacji zbierania i przetwarzania danych operacyjnych (Power, 2008).

Wraz z rozwojem technologii komputerowych i teorii systemów, w latach 70. pojawił się koncepcja Decision Support Systems (DSS) – Systemów Wspomaganie Decyzji. DSS były projektowane z myślą o wsparciu menedżerów w analizowaniu danych i modelowaniu różnych scenariuszy decyzyjnych, co stanowiło istotny krok naprzód w stosunku do wcześniejszych

MIS, które przede wszystkim dostarczały informacji bez narzędzi do ich głębszej analizy. Pierwsze systemy DSS wykorzystywały proste modele danych i algorytmy, ale już wtedy zauważono ich potencjał w udoskonalaniu procesu decyzyjnego (Arnott and Pervan, 2008).

Lata 80. i 90. przyniosły dalszy rozwój SWD, napędzany przez postęp w dziedzinie baz danych, języków zapytań oraz interfejsów użytkownika. To właśnie w tym okresie zaczęto eksplorować możliwości sztucznej inteligencji i systemów ekspertowych jako komponentów SWD, co umożliwiło tworzenie coraz bardziej zaawansowanych i dostosowanych do specyficznych potrzeb systemów wspomaganie decyzji (*A Brief History of Decision Support Systems*).

Wiek XXI otworzył nowy rozdział w historii SWD dzięki eksponencjalnemu wzrostowi możliwości obliczeniowych, dostępu do dużych zbiorów danych (big data) oraz rozwojowi zaawansowanych technik analizy danych, takich jak uczenie maszynowe (ang. machine learning) i eksploracja danych (ang. data mining). Te nowe technologie znacząco poszerzyły możliwości SWD, przekształcając je w potężne narzędzia zdolne do analizy skomplikowanych zbiorów danych, przewidywania trendów i automatyzowania części procesów decyzyjnych.

Historia SWD jest więc historią ciągłego postępu technologicznego i adaptacji do rosnących wymagań zarządczych. Od prostych systemów raportujących po zaawansowane platformy analityczne wykorzystujące AI i uczenie maszynowe, SWD przeszły długą drogę, stając się nieodzownym elementem współczesnych organizacji dążących do efektywnego i skutecznego podejmowania decyzji (Razmak and Aouni, 2015).

1.3. Klasyfikacja systemów wspomaganie decyzji

W literaturze przedmiotu można znaleźć różne podejścia do klasyfikacji SWD, które zazwyczaj opierają się na takich kryteriach jak mechanizm działania, typ wykorzystywanych danych, sposób interakcji z użytkownikiem czy zakres zastosowań. Poniżej przedstawiono syntezę najbardziej rozpowszechnionych typów SWD, w oparciu o współczesne źródła naukowe (Robert H. Bonczek, 2014).

- Systemy ekspertowe (Expert Systems, ES): opierają się na wiedzy eksperckiej, zakodowanej w formie reguł if-then, które umożliwiają systemowi wnioskowanie w określonych dziedzinach wiedzy. Systemy ekspertowe symulują procesy decyzyjne ekspertów ludzkich poprzez aplikację złożonych reguł do dostępnych danych, umożliwiając podejmowanie decyzji w specjalistycznych obszarach, gdzie wiedza jest głęboko strukturyzowana. Ich zastosowanie jest szczególnie wartościowe w dziedzinach wymagających szczegółowej, specjalistycznej wiedzy, jak medycyna czy inżynieria.
- Systemy oparte na danych (Data-driven DSS): charakteryzują się skupieniem na gromadzeniu, przetwarzaniu i analizie dużych zbiorów danych w celu wsparcia procesu decyzyjnego. Systemy oparte na danych umożliwiają menedżerom dostęp do wskaźników i trendów rynkowych, wspierając podejmowanie decyzji strategicznych na podstawie empirycznych danych.

- Inteligentne systemy wspomaganie decyzji (Intelligent DSS): Integracja technologii sztucznej inteligencji (AI) i uczenia maszynowego (ML) z tradycyjnymi systemami wspomaganie decyzji doprowadziła do powstania inteligentnych SWD.
- Różnorodność typów SWD odzwierciedla ewolucję technologiczną oraz rosnące potrzeby organizacji w zakresie wspomaganie decyzji. Wybór odpowiedniego typu systemu zależy od specyfiki problemu decyzyjnego, dostępnych danych oraz wymaganej głębokości analizy. Współczesne badania w dziedzinie SWD koncentrują się na integracji różnych podejść i technologii w celu stworzenia hybrydowych systemów wspomaganie decyzji, które łączą zalety poszczególnych typów systemów, oferując bardziej kompleksowe i elastyczne narzędzia do podejmowania decyzji w organizacjach (Power and Power, 2004; Gupta, Forgionne and Mora, 2007; Robert H. Bonczek, 2014).

1.4. Główne komponenty systemów wspomaganie decyzji

W strukturze systemów wspomaganie decyzji (SWD) można wyróżnić kilka kluczowych komponentów, które są niezbędne do ich efektywnego funkcjonowania. Te komponenty tworzą zintegrowany system zdolny do przetwarzania danych, analizy informacji i wspierania procesu decyzyjnego. Poniżej przedstawiono naukowo ujętą charakterystykę głównych elementów SWD (Gupta, Forgionne and Mora, 2007).

- Systemy Zarządzania Informacją (Database Management Systems, DBMS): są to zbiory danych organizowane w sposób umożliwiający efektywne przechowywanie, wyszukiwanie i przetwarzanie informacji. Bazy danych stanowią fundament systemów wspomaganie decyzji, dostarczając niezbędnych danych wejściowych do analizy. W kontekście SWD, bazy danych mogą zawierać zarówno dane historyczne, jak i bieżące, pochodzące z różnych źródeł wewnętrznych i zewnętrznych. Zarządzanie bazami danych obejmuje mechanizmy zapewniające integralność, bezpieczeństwo i dostępność danych.
- Modele decyzyjne (Decision Models): modele te są formalnymi reprezentacjami procesów decyzyjnych, służącymi do symulacji różnych scenariuszy i oceny potencjalnych wyników decyzji. Mogą one przyjmować formę matematyczną, statystyczną, heurystyczną czy opartą na regułach.
- Interfejs użytkownika (User Interface, UI): interfejs użytkownika w systemach wspomaganie decyzji jest punktem kontaktu między systemem a jego użytkownikami. Jego zadaniem jest zapewnienie intuicyjnej i efektywnej interakcji, umożliwiającej dostęp do danych, uruchamianie analiz i interpretację wyników.
- Oprogramowanie analityczne (Analytical Software): to zestaw narzędzi i algorytmów wykorzystywanych do przetwarzania danych, analizy statystycznej, eksploracji danych, uczenia maszynowego oraz innych zaawansowanych analiz.

1.5. Metody i techniki wykorzystywane w systemach wspomaganie decyzji

Rozwój systemów wspomaganie decyzji (SWD) jest ściśle powiązany z postępami w metodach i technikach analizy danych. Te nowoczesne podejścia umożliwiają nie tylko efektywne przetwarzanie dużych wolumenów danych, ale także wydobywanie z nich wartościowych

informacji wspierających proces decyzyjny. Poniżej przedstawiono naukowe omówienie najważniejszych metod i technik stosowanych w SWD (Shim *et al.*, 2002; Gupta, Forgionne and Mora, 2007).

- Sztuczna inteligencja (Artificial Intelligence) i uczenie maszynowe (Machine Learning): Uczenie maszynowe stanowi kluczowy element nowoczesnych systemów wspomaganie decyzji. Sztuczna inteligencja pozwala na nadzorowaną i nienadzorowaną analizę danych i identyfikację wzorców, predykcję oraz klasyfikację.
- Analiza danych (Data Analytics): Obejmuje szereg technik statystycznych i matematycznych służących do analizy zbiorów danych w celu wydobycia użytecznych informacji, wzorców i trendów. Analiza danych jest kluczowym elementem SWD, umożliwiającym przekształcenie surowych danych w wiedzę, która może być wykorzystana w procesie decyzyjnym. Wśród technik analizy danych wyróżnia się między innymi eksplorację danych (data mining), analizę skupień (cluster analysis) oraz analizę głównych składowych (principal component analysis, PCA).
- Modelowanie matematyczne: Jest to proces tworzenia matematycznych abstrakcji rzeczywistych sytuacji, które mogą być użyte do symulacji różnych scenariuszy i oceny ich potencjalnych wyników. Modelowanie matematyczne w SWD pozwala na przeprowadzanie zaawansowanych analiz warunkowych what-if oraz ocenę ryzyka, wspierając tym samym procesy decyzyjne. Modele te mogą być stosowane w wielu dziedzinach, w tym w finansach, logistyce oraz zarządzaniu zasobami ludzkimi.
- Systemy ekspertowe: Wykorzystują wiedzę ekspercką zakodowaną w formie reguł, aby symulować ludzkie procesy decyzyjne w specyficznych dziedzinach. Systemy ekspertowe są w stanie wnioskować na podstawie dostępnych danych i zaproponowanych reguł, oferując rekomendacje lub decyzje w obszarach, gdzie wymagana jest głęboka, specjalistyczna wiedza.
- Przetwarzanie języka naturalnego (NLP): Technika ta pozwala na analizę i przetwarzanie języka ludzkiego, umożliwiając maszynom rozumienie, interpretację i generowanie języka naturalnego. W kontekście systemów wspomaganie decyzji NLP może być wykorzystywane do analizy nastrojów, ekstrakcji informacji z tekstów czy automatycznego generowania raportów i podsumowań.
- Wizualizacja danych: Narzędzia wizualizacji danych umożliwiają graficzną prezentację złożonych zbiorów danych, co ułatwia ich interpretację i analizę. Wizualizacje takie jak wykresy, grafy i mapy cieplne są kluczowym komponentem interfejsów użytkownika w SWD, umożliwiając szybką ocenę sytuacji decyzyjnej i ułatwiając komunikację wyników analiz.

Integracja tych metod i technik w ramach systemów wspomaganie decyzji pozwala na tworzenie zaawansowanych narzędzi analitycznych, które są w stanie wspierać organizacje w podejmowaniu bardziej efektywnych decyzji w złożonym i dynamicznie zmieniającym się środowisku biznesowym.

1.6. Proces podejmowania decyzji wspomagany przez SWD

Proces decyzyjny w organizacjach można przedstawić jako sekwencję etapów, rozpoczynając od identyfikacji problemu lub szansy, poprzez analizę opcji i wybór najlepszego

rozwiązania, aż po wdrożenie decyzji i jej ocenę. Systemy wspomaganie decyzji (SWD) pełnią kluczową rolę na każdym z tych etapów, umożliwiając bardziej efektywne i efektywne zarządzanie procesem decyzyjnym.

1. Identyfikacja problemu: Na tym wstępnym etapie SWD mogą pomóc w gromadzeniu i analizie danych w celu zrozumienia istoty problemu. Narzędzia analizy danych i wizualizacji umożliwiają identyfikację anomalii, trendów i wzorców, które mogą wskazywać na istotne problemy lub szanse.
2. Generowanie alternatyw: SWD wspierają generowanie możliwych rozwiązań poprzez zastosowanie modeli symulacyjnych, algorytmów optymalizacyjnych i technik generowania idei. Systemy te mogą również wykorzystać historię wcześniejszych decyzji i ich skutków, aby zasugerować potencjalne alternatywy.
3. Analiza i ocena alternatyw: W tym kluczowym etapie SWD umożliwiają zastosowanie zaawansowanych metod analizy, takich jak analiza kosztów i korzyści, analiza ryzyka oraz modelowanie scenariuszy. Narzędzia te pomagają ocenić możliwe konsekwencje każdej alternatywy, wspierając tym samym proces wyboru najlepszego rozwiązania.
4. Wybór rozwiązania: Na podstawie analizy przeprowadzonej w poprzednim etapie, SWD ułatwiają podejmowanie decyzji przez prezentację uporządkowanych i ocenionych opcji, zilustrowanych za pomocą intuicyjnych wizualizacji danych. W niektórych przypadkach, systemy mogą nawet automatycznie wybrać najlepsze rozwiązanie na podstawie zdefiniowanych kryteriów i algorytmów.
5. Wdrożenie i ocena decyzji: Po podjęciu decyzji SWD mogą wspierać proces jej implementacji oraz monitorowania i oceny efektów. Systemy analityczne pozwalają na śledzenie postępów w realizacji planu i ocenę, czy podjęte decyzje przynoszą oczekiwane rezultaty.

1.7. Praktyczne zastosowania systemów wspomaganie decyzji

Systemy wspomaganie decyzji (SWD) są wszechstronnymi narzędziami stosowanymi w szerokim spektrum branż i dziedzin. Ich elastyczność i zdolność do adaptacji do specyficznych potrzeb użytkowników sprawiają, że stanowią nieocenione wsparcie w procesach decyzyjnych na różnych poziomach zarządzania (Zhai *et al.*, 2020). Poniżej omówione zostaną przykładowe obszary, w których SWD znalazły szerokie zastosowanie, wraz z wyjaśnieniem ich roli i korzyści wynikających z ich implementacji.

W kontekście zarządzania przedsiębiorstwem, SWD odgrywają kluczową rolę w wspieraniu decyzji strategicznych i operacyjnych. Systemy te są wykorzystywane przykładowo do:

- optymalizacji łańcuchów dostaw: Poprzez analizę danych dotyczących zapasów, produkcji i dystrybucji, SWD mogą sugerować najbardziej efektywne strategie zarządzania łańcuchem dostaw, redukując koszty i zwiększając efektywność operacyjną (Govindan, Mina and Alavi, 2020),
- zarządzania zasobami ludzkimi: SWD pomagają w planowaniu zatrudnienia, ocenie wydajności pracowników oraz optymalizacji procesów rekrutacyjnych i szkoleniowych,

co prowadzi do zwiększenia produktywności i zaangażowania pracowników (Leicht-Deobald *et al.*, 2022),

- planowania finansowego i budżetowania: Systemy te umożliwiają tworzenie dokładnych prognoz finansowych, analizę kosztów i korzyści oraz monitorowanie realizacji budżetu, co wspiera podejmowanie świadomych decyzji finansowych (Velasco *et al.*, 2021).

W sektorze opieki zdrowotnej, SWD przynoszą liczne korzyści zarówno pacjentom, jak i placówkom medycznym (Sutton *et al.*, 2020). Systemy te są wykorzystywane między innymi do:

- analizy danych pacjentów: SWD umożliwiają integrację i analizę danych medycznych, wspierając diagnozowanie i planowanie leczenia, co może prowadzić do poprawy wyników zdrowotnych i zadowolenia pacjentów,
- zarządzania zasobami medycznymi: Systemy te pomagają w optymalizacji wykorzystania zasobów, takich jak personel medyczny, łóżka szpitalne i sprzęt, co zwiększa efektywność operacyjną placówek medycznych,
- optymalizacji procesów: SWD wspierają zarządzanie procesami wewnętrznymi, takimi jak harmonogramowanie operacji, zarządzanie przepływem pacjentów i logistyka zaopatrzenia, co przyczynia się do lepszej organizacji pracy i redukcji kosztów.

W sektorze finansowym: SWD są niezastąpione w zarządzaniu ryzykiem i podejmowaniu decyzji inwestycyjnych. Przykłady zastosowań obejmują (Hernández-Nieves *et al.*, 2020; Sachan *et al.*, 2020; Verma, 2022; Hasan *et al.*, 2024):

- analizę ryzyka kredytowego: SWD wykorzystują zaawansowane algorytmy do oceny zdolności kredytowej klientów, co pozwala na minimalizację ryzyka niewypłacalności i optymalizację portfela kredytowego,
- zarządzanie portfelami inwestycyjnymi: Systemy te wspierają decyzje inwestycyjne poprzez analizę trendów rynkowych, prognozowanie cen aktywów oraz ocenę ryzyka i zwrotu, co pozwala na lepsze zarządzanie portfelem inwestycyjnym,
- prognozowanie rynków finansowych: SWD analizują dane historyczne i bieżące, aby przewidywać przyszłe zmiany na rynkach finansowych, co umożliwia podejmowanie bardziej trafnych decyzji inwestycyjnych,
- detekcję oszustw finansowych: Zaawansowane algorytmy SWD mogą wykrywać nietypowe wzorce transakcji, co pozwala na szybsze i skuteczniejsze identyfikowanie i zapobieganie oszustwom.

W zarządzaniu kryzysowym: SWD wspierają koordynację i efektywność działań ratunkowych (Kuziemski and Misuraca, 2020; Pegoraro, Alves Portela Santos and de Freitas Rocha Loures, 2020; Sun, Bocchini and Davison, 2020). Przykłady zastosowań obejmują:

- planowanie i koordynację działań ratunkowych: SWD umożliwiają analizę danych z różnych źródeł, co wspiera podejmowanie szybkich i trafnych decyzji w sytuacjach kryzysowych,
- analizę ryzyka: Systemy te pomagają w ocenie ryzyka i przygotowaniu strategii minimalizacji skutków kryzysów, takich jak katastrofy naturalne, awarie technologiczne czy pandemie,

- alokację zasobów: SWD wspierają optymalizację alokacji zasobów, takich jak personel ratunkowy, sprzęt i materiały, co zwiększa efektywność działań ratunkowych i minimalizuje straty.

W dziedzinie ochrony środowiska, SWD są wykorzystywane do monitorowania i zarządzania zasobami naturalnymi oraz oceny wpływu działalności człowieka na środowisko (Matthies, Giupponi and Ostendorf, 2007; Li, Zhao and Zheng, 2020; Barzehkar *et al.*, 2021). Przykłady zastosowań obejmują:

- monitorowanie i zarządzanie zasobami naturalnymi: SWD umożliwiają analizę danych dotyczących zasobów wodnych, leśnych i innych, co wspiera podejmowanie decyzji dotyczących ich ochrony i zrównoważonego wykorzystania,
- prognozowanie zmian klimatycznych: Systemy te analizują dane klimatyczne, aby przewidywać przyszłe zmiany i wspierać planowanie adaptacyjne oraz strategie łagodzenia skutków zmian klimatu,
- planowanie użytkowania terenu: SWD wspierają decyzje dotyczące zagospodarowania przestrzennego, pomagając w identyfikacji obszarów narażonych na zagrożenia środowiskowe oraz w planowaniu działań ochronnych,
- ocenę wpływu działań człowieka: Systemy te analizują dane dotyczące emisji zanieczyszczeń, zużycia zasobów i innych aspektów działalności człowieka, co wspiera podejmowanie działań mających na celu minimalizację negatywnego wpływu na środowisko.

Systemy wspomaganie decyzji są niezastąpionym narzędziem w wielu branżach i dziedzinach. Dzięki zaawansowanym algorytmom, modelom matematycznym i zdolności do analizy dużych zbiorów danych, SWD wspierają podejmowanie bardziej świadomych i efektywnych decyzji. Ich zastosowanie przyczynia się do optymalizacji działań, minimalizacji ryzyka oraz zwiększenia efektywności operacyjnej, co ma kluczowe znaczenie dla konkurencyjności i zrównoważonego rozwoju organizacji.

Poniżej podano przykłady przypadków zastosowania systemów wspomaganie decyzji (SWD) w zróżnicowanych sektorach gospodarki, ze szczególnym uwzględnieniem ich roli w optymalizacji procesów operacyjnych oraz wspieraniu złożonych procesów decyzyjnych. Każdy z omawianych przykładów ukazuje, w jaki sposób wdrożenie SWD przyczyniło się do zwiększenia efektywności funkcjonowania organizacji poprzez zaawansowaną analizę danych oraz optymalizację kluczowych procesów. Przykłady obejmują optymalizację łańcucha dostaw w przedsiębiorstwie produkcyjnym, zarządzanie danymi pacjentów w placówkach medycznych oraz analizę ryzyka inwestycyjnego w sektorze finansowym. W każdym z tych przypadków, zaawansowane modele analityczne i algorytmy wspomagające decyzje przyczyniły się do poprawy wyników operacyjnych oraz strategicznych, co podkreśla znaczenie SWD jako narzędzi nieodzownych we współczesnym zarządzaniu organizacjami.

- Optymalizacja łańcucha dostaw w przedsiębiorstwie produkcyjnym: SWD umożliwiły firmie produkcyjnej zidentyfikowanie słabych punktów w łańcuchu dostaw, przyczyniając się do znaczącej poprawy efektywności operacyjnej i redukcji kosztów. System analizował dane z różnych etapów procesu produkcyjnego, oferując rekomendacje dotyczące

zarządzania zapasami, harmonogramowania produkcji i optymalizacji transportu (Biswas and Samanta, 2016; Yazdani *et al.*, 2017).

- Zarządzanie danymi pacjentów w szpitalu: Wdrożenie SWD w szpitalu pozwoliło na lepszą koordynację opieki nad pacjentami oraz optymalizację procesów medycznych i administracyjnych. System wspomagał personel medyczny w analizie historii chorób, wyników badań i danych demograficznych pacjentów, przyczyniając się do podniesienia jakości opieki zdrowotnej (Liberati *et al.*, 2017).
- Analiza ryzyka inwestycyjnego w sektorze finansowym: Dzięki zastosowaniu SWD firma doradztwa finansowego mogła oferować swoim klientom bardziej precyzyjne analizy ryzyka inwestycyjnego oraz rekomendacje dotyczące zarządzania portfelami. System wykorzystywał zaawansowane modele finansowe i algorytmy uczenia maszynowego do analizy historycznych danych rynkowych i identyfikacji potencjalnych trendów inwestycyjnych (Gottschlich and Hinz, 2014).

1.8. Przykładowy System Wspomagania Decyzji w przedsiębiorstwie energetycznym

System Wspomagania Decyzji (SWD) w przedsiębiorstwie energetycznym ma na celu optymalizację zarządzania zasobami serwisowymi, co jest kluczowe dla zapewnienia ciągłości funkcjonowania infrastruktury energetycznej. Efektywne planowanie i alokacja zasobów, takich jak zespoły serwisowe, sprzęt techniczny czy pojazdy, stanowi centralny element procesu, mający bezpośredni wpływ na minimalizację przestojów operacyjnych oraz maksymalizację efektywności działań serwisowych. Przedsiębiorstwa energetyczne, ze względu na swoją kluczową rolę w dostarczaniu energii, muszą minimalizować ryzyko awarii oraz szybko reagować na wszelkie nieprawidłowości w działaniu sieci i systemów energetycznych.

SWD pozwala na integrację danych historycznych, bieżących oraz prognostycznych, co umożliwia przewidywanie przyszłego zapotrzebowania na usługi serwisowe oraz dynamiczne dostosowywanie dostępnych zasobów do aktualnych potrzeb. Tym samym, system wspiera nie tylko sam proces decyzyjny, ale także zarządzanie kosztami operacyjnymi przedsiębiorstwa, zmniejszając ryzyko nadmiernych wydatków na utrzymanie infrastruktury. Do głównych funkcjonalności przykładowego systemu możemy zaliczyć:

- Prognozowanie zapotrzebowania na usługi serwisowe
System wykorzystuje zaawansowane modele prognostyczne oparte na danych historycznych, które pozwalają przewidzieć przyszłe potrzeby w zakresie działań serwisowych. Prognozy te są niezbędne do zapewnienia odpowiedniej ilości zasobów serwisowych oraz optymalnego rozplanowania prac konserwacyjnych i naprawczych.
- Optymalizacja alokacji zasobów serwisowych
Kluczową funkcją SWD jest optymalizacja alokacji dostępnych zasobów serwisowych w odpowiedzi na przewidywane zapotrzebowanie. System bierze pod uwagę aktualną dostępność zespołów serwisowych, sprzętu i innych zasobów, oraz dynamicznie przydziela je tam, gdzie są najbardziej potrzebne, przy jednoczesnym minimalizowaniu kosztów operacyjnych.
- Monitorowanie i raportowanie efektywności działań serwisowych

System monitoruje realizowane działania serwisowe, zbierając dane dotyczące alokacji zasobów, czasu reakcji oraz kosztów. Raportowanie tych informacji w czasie rzeczywistym umożliwia bieżące śledzenie efektywności działań, identyfikację obszarów wymagających poprawy oraz dostosowywanie strategii zarządzania zasobami.

Przykładowy Pseudokod Systemu Wspomagania Decyzji dla przedsiębiorstwa energetycznego

Początkowa faza systemu obejmuje załadowanie danych historycznych, aktualnych zasobów oraz bieżących zgłoszeń serwisowych, które stanowią podstawę dla wszystkich kolejnych procesów decyzyjnych.

```
#Inicjalizacja danych wejściowych
historical_data = load_historical_data() # Ładowanie danych historycznych dotyczących usług
serwisowych
current_resources = load_current_resources() # Ładowanie danych o dostępnych zasobach
serwisowych
service_requests = load_service_requests() # Ładowanie bieżących zgłoszeń serwisowych
```

System prognozuje zapotrzebowanie na usługi serwisowe, korzystając z modelu prognostycznego, który analizuje dane historyczne i przewiduje przyszłe potrzeby.

```
def forecast_service_demand(historical_data):
    # Użycie modelu prognostycznego do przewidzenia zapotrzebowania
    demand_forecast = []
    for data in historical_data:
        forecast = model.predict(data)
        demand_forecast.append(forecast)
    return demand_forecast
# Przewidywanie zapotrzebowania na usługi serwisowe
demand_forecast = forecast_service_demand(historical_data)
```

Optymalizacja alokacji zasobów polega na dynamicznym przydzielaniu dostępnych zasobów do prognozowanego zapotrzebowania, z jednoczesnym minimalizowaniem kosztów operacyjnych.

```
def optimize_resource_allocation(demand_forecast, current_resources):
    # Inicjalizacja zmiennych
    optimal_allocation = []
    total_cost = 0
    for period in range(len(demand_forecast)):
        allocation = {}
        for resource in current_resources:
            # Obliczanie optymalnej alokacji zasobów dla danego okresu
            if resource.available >= demand_forecast[period]:
                allocation[resource.id] = demand_forecast[period]
            else:
                allocation[resource.id] = resource.available
            # Aktualizacja dostępnych zasobów
            resource.available -= allocation[resource.id]
        optimal_allocation.append(allocation)
        total_cost += calculate_cost(allocation)
    return optimal_allocation, total_cost
```

Optymalizacja alokacji zasobów serwisowych

```
optimal_allocation, total_cost = optimize_resource_allocation(demand_forecast,
current_resources)
```

System monitoruje działania serwisowe i generuje raporty efektywności, które służą do oceny jakości alokacji zasobów oraz identyfikacji potencjalnych obszarów do poprawy.

```
def monitor_and_report(optimal_allocation):
    # Inicjalizacja zmiennych monitorowania
    efficiency_report = []
    for allocation in optimal_allocation:
        report = {}
        for resource_id, allocated in allocation.items():
            report[resource_id] = {
                "allocated": allocated,
                "efficiency": calculate_efficiency(resource_id, allocated)
            }
        efficiency_report.append(report)
    generate_report(efficiency_report)
monitor_and_report(optimal_allocation)
```

System wykorzystuje szereg funkcji pomocniczych, które wspierają główne operacje, takie jak ładowanie danych, obliczanie kosztów czy efektywności działań.

```
def load_historical_data():
    # Załadowanie danych historycznych dotyczących usług serwisowych
def load_current_resources():
    # Załadowanie aktualnych zasobów serwisowych
def load_service_requests():
    # Załadowanie bieżących zgłoszeń serwisowych
def model.predict(data):
    # Funkcja prognostyczna modelu
def calculate_cost(allocation):
    # Obliczanie całkowitych kosztów alokacji zasobów
def calculate_efficiency(resource_id, allocated):
    # Obliczanie efektywności alokacji zasobów
def generate_report(efficiency_report):
    # Generowanie raportu z efektywności działań serwisowych
```

Przykładowy system wspomagania decyzji dla przedsiębiorstwa energetycznego ukazuje, w jaki sposób można efektywnie zarządzać zasobami serwisowymi, minimalizując koszty operacyjne i maksymalizując efektywność działań serwisowych. Dzięki implementacji zaawansowanych modeli prognostycznych oraz algorytmów optymalizacji, system taki może znacząco zwiększyć efektywność operacyjną, zapewniając równocześnie lepszą jakość usług oraz szybszą reakcję na awarie. W perspektywie długoterminowej, zastosowanie SWD przyczynia się do lepszego zarządzania zasobami, redukując koszty oraz poprawiając jakość obsługi klienta, co w konsekwencji zwiększa konkurencyjność przedsiębiorstwa na rynku energetycznym.

1.9. Przyszłość systemów wspomagania decyzji

Rozwój systemów wspomagania decyzji (SWD) jest ściśle związany z postępowaniem w dziedzinach technologii informacyjnych, sztucznej inteligencji (AI) i analizy danych. Wzrost możliwości obliczeniowych, dostęp do ogromnych zbiorów danych (big data) oraz postępy w uczeniu maszynowym (ML) i przetwarzaniu języka naturalnego (NLP) otwierają nowe

perspektywy dla SWD (Turner *et al.*, 2019; Ding *et al.*, 2020; Tang and Liao, 2021; Nguyen *et al.*, 2022).

Wśród najważniejszych trendów, które będą kształtować przyszłość SWD, należy wyróżnić:

- automatyzację i autonomiczne systemy decyzyjne: Rozwój AI i ML umożliwia tworzenie coraz bardziej autonomicznych SWD, które nie tylko wspierają proces decyzyjny, ale również mogą samodzielnie podejmować decyzje w określonych warunkach. Taka automatyzacja otwiera drogę do zastosowań w zarządzaniu łańcuchem dostaw, finansach czy monitoringu bezpieczeństwa,
- personalizację i adaptacyjne systemy wspomaganie decyzji: Przyszłe SWD będą w większym stopniu personalizowane i adaptacyjne, dzięki wykorzystaniu technik AI do analizy preferencji użytkownika i dostosowywania procesów decyzyjnych do indywidualnych potrzeb. Taki indywidualizowany podejście może znaleźć zastosowanie w edukacji, medycynie personalizowanej oraz w rekomendowanych systemach sprzedaży,
- integrację z systemami IoT (Internet of Things) i przetwarzanie w chmurze: Wzrost liczby urządzeń podłączonych do Internetu (IoT) oraz rozwój usług chmurowych oferuje nowe możliwości w zakresie zbierania i przetwarzania danych w czasie rzeczywistym. SWD będą w stanie wykorzystywać te dane do monitorowania, analizy i reagowania na zmieniające się warunki w różnych środowiskach, od inteligentnych domów po *smart cities*,
- etyczne i społeczne aspekty automatyzacji decyzji: Wraz z rosnącą autonomią SWD, wzrasta również znaczenie kwestii etycznych i społecznych związanych z automatyzacją procesów decyzyjnych. Będzie to wymagać rozwoju standardów etycznych i prawnych regulujących stosowanie AI i automatycznych systemów decyzyjnych, zwłaszcza w obszarach o wysokiej stawce, takich jak medycyna, prawo czy bezpieczeństwo publiczne, w tym bezpieczeństwo energetyczne.

Przyszłość systemów wspomaganie decyzji rysuje się jako kluczowy element transformacji cyfrowej organizacji, mający istotny wpływ na sposób pracy i podejmowania decyzji. SWD będą coraz bardziej integrować się z codziennymi procesami biznesowymi, oferując wsparcie decyzyjne w czasie rzeczywistym i przyczyniając się do zwiększenia efektywności, redukcji kosztów oraz poprawy jakości podejmowanych decyzji.

Automatyzacja rutynowych zadań dzięki SWD pozwoli pracownikom skupić się na bardziej strategicznych aspektach pracy, jednocześnie podnosząc poziom zadowolenia z pracy i efektywność. Jednakże, rosnąca rola automatycznych systemów decyzyjnych będzie również wymagać od pracowników nowych umiejętności, w tym umiejętności analitycznych, adaptacyjnych oraz zrozumienia działania zaawansowanych technologii.

Przyszłość systemów wspomaganie decyzji zapowiada się obiecująco, oferując potencjał do rewolucjonizowania procesów decyzyjnych w wielu dziedzinach i branżach. Postęp technologiczny, zwłaszcza w obszarach AI, ML i przetwarzania danych, otwiera nowe możliwości dla rozwoju bardziej zaawansowanych, autonomicznych i personalizowanych systemów wspomaganie decyzji. Jednakże, rosnąca automatyzacja i wykorzystanie SWD niosą ze sobą również wyzwania etyczne i społeczne, wymagające uwagi i odpowiedzialnego podejścia zarówno ze strony twórców technologii, jak i użytkowników. W odpowiedzi na te

wyzwania, przyszłość SWD będzie kształtowana nie tylko przez innowacje technologiczne, ale również przez rozwój standardów etycznych i regulacji prawnych, które zapewnią odpowiedzialne i skuteczne wykorzystanie tych potężnych narzędzi.

Systemy wspomaganie decyzji (SWD) stanowią istotne narzędzie w arsenale nowoczesnych organizacji, umożliwiając im efektywne przetwarzanie danych, analizę informacji i wspomaganie procesów decyzyjnych. W dynamicznym i często nieprzewidywalnym środowisku biznesowym, zdolność do szybkiego reagowania na zmieniające się warunki i podejmowanie informowanych decyzji jest kluczowa dla utrzymania konkurencyjności i osiągnięcia celów strategicznych. SWD przyczyniają się do osiągnięcia tych celów poprzez zapewnienie dostępu do precyzyjnych, aktualizowanych danych i zaawansowanych narzędzi analizy.

Podsumowanie

Budowa systemu wspomaganie decyzji (SWD) opartego na analizie danych i technikach uczenia maszynowego (ML) otwiera nowe możliwości standaryzacji analizy i zarządzania w złożonym, niehomogenicznym środowisku technicznym, będącym w użytkowaniu spółki TAURON Dystrybucja S.A. W szczególności, integracja tych technologii staje się kluczowa w kontekście zarządzania rozproszonymi geograficznie nieruchomościami oraz ich różnorodnymi systemami automatyki budynkowej (BMS – Building Management System), które odpowiadają za zarządzanie komfortem użytkowników, kontrolę systemów HVAC, a także monitoring i optymalizację zużycia energii.

Wykorzystanie ML w ramach SWD umożliwi efektywną harmonizację zarządzania rozproszonymi lokalizacjami i różnorodnymi systemami technicznymi, ułatwiając prognozowanie zapotrzebowania na energię, wykrywanie awarii oraz zapewnienie ciągłości funkcjonowania krytycznej infrastruktury. Co więcej, zintegrowany system będzie mógł na bieżąco dostosowywać parametry automatyki budynkowej w celu optymalizacji kosztów operacyjnych, jednocześnie dbając o komfort użytkowników oraz zrównoważone gospodarowanie energią.

Pomimo szerokiego zakresu badań nad systemami wspomaganie decyzji, w literaturze brakuje podejścia, które łączyłoby zarządzanie energią, komfort użytkowników, przewidywanie awarii oraz zapewnienie ciągłości działania w rozproszonym, heterogenicznym środowisku technicznym (Ding *et al.*, 2020). Niniejsza praca ma szansę wypełnić tę lukę, proponując holistyczne rozwiązanie, które umożliwi spójne zarządzanie rozproszonymi lokalizacjami i systemami automatyki budynkowej, znacząco podnosząc efektywność operacyjną i zarządczą w przedsiębiorstwach takich jak TAURON Dystrybucja S.A.

Systemy wspomaganie decyzji (SWD) odgrywają niepodważalną rolę we współczesnym zarządzaniu, jednak ich skuteczne wdrożenie i użytkowanie wymaga dogłębnego zrozumienia zarówno potencjału, jak i ograniczeń tych systemów (Turner *et al.*, 2019). Kluczowym elementem jest integracja SWD z istniejącymi procesami biznesowymi, co wymaga również odpowiedniego szkolenia pracowników i zarządzania zmianą. Tylko wtedy organizacje mogą maksymalizować korzyści płynące z wykorzystania tych narzędzi.

Ważnym aspektem współczesnych SWD jest ich potencjał w zasilaniu danymi z modeli zarządzania predykcyjnego. Integracja predykcyjnych modeli zarządzania z SWD pozwala na bardziej precyzyjne i efektywne podejmowanie decyzji, poprzez analizę dużych zbiorów danych i przewidywanie przyszłych trendów oraz wyników (Olaniyi, Okunleye and Olabanji, 2023).

Ponadto, rosnąca autonomia i złożoność SWD niesie ze sobą wyzwania etyczne i regulacyjne, które wymagają dalszych badań i dyskusji. Etyczne aspekty obejmują kwestie takie jak prywatność danych, odpowiedzialność za decyzje podejmowane przez autonomiczne systemy oraz transparentność algorytmów (Braun *et al.*, 2021). Regulacyjne wyzwania dotyczą tworzenia odpowiednich ram prawnych, które będą w stanie nadążać za szybkim rozwojem technologii SWD.

Podsumowując, systemy wspomaganie decyzji odgrywają kluczową rolę w umożliwianiu organizacjom efektywnego i skutecznego reagowania na wyzwania współczesnego świata. Ich ciągły rozwój i adaptacja do zmieniających się potrzeb biznesowych i technologicznych będzie miała istotny wpływ na przyszłość zarządzania i podejmowania decyzji w organizacjach. W związku z tym, dalsze badania nad SWD, ich zastosowaniami i wpływem na praktyki zarządcze, a także ich integracją z modelami zarządzania predykcyjnego, stanowią ważne pole do eksploracji dla naukowców i praktyków zarządzania.

W rozdziale wykazano, że systemy wspomaganie decyzji SWD są kluczowym narzędziem wspierającym procesy zarządcze, integrującym dane w czasie rzeczywistym oraz umożliwiającym zaawansowaną analizę i optymalizację operacyjną. Ponadto przeprowadzono kompleksową analizę roli tych systemów w zarządzaniu nieruchomościami komercyjnymi, ze szczególnym uwzględnieniem ich zastosowania w rozproszonych, heterogenicznych środowiskach technicznych. Przeanalizowano również ich znaczenie w kontekście zrównoważonego zarządzania energią, podkreślając, że systemy te odpowiadają na rosnące wymogi prawne dotyczące redukcji zużycia energii i mają pozytywny wpływ na środowisko naturalne.

Rozdział szczegółowo omawia także ekonomiczne korzyści wynikające z wdrożenia SWD, wskazując na ich rolę w obniżaniu kosztów operacyjnych dzięki optymalizacji zużycia zasobów oraz efektywnemu zarządzaniu infrastrukturą techniczną. Analiza wpływu SWD na stabilność operacyjną organizacji wskazuje, że systemy te zapewniają niezakłócone warunki funkcjonowania, co ma kluczowe znaczenie dla przedsiębiorstw.

Rozdział obejmował również omówienie wyzwań współczesnego środowiska biznesowego oraz roli SWD w uproszczeniu procesów decyzyjnych, zwłaszcza w dynamicznie zmieniających się warunkach rynkowych. Podkreślono, że rozwój SWD, wsparty postępem w sztucznej inteligencji i analizie dużych zbiorów danych, znacząco poprawia efektywność podejmowania decyzji, umożliwiając organizacjom zarówno reagowanie na bieżące wyzwania, jak i przewidywanie przyszłych trendów.

Podsumowanie wskazuje na znaczenie SWD w promowaniu kultury organizacyjnej opartej na danych, która wspiera bardziej racjonalne i uzasadnione podejmowanie decyzji. Rozdział podkreśla, że SWD są fundamentem nowoczesnych strategii zarządzania, które

pozwalają na zwiększenie konkurencyjności oraz optymalizację procesów decyzyjnych w organizacjach.

Wnioski przedstawione w rozdziale stanowią istotny przyczynek do budowy systemu wspomagania decyzji, który będzie uzupełniał istotną lukę badawczą w obszarze zarządzania budynkami oraz infrastrukturą techniczną. Analiza literatury wykazała, że istnieje potrzeba opracowania bardziej zaawansowanych i zintegrowanych narzędzi, które nie tylko wspierają zarządzanie rozproszonymi nieruchomościami, ale także umożliwiają efektywne monitorowanie, diagnozowanie i optymalizację procesów funkcjonowania automatyki budynkowej oraz procesów powiązanych ze zużyciem mediów. W toku prac zidentyfikowano, że współczesne rozwiązania nie w pełni odpowiadają na potrzeby zarządzania złożonymi, heterogenicznymi systemami infrastruktury, zwłaszcza w kontekście przewidywania awarii jak również w kontekście zrównoważonego zarządzania mediami. Będący przedmiotem pracy badawczej SWD opiera się na technologiach sztucznej inteligencji, uczenia maszynowego, analizie dużych zbiorów danych, co pozwoli na podejmowanie decyzji opartych o fakty i urealnione przewidywania, skutkując obniżeniem kosztów utrzymania nieruchomości oraz szybszym usuwaniem uszkodzeń i awarii, dla utrzymania ciągłości pracy budynków. Budowa takiego systemu nie tylko uzupełni lukę badawczą, ale także przyczyni się do rozwoju narzędzi zarządzania infrastrukturą techniczną budynków zapewniając organizacji nowe rozwiązania oraz wnioski z budowy systemu.

2. Konserwacja predykcyjna: koncepcje, metody i narzędzia

Prawidłowe funkcjonowanie zarządzanych nieruchomości jest kluczowe dla zapewnienia stabilnej i bezpiecznej realizacji celów biznesowych przedsiębiorstw. Użytkownicy tych nieruchomości oczekują, że warunki pracy będą dostosowane do ich potrzeb i utrzymywane w sposób stabilny, bez zakłóceń związanych z utratą komfortu pracy. Z tego względu szczególnie istotne jest utrzymanie systemów zarządzających komfortem termicznym oraz bezpieczeństwem użytkowników w odpowiednim stanie technicznym. Właściwe zarządzanie tymi systemami znacząco wpływa na ciągłość działania kluczowych procesów operacyjnych. W tym kontekście, predykcja uszkodzeń w systemach zarządzania komfortem termicznym, systemach kontroli dostępu oraz systemach wspierających bezpieczeństwo staje się kluczowym zagadnieniem.

Predykcja uszkodzeń w systemach technologicznych została szeroko zbadana i opisana w literaturze w kontekście procesów produkcyjnych, jednak w mniejszym stopniu dotyczy to zintegrowanych systemów zarządzania budynkami i ich podsystemami realizującymi autonomiczne funkcje (Dalzochio *et al.*, 2020; Zonta *et al.*, 2020; Theissler *et al.*, 2021; van Dinter, Tekinerdogan and Catal, 2022; Nunes, Santos and Rocha, 2023). Wdrażanie procesów predykcji uszkodzeń w heterogenicznych zespołach budynków, obejmujących obiekty o różnorodnym przeznaczeniu (biurowe, magazynowe, warsztatowe itp.) oraz wyposażonych w zróżnicowane systemy automatyki budynkowej, stanowi wyzwanie. Wynika to z potrzeby opracowania spójnego systemu gromadzenia danych z wielu różnorodnych obiektów, co jest niezbędne do efektywnej predykcji uszkodzeń.

Dodatkowe trudności we wdrożeniu produkcyjnym tego typu systemów wynikają z konieczności zaprojektowania rozwiązania, które będzie uniwersalne i możliwe do zastosowania w różnych typach budynków, różniących się pod względem wielkości oraz zastosowanych rozwiązań technicznych. Ważnym aspektem, który należy uwzględnić, są także koszty wdrożenia oraz opłacalność stosowania takiego rozwiązania jako narzędzia centralnego do monitorowania rozproszonych terytorialnie nieruchomości.

W literaturze istnieje wiele metod predykcji uszkodzeń, które mogą być zaadaptowane do systemów automatyki budynkowej, co może znacząco podnieść niezawodność działania tych systemów (Zonta *et al.*, 2020). Jednak spośród dostępnych metod należy dobrać te, które zapewnią najlepsze rezultaty w zakresie utrzymania ciągłości funkcjonowania systemów przy jednoczesnym optymalnym koszcie ich wdrożenia. Z tego względu kluczowe jest precyzyjne zidentyfikowanie zakresu systemów i komponentów, które powinny być objęte predykcją uszkodzeń, zakresu danych niezbędnych do ich efektywnego monitorowania oraz celów, jakie ma spełniać stosowanie takich rozwiązań w kontekście ciągłości funkcjonowania poszczególnych podsystemów.

2.1. Cechy i zastosowanie konserwacji predykcyjnej

Konserwacja predykcyjna (ang. predictive maintenance) to zaawansowana metoda wykorzystująca narzędzia i techniki analizy danych w celu identyfikacji anomalii, które mogą wystąpić podczas operacji i realizacji procesów biznesowych. Dzięki tej technice możliwe jest wykrywanie nieprawidłowości na wczesnym etapie, co umożliwia ich naprawę przed wystąpieniem poważnych konsekwencji, które wymagałyby doraźnej interwencji (Çinar *et al.*, 2020). Stosowanie konserwacji predykcyjnej prowadzi do redukcji liczby koniecznych interwencji konserwacyjnych oraz minimalizuje potrzebę stosowania konserwacji reaktywnej. Konserwacja reaktywna, polegająca na naprawie problemów po ich wystąpieniu, generuje wyższe koszty operacyjne i prowadzi do przestoju. Wykorzystanie technik konserwacji predykcyjnej, bazującej na analizie danych historycznych oraz danych w czasie rzeczywistym, pozwala na wczesne wykrywanie potencjalnych problemów, zanim te się zmaterializują, co skutkuje oszczędnością czasu i środków finansowych.

Narzędzia informatyczne wykorzystywane w konserwacji predykcyjnej muszą spełniać określone warunki techniczne, aby mogły precyzyjnie przewidywać przyszłe błędy i awarie. Monitorowanie działań operacyjnych w czasie rzeczywistym umożliwia tym narzędziom analizę stanów urządzeń i wykrywanie odchyleń od pożądanych parametrów pracy. Algorytmy maszynowe, analizując standardowe przebiegi operacji, stan techniczny urządzeń oraz przeszłe wydarzenia związane z pomiarami i alarmami, są w stanie zidentyfikować anomalie, które mogą prowadzić do problemów z funkcjonowaniem infrastruktury technicznej. Konserwacja predykcyjna umożliwia zatem wykrycie potencjalnych błędów i awarii jeszcze przed ich wystąpieniem, co pozwala uniknąć negatywnych skutków dla systemów operacyjnych (van Dinter, Tekinerdogan and Catal, 2022).

Wdrożenie konserwacji predykcyjnej w standardowych operacjach utrzymaniowych wymaga podjęcia szeregu decyzji i spełnienia określonych warunków przez użytkowników oraz organizacje, w celu zapewnienia maksymalnej efektywności wdrożonych metod i osiągnięcia pożądanych rezultatów, takich jak redukcja kosztów utrzymania infrastruktury. Lokalne kontrolery i sterowniki, wykorzystywane do bieżącego monitorowania parametrów infrastruktury, wymagają wstępnej analizy oraz konsultacji z przedstawicielami organizacji biznesowej, co pozwala na pełne zrozumienie oczekiwanych efektów operacyjnych i optymalizację procesów utrzymaniowych (Dalzochio *et al.*, 2020).

Skuteczność modelu predykcyjnego opiera się na analizie danych historycznych, takich jak przestoje, alarmy i zapisy parametrów operacyjnych. W przypadku niektórych urządzeń wspierających procesy biznesowe, zmieniające się technologie i zakup nowych maszyn mogą stanowić wyzwanie dla algorytmów predykcyjnych, które mogą mieć trudności w rozróżnieniu starych i nowych urządzeń. Z tego względu budowa algorytmów predykcyjnych oraz wdrożenie złożonych rozwiązań w wielodomenowych i heterogenicznych środowiskach wymaga szczególnej uwagi i precyzyjnego planowania.

Aktualizacja inwentaryzacji technologicznej, obejmującej szczegółowe informacje dotyczące każdego elementu parku technologicznego, jest kluczowym krokiem w procesie wdrażania konserwacji predykcyjnej. Pozwala to na rozróżnienie między różnymi typami

i modelami urządzeń, co umożliwi dokładniejsze prognozowanie przyszłych awarii. Dobór odpowiednich technologii akwizycji danych, które są niezbędne do rozpoczęcia analizy procesów i operacji w danym środowisku, jest warunkiem koniecznym skutecznego wdrożenia systemów predykcyjnych.

Niektóre przewidywane anomalie mogą prowadzić do większych szkód niż inne, a krytyczne awarie mają największy potencjał do generowania strat. Zdefiniowanie poziomów ryzyka związanych z takimi anomaliami pozwala na szybką reakcję na te o najwyższym priorytecie. Ze względu na koszty pełnego wdrożenia narzędzi konserwacji predykcyjnej, niemożliwe może być monitorowanie wszystkich operacji w czasie rzeczywistym. Dlatego kluczowe jest przeprowadzenie oceny, które operacje wymagają predykcji anomalii, aby procesy były maksymalnie efektywne pod względem kosztów i działania (Zonta *et al.*, 2020; Nunes, Santos and Rocha, 2023).

Szkolenie personelu odpowiedzialnego za modernizację sprzętu oraz reagowanie na przewidywane anomalie stanowi ważny element budowania pełnej świadomości operacyjnej oraz skutecznego zarządzania zagrożeniami awariami. Komputerowe systemy zarządzania konserwacją, które rejestrują wykryte anomalie i opisują sposób zapobieżenia awariom, sprawiają, że procesy utrzymania operacyjnego stają się bardziej efektywne i generują znaczne oszczędności kosztowe w długim horyzoncie czasowym.

Konserwacja predykcyjna jest ściśle powiązana z konserwacją prewencyjną, choć obie te formy utrzymania mają różne genezy i są realizowane w odmienny sposób. Konserwacja predykcyjna odnosi się do stanu sprzętu lub procesu, gdy urządzenie jest w pełni sprawne, a operacja przebiega bez zakłóceń. Jej celem jest przewidywanie potencjalnych usterek na podstawie bieżących danych operacyjnych i podejmowanie odpowiednich działań zapobiegawczych. Z kolei konserwacja prewencyjna opiera się na określonym cyklu życia urządzeń i jest przeprowadzana w przewidzianym horyzoncie czasowym, zwykle przed spodziewaną awarią, wynikającą z upływu zakładanego okresu eksploatacji.

W ramach konserwacji predykcyjnej decyzje dotyczące działań utrzymaniowych podejmowane są na podstawie danych zebranych z operacji, które miały miejsce. Reakcje na potencjalne problemy są inicjowane po wykryciu alertów w wyniku ciągłego monitorowania oraz spełnieniu wcześniej zdefiniowanych kryteriów operacyjnych. Takie podejście może prowadzić do wymiany sprzętu, który nadal jest sprawny, lub do reakcji na problemy już istniejące, takie jak defekty, anomalie czy awarie. W związku z tym konserwacja prewencyjna często wiąże się z przestojami operacyjnymi, ponieważ nie można jej przeprowadzać w trakcie trwających procesów, co skutkuje opóźnieniami i stratami finansowymi.

Podsumowując, należy podkreślić, że decyzja o wdrożeniu konserwacji predykcyjnej jest złożona. Z jednej strony, jej zastosowanie pozwala uniknąć kosztów związanych z ewentualnymi awariami i ich konsekwencjami, jednak z drugiej strony może generować niepotrzebne koszty i przestoje w sytuacjach, gdy przewidywana awaria nie wystąpi lub wystąpi znacznie później niż prognozowano. Z tego względu kluczowym aspektem podczas podejmowania decyzji o wdrożeniu konserwacji predykcyjnej jest właściwy dobór metod i narzędzi technologicznych, które zapewnią optymalne rezultaty.

2.2. Wytyczne dla konserwacji predykcyjnej

Konserwacja predykcyjna opiera się na szeregu wymagań wstępnych, których spełnienie jest kluczowym warunkiem powodzenia wdrożeń zarówno w procesach biznesowych, jak i operacjach technicznych. Wymagania te obejmują zasoby ludzkie, sprzęt, narzędzia i części, technologie, dane oraz procesy. Zasoby ludzkie odgrywają centralną rolę w realizacji konserwacji predykcyjnej, ponieważ to pracownicy są odpowiedzialni za reagowanie na ostrzeżenia generowane przez narzędzia monitorujące operacje. Definiowanie i wdrażanie warunków, które muszą być spełnione, aby systemy alarmowe mogły generować właściwe powiadomienia, jest zadaniem członków organizacji, stanowiącym istotny element budowy skutecznego ekosystemu konserwacji predykcyjnej.

Dane są niezbędnym komponentem procesu predykcji, ponieważ to one umożliwiają identyfikację i przewidywanie anomalii w systemie. Dane pochodzące z monitoringu operacji i urządzeń infrastruktury technicznej są wykorzystywane do analizy, tworzenia wzorców oraz generowania alertów w przypadku wykrycia anomalii. Kluczowe znaczenie ma jakość i dokładność generowanych danych, gdyż wpływa ona na poprawność wyników analiz predykcyjnych (Dalzochio *et al.*, 2020; Theissler *et al.*, 2021; Nunes, Santos and Rocha, 2023). Zgromadzone duże wolumeny danych muszą być systematycznie weryfikowane pod kątem jakości oraz odpowiednio normalizowane, aby zapewnić prawidłowe wyniki analiz. Sposób zarządzania danymi oraz procesy związane z predykcją mają bezpośredni wpływ na wydajność konserwacji predykcyjnej, ponieważ szybkość i skuteczność reakcji na alerty są kluczowe dla efektywności systemu.

Narzędzia technologiczne, wraz z odpowiednimi algorytmami oraz poziomami zapasów części zamiennych, umożliwiają realizację konserwacji predykcyjnej zgodnie z założeniami biznesowymi i technologicznymi. Narzędzia te mierzą stan zasobów oraz pełnią funkcję instrumentów do monitorowania i naprawy elementów infrastruktury technicznej. Części zamienne oraz zapasowe urządzenia są istotnym elementem konserwacji predykcyjnej, a ich odpowiedni poziom dostępności jest warunkiem koniecznym dla prawidłowego funkcjonowania procesu predykcyjnego. Zasoby te muszą dostarczać wiarygodnych danych, które umożliwią systemowi skuteczne wykrywanie anomalii i generowanie alertów przed wystąpieniem poważnych awarii. Najbardziej krytyczne operacje są najlepszym obszarem do zastosowania konserwacji predykcyjnej, ponieważ zwrot z inwestycji w tego typu technologie następuje najkrótszym czasie.

Technologie informatyczne odgrywają kluczową rolę we wdrażaniu procesów konserwacji predykcyjnej, ponieważ umożliwiają usprawnienie zarządzania wszystkimi komponentami zaangażowanymi w proces decyzyjny. Dzięki technologiom informatycznym możliwy jest dostęp do danych w czasie rzeczywistym, co eliminuje potrzebę ręcznego przeglądania i analizowania informacji. Rozwiązania technologiczne w zakresie konserwacji predykcyjnej pozwalają na przechwytywanie, przechowywanie, analizowanie oraz dostarczanie istotnych danych, które mogą być bezpośrednio wykorzystywane do podejmowania decyzji operacyjnych (Zonta *et al.*, 2020).

Wszystkie wymienione komponenty, które składają się na wymagania wstępne konserwacji predykcyjnej, są wzajemnie zależne i głęboko ze sobą powiązane. Niewłaściwy dobór lub dopasowanie któregoś z tych elementów może narazić cały system predykcyjny na niepowodzenie.

Skuteczna konserwacja predykcyjna wymaga przetwarzania dużych zbiorów danych, a samo przetwarzanie takich ilości danych jest wyzwaniem zarówno pod względem technicznym, jak i kosztowym. Zgromadzone dane muszą być przechowywane i analizowane za pomocą zaawansowanych narzędzi, takich jak systemy oparte na architekturze zorientowanej na usługi (SOA, Service-Oriented Architecture), aby nadawać sens operacjom i zapobiegać przestojom w procesach biznesowych. Bazy danych, które są wykorzystywane do przechowywania dużych ilości danych, muszą być skalowalne, aby sprostać wymogom związanym z ich regularnym generowaniem. Skalowanie takich baz danych wymaga zastosowania inteligentnych algorytmów, które będą w stanie przetwarzać te dane i dostarczać wiarygodne wyniki.

Konserwacja predykcyjna znajduje swoje zastosowanie przede wszystkim w operacjach krytycznych dla organizacji, które mają bezpośredni wpływ na działalność biznesową. W przypadku urządzeń i operacji, które nie mają krytycznego znaczenia dla organizacji, wdrażanie konserwacji predykcyjnej może być nieopłacalne, ze względu na zbyt wysokie koszty w porównaniu do oczekiwanych efektów. Należy również wziąć pod uwagę grupy urządzeń i procesów, w których awarii nie da się efektywnie przewidzieć, a zastosowanie konserwacji predykcyjnej nie przyniesie wymiernych korzyści ekonomicznych.

2.3. Potencjalne źródła danych w konserwacji predykcyjnej

Skuteczna konserwacja predykcyjna wymaga dostarczenia odpowiedniej ilości i jakości danych. W tym celu niezbędne jest stosowanie odpowiednich urządzeń i technologii.

Wykorzystanie urządzeń Internetu Rzeczy (IoT) w konserwacji predykcyjnej znacząco poprawia jakość danych oraz precyzję wyników uzyskiwanych z algorytmów predykcyjnych. Urządzenia IoT często są wyposażone w wbudowane funkcje analityczne i pomiarowe, co umożliwia dostarczanie większej ilości informacji z monitorowanych operacji i urządzeń do analizy. Wbudowane czujniki oraz sensory mają zdolność rejestrowania fizycznych działań maszyn i przekształcania ich na dane cyfrowe, co pozwala na skuteczniejszą i dokładniejszą analizę procesów operacyjnych (Kanawaday and Sane, 2017; Compare, Baraldi and Zio, 2020).

Analiza drgań maszyn jest możliwa zarówno dzięki przenośnym analizatorom, jak i wbudowanym czujnikom, które dostarczają dane w czasie rzeczywistym. Czujniki drgań są powszechnie stosowane w urządzeniach, które zawierają szybkoobrotowe elementy wirujące, takie jak łożyska czy wały. Zużycie i awarie tych elementów prowadzą do zmian w charakterystyce drgań, które mogą być analizowane pod kątem wykrywania nieprawidłowości. Analiza wzorców drgań i ich porównanie z innymi znanymi wzorcami pozwala na identyfikację problemów eksploatacyjnych, a także źródeł alarmów i awarii.

Wykryte alerty mogą wskazywać na istniejące problemy, takie jak luźne elementy, wygięte wały, niewspółosiowość czy niewyważone wałki (Compare, Baraldi and Zio, 2020).

Termografia podczerwieni jest technologią umożliwiającą monitorowanie temperatur sprzętu za pomocą kamer na podczerwień. Zużyte lub wadliwe podzespoły zazwyczaj emitują ciepło wyższe niż normalne, co pozwala na szybkie zidentyfikowanie tzw. punktów ciepłych. Identyfikacja tych punktów umożliwia podjęcie działań naprawczych, zanim dojdzie do uszkodzeń powodujących długie przestoje w pracy maszyn (Hashemian, 2011).

Akustyczne monitorowanie sprzętu jest kolejną techniką wykorzystywaną do wykrywania problemów technicznych. Analiza dźwięków emitowanych przez urządzenia pozwala na identyfikację pogarszających się lub uszkodzonych ruchomych części, które generują dźwięki różniące się od dźwięków generowanych przez nowe elementy. Porównanie danych akustycznych umożliwia zidentyfikowanie komponentów emitujących nietypowe dźwięki, co z kolei umożliwia podjęcie niezbędnych działań zaradczych (Romanssini *et al.*, 2023).

Urządzenia infrastruktury technicznej, które wykorzystują olej do chłodzenia i smarowania, również wymagają monitorowania. Analiza oleju pozwala na ocenę aktualnego stanu maszyn poprzez określenie takich parametrów, jak lepkość oleju, kwasowość lub zasadowość, obecność cząstek stałych, metali wynikających z zużycia części lub zanieczyszczeń, takich jak woda. Regularne monitorowanie tych parametrów umożliwia wczesne wykrycie zmian, które mogą prowadzić do problemów technicznych, a także generowanie ostrzeżeń wskazujących na potrzebę podjęcia działań konserwacyjnych (Hashemian, 2011).

Czujniki wykorzystywane do monitorowania sprzętu i operacji gromadzą ogromne ilości danych dotyczących wybranych parametrów technicznych urządzeń. Dane te są przechowywane w dedykowanych bazach danych, które muszą być odpowiednio zarządzane i analizowane przy pomocy zaawansowanych algorytmów. Dane o wysokiej jakości stanowią podstawę do skutecznej predykcji zdarzeń, co umożliwia identyfikację potencjalnych problemów i podejmowanie działań naprawczych zanim wystąpią poważne awarie. Dzięki wdrożeniu modeli analizy danych możliwe jest efektywne przewidywanie zdarzeń, co przyczynia się do zwiększenia niezawodności infrastruktury technicznej (Compare, Baraldi and Zio, 2020).

2.4. Zalety konserwacji predykcyjnej

Prawidłowe stosowanie konserwacji predykcyjnej niesie ze sobą liczne korzyści, zarówno dla pracowników operacyjnych, jak i całych organizacji. Przede wszystkim, jednym z najważniejszych efektów wdrożenia konserwacji predykcyjnej jest znaczne obniżenie kosztów operacyjnych, które wynikają z redukcji przestojów spowodowanych awariami oraz koniecznością przeprowadzania doraźnych napraw. Mniejsze liczby nieplanowanych przestojów mają bezpośredni wpływ na wzrost efektywności ekonomicznej przedsiębiorstwa, co pozwala na bardziej efektywnie wykorzystanie zasobów.

Regularna konserwacja predykcyjna umożliwia także wydłużenie żywotności systemów i maszyn, ponieważ procesy monitorowania i analizy danych pozwalają na wczesne wykrycie potencjalnych problemów oraz zapobieganie ich eskalacji. Dzięki zastosowaniu zaawansowanej analizy danych, czas potrzebny na konserwację systemów może być dokładnie obliczony, co zwiększa efektywność planowania działań utrzymaniowych. Procesy produkcyjne można łatwiej zintegrować z harmonogramem konserwacji, co skutkuje ich lepszą koordynacją i w efekcie, wzrostem wydajności globalnej organizacji (Compare, Baraldi and Zio, 2020).

Konserwacja predykcyjna wpływa również pozytywnie na wydajność systemów w skali całej organizacji. Skutecznie wdrożone procesy predykcyjne, oparte na precyzyjnej analizie danych, umożliwiają identyfikację obszarów o potencjalnie wysokim ryzyku awarii. W rezultacie możliwe jest skoncentrowanie zasobów utrzymaniowych tam, gdzie będą one najbardziej efektywne. Analiza przeprowadzona na poziomie całych domen organizacyjnych wskazuje, w których procesach istnieje możliwość dalszej optymalizacji poprzez redukcję nieplanowanych przestoju i awarii (Paolanti *et al.*, 2018).

Zespoły odpowiedzialne za utrzymanie techniczne mogą także odczuć bezpośrednie korzyści wynikające z wdrożenia konserwacji predykcyjnej. Dzięki analizie zebranych danych narzędzia predykcyjne umożliwiają skuteczniejszą alokację zasobów, zarówno ludzkich, jak i materialnych, co zwiększa produktywność zespołów utrzymaniowych. Ponadto, nowoczesne systemy konserwacji predykcyjnej przedstawiają wyniki w sposób intuicyjny i przejrzysty, co pozwala technikom na szybsze diagnozowanie problemów oraz skrócenie czasu reakcji. Zredukowana potrzeba ręcznego diagnozowania i analizy sprawia, że pracownicy mogą skupić się na bardziej złożonych zadaniach, co dodatkowo podnosi ich wydajność.

Reasumując, konserwacja predykcyjna nie tylko poprawia efektywność operacyjną przedsiębiorstw, ale również przyczynia się do lepszego wykorzystania zasobów, co przekłada się na długofalowe korzyści finansowe oraz większą stabilność operacyjną organizacji.

2.5. Wady i problemy w procesach konserwacji predykcyjnej

Proces analizy i wdrożenia harmonogramu konserwacji predykcyjnej jest skomplikowany i czasochłonny, wymagający precyzyjnego planowania oraz zaangażowania znacznych zasobów. Jednym z kluczowych wyzwań jest konieczność odpowiedniego przeszkolenia personelu w obsłudze zaawansowanych narzędzi informatycznych, co wiąże się ze wzrostem kosztów utrzymania w krótkim okresie (Yan *et al.*, 2017). Szkolenia te mają na celu przygotowanie pracowników do posługiwania się złożonymi algorytmami analizy danych oraz systemami monitoringu, które stanowią podstawę skutecznego wdrożenia predykcyjnych metod konserwacji.

Dodatkową trudność stanowi brak kompatybilności niektórych urządzeń z narzędziami przeznaczonymi do konserwacji predykcyjnej. W takich przypadkach implementacja tego rodzaju rozwiązań może być utrudniona lub wręcz niemożliwa, co ogranicza ich potencjalne zastosowanie w całej infrastrukturze technicznej organizacji.

Należy również podkreślić, że nie wszystkie operacje i urządzenia są odpowiednimi kandydatami do wdrożenia konserwacji predykcijnej. Wprowadzenie tej technologii jest zazwyczaj opłacalne jedynie w przypadku systemów z wieloma punktami pomiarowymi, gdzie analiza danych przynosi wymierne korzyści w zakresie monitorowania stanu technicznego. Celem konserwacji predykcijnej jest utrzymanie możliwie niskiego wskaźnika awarii oraz zapewnienie maksymalnej niezawodności operacji i zasobów, jednakże jej efektywność zależy od kosztów utrzymania, które muszą pozostać na niskim poziomie w długim okresie (Li, Wang and Wang, 2017).

W przypadku niektórych organizacji, koszty związane z wdrożeniem konserwacji predykcijnej, nawet w dłuższym horyzoncie czasowym, mogą przewyższać korzyści wynikające z poprawy świadomości sytuacyjnej oraz zwiększonej kontroli nad stanem technicznym infrastruktury. W takich przypadkach koszty związane z wdrożeniem i utrzymaniem zaawansowanych narzędzi analitycznych mogą nie uzasadniać inwestycji, co stanowi istotne ograniczenie w kontekście powszechnego wdrożenia tej technologii (Sezer *et al.*, 2018).

2.6. Stosowane modele i metody predykcji

Modele analizy danych wykorzystują dostępne zbiory informacji do tworzenia wzorców, które następnie porównują z innymi istniejącymi wzorcami w celu identyfikacji odchyleń. Zidentyfikowane różnice mogą być sygnałem, że istnieje ryzyko awarii, co uruchamia alerty. Kluczowym czynnikiem wpływającym na skuteczność takich systemów są dane o wysokiej jakości, które zostały znormalizowane i cechują się dokładnością, ponieważ to one zapewniają wiarygodność wyników uzyskanych w wyniku analizy. Zastosowanie algorytmów analizy danych, w szczególności w połączeniu z uczeniem maszynowym i różnymi modelami danych, znacząco zwiększa prawdopodobieństwo, że system będzie w stanie dostarczyć prawidłowe informacje na temat bieżących operacji oraz stanu utrzymania.

Współczesne modele predykcyjne stanowią fundamentalne narzędzie w dziedzinie analizy danych, umożliwiając prognozowanie przyszłych zdarzeń i trendów z wysoką precyzją. Wraz z rosnącą ilością dostępnych danych oraz postępem technologicznym, coraz większego znaczenia nabierają zaawansowane metody prognostyczne, które znajdują zastosowanie w wielu obszarach nauki i przemysłu. W niniejszym rozdziale zostaną omówione wybrane metody i modele predykcyjne, takie jak Gradient Boosting Machines (GBM), sieci neuronowe, modele SARIMA, model Holta-Wintersa oraz Facebook Prophet.

Dobór odpowiedniej metody predykcijnej jest ściśle uzależniony od charakterystyki danych, które podlegają analizie. Różne typy danych wymagają zastosowania odmiennych podejść modelowych, aby uzyskać optymalne wyniki prognozowania. Kluczowe jest zrozumienie struktury danych, obecności trendów, sezonowości, a także ewentualnych nieliniowości czy zależności pomiędzy zmiennymi.

W przypadku szeregów czasowych charakteryzujących się wyraźnymi wzorcami sezonowymi i trendami, ogólnie efektywne okazują się modele statystyczne, takie jak SARIMA (Seasonal Autoregressive Integrated Moving Average) oraz model Holta-Wintersa. Modele

te są zdolne do uchwycenia zależności czasowych oraz sezonowych w danych, co umożliwia precyzyjne prognozowanie przyszłych wartości na podstawie historycznych obserwacji.

Dla danych zawierających złożone wzorce, nieregularności czy nietypowe zdarzenia, coraz częściej wykorzystywane są nowoczesne narzędzia takie jak Facebook Prophet. Metoda ta została zaprojektowana z myślą o łatwym modelowaniu szeregów czasowych z uwzględnieniem czynników takich jak sezonowość, święta czy inne zmienne zewnętrzne, oferując jednocześnie prostotę użycia i interpretacji wyników.

W sytuacjach, gdy dane są wielowymiarowe i występują w nich nieliniowe zależności pomiędzy zmiennymi, zastosowanie znajdują metody uczenia maszynowego, takie jak Gradient Boosting Machines (GBM) oraz sieci neuronowe. GBM to potężne narzędzie, które łączy prostotę drzew decyzyjnych z mechanizmem wzmacniania, co pozwala na budowę modeli o wysokiej skuteczności zarówno w zadaniach regresji, jak i klasyfikacji. Sieci neuronowe, inspirowane strukturą ludzkiego mózgu, są zdolne do modelowania skomplikowanych, nieliniowych relacji w danych, co czyni je niezastąpionymi w dziedzinach takich jak przetwarzanie obrazów, rozpoznawanie mowy czy analiza dużych zbiorów danych. Wybór odpowiedniej metody predykcyjnej powinien być dokonywany z uwzględnieniem specyfiki danych oraz celów analizy. Czynniki takie jak rozmiar i jakość zbioru danych, obecność brakujących wartości, struktura zmiennych czy oczekiwana interpretowalność modelu odgrywają kluczową rolę w procesie decyzyjnym. Nie bez znaczenia są również wymagania obliczeniowe oraz dostępność zasobów sprzętowych i programistycznych.

W dalszej części rozdziału dokonana zostanie szczegółowa analiza wymienionych metod i modeli predykcyjnych. Omówione zostaną ich podstawy teoretyczne, zastosowania praktyczne oraz kryteria wyboru w kontekście różnych typów danych. Pozwoli to na świadome i efektywne wykorzystanie odpowiednich narzędzi prognostycznych w zależności od specyfiki problemu badawczego.

2.7. Charakterystyka algorytmów klasy GBM

Aby zapewnić wysoką dokładność predykcji, stosuje się uogólnione modele wzmacniające (GBM) w połączeniu z algorytmami uczenia maszynowego. Modele te wielokrotnie dopasowują się do drzew decyzyjnych, co pozwala na lepsze odwzorowanie zależności w danych. Algorytmy uczenia maszynowego w tych modelach bazują na technikach uczenia nadzorowanego, gdzie zmienne docelowe są przewidywane na podstawie zestawu zmiennych niezależnych (predyktorów). Modele uczenia nadzorowanego, takie jak drzewa decyzyjne i losowy las decyzyjny, wykorzystują techniki wzmacniania gradientowego, które umożliwiają tworzenie dokładnych modeli predykcyjnych (Natekin and Knoll, 2013).

Uogólnione modele wzmacniające mogą być efektywnie stosowane nawet w przypadku dużych zbiorów danych oraz licznych zmiennych środowiskowych. Wzmacnianie gradientowe pozwala na modyfikację tzw. "słabych uczniów" (słabo działających modeli), aby z czasem stali się bardziej efektywni. W procesie wzmacniania, klasyfikatory słabych modeli są stopniowo doskonalone, co prowadzi do powstania bardziej precyzyjnych hipotez. Początkowo słabe modele, które przewidują wyniki nieco lepiej niż losowe typowanie, są wzmacniane w miarę filtrowania obserwacji, a bardziej złożone obserwacje są rozwiązywane przez kolejne

„słabe modele”. Ten proces jest powtarzany wielokrotnie, co prowadzi do usprawnienia predykcji (Ridgeway, 2024).

Pojedynczy model predykcyjny może być wdrażany w wielu systemach uczenia maszynowego, takich jak modele penalizowane, maszyny wektorów nośnych, regresja liniowa czy klasyfikator Bayesa. Modele losowych lasów i worków (bagging) wykorzystują ideę zespołów modeli, gdzie każdy model generuje swoje prognozy, a wynik końcowy jest średnią z prognoz wszystkich modeli w zespole. Wzmacnianie opiera się na kluczowej idei dodawania kolejnych modeli do zespołu w określonej kolejności, gdzie słabsze modele są stopniowo trenowane, aby poprawiać błędy (Bentéjac, Csörgő and Martínez-Muñoz, 2021).

Strategia ta oferuje wiele korzyści, takich jak niski koszt obliczeniowy, szybka budowa modeli, zwiększona dokładność predykcji oraz unikanie nadmiernego dopasowania (overfittingu). Modele wzmacniane, tworzone w sekwencji, wykorzystują informacje z poprzednich iteracji drzew decyzyjnych, aby tworzyć bardziej precyzyjne modele. Algorytm ten można uogólnić przy pomocy wartości x (cechy) oraz y (odpowiedzi), gdzie:

1. Dopasowuje się pierwsze drzewo decyzyjne: $F_{1(x)} = y$,
2. Następne drzewo dopasowuje się do reszt błędów z F_1 : $h_{1(x)} = y - F_{1(x)}$,
3. Dodaje się nowe drzewo do modelu: $F_{2(x)} = F_{1(x)} + h_{1(x)}$,
4. Kolejne drzewo jest dopasowane do reszt F_2 : $h_{2(x)} = y - F_{2(x)}$,
5. Proces ten jest kontynuowany, aż do spełnienia warunku zatrzymania.

W ten sposób, z każdym kolejnym modelem, system staje się coraz bardziej precyzyjny, co pozwala na budowanie dokładnych modeli predykcyjnych, które mogą być skutecznie stosowane w różnych dziedzinach (Bentéjac, Csörgő and Martínez-Muñoz, 2021).

Opadanie gradientowe koncentruje się na minimalizacji błędu średniokwadratowego (MSE) poprzez wzmacnianie gradientu. Czasami proces ten odnosi się również do innych funkcji straty, takich jak średni błąd bezwzględny, w zależności od specyfiki problemu. W przypadkach, gdzie minimalizacja błędów predykcji jest kluczowa, zastosowanie znajdują algorytmy wzmacniania gradientu. Zejście gradientowe jest powszechnie stosowane w rozwiązywaniu szerokiego zakresu problemów optymalizacyjnych, prowadząc do znalezienia optymalnych rozwiązań.

Według literatury (CAO *et al.*, 2013), adaptacyjne wzmacnianie (AdaBoost) jest jednym z najbardziej efektywnych algorytmów wzmacniania. AdaBoost wykorzystuje „słabych uczniów”, zwanych drzewami decyzyjnymi, które są zredukowane do prostych podziałów, zwanych "pniami decyzyjnymi". Pomimo swojej prostoty, AdaBoost tworzy dokładne reguły predykcyjne, łącząc niedoskonałe i umiarkowanie dokładne reguły przewidywania. Algorytm przypisuje wagi obserwacjom, co pozwala odróżnić łatwe przypadki od tych trudniejszych do sklasyfikowania. Trudniejsze obserwacje są przydzielane nowym słabym uczniom. Algorytm stopniowo buduje model, ważąc przewidywania słabych uczniów zgodnie z ich dokładnością (Schapire, 2013).

W pierwszej fazie AdaBoost buduje modele poprzez trenowanie na zestawach danych, a następnie tworzy kolejne modele, które korygują błędy wcześniejszych modeli. Algorytm

osiąga coraz bardziej precyzyjne przewidywania z każdym kolejnym modelem, aż do momentu osiągnięcia optymalnej liczby modeli lub maksymalnej dokładności (Schapire, 2013). AdaBoost stał się podstawą wielu nowoczesnych technik wzmacniania, takich jak maszyny do zwiększania gradientu stochastycznego.

AdaBoost zwiększa wydajność drzew decyzyjnych w klasyfikacji problemów binarnych. Freund i Schapire (Freund and Schapire, 1997) opracowali jego wariant nazwany AdaBoost.M1, który pierwotnie był przeznaczony do klasyfikacji dyskretnej, a nie regresji, stąd też określenie "dyskretny AdaBoost". Algorytm ten został później uogólniony w postaci algorytmów ARcing, które obejmują ważoną minimalizację błędów w każdym kroku oraz ponowne ważenie danych wejściowych i klasyfikatorów.

Friedman (Friedman, 2002) wprowadził dalsze udoskonalenie w postaci Gradient Boosting Machines (GBM), które przekształciły się w popularne obecnie maszyny predykcyjne ze wzmocnionym gradientem. Głównym celem GBM jest minimalizacja funkcji straty poprzez etapowe dodawanie „słabych uczniów”. W algorytmach uczenia maszynowego, „słaby uczeń” (ang. weak learner) to model, który osiąga wyniki tylko nieznacznie lepsze od losowego zgadywania. Innymi słowy, jest to model o stosunkowo niskiej dokładności predykcji, ale nadal mający pewną wartość w przewidywaniu wyników.

Słabi uczniowie są kluczowym elementem w algorytmach zespołowych, takich jak boosting, gdzie wiele takich słabych modeli jest łączonych w jeden silny model. Chociaż pojedynczy słaby uczeń nie jest bardzo skuteczny, to algorytm wzmacniania stopniowo poprawia jego wyniki poprzez iteracyjne budowanie kolejnych modeli, które korygują błędy poprzednich.

Przykładem słabego ucznia może być proste drzewo decyzyjne o małej liczbie węzłów, często zwane "pniem decyzyjnym" (decision stump), które samo w sobie nie jest szczególnie dokładne, ale w połączeniu z innymi modelami może tworzyć silny, precyzyjny system predykcji. Każdy nowy słaby model jest dodawany do algorytmu, co pozwala poprawiać dokładność modeli predykcyjnych na przestrzeni kolejnych etapów. Tego rodzaju etapowe modele addytywne pozwalają na zamrożenie wcześniejszych uczniów i stopniowe dodawanie kolejnych, co poprawia dokładność przewidywań. Modele te mogą obsługiwać zarówno problemy klasyfikacji wieloklasowej, jak i regresji, rozszerzając techniki klasyfikacji binarnej na bardziej złożone problemy.

Podczas przygotowywania danych dla algorytmu AdaBoost, kluczowe jest zapewnienie wysokiej jakości danych oraz usunięcie wartości odstających, które mogą negatywnie wpłynąć na proces klasyfikacji. AdaBoost nieustannie koryguje błędne klasyfikacje, dlatego wartości odstające powinny być eliminowane, aby uniknąć nadmiernej koncentracji na ich poprawie (CAO *et al.*, 2013). Również zaszumione dane mogą stanowić problem i powinny być usunięte, aby algorytm działał zgodnie z założeniami.

Wzmacnianie gradientowe opiera się na trzech kluczowych elementach: funkcji straty, która jest najczęściej różniczkowalna i definiowana w zależności od problemu; strukturze ogólnej, która nie wprowadza nowych algorytmów, oraz słabych uczniach, najczęściej w postaci drzew decyzyjnych. Funkcja straty ukazuje różnicę między wartościami

rzeczywistymi a przewidywanymi, a drzewa decyzyjne poprawiają proces uczenia, upraszczając iteracje i zmniejszając liczbę potrzebnych do uzyskania optymalnych wyników.

Wzmacniane gradientowo drzewa regresji generują rzeczywiste wartości predykcji poprzez sumowanie wyników i dodawanie kolejnych modeli. Procedura ta działa zachłannie, a słabi uczniowie są ograniczeni przez liczbę węzłów drzew lub liści. Proces dodawania drzew odbywa się etapami, przy jednoczesnym minimalizowaniu funkcji straty. Każde drzewo jest modyfikowane, aby kierować model w stronę optymalnych rozwiązań, co skutkuje dokładniejszymi predykcjami.

XGBoost (eXtreme Gradient Boosting)

XGBoost, rozszerzenie algorytmu wzmacniania gradientowego, jest zaawansowaną implementacją stworzoną z myślą o maksymalizacji wydajności i precyzji predykcyjnej w szerokim zakresie zastosowań modelowania predykcyjnego. Uznawany za jeden z najbardziej efektywnych i wszechstronnych algorytmów w dziedzinie uczenia maszynowego (Nielsen, 2016), XGBoost jest szczególnie ceniony za swoje zdolności do szybkiego przetwarzania dużych ilości danych oraz za radzenie sobie z zadaniami, gdzie standardowe metody często zawodzą.

XGBoost, co jest skrótem od eXtreme Gradient Boosting, to zaawansowana implementacja algorytmu wzmacniania gradientowego (Gradient Boosting Machine, GBM), który jest szeroko stosowany w różnych zadaniach uczenia maszynowego ze względu na swoją wydajność i efektywność (Chen and Guestrin, 2016). W odróżnieniu od tradycyjnego GBM, XGBoost wprowadza szereg optymalizacji obliczeniowych i funkcjonalnych, które znacząco zwiększają jego skuteczność i skalowalność.

Podstawowym budulcem modelu XGBoost są drzewa decyzyjne. Algorytm buduje model predykcyjny poprzez iteracyjne dodawanie drzew, gdzie każde kolejne drzewo jest uczone, aby minimalizować reszty (błędy predykcji) generowane przez zbiór drzew utworzonych w poprzednich iteracjach. Proces ten jest realizowany przez minimalizację zregulowanej funkcji straty, co jest kluczowym aspektem redukcji przeuczenia.

XGBoost wykorzystuje gradientowy algorytm wzmacniania do optymalizacji ogólnej funkcji straty, która jest sumą strat predykcyjnych na poszczególnych obserwacjach oraz terminów regularyzacyjnych. Regularyzacja jest realizowana zarówno przez L1 (regresja Lasso), jak i L2 (regresja Ridge), które są dodawane do funkcji straty, zwiększając zdolność modelu do generalizacji na niewidzianych danych. Optymalizacja tej funkcji wykorzystuje drugą pochodną straty (metoda Newton-Raphson), co pozwala na bardziej precyzyjne i szybkie znalezienie minimum funkcji (Chen and Guestrin, 2016).

W tradycyjnych algorytmach drzew decyzyjnych, wybór najlepszego punktu podziału odbywa się poprzez analizę wszystkich możliwych miejsc rozdzielenia danych. XGBoost wprowadził innowacyjne podejście, wykorzystując kwantylowe przybliżenie histogramu (Quantile Sketch Approximation), co umożliwia efektywne znajdowanie optymalnych punktów podziału nawet w bardzo dużych zestawach danych. Dzięki temu metoda ta redukuje zapotrzebowanie na zasoby obliczeniowe i pamięciowe w porównaniu z pełnym przeglądem wszystkich opcji.

XGBoost został także zoptymalizowany do pracy zarówno na wielu rdzeniach CPU, jak i na GPU, co pozwala na równoległe tworzenie wielu drzew decyzyjnych jednocześnie. To równoległe przetwarzanie znacząco skraca czas potrzebny na budowę modelu, co ma kluczowe znaczenie w zastosowaniach, gdzie czas jest istotnym ograniczeniem.

XGBoost stanowi jedno z najbardziej efektywnych narzędzi w dziedzinie uczenia maszynowego, oferujące wyjątkową mieszankę szybkości, efektywności oraz skuteczności predykcyjnej, zdolną do radzenia sobie z szerokim zakresem zastosowań predykcyjnych w praktycznych i badawczych kontekstach.

Do zalet algorytmu XGBoost możemy zaliczyć (Uzir *et al.*, 2016):

- Wysoką Skuteczność w Redukcji Przeuczenia: XGBoost wdraża regularyzację zarówno L1, jak i L2, które pomagają kontrolować złożoność modelu, zapobiegając tym samym jego nadmiernemu dopasowaniu do danych treningowych. Dzięki temu modele są bardziej generalizowalne i lepiej sprawdzają się na nowych, niewidocznych wcześniej danych,
- Optymalizację Przetwarzania: Algorytm korzysta z zaawansowanych technik jak przybliżone drzewa decyzyjne oparte na histogramach, co umożliwia efektywniejsze i szybsze sortowanie oraz agregację danych podczas treningu. Ta metoda pozwala na radzenie sobie z bardzo dużymi zbiorami danych i jest kluczowym elementem, który wpływa na popularność XGBoost w przemyśle i naukach o danych,
- Zaawansowane Funkcje Obsługi Danych: XGBoost efektywnie radzi sobie z brakującymi wartościami i różnorodnością typów danych, co czyni go niezwykle użytecznym w realnych scenariuszach biznesowych, gdzie dane rzadko są idealnie czyste lub kompletnie strukturyzowane,
- Skalowalność i Wsparcie dla Różnych Platform: XGBoost może być stosowany na pojedynczych maszynach oraz w rozproszonych środowiskach obliczeniowych takich jak Hadoop i Spark. Możliwość pracy na platformach GPU i CPU pozwala na dalsze zwiększenie szybkości przetwarzania, czyniąc XGBoost atrakcyjnym wyborem dla aplikacji wymagających intensywnych obliczeń,
- Zaawansowane Metody Optymalizacji Modelu: XGBoost oferuje różnorodne metody dla walidacji krzyżowej oraz dostosowania parametrów, co pozwala na szczegółowe dopasowanie modelu do specyficznych potrzeb projektów. Użytkownicy mogą również definiować własne funkcje celu, co jest kluczowe w aplikacjach wymagających specjalistycznych i niestandardowych kryteriów oceny.

XGBoost znajduje zastosowanie w bardzo szerokim spektrum dziedzin, od detekcji oszustw finansowych, przez analizę sentymentu, prognozowanie sprzedaży, aż po zaawansowane systemy rekomendacyjne. Jego zdolność do efektywnego uczenia się z nieliniowych wzorców i złożonych zależności w danych sprawia, że jest chętnie wybierany przez naukowców i praktyków na całym świecie (Nielsen, 2016).

XGBoost jest również niezwykle popularny w środowiskach akademickich i konkursach danych, takich jak Kaggle, gdzie jego efektywność w rozwiązywaniu złożonych problemów predykcyjnych została wielokrotnie potwierdzona. Ponadto, jego otwarta architektura i aktywna społeczność użytkowników przyczyniają się do ciągłego rozwoju i ulepszania

algorytmu, co zapewnia jego aktualność i przydatność w dynamicznie zmieniającym się świecie danych i technologii.

LightGBM

LightGBM, czyli Light Gradient Boosting Machine, to zaawansowany algorytm wzmacniania gradientowego zaprojektowany przez Microsoft. Został stworzony w celu zwiększenia wydajności i efektywności pamięciowej w porównaniu do tradycyjnych algorytmów Gradient Boosting, takich jak XGBoost. LightGBM wykorzystuje innowacyjne techniki do przetwarzania dużych zbiorów danych z wysoką prędkością, co sprawia, że jest atrakcyjny dla szerokiego spektrum zastosowań przemysłowych i badawczych (Ke *et al.*, 2017).

LightGBM (Light Gradient Boosting Machine) również opiera się na technice wzmacniania gradientowego, ale wyróżnia się nowatorskim podejściem do budowy drzew decyzyjnych, co znacząco zwiększa jego wydajność, szczególnie w przypadku dużych zbiorów danych o licznych cechach. Dwie kluczowe innowacje, które odróżniają LightGBM od tradycyjnych metod, to Gradient-based One-Side Sampling (GOSS) oraz Exclusive Feature Bundling (EFB). GOSS umożliwia bardziej efektywne zarządzanie próbkowaniem, podczas gdy EFB optymalizuje przetwarzanie cech, co pozwala na skuteczne radzenie sobie z dużą liczbą zmiennych i szybsze przetwarzanie dużych zbiorów danych (Ke *et al.*, 2017).

Gradient-based One-Side Sampling (GOSS) to technika próbkowania danych, która pozwala na zachowanie skuteczności algorytmu przy znacznie zredukowanej objętości danych. Tradycyjne metody wzmacniania gradientowego mogą być niewydajne, ponieważ wymagają iteracyjnego przetwarzania wszystkich danych w każdej rundzie. GOSS zmienia tę dynamikę przez inteligentne próbkowanie danych. W tym podejściu, obserwacje z największymi gradientami, które są trudniejsze do przewidzenia i które mają większy wpływ na aktualizacje modelu, są zachowywane z większym prawdopodobieństwem. Jednocześnie, losowy podzbiór obserwacji z mniejszymi gradientami jest również zachowywany, ale z mniejszą wagą. To pozwala na redukcję obciążenia obliczeniowego bez istotnej utraty informacji, co przekłada się na szybsze i bardziej efektywne treningi (Song *et al.*, 2021).

W zbiorach danych o wysokiej wymiarowości, wiele cech może być rzadko występujących lub nawet wzajemnie wykluczających się, co stanowi wyzwanie dla tradycyjnych algorytmów. EFB radzi sobie z tym problemem, agregując współwystępujące cechy w „pakiety”, co zmniejsza wymiarowość danych bez znaczącej utraty użyteczności informacji. Pakiety są tworzone w sposób, który minimalizuje informacje o kolizjach cech, dzięki czemu dane są bardziej zwarte, a drzewa decyzyjne mogą być budowane szybciej.

Podczas gdy standardowe algorytmy GBM budują drzewa poziomowo (level-wise), LightGBM używa podejścia opartego na liściach (leaf-wise). W podejściu leaf-wise, algorytm rozszerza drzewo decyzyjne przez dodawanie liści na podstawie zmniejszenia funkcji straty, co pozwala na bardziej precyzyjne dopasowanie do złożonych wzorców w danych. Ta metoda jest szczególnie efektywna w przypadku danych asymetrycznych i nierównomiernie rozłożonych, ale może wymagać dodatkowej regulacji, aby uniknąć przeuczenia.

LightGBM oferuje szeroki zestaw parametrów konfiguracyjnych, które umożliwiają użytkownikom dostosowanie działania algorytmu do specyficznych wymagań ich danych i zastosowań. Możliwość dostosowania takich elementów jak głębokość drzewa, szybkość uczenia się i funkcje straty umożliwia optymalizację modeli pod kątem dokładności, czasu treningu, i unikania przeuczenia. Dostępne są także funkcje umożliwiające obsługę kategoryjnych cech bez konieczności ich wcześniejszego przetwarzania, co dodatkowo zwiększa użyteczność algorytmu.

Jedną z największych zalet LightGBM jest jego zdolność do efektywnego radzenia sobie z dużymi zbiorami danych, które zawierają szeroki zakres cech. Technologia EFB pozwala na zmniejszenie liczby cech przez ich grupowanie, co jest kluczowe w przypadku zbiorów danych z dużą ilością rzadko występujących lub rozrzuconych cech.

Choć LightGBM stosuje podejście leaf-wise, które może teoretycznie prowadzić do większego ryzyka przeuczenia, algorytm oferuje funkcje takie jak regularyzacja L1 i L2 oraz mechanizmy kontroli głębokości drzewa i minimalnego spadku straty, które pomagają w zachowaniu ogólnej zdolności modelu do generalizacji na nieznanymi danych.

LightGBM może być używany w środowiskach jednomaszynowych oraz rozproszonych, wykorzystując architektury wielordzeniowe oraz klastry obliczeniowe do dalszego przyspieszenia przetwarzania danych. Możliwość równoległego budowania drzew i rozproszonego przetwarzania danych jest kluczowa dla zastosowań, które wymagają skalowalności i szybkości.

LightGBM, dzięki swojej wyjątkowej wydajności i efektywności, znalazł szerokie zastosowanie w wielu dziedzinach przemysłu i nauki. Jego zdolność do szybkiego i efektywnego przetwarzania dużych zbiorów danych z kompleksowymi wzorcami sprawia, że jest preferowanym wyborem w różnych zastosowaniach analizy predykcyjnej.

LightGBM jest szczególnie skuteczny w kilku poniższych kluczowych obszarach.

- W branży finansowej, gdzie szybkość i dokładność są kluczowe, LightGBM jest używany do budowania modeli detekcji oszustw. Jego zdolność do przetwarzania dużych ilości transakcji w czasie rzeczywistym oraz efektywne radzenie sobie z niespójnymi i rozproszonymi danymi pozwala na szybkie identyfikowanie potencjalnych oszustw, minimalizując fałszywe alarmy i optymalizując procesy weryfikacyjne (Wang, Li and Zhao, 2022).
- LightGBM znajduje zastosowanie w prognozowaniu popytu, co jest szczególnie ważne w sektorach takich jak handel detaliczny, produkcja i logistyka. Dzięki szybkiemu przetwarzaniu danych i zdolności do modelowania złożonych zależności między cechami, algorytm pozwala firmom na lepsze planowanie zapasów i optymalizację łańcuchów dostaw, co przekłada się na znaczące oszczędności i lepszą efektywność operacyjną.
- W branży e-commerce i mediach, gdzie personalizacja i odpowiednie dopasowanie treści do preferencji użytkownika są kluczowe, LightGBM jest wykorzystywany do tworzenia zaawansowanych systemów rekomendacji. Dzięki swojej zdolności do szybkiego uczenia się na dużych zbiorach danych, LightGBM może efektywnie

analizować wzorce zakupów i preferencji użytkowników, dostarczając trafne rekomendacje w czasie rzeczywistym (Liang *et al.*, 2019).

- LightGBM jest również stosowany w analizie sentymentu i innych aplikacjach NLP, gdzie jest potrzebna szybka i skuteczna klasyfikacja tekstów na podstawie ich treści emocjonalnej lub innych cech. Algorytm ten, dzięki swojej wydajności, radzi sobie z analizą dużych zbiorów danych tekstowych, co jest nieocenione w monitorowaniu mediów społecznościowych, analizach rynkowych czy w obszarze obsługi klienta (Lin, 2020).
- Chociaż LightGBM nie jest tradycyjnie kojarzony z przetwarzaniem obrazów, jego zdolności do szybkiego przetwarzania i analizy dużych ilości cech czynią go przydatnym narzędziem także w tej dziedzinie. Może być stosowany do wstępnej selekcji cech lub klasyfikacji w połączeniu z głębokimi sieciami neuronowymi, gdzie może służyć do wstępnych klasyfikacji lub jako część hybrydowego systemu przetwarzania obrazów (Gao *et al.*, 2019).
- W badaniach medycznych i bioinformatyce, gdzie analiza dużych ilości danych genetycznych i klinicznych jest konieczna, LightGBM pozwala na szybkie identyfikowanie wzorców i potencjalnych biomarkerów chorób. Jego zdolność do efektywnego modelowania złożonych zależności między cechami pozwala na lepsze zrozumienie mechanizmów chorób i potencjalne ścieżki leczenia (Wang, Zhang and Zhao, 2017).

LightGBM oferuje szeroki zakres zastosowań dzięki swojej wysokiej wydajności, efektywności i zdolności do radzenia sobie z dużymi i złożonymi zbiorami danych. Jego elastyczność i moc obliczeniowa sprawiają, że jest doskonałym narzędziem do rozwiązywania wielu zaawansowanych problemów analizy danych.

Random Forest

Random Forest (RF) to jeden z najpopularniejszych algorytmów uczenia maszynowego, szczególnie skuteczny w zadaniach klasyfikacji i regresji. Został wprowadzony przez Leo Breimana w 2001 roku i jest rozwinięciem klasycznego algorytmu drzew decyzyjnych (Rigatti, 2017). Jego główną zaletą jest zdolność do radzenia sobie z dużą liczbą zmiennych wejściowych, przy jednoczesnym minimalizowaniu problemu nadmiernego dopasowania (overfitting). Dzięki wykorzystaniu zespołu wielu drzew decyzyjnych (tzw. lasu), RF osiąga większą stabilność i dokładność predykcji niż pojedyncze drzewa decyzyjne, co czyni go dobrym narzędziem do analizy danych w zarządzaniu nieruchomościami komercyjnymi, gdzie dane są często złożone i zróżnicowane.

Podstawowe zasady działania algorytmu RF

Algorytm Random Forest działa na zasadzie "zespołowego uczenia" (ensemble learning), w którym wiele słabszych modeli, jakimi są drzewa decyzyjne, współpracuje, by stworzyć silniejszy model predykcyjny. Proces uczenia Random Forest opiera się na dwóch kluczowych technikach: losowym wyborze próbek danych oraz losowym wyborze zmiennych. Dzięki tym

technikom RF zwiększa różnorodność drzew w lesie, co prowadzi do bardziej stabilnych i precyzyjnych prognoz (Biau and Scornet, 2016).

1. Bagging (Bootstrap Aggregating):

Każde drzewo w lesie jest trenowane na innym losowym podzestawie danych. Ten proces nazywany jest próbkowaniem ze zamianą (bootstrap sampling). Pozwala to na stworzenie różnorodnych drzew, co zmniejsza ryzyko nadmiernego dopasowania modelu do jednej próbki danych.

2. Losowy wybór cech:

Podczas konstrukcji każdego drzewa, dla każdej decyzji o podziale (tzw. node), algorytm losowo wybiera podzestaw cech, na podstawie których wybiera najlepszy podział. To ograniczenie różnorodności cech używanych przez każde drzewo zwiększa odporność lasu na szumy i kolinearne cechy, a także zwiększa ogólną zdolność uogólniania modelu.

3. Agregacja wyników:

Po wygenerowaniu wielu drzew decyzyjnych, algorytm Random Forest dokonuje agregacji ich wyników. W zadaniach klasyfikacyjnych stosuje się głosowanie większościowe (każde drzewo głosuje na swoją klasę, a wynik końcowy to klasa, która uzyskała najwięcej głosów), natomiast w regresji obliczana jest średnia predykcji wszystkich drzew.

Zastosowanie Random Forest w zarządzaniu nieruchomościami komercyjnymi

W kontekście zarządzania nieruchomościami komercyjnymi, gdzie dane pochodzą z wielu różnorodnych źródeł, takich jak systemy automatyki budynkowej (BMS), systemy HVAC, monitoring zużycia energii czy systemy zabezpieczeń technicznych, algorytm Random Forest może odgrywać kluczową rolę w predykcji wielu zjawisk (Biau and Scornet, 2016).

1. Prognozowanie zużycia energii:

Random Forest może być używany do przewidywania zużycia energii na podstawie danych historycznych oraz informacji z sensorów dotyczących aktualnych warunków środowiskowych (np. temperatura zewnętrzna, wilgotność) oraz danych operacyjnych (np. liczba użytkowników, harmonogramy pracy). Dzięki zdolności RF do radzenia sobie z dużą liczbą cech oraz danych o zróżnicowanej skali, algorytm ten może skutecznie przewidywać przyszłe potrzeby energetyczne w nieruchomościach o różnych funkcjach (Oshiro, Perez and Baranauskas, 2012).

2. Predykcja awarii systemów technicznych:

Systemy takie jak HVAC, które są kluczowe dla komfortu termicznego, mogą podlegać awariom. Random Forest może zostać zastosowany do predykcji potencjalnych usterek na podstawie danych o historii pracy urządzeń, danych o zużyciu energii i wyników inspekcji technicznych. Dzięki agregacji wyników z wielu drzew, RF jest odporny na szumy i niekompletne dane, co jest częstym problemem w heterogenicznych systemach technicznych.

3. Optymalizacja kosztów operacyjnych:

W zarządzaniu rozproszonymi nieruchomościami komercyjnymi jednym z wyzwań jest optymalizacja kosztów operacyjnych. Random Forest może analizować dane historyczne związane z kosztami utrzymania oraz zużyciem mediów, by przewidywać, które nieruchomości wymagają interwencji serwisowej w najbliższym czasie. Algorytm może również wspierać proces podejmowania decyzji, wskazując, które działania serwisowe będą najbardziej opłacalne z punktu widzenia długoterminowej redukcji kosztów.

Zalety algorytmu Random Forest

Do podstawowych zalet algorytmu RF należą (Biau and Scornet, 2016; Rigatti, 2017):

1. Odporność na nadmierne dopasowanie (overfitting):

Dzięki wykorzystaniu technik baggingu i losowego wyboru cech, Random Forest jest mniej podatny na nadmierne dopasowanie do danych treningowych, co czyni go bardziej niezawodnym modelem predykcyjnym w sytuacjach, gdy dane są szumne lub zawierają dużo zmiennych.

2. Wsparcie dla dużych zestawów danych:

Algorytm RF radzi sobie z dużymi zestawami danych o wielu cechach, co jest szczególnie istotne w zarządzaniu rozproszonymi nieruchomościami komercyjnymi, gdzie dane pochodzą z różnych źródeł i mają zróżnicowaną strukturę.

3. Obsługa brakujących danych:

Random Forest radzi sobie dobrze z brakującymi danymi, co jest dużą zaletą w przypadku heterogenicznych zespołów nieruchomości, gdzie dane z różnych systemów mogą nie być kompletne.

4. Interpretowalność modelu:

Pomimo że RF jest zespołem wielu drzew decyzyjnych, wciąż można uzyskać pewien poziom interpretowalności modelu, analizując znaczenie poszczególnych cech. Algorytm dostarcza metryki "ważności cech", które pozwalają określić, które zmienne mają największy wpływ na wyniki modelu.

Ograniczenia Random Forest

Mimo licznych zalet, algorytm Random Forest ma pewne ograniczenia, które należy uwzględnić podczas jego implementacji (Parmar, Katariya and Patel, 2019):

1. Czas treningu i pamięć:

W przypadku bardzo dużych zestawów danych, trenowanie wielu drzew decyzyjnych może być czasochłonne i wymagać znacznych zasobów pamięciowych. Optymalizacja parametrów oraz wykorzystanie równoległego przetwarzania danych może jednak zmniejszyć te wymagania.

2. Brak predykcji poza zakresem:

Algorytm RF nie radzi sobie dobrze z przewidywaniem wartości wykraczających poza zakres danych treningowych. Oznacza to, że w sytuacjach, gdzie pojawiają się nowe, nietypowe wzorce, może być mniej efektywny.

Podsumowując, algorytm Random Forest może stanowić istotne narzędzie w zarządzaniu nieruchomościami komercyjnymi, zwłaszcza w kontekście analizy danych o dużej złożoności i różnorodności. Dzięki swojej odporności na overfitting, wsparciu dla dużych zestawów danych oraz zdolności do radzenia sobie z brakami danych, Random Forest może być bardzo efektywnym algorytmem do przewidywania zużycia energii, awarii systemów technicznych oraz optymalizacji kosztów operacyjnych. Wdrożenie tego algorytmu w ramach systemów wspomagania decyzji w nieruchomościach komercyjnych może przynieść znaczące korzyści ekonomiczne, operacyjne oraz poprawić efektywność zarządzania.

CatBoost

CatBoost to zaawansowany algorytm wzmacniania gradientowego stworzony przez firmę Yandex, zaprojektowany z myślą o efektywnym przetwarzaniu danych kategoryalnych. Wyróżnia się unikalnym podejściem do radzenia sobie z tego typu danymi, co czyni go bardzo skutecznym w praktycznych zastosowaniach, zwłaszcza tam, gdzie dane są nieustrukturyzowane lub zawierają liczne cechy kategoryalne. CatBoost jest ceniony za swoją wysoką wydajność, precyzję oraz prostotę w użyciu, co sprawia, że jest chętnie wybierany przez specjalistów zajmujących się analizą danych (Prokhorenkova *et al.*, 2018).

Dane kategoryalne stanowią wyzwanie w modelowaniu predykcyjnym, ponieważ nie mogą być bezpośrednio wykorzystane w algorytmach uczenia maszynowego w ich surowej, tekstowej postaci. Tradycyjne metody, takie jak one-hot encoding czy kodowanie liczbowe, często prowadzą do tworzenia bardzo dużych macierzy cech, co z kolei zwiększa ryzyko przeuczenia modelu. CatBoost rozwiązuje ten problem poprzez zastosowanie innowacyjnych technik, takich jak „ordered target statistics” (uporządkowane statystyki celu), które umożliwiają bardziej efektywne przetwarzanie danych kategoryalnych i minimalizują ryzyko błędów. Dla każdej cechy kategoryalnej, algorytm oblicza średnią wartości docelowej, ale w sposób zapobiegający przeuczeniu poprzez (Hancock and Khoshgoftaar, 2020):

- Zasady Liczenia:
- Statystyka Celu: dla każdej unikalnej wartości cechy kategoryalnej algorytm oblicza średnią wartości docelowej, z uwzględnieniem regularyzacji.
- Skrzyżowane Walidacje: aby uniknąć przeuczenia, CatBoost stosuje strategię podobną do walidacji krzyżowej podczas obliczania statystyk celu, przetwarzając dane w taki sposób, że każda obserwacja nie bierze pod uwagę własnej wartości docelowej w obliczeniach.

- Ordered Boosting:

- Tradycyjne algorytmy wzmacniania gradientowego mogą przeuczać się na danych treningowych, szczególnie przy obróbce danych kategoryalnych. CatBoost wprowadza technikę zwaną „ordered boosting”, która tworzy symulowane zestawy treningowe w każdej iteracji, aby zapobiec przeuczeniu.

CatBoost może również tworzyć nowe cechy poprzez łączenie informacji między różnymi cechami kategoryalnymi, co jest znane jako „cross feature target”. Pozwala to na efektywne tworzenie bardziej informatywnych cech, które pomagają modelowi w lepszym rozpoznawaniu wzorców (Dorogush, Ershov and Yandex, 2018).

CatBoost stosuje symetryczne drzewa decyzyjne, co odróżnia go od innych algorytmów gradient boosting. Symetryczne drzewa różnią się od asymetrycznych tym, że wszystkie poddrzewa w danym poziomie są dzielone na identycznej głębokości. Zalety tego podejścia to:

- Stabilność: Symetryczne drzewa są bardziej stabilne i przewidywalne, ponieważ każdy podział następuje na tej samej głębokości dla wszystkich liści. To zapewnia bardziej zbalansowany model i jest szczególnie ważne w przypadku niestabilnych cech kategoryalnych.
- Efektywność Obliczeniowa: Ze względu na jednolitą strukturę drzewa, algorytm może przyspieszyć proces wyszukiwania i optymalizacji punktów podziału, co skutkuje szybszym budowaniem modelu.
- Optymalizacja Pamięciowa: Symetryczne drzewa są bardziej efektywne pamięciowo, ponieważ ich struktura jest bardziej zwieszła, co pozwala na lepsze zarządzanie pamięcią podczas przetwarzania dużych zbiorów danych.

Jak wspomniano wcześniej, CatBoost stosuje technikę „ordered boosting” do kontrolowania przeuczenia podczas wzmacniania gradientowego. Pozwala to na wyeliminowanie wpływu wartości docelowych z danych treningowych na aktualizację modelu, zapobiegając nadmiernemu dopasowaniu.

CatBoost umożliwia regulację stopnia dopasowania modelu poprzez standaryzację L2 oraz funkcję kar za złożoność modelu. Pozwala to na kontrolowanie głębokości drzew, minimalnego spadku funkcji straty oraz minimalnej liczby próbek na liść, co ogranicza ryzyko przeuczenia. Ponadto CatBoost oferuje pełne wsparcie dla równoległego przetwarzania zarówno na CPU, jak i na GPU, co pozwala na przyspieszenie procesu treningu, szczególnie w przypadku dużych zbiorów danych. Optymalizacja na GPU jest kluczowa w przypadku dużych i złożonych zbiorów danych. CatBoost wykorzystuje biblioteki CUDA do przyspieszenia obliczeń. Algorytm efektywnie zarządza pamięcią poprzez kompresję danych, co jest kluczowe w kontekście obróbki dużych zbiorów danych o wysokiej wymiarowości (Prokhorenkova *et al.*, 2018).

Architektura CatBoost zapewnia wysoką wydajność, stabilność i precyzję predykcijną dzięki unikalnemu podejściu do obróbki danych kategoryalnych, zarządzania przeuczeniem i optymalizacji obliczeniowej. W rezultacie CatBoost jest atrakcyjnym wyborem w zastosowaniach analitycznych obejmujących duże zbiory danych o złożonej strukturze cech.

CatBoost oferuje szereg unikalnych zalet, które czynią go wyjątkowo skutecznym narzędziem w dziedzinie uczenia maszynowego, zwłaszcza w scenariuszach, które wymagają

efektywnego przetwarzania danych kategoryalnych oraz zapewnienia wysokiej dokładności i stabilności modelu. Kluczowe atuty tego algorytmu to:

- CatBoost jest znany z jego zdolności do generowania modeli o wysokiej dokładności predykcyjnej. Jego specjalistyczne podejście do danych kategoryalnych, w połączeniu z zaawansowanymi technikami zarządzania przeuczeniem, pozwala na osiąganie lepszych wyników niż tradycyjne algorytmy gradient boosting w wielu zadaniach przewidywania.
- Dzięki efektywnym algorytmom obliczeniowym i wsparciu dla przetwarzania równoległego na GPU, CatBoost jest w stanie szybko przetwarzać bardzo duże zbiory danych. To sprawia, że jest idealnym wyborem dla przedsięwzięć, które muszą radzić sobie z dużymi ilościami informacji w krótkim czasie, jak przetwarzanie danych w czasie rzeczywistym czy analizy big data.
- CatBoost wyróżnia się na tle innych frameworków ML dzięki swojej prostocie w implementacji i użyteczności. Posiada wbudowane procedury przetwarzania danych kategoryalnych, co eliminuje potrzebę stosowania zewnętrznych metod kodowania i wstępnego przetwarzania danych. Dzięki temu użytkownicy mogą szybko rozpocząć tworzenie modeli bez konieczności skomplikowanej preparacji danych (Ibrahim *et al.*, 2020).
- Jako jedyny z głównych algorytmów boostingowych, CatBoost oferuje innowacyjne podejście do przetwarzania danych kategoryalnych, co jest kluczowe w wielu aplikacjach biznesowych i naukowych, gdzie dane kategoryalne są powszechne. CatBoost automatycznie i efektywnie radzi sobie z kategoriami bez dodatkowej inżynierii cech, co zwykle jest wymagane w innych algorytmach (Ibrahim *et al.*, 2020).
- CatBoost zawiera zaawansowane mechanizmy kontroli przeuczenia, co jest szczególnie istotne w kontekście kompetencyjnych zadań modelowania, gdzie przeuczenie może znacząco wpłynąć na wydajność modelu. Techniki takie jak "ordered boosting" i "cross-validation" są integralną częścią algorytmu, pozwalając na tworzenie bardziej generalizujących modeli.

CatBoost, dzięki swoim unikalnym cechom i efektywności, znajduje zastosowanie w różnorodnych obszarach analitycznych, zarówno w przemyśle, jak i w badaniach naukowych. Jego zdolność do skutecznego przetwarzania danych kategoryalnych oraz wysoka dokładność predykcyjna sprawiają, że jest to algorytm wyjątkowo przydatny w wielu praktycznych aplikacjach. Poniżej zaprezentowano kilka kluczowych zastosowań CatBoost:

- Analiza Ryzyka Kredytowego: W sektorze bankowym i finansowym, CatBoost jest stosowany do oceny ryzyka kredytowego klientów. Algorytm analizuje historię kredytową, dane demograficzne i inne zmienne kategoryalne, aby przewidywać prawdopodobieństwo niewywiązania się z płatności. Dzięki swojej zdolności do efektywnego przetwarzania danych kategoryalnych, CatBoost pomaga instytucjom finansowym minimalizować ryzyko i maksymalizować zwrot z inwestycji (Barua *et al.*, 2021),
- Systemy Rekomendacji: CatBoost znajduje zastosowanie w e-commerce i systemach rekomendacji mediów, gdzie konieczna jest analiza dużych ilości danych o preferencjach użytkowników i ich interakcjach z produktami. Algorytm wykorzystuje te informacje do

tworzenia personalizowanych rekomendacji, które zwiększają zaangażowanie użytkowników i sprzedaż (Jagatheesaperumal *et al.*, 2023),

- Zarządzanie Łańcuchem Dostaw: W przemyśle logistycznym i produkcyjnym, CatBoost może być wykorzystywany do prognozowania popytu oraz optymalizacji zapasów i produkcji. Algorytm analizuje historyczne dane sprzedaży oraz zmienne zewnętrzne, takie jak sezony czy święta, dostarczając prognozy, które pomagają w lepszym planowaniu i zarządzaniu łańcuchem dostaw (Abed, 2024),
- Ochrona Zdrowia: W sektorze zdrowia, CatBoost jest stosowany do przewidywania wyników leczenia, analizy ryzyka chorób czy optymalizacji ścieżek terapeutycznych. Przetwarzanie danych klinicznych, w tym wyników badań, informacji demograficznych i historii medycznej, umożliwia tworzenie precyzyjnych modeli predykcyjnych, które wspierają decyzje kliniczne i poprawiają opiekę nad pacjentem (Dhananjay and Sivaraman, 2021),
- Badania Naukowe i Akademickie: CatBoost jest również szeroko stosowany w badaniach naukowych, gdzie jego zdolność do efektywnego modelowania zmiennych kategoryalnych i numerycznych sprawdza się w analizach danych biologicznych, behawioralnych czy ekonomicznych. Przykładem może być analiza danych genetycznych, gdzie CatBoost pomaga identyfikować markery związane z określonymi chorobami (Samat *et al.*, 2022),
- Detekcja Oszustw: CatBoost jest skutecznie wykorzystywany do detekcji oszustw w różnych branżach, od finansów po telekomunikację. Analizując wzorce transakcji i zachowania użytkowników, algorytm pomaga identyfikować podejrzane działania, minimalizując straty finansowe i zwiększając bezpieczeństwo systemów (Chen and Han, 2021).

Omawiany algorytm jest niezwykle wszechstronnym narzędziem, które dzięki swojej wydajności i precyzji znajduje zastosowanie w szerokiej gamie zastosowań przemysłowych i badawczych. Jego zdolność do efektywnego przetwarzania złożonych zbiorów danych, w tym danych kategoryalnych, czyni go cennym narzędziem każdego analityka.

Holt-Winters

Metoda Holta-Wintersa to zaawansowany model prognozowania szeregów czasowych, który rozwija koncepcję wygładzania eksponencjalnego poprzez dodanie dwóch dodatkowych składników: trendu i sezonowości. Pozwala to na bardziej kompleksowe i dokładne modelowanie danych, które wykazują zarówno zmiany w czasie (trendy), jak i regularne wzorce sezonowe (Koehler, Snyder and Ord, 2001). Rozważmy szczegółowo każdy z komponentów tego modelu:

Równanie poziomu odpowiada za aktualizację oszacowanego poziomu szeregu czasowego w każdym kolejnym punkcie czasowym. Jest to podstawowe równanie, które adaptuje model do aktualnych wartości danych, jednocześnie uwzględniając ostatni zauważony trend i składnik sezonowy. Matematycznie przedstawia się to następująco (Hansun *et al.*, 2019):

$$L_t = \alpha(y_t - S_{\{t-s\}}) + (1 - \alpha)(L_{\{t-1\}} + T_{\{t-1\}})$$

gdzie:

- L_t to oszacowany poziom na moment t ,
- α to współczynnik wygładzania dla poziomu,
- y_t to rzeczywista wartość szeregu w chwili t ,
- $S_{\{t-s\}}$ to składnik sezonowy z okresu odpowiadającego jednemu cyklowi sezonowemu przed chwilą t ,
- $T_{\{t-1\}}$ to oszacowany trend w poprzednim kroku.

Równanie trendu (Trend Equation) aktualizuje szacowany trend w szeregu czasowym. Trend może być rosnący, malejący lub stały, a odpowiednie dostosowanie tego składnika pozwala modelowi na adaptację do długoterminowych zmian w danych.

$$T_t = \beta(L_t - L_{\{t-1\}}) + (1 - \beta)T_{\{t-1\}}$$

gdzie:

- T_t to trend na moment t ,
- β to współczynnik wygładzania dla trendu.

Równanie sezonowości pozwala na modelowanie regularnie powtarzających się wzorców w danych, takich jak wzrost sprzedaży w okresie świątecznym lub tygodniowe cykle zakupowe.

$$S_t = \gamma(y_t - L_t) + (1 - \gamma)S_{\{t-s\}}$$

gdzie:

- S_t to składnik sezonowy na moment t ,
- γ to współczynnik wygładzania dla sezonowości,
- s to długość sezonu (np. 12 miesięcy w przypadku danych miesięcznych).

Model Holta-Wintersa generuje prognozy poprzez kombinację wyestymowanych składników poziomu, trendu i sezonowości na przyszłe okresy:

$$y_{\{t+m\}} = L_t + mT_t + S_{\{t-s+1+(m-1)\}}$$

gdzie m reprezentuje liczbę kroków czasowych do przodu, dla których generowana jest prognoza. Dzięki zastosowaniu tej metody, model może dostarczać bardzo precyzyjne prognozy dla danych wykazujących zarówno trend, jak i sezonowość, co czyni go efektywnym narzędziem w wielu zastosowaniach praktycznych.

Metoda Holta-Wintersa, jako rozbudowany model wygładzania eksponencjalnego, posiada zarówno swoje zalety, jak i wady, które wpływają na jej przydatność w różnych kontekstach analitycznych. Poniżej dokonano analizy tych aspektów, by przybliżyć, gdzie metoda ta sprawdza się najlepiej, a gdzie może napotkać trudności (Trull, García-Díaz and Troncoso, 2020).

- Metoda Holta-Wintersa jest szczególnie efektywna w modelowaniu danych wykazujących wyraźne wzorce sezonowe. Przez dodanie specyficznego składnika sezonowego do modelu, metoda potrafi dostosować prognozy do powtarzających się wzorców, co jest kluczowe w wielu zastosowaniach biznesowych i ekonomicznych.
- Dzięki trzem parametrom wygładzania (dla poziomu, trendu i sezonowości), metoda Holta-Wintersa pozwala na finezyjne dostosowanie modelu do specyfik danych. Użytkownik może kontrolować, jak szybko model reaguje na zmiany w każdym z tych aspektów, co pozwala na zbalansowanie między reaktywnością a stabilnością prognoz (Ferbar Tratar and Strmčnik, 2016).
- Metoda jest szczególnie użyteczna w krótkoterminowych prognozach, gdzie potrzebne jest szybkie i dokładne przewidywanie przyszłych wartości na podstawie znanych wzorców sezonowych i trendów.
- Metoda Holta-Wintersa może nie być efektywna, gdy w strukturze danych szeregów czasowych występują nagłe, nieoczekiwane zmiany (np. punkty odstające, zmiany strukturalne), które nie były obecne w danych historycznych. Modelowanie takich danych może prowadzić do nieadekwatnych prognoz.
- Aby skutecznie modelować sezonowość, metoda wymaga danych obejmujących wiele sezonów. W przypadku nowych serii danych, gdzie dostępna historia jest ograniczona, metoda może nie mieć wystarczającej ilości informacji do nauki wzorców sezonowych (J. Lu *et al.*, 2018).
- Mimo że metoda Holta-Wintersa jest mniej skomplikowana niż niektóre inne modele szeregów czasowych, jej implementacja i kalibracja, zwłaszcza przy doborze optymalnych parametrów wygładzania, może być trudniejsza niż w bardziej podstawowych metodach wygładzania.
- Model może czasami nadmiernie reagować na sezonowość, szczególnie gdy sezonowe wzorce nie są całkowicie regularne. To może prowadzić do nadmiernej korekty prognoz, szczególnie w danych z dużą wariancją lub nieregularnościami (Trull, García-Díaz and Troncoso, 2020).

Metoda Holta-Wintersa jest istotnym narzędziem analityka danych, szczególnie wartościowym w kontekstach, gdzie dane wykazują wyraźne i regularne wzorce sezonowe oraz trendowe. Jednak w przypadkach nieregularnych lub bardzo dynamicznie zmieniających się danych, konieczne może być zastosowanie bardziej zaawansowanych lub elastycznych metod analizy szeregów czasowych.

Metoda Holta-Wintersa, ze względu na swoją zdolność do skutecznego modelowania danych z wyraźnymi trendami i wzorcami sezonowymi, znajduje szerokie zastosowanie w wielu dziedzinach. Jej unikalna struktura, która obejmuje zarówno trend, jak i sezonowość, czyni ją idealnym narzędziem do prognozowania w kontekstach, gdzie takie wzorce są kluczowe. Oto kilka przykładów praktycznych zastosowań tej metody (Ferbar Tratar and Strmčnik, 2016):

- Prognozowanie Popytu w Handlu Detalicznym: W sektorze detalicznym, metoda Holta-Wintersa jest wykorzystywana do prognozowania sprzedaży produktów. Można ją zastosować do planowania zapasów, zarządzania promocjami i

optymalizacji łańcucha dostaw, szczególnie w przypadkach sezonowych wzrostów sprzedaży, jak okresy świąteczne czy letnie wyprzedaże.

- Zarządzanie Łańcuchem Dostaw: Firmy produkcyjne i logistyczne używają metody Holta-Wintersa do prognozowania zapotrzebowania na materiały i produkty gotowe. Przewidywanie fluktuacji popytu pozwala na lepsze zarządzanie zapasami, minimalizację kosztów magazynowania oraz zapobieganie brakom w dostawach.
- Sektor Energetyczny: Prognozowanie zużycia energii jest kluczowe dla firm energetycznych, które muszą równoważyć popyt z produkcją, aby zapewnić ciągłość dostaw i optymalizację kosztów. Metoda Holta-Wintersa jest używana do przewidywania wzorców zużycia energii w różnych porach roku, co umożliwia efektywne planowanie i reagowanie na zmieniające się warunki rynkowe.
- Planowanie Turystyczne i Hotelarstwo: Branża turystyczna wykorzystuje tę metodę do prognozowania liczby odwiedzających i rezerwacji hotelowych, co jest szczególnie ważne w okresach szczytowego popytu. To pozwala na optymalizację cen i promocji, zarządzanie personelem oraz przygotowanie odpowiednich zasobów.
- Telekomunikacja: Firmy telekomunikacyjne stosują metodę Holta-Wintersa do przewidywania wzorców ruchu w sieciach, co pomaga w zarządzaniu przepustowością i infrastrukturą sieciową. Prognozowanie wzrostu ruchu pozwala na zaplanowanie rozbudowy sieci oraz efektywne zarządzanie zasobami.
- Usługi Publiczne i Administracja: W sektorze publicznym, metoda Holta-Wintersa może być wykorzystywana do prognozowania dochodów z podatków, które często wykazują sezonowe wzorce. Również w planowaniu miejskim, prognozy te mogą pomóc w alokacji zasobów i usług zgodnie z oczekiwanym zapotrzebowaniem.

Metoda Holta-Wintersa jest niezwykle przydatnym narzędziem w różnorodnych branżach, gdzie dane wykazują sezonowe zmienności. Jej zdolność do precyzyjnego modelowania zarówno trendów, jak i sezonowości sprawia, że jest to preferowana metoda do krótko- i średnioterminowych prognoz w dynamicznych środowiskach.

SARIMA

Metoda SARIMA, czyli Seasonal Autoregressive Integrated Moving Average, jest rozbudowaną wersją modelu ARIMA, która dodatkowo uwzględnia sezonowość w danych. Model SARIMA jest bardzo użyteczny w analizie szeregów czasowych, które wykazują zarówno niestacjonarność jak i sezonowe wzorce (Williams and Hoel, 2003).

Struktura modelu SARIMA jest zdefiniowana przez zestaw parametrów $(p, d, q) \times (P, D, Q, S)$, gdzie:

- p: liczba opóźnień wykorzystanych w komponencie autoregresji (AR),
- d: stopień różnicowania potrzebny do osiągnięcia stacjonarności szeregu,
- q: rozmiar okna średniej ruchomej (MA),
- P: liczba opóźnień w sezonowym komponencie autoregresji,
- D: stopień sezonowego różnicowania,
- Q: rozmiar okna sezonowej średniej ruchomej,

- S: długość sezonu.

Model SARIMA skupia się na kilku głównych równaniach, które razem opisują jak szereg czasowy jest modelowany:

Model Autoregresyjny (AR):

Model AR opisuje obecną wartość szeregu czasowego jako liniową kombinację jego poprzednich wartości. Jest to wyrażane przez:

$$\Phi(B)y_t = a_t$$

gdzie $\Phi(B)$ jest wielomianem autoregresji stopnia p, B oznacza operator przesunięcia wstecz, a (a_t) jest białym szumem.

Różnicowanie jest techniką stosowaną do uzyskania stacjonarności szeregu czasowego, co jest kluczowe dla modelowania ARIMA. Różnicowanie polega na odejmowaniu obecnej wartości szeregu od jego poprzedniej wartości:

$$(1 - B)^d y_t$$

gdzie d jest stopniem różnicowania.

Model Średniej Ruchomej (MA):

Model MA opisuje błąd obecnej prognozy jako kombinację błędów poprzednich prognoz:

$$\Theta(B)a_t = y_t$$

gdzie $\Theta(B)$ jest wielomianem średniej ruchomej stopnia q.

Sezonowe składniki SARIMA są analogiczne do niesezonowych, ale stosowane są na danych przesuniętych o S okresów:

- Sezonowy Model Autoregresyjny (SAR):

$$\Phi_P(B^S)y_t$$

gdzie Φ_P jest sezonowym wielomianem autoregresji stopnia P.

- Sezonowa Integracja SI:

$$(1 - B^S)^D y_t$$

gdzie D to stopień sezonowego różnicowania.

- Sezonowy Model Średniej Ruchomej (SMA):

$$\Theta_Q(B^S)a_t = y_t$$

gdzie Θ_Q jest sezonowym wielomianem średniej ruchomej stopnia Q.

Aby wygenerować prognozy, SARIMA łączy wszystkie powyższe elementy, modelując szereg czasowy jako funkcję swoich przeszłych wartości, błędów prognoz, a także ich sezonowych odpowiedników. Proces prognozowania z SARIMA wykorzystuje dopasowany model do estymacji przyszłych wartości na podstawie historii szeregu.

SARIMA jest zaawansowanym narzędziem do analizy i prognozowania szeregów czasowych, które wykazują zarówno sezonowe, jak i niestacjonarne właściwości. Zapewnia ona elastyczne podejście do modelowania złożonych danych czasowych, umożliwiając

analitykom precyzyjne prognozowanie w wielu praktycznych zastosowaniach (Fang and Lahdelma, 2016).

Metoda SARIMA (Seasonal Autoregressive Integrated Moving Average) jest jednym z najbardziej popularnych i skutecznych narzędzi stosowanych do analizy i prognozowania szeregów czasowych, które charakteryzują się zarówno sezonowością, jak i niestacjonarnością. Mimo swojej wszechstronności, metoda SARIMA posiada zarówno znaczące zalety, jak i pewne ograniczenia (Nobre *et al.*, 2001).

Do powszechnie wskazywanych w literaturze zalet metody SARIMA możemy zaliczyć:

- Kompleksowa Analiza Danych: SARIMA jest zdolna do modelowania szeregów czasowych z zarówno trendami, jak i sezonowością, co sprawia, że jest niezwykle użyteczna w szerokim zakresie zastosowań praktycznych. Możliwość dostosowania modelu do specyficznych charakterystyk danych pozwala na bardzo dokładne prognozy.
- Elastyczność: Model SARIMA pozwala na elastyczne dopasowanie do różnych typów danych szeregów czasowych, dzięki możliwości konfiguracji różnych stopni różnicowania, autoregresji i średniej ruchomej, zarówno w skali sezonowej, jak i niesezonowej.
- Mocne Podstawy Teoretyczne: Model SARIMA opiera się na solidnych podstawach statystycznych, co zapewnia jego wiarygodność w kontekście naukowym i profesjonalnym.

Spośród wad wskazywanych w literaturze przedmiotu warto przywołać:

- Złożoność modelu: Wybór odpowiednich parametrów dla modelu SARIMA (p , d , q , P , D , Q , S) może być skomplikowany i czasochłonny. Wymaga to często iteracyjnego testowania i walidacji, co może być trudne dla osób bez głębokiej wiedzy statystycznej.
- Wrażliwość na zmiany w danych: SARIMA najlepiej działa, gdy szereg czasowy jest stosunkowo stabilny i wykazuje regularne wzorce sezonowe i trendowe. Nagłe zmiany strukturalne lub punkty odstające mogą znacznie wpłynąć na wydajność modelu.
- Duże zapotrzebowanie na dane: Skuteczne wykorzystanie SARIMA wymaga dostępności dużych ilości danych historycznych, co może być ograniczeniem w przypadku nowych szeregów czasowych lub takich, które są rzadko próbkowane.
- Zapotrzebowanie obliczeniowe: Bardziej złożone modele SARIMA, szczególnie te z wieloma parametrami sezonowymi i nie sezonowymi, mogą wymagać znacznych zasobów obliczeniowych, co może być wyzwaniem w środowiskach z ograniczoną mocą przetwarzania.

Mimo tych wyzwań, SARIMA pozostaje jednym z najbardziej efektywnych narzędzi do analizy szeregów czasowych, szczególnie tam, gdzie występują wyraźne wzorce sezonowe. W praktyce, sukces w zastosowaniu SARIMA zależy od starannego dobierania modelu, testowania i dostosowania do konkretnych danych i kontekstu, w którym jest stosowany. Analitycy muszą również być świadomi potencjalnych pułapek i przygotowani na intensywne prace związane z kalibracją modelu, aby osiągnąć najlepsze możliwe wyniki. Metoda SARIMA jest niezwykle użyteczna w wielu dziedzinach, które polegają na analizie i prognozowaniu szeregów czasowych. Jej zdolność do modelowania zarówno niestacjonarności jak i sezonowości sprawia, że jest to narzędzie o szerokim zastosowaniu praktycznym. Oto kilka

przykładów, gdzie metoda SARIMA znajduje swoje zastosowanie (Library and Valipour, 2015):

- Prognozowanie Popytu w Handlu Detalicznym: SARIMA jest szeroko stosowana do prognozowania sprzedaży produktów, zwłaszcza w branżach, gdzie istotne są sezonowe wzorce sprzedażowe. Detaliści używają SARIMA do planowania zapasów, zarządzania promocjami i optymalizacji zakupów, szczególnie w okresach o zwiększonym popycie, takich jak święta czy okresy szkolne.
- Analiza Ruchu i Transportu: W transporcie publicznym oraz zarządzaniu ruchem drogowym, SARIMA pomaga w prognozowaniu wzorców ruchu, co jest kluczowe dla planowania potrzeb infrastrukturalnych i optymalizacji harmonogramów. Modelowanie ruchu pasażerskiego pozwala na lepsze zarządzanie flotą i ograniczenie opóźnień.
- Sektor Energetyczny: W energetyce, SARIMA jest używana do prognozowania popytu na energię. Precyzyjne przewidywanie szczytów i dołków w zapotrzebowaniu na energię pomaga firmom energetycznym w optymalizacji produkcji, redukcji kosztów oraz zarządzaniu zasobami energii odnawialnej.
- Zarządzanie Finansami i Ekonomia: SARIMA jest również cenna w finansach, gdzie służy do prognozowania wskaźników ekonomicznych, takich jak inflacja, stopy bezrobocia czy kursy walut. Takie modele pozwalają analitykom i decydom lepiej rozumieć przyszłe tendencje rynkowe i podejmować bardziej świadome decyzje.
- Meteorologia i Badania Środowiskowe: W meteorologii, SARIMA jest wykorzystywana do prognozowania warunków pogodowych, takich jak opady czy temperatury. Modelowanie tych zjawisk z wyprzedzeniem jest niezwykle ważne nie tylko dla codziennego planowania, ale też w kontekście zarządzania kryzysowego i reagowania na klęski żywiołowe.
- Zarządzanie Zasobami Wodnymi: SARIMA może służyć do prognozowania poziomów wód w rzekach i zbiornikach, co ma kluczowe znaczenie dla zarządzania zasobami wodnymi, planowania irygacji w rolnictwie oraz prewencji powodzi.

Podsumowując, metoda SARIMA jest wszechstronnym narzędziem, które znajduje zastosowanie w różnorodnych dziedzinach wymagających skutecznych prognoz szeregów czasowych. Jej zdolność do dostosowania się do danych charakteryzujących się niestacjonarnością oraz sezonowością czyni ją niezastąpioną w wielu krytycznych i operacyjnych zastosowaniach.

Sieci Neuronowe: DNN, RNN, LSTM

Sieci neuronowe to zaawansowane modele uczenia maszynowego, które naśladują sposób działania ludzkiego mózgu w celu rozpoznawania wzorców i wykonywania zadań na podstawie danych. Istnieje kilka rodzajów sieci neuronowych, z których każda ma specyficzne zastosowania i charakterystyki. Trzy z nich – głębokie sieci neuronowe (DNN), rekurencyjne sieci neuronowe (RNN) i długoterminowe sieci pamięci krótkotrwałej (LSTM) – są szczególnie popularne w różnych dziedzinach uczenia maszynowego.

Głębokie Sieci Neuronowe (DNN)

Struktura i działanie:

Głębokie sieci neuronowe (DNN, Deep Neural Networks) składają się z wielu warstw neuronów, z których każda przetwarza wejście otrzymane z poprzedniej warstwy, dokonując coraz to bardziej skomplikowanych transformacji danych (Mittal, 2020). Struktura DNN zazwyczaj obejmuje trzy główne rodzaje warstw (Zhang *et al.*, 2016):

- Warstwa wejściowa: Odpowiada za przyjęcie wejścia do sieci. W przypadku przetwarzania obrazów może to być surowy piksel obrazu, w przypadku danych tekstowych mogą to być zakodowane słowa lub znaki.
- Warstwy ukryte: Wiele warstw ukrytych, gdzie każda wykonuje określone przekształcenia matematyczne za pomocą ważonych połączeń i funkcji aktywacji, takich jak ReLU lub sigmoid. Warstwy te tworzą „głęboką” sieć, umożliwiającą naukę coraz bardziej złożonych reprezentacji danych wejściowych.
- Warstwa wyjściowa: Generuje wynik przetwarzania, który może reprezentować klasy w zadaniach klasyfikacji, ciągłe wartości w regresji czy kolejny element sekwencji w problemach sekwencyjnych.

Proces uczenia DNN:

Uczenie DNN odbywa się przez procedurę zwaną propagacją wsteczną (backpropagation), która wykorzystuje algorytm optymalizacyjny, zazwyczaj stochastyczny spadek gradientu (SGD), do aktualizacji wag sieci w taki sposób, aby minimalizować różnice między predykcjami sieci a rzeczywistymi wartościami wyjściowymi (przykładowo za pomocą funkcji straty jak błąd średniokwadratowy czy entropia krzyżowa) (Mittal, 2020).

Zastosowania DNN:

- Rozpoznawanie obrazów: DNN są fundamentem nowoczesnych systemów rozpoznawania obrazów, stosowanych w autonomicznych pojazdach, systemach rozpoznawania twarzy i automatycznej analizie medycznej.
- Przetwarzanie języka naturalnego (NLP): Sieci DNN, zwłaszcza te połączone z architekturami rekurencyjnymi lub konwolucyjnymi, są używane do tłumaczenia maszynowego, generowania tekstów i rozumienia mowy (Parashar *et al.*, 2019).

Wyzwania i ograniczenia DNN:

- Nadmierne dopasowanie (overfitting): Bez odpowiednich technik regularyzacji, takich jak dropout czy wcześniejsze zatrzymanie (early stopping), DNN mogą "nauczyć się na pamięć" danych treningowych, tracąc zdolność do generalizacji na nowe dane.
- Zapotrzebowanie na dane: DNN zazwyczaj wymagają dużych ilości danych treningowych do efektywnego nauczenia, co może być ograniczeniem w aplikacjach z ograniczonym dostępem do danych.
- Interpretowalność: Warstwowa i złożona natura DNN może utrudniać zrozumienie i interpretację działania modelu, co jest wyzwaniem w dziedzinach wymagających przejrzystości decyzji, takich jak medycyna czy finanse.

DNN to zaawansowane narzędzia zdolne do modelowania skomplikowanych wzorców w dużych zbiorach danych. Ich efektywność sprawia, że znajdują one zastosowanie w wielu dziedzinach, od automatyzacji po zaawansowane analizy naukowe (Parashar *et al.*, 2019).

Rekurencyjne Sieci Neuronowe (RNN)

Rekurencyjne sieci neuronowe (RNN) to klasa sieci neuronowych specjalnie zaprojektowana do pracy z sekwencjami danych. Unikalna cecha RNN polega na ich zdolności do przechowywania informacji o przeszłości, co jest realizowane poprzez pętle zwrotne, które pozwalają informacjom przepływać od jednego kroku do kolejnego. To sprawia, że RNN są idealne do zastosowań, gdzie kontekst sekwencji jest istotny, takich jak przetwarzanie języka naturalnego czy analiza serii czasowych (Sherstinsky, 2020).

Podobnie jak DNN, RNN uczą się przez propagację wsteczną, ale z dodatkiem „propagacji w czasie” (backpropagation through time, BPTT), która rozważa nie tylko bieżące, ale także poprzednie stany sieci do aktualizacji wag. Ten proces jest kluczowy dla zachowania kontinuum w sekwencji danych. Istnieje kilka ważnych odmian RNN, które zmniejszają niektóre z ich ograniczeń, takie jak LSTM (Long Short-Term Memory) i GRU (Gated Recurrent Units). Te modele wprowadzają bramki kontrolujące przepływ informacji, co pozwala im lepiej radzić sobie z problemami długoterminowych zależności (Sherstinsky, 2020).

Do zastosowań DNN możemy zaliczyć (Li *et al.*, 2018):

- Przetwarzanie języka naturalnego (NLP): RNN są używane do zadań takich jak tłumaczenie maszynowe, rozpoznawanie mowy i generowanie tekstu, gdzie zdolność do analizy i generowania danych sekwencyjnych jest kluczowa.
- Analiza serii czasowych: W finansach, meteorologii i innych dziedzinach naukowych, RNN służą do prognozowania przyszłych wartości na podstawie historycznych danych.
- Synteza muzyki: RNN mogą generować muzykę, ucząc się struktury i rytmu z istniejących utworów muzycznych.

Wyzwania i ograniczenia RNN (Yin *et al.*, 2017):

- Problem znikającego gradientu: W tradycyjnych RNN, gradient używany do aktualizacji wag może zanikać (lub eksplodować), co utrudnia uczenie w przypadku długich sekwencji danych. To ograniczenie jest częściowo adresowane przez wspomniane warianty, takie jak LSTM i GRU.
- Złożoność obliczeniowa: Uczenie RNN, zwłaszcza na długich sekwencjach, może być obliczeniowo kosztowne i czasochłonne.
- Potrzeba dużych zbiorów danych: Podobnie jak inne modele głębokiego uczenia, skuteczne zastosowanie RNN wymaga dużych ilości danych treningowych, co może być barierą w niektórych zastosowaniach.

RNN oferują zaawansowane możliwości modelowania sekwencji danych, ale wymagają starannego projektowania i intensywnych obliczeń. Ich zdolność do przechowywania informacji w czasie sprawia, że są one nieocenione w aplikacjach, które zależą od kontekstu i historii danych.

Sieć długiej pamięci krótkotrwałej (LSTM)

Sieć długiej pamięci krótkotrwałej, znana jako LSTM (Long Short-Term Memory), to specjalny rodzaj rekurencyjnych sieci neuronowych (RNN) zaprojektowanych do rozwiązywania problemu znikającego gradientu, z którym borykają się standardowe RNN. LSTMs są wyposażone w strukturę składającą się z bramek: bramki wejściowej, bramki zapomnienia i bramki wyjściowej. Te bramki regulują przepływ informacji, pozwalając na efektywne zachowanie i zapominanie informacji przez dłuższy czas, co jest kluczowe dla zadań wymagających zrozumienia długoterminowych zależności w danych (Huang *et al.*, 2015).

- Bramka wejściowa: decyduje o tym, które informacje zostaną przechowane w stanie komórki.
- Bramka zapomnienia: pozwala sieci "zapomnieć" nieistotne informacje z przeszłości, co pomaga w utrzymaniu skuteczności modelu na dłuższe sekwencje.
- Bramka wyjściowa: kontroluje, które informacje ze stanu komórki zostaną przekazane do kolejnych warstw sieci.

Dzięki temu mechanizmowi, LSTM są w stanie uczyć się i przewidywać na podstawie bardzo długich sekwencji danych bez utraty ważnych informacji.

Zastosowania LSTM są następujące (Smagulova and James, 2019):

- Przetwarzanie języka naturalnego (NLP): LSTM znajdują zastosowanie w wielu zadaniach NLP, takich jak tłumaczenie maszynowe, generowanie tekstu i analiza sentymentu, gdzie zdolność do zapamiętywania długoterminowych kontekstów jest niezbędna.
- Przewidywanie serii czasowych: W dziedzinach takich jak finanse, meteorologia czy prognozowanie popytu, LSTM są stosowane do modelowania i przewidywania danych czasowych z uwzględnieniem długoterminowych trendów i cykli.
- Rozpoznawanie mowy: W technologiach rozpoznawania i generowania mowy, LSTM pomagają modelować skomplikowane zależności w danych audio, co jest kluczowe dla naturalnego brzmienia i zrozumienia mowy.

Wyzwania i ograniczenia LSTM (Yu *et al.*, 2019):

- Złożoność obliczeniowa: LSTM są bardziej skomplikowane niż standardowe RNN, co czyni je bardziej wymagającymi obliczeniowo, szczególnie przy dużych zbiorach danych.
- Zapotrzebowanie na zasoby: Efektywne trenowanie modeli LSTM wymaga dostępu do odpowiednich zasobów obliczeniowych, takich jak GPU, co może zwiększać koszty i ograniczenia infrastrukturalne.
- Dobór parametrów: Podobnie jak w przypadku innych sieci neuronowych, odpowiedni dobór hiperparametrów (takich jak liczba warstw, liczba jednostek w warstwach, szybkość uczenia) jest kluczowy dla osiągnięcia optymalnej wydajności modelu, co może być czasochłonne i wymaga eksperymentowania.

Podsumowując, LSTM są niezwykle skutecznym narzędziem w dziedzinie uczenia maszynowego, oferującym zaawansowane możliwości modelowania sekwencji danych

z uwzględnieniem długoterminowych zależności. Ich zdolność do przetwarzania i zachowania informacji na długi czas sprawia, że znajdują one zastosowanie w wielu zaawansowanych aplikacjach analizy danych.

Facebook Prophet

Facebook Prophet to nowoczesne narzędzie do prognozowania szeregów czasowych, które zostało opracowane przez zespół badawczy Facebooka. Jest to biblioteka open-source przeznaczona do analizy i prognozowania danych czasowych, szczególnie tych o silnej sezonowości i wielu brakujących wartościach. Prophet jest szczególnie użyteczny w aplikacjach biznesowych, gdzie szybkie i dokładne prognozy są kluczowe, takich jak prognozowanie produktów, zapotrzebowania na usługi czy ruchu internetowego (Daraghme *et al.*, 2021).

Prophet używa addytywnego modelu, gdzie nieliniowe trendy są dopasowywane do rocznej, tygodniowej i dziennej sezonowości, a także do efektów świąt i wydarzeń specjalnych. Model składa się z następujących komponentów (Toharudin *et al.*, 2023):

- Trend: Prophet automatycznie wybiera między modelem liniowym a logistycznym wzrostu, gdzie model logistyczny jest użyteczny w przypadkach, gdy istnieją ograniczenia lub nasycenie rynku.
- Sezonowość: Model wykorzystuje rozbudowaną funkcję Fouriera do elastycznego modelowania skomplikowanych wzorców sezonowych. Pozwala to na dokładne uwzględnienie zmienności w danych, które mają różne amplitudy w zależności od okresu roku.
- Święta i wydarzenia: Prophet pozwala na specyfikację dat świąt i innych wydarzeń, które mogą wpływać na obserwowane zjawiska, umożliwiając modelowi uwzględnienie tych jednorazowych zmian w danych.

Do niewątpliwych zalet algorytmu możemy zaliczyć:

- Łatwość użycia: Jedną z głównych zalet Prophet jest jego prostota w użyciu, nawet dla osób bez głębokiej wiedzy statystycznej. Dostarcza on intuicyjnych i elastycznych API w Pythonie i R.
- Automatyczna detekcja zmian punktów (change points): Prophet automatycznie wykrywa i dostosowuje się do zmian w trendach, co jest przydatne w dynamicznie zmieniających się środowiskach.
- Obsługa brakujących danych: Prophet radzi sobie z brakami w danych bez konieczności manualnego uzupełniania lub usuwania tych danych.
- Skalowalność: Dzięki efektywnej implementacji, Prophet jest zdolny do szybkiego przetwarzania dużych zbiorów danych.

Wady algorytmu to:

- Mniej skuteczny w danych o wysokiej częstotliwości: Prophet może nie być idealny dla danych rejestrowanych co minuty lub sekundy, gdzie modelowanie sezonowości staje się bardziej złożone.

- Ograniczona kontrola nad modelem: Chociaż Prophet jest łatwy w użyciu, oferuje mniejszą kontrolę nad szczegółami modelu w porównaniu do bardziej zaawansowanych technik, takich jak SARIMA.

Do najczęstszych praktycznych zastosowań algorytmu FP możemy zaliczyć (Daraghmeah *et al.*, 2021; Sivaramakrishnan *et al.*, 2021):

Planowanie biznesowe: - Prophet jest często stosowany do prognozowania popytu na produkty, co pomaga firmom w optymalizacji zapasów i planowaniu produkcji.

Analiza ruchu internetowego: - Firmy technologiczne używają Prophet do prognozowania wzorców ruchu na stronach internetowych, co pozwala na lepszą optymalizację zasobów serwerowych i planowanie kampanii marketingowych.

Finanse i ekonomia: - W sektorze finansowym, Prophet może być wykorzystywany do analizy i prognozowania wskaźników ekonomicznych, cen akcji czy walut, co jest kluczowe dla inwestorów i analityków finansowych.

Podsumowując, Facebook Prophet stanowi zaawansowane, a zarazem użyteczne narzędzie do analizy i prognozowania szeregów czasowych, które jest szczególnie przydatne w środowiskach biznesowych, gdzie szybkie i precyzyjne prognozy mają bezpośredni wpływ na decyzje operacyjne i strategiczne.

2.8. Mierniki jakości predykcji

Istnieje wiele sposobów określenia dokładności otrzymanej prognozy z rzeczywistym wynikiem.

Metryki przedstawione poniżej stanowią literaturę i standard branżowy służący do oceny jakości i efektywności algorytmów uczenia maszynowego i (Botchkarev, 2018). Pozwalają one na ocenę stopnia zbieżności przewidywanych danych z danymi w zbiorze testowym.

Dla ciągłych danych wejściowych niezbędna jest wiedza dla oceny różnicy pomiędzy przewidywaną prawdziwą informacją, a rzeczywiście prawdziwą.

Dla oceny modeli regresji stosowane są najczęściej Metryki (Botchkarev, 2018):

- Błąd średniokwadratowy (MSE),
- Średni błąd bezwzględny (MAE);
- Błąd średniokwadratowy (RMSE)
- R^2 (R-kwadrat)

Błąd średniokwadratowy (MSE) - oblicza się, biorąc średnią z kwadratów różnic między wartościami obserwowanymi i przewidywanymi. Pozwala on na (Chicco, Warrens and Jurman, 2021) oszacowanie średniego błędu przewidywania modelu. Im niższa wartość MSE, tym lepsze dopasowanie modelu. MSE jest popularną metodą oceny dokładności i precyzji modeli statystycznych.

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2$$

Gdzie:

- y_j – wartość obserwowana

- \check{y}_j – wartość predykowana
- N - całkowita liczba obserwacji

Średni błąd bezwzględny MAE (Mean Absolute Error) - mierzy średnią bezwzględną różnicę między wartościami przewidywanymi i obserwowanymi. Stanowi miarę średniej wielkości błędów, niezależnie od ich kierunku. MAE jest przydatne, gdy nacisk kładziony jest na wielkość błędów, a nie na ich kierunek (Wang and Lu, 2018).

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

Gdzie:

- y_i – wartość przewidywana
- x_i – wartość obserwowana
- n - całkowita liczba obserwacji

RMSE (Root Mean Squared Error) – jest pierwiastkiem kwadratowym średniego błędu bezwzględnego. Zapewnia oszacowanie średniego błędu przewidywania, podobnego do MSE, ale w oryginalnej skali danych. RMSE jest szeroko stosowany w różnych dziedzinach, w tym w analizie regresji, analizie szeregów czasowych i uczeniu maszynowym (Wang and Lu, 2018).

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

Gdzie:

- y_i – wartość przewidywana
- x_i – wartość rzeczywista
- n - całkowita liczba obserwacji

MAPE (Mean Absolute Percentage Error) – jest to suma błędów bezwzględnych podzielona przez sumę rzeczywistej wartości. Aby wynik był skalowalny, wartości podawane są w procentach (Chicco, Warrens and Jurman, 2021).

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

Gdzie:

- N – liczba obserwacji, czyli ilość prognozowanych wartości (lub punktów danych).
- A_i – rzeczywista wartość dla obserwacji ii (faktyczny wynik).
- F_i – prognozowana wartość dla obserwacji ii (wynik przewidywany przez model).
- $\left| \frac{A_i - F_i}{A_i} \right|$ – bezwzględna różnica między rzeczywistą a prognozowaną wartością, wyrażona jako stosunek do rzeczywistej wartości. Wyrażenie to pozwala zmierzyć błąd jako odsetek od rzeczywistej wartości.

MAPE sumuje te błędy dla wszystkich NN obserwacji, a następnie dzieli przez liczbę obserwacji, aby uzyskać średni procentowy błąd. Wartość jest zwykle podawana w procentach, co umożliwia porównywanie wyników między różnymi zestawami danych.

Metryka R^2 – wartość mieści się w zakresie od 0 do 1, przy czym wyższa wartość wskazuje na lepsze dopasowanie modelu do danych.

Wzór na obliczenie R^2 jest następujący:

$$R^2 = 1 - \frac{\sum_{j=1}^N (y_j - \hat{y}_j)^2}{\sum_{j=1}^N (\bar{y}_j - \hat{y}_j)^2}$$

Gdzie:

$\sum_{j=1}^N (y_j - \hat{y}_j)^2$ - błąd średniokwadratowy przewidywań w stosunku do wartości rzeczywistych,

$\sum_{j=1}^N (\bar{y}_j - \hat{y}_j)^2$ - błąd średniokwadratowy przewidywania średniej w stosunku do wartości rzeczywistych

2.9. Podsumowanie

Zintegrowane systemy zdalnego monitorowania odgrywają istotną rolę w akwizycji danych niezbędnych do funkcjonowania zaprojektowanego systemu wspomaganie decyzji (DSS) w obszarze konserwacji predykcyjnej. Dzięki temu możliwe jest budowanie świadomości sytuacyjnej na temat stanu urządzeń oraz wspomaganie decyzji dotyczących ich optymalnego utrzymania.

Dokonana analiza różnych podejść do konserwacji predykcyjnej pozwoliła na zaproponowanie systemu wspomaganie decyzji, który został zaprojektowany z myślą o organizacjach posiadających wielodomenowe i niejednorodne parki technologiczne, napotykających trudności w skutecznym monitorowaniu oraz analizowaniu dużych wolumenów danych pochodzących z różnych urządzeń. W niniejszej pracy opracowano system, który umożliwia wybór najbardziej odpowiedniego algorytmu predykcyjnego w zależności od charakterystyki danych. Zamiast ograniczać się do jednego algorytmu, jak Gradient Boosting Machines (GBM), system ten oferuje standaryzację analizy danych oraz dopasowanie algorytmów do specyficznych potrzeb, co zapewnia lepsze wyniki predykcyjne oraz optymalne dostosowanie do kontekstu danych i infrastruktury technicznej.

Kluczowym elementem zaprezentowanego systemu jest jego zdolność do elastycznego wyboru algorytmów predykcyjnych, takich jak GBM, sieci neuronowe, SARIMA, Holt-Winters czy Facebook Prophet. Pozwala to na uzyskanie bardzo dobrych wyników w zależności od rodzaju danych i potrzeb operacyjnych. Standaryzacja procesów analitycznych oraz dopasowanie algorytmów do charakterystyki danych zwiększa skuteczność konserwacji

predykcijnej, przyczyniając się do minimalizacji przestoju i awarii oraz zwiększenia niezawodności infrastruktury.

Wnioski płynące z przeprowadzonej analizy stanowią istotny przyczynek do budowy omawianego systemu wspomagania decyzji. Współczesne systemy analizy predykcijnej coraz częściej napotykać na wyzwania związane z utrzymaniem stabilnych warunków pracy urządzeń, szczególnie w kontekście rosnącej heterogeniczności i złożoności infrastruktury technicznej. Opracowywane rozwiązanie ma na celu agregację danych z całego zespołu zarządzanych budynków w taki sposób, aby nie utracić istotnych danych dla podejmowanych decyzji, jednocześnie uzyskując jednorodne źródło danych.

W badanym kontekście szczególne znaczenie ma zapewnienie ciągłości działania kluczowych systemów takich jak np. systemy zabezpieczenia budynku i kontroli dostępu, systemy utrzymania komfortu cieplnego, itp. w szczególności wdrażanie algorytmów predykcyjnych w heterogenicznych zespołach budynków stanowi wyzwanie dla całościowego gromadzenia, analizy i interpretacji danych. Projektowane rozwiązanie zasilane będzie z jednej spójnej bazy danych, natomiast wykorzystywać będzie różne algorytmy predykcyjne do których można zaliczyć SARIMA, Regresja liniowa, Random Forest, GBM. Każdy z tych algorytmów jest zaprojektowany z różnymi typami danych i różnorodnymi scenariuszami, co zapewni elastyczność prognozowania w kontekście złożonych systemów zarządzania budynkami. Dla przykładu algorytmy klasy GBM sprawdzają się w analizie dużych zbiorów danych, a modele sezonowe są idealne do przewidywania zmian sezonowych i trendów. Istotnym aspektem pracy jest integracja danych pochodzących z różnych źródeł oraz systemów automatyki, co pozwoli na uzyskanie pełniejszego obrazu stanu technicznego infrastruktury.

3. Specyfika sterowania oraz zarządzania budynkami

Efektywne zarządzanie budynkami wymaga między innymi zastosowania odpowiednich systemów i urządzeń technicznych. Wykorzystanie i optymalizacja sterowania chociażby systemów zarządzających komfortem cieplnym budynku lub zespołów budynków umożliwia oszczędności energii. W przypadku zarządzania całymi zespołami różnorodnych budynków istotnym jest weryfikacja możliwości standaryzacji rozwiązań instalowanych w budynkach z uwzględnieniem aspektów związanych z możliwościami integracji różnych rozwiązań oraz zdalnego zarządzania nimi. Poniżej scharakteryzowano przyczyny powodujące powstanie heterogenicznej grupy budynków w omawianym obszarze. Ponadto scharakteryzowano od strony parametrów funkcjonalnych wyposażenie przeznaczone do utrzymania komfortu cieplnego użytkowników stosowane w różnych budynkach lub zespołach budynków.

3.1. Różnorodność rozwiązań w zakresie wyposażenia budynków na różnych etapach życia

Na przestrzeni lat projekty budynków, materiały konstrukcyjne oraz wielkość projektowanych nieruchomości komercyjnych zmieniały się wraz z zmianami potrzeb użytkowników. Taka sytuacja powoduje, że zarządzając znaczącą grupą ponad tysiąca budynków rozlokowanych w postaci zespołów budynków w południowej Polsce mamy do czynienia z bardzo zróżnicowaną technicznie populacją. Przede wszystkim, wychodząc od okresu budowy budynków omawiana populacja posiada obiekty wybudowane na początku XX wieku jak również obiekty nowe zaprojektowane i wybudowane w ostatnich latach. Obiekty zaprojektowane w pierwszej połowie XX wieku często posiadały inne podstawowe zastosowanie, niż to, do którego są obecnie wykorzystywane. Mowa tutaj o budynkach wybudowanych w okresie międzywojennym XX wieku z przeznaczeniem do lokowania elektrowni miejskich, służb obsługi technicznej elektrowni oraz niewielkiego zespołu pracowników administracyjnych i zarządzających działalnością. Ze względu na potrzeby związane z rozwojem energetyki w tym okresie, budowane obiekty miały w głównej mierze charakter obiektów przemysłowych, co wiązało się z wielkością i wysokością hal produkcyjnych, oraz wielkością i wysokością powierzchni biurowych. Obiekty te dostosowane były wizualnie do trendów architektury obowiązujących w okresie budowy i posiadały trwałą konstrukcję wykonaną z materiałów takich jak beton lub cegła (Atkin and Brooks, 2021).

W kolejnych latach, wraz z rozwojem energetyki zespoły budynków były albo rozbudowywane, albo w lokalizacjach, w których się znajdowały budowane były kolejne - często małe - obiekty o charakterze warsztatów, magazynów, lub biur. Zaznaczyć należy, że w tego typu budynkach często lokowane były w części biurowej mieszkania pracownicze. Wraz z rozwojem sieci elektroenergetycznej i budową sieci wysokiego napięcia przy budowanych stacjach transformatorowo - rozdzielczych lokowano budynki o charakterze techniczno- biurowym przeznaczono do sterowania i nadzoru stacji elektroenergetycznej. Dodatkowo częstą praktyką było lokowanie mieszkań pracowniczych przy (lub w) tego typu budynkach. Dla obsługi sieci średnich i niskich napięć, w celu szybszego reagowania

na uszkodzenia infrastruktury sieciowej na całym terenie działania spółki lokowano budynki techniczno- administracyjne w postaci rejonów energetycznych i mniejszych posterunków energetycznych. Obiekty tego typu składały się w głównej mierze z części warsztatowo - magazynowej, której celem była naprawa urządzeń sieciowych oraz często także wytwarzanie elementów konstrukcyjnych sieci elektroenergetycznych (Azman *et al.*, 2014; Atkin and Brooks, 2021).

Wraz z rozwojem motoryzacji pracownicy serwisujący sieć elektroenergetyczną otrzymywali do dyspozycji coraz większą ilość pojazdów, często specjalistycznych, co powodowało rozwój budynków w kierunku funkcji garażowo - warsztatowej realizującej funkcję utrzymania ruchu pojazdów.

Kolejne istotne zmiany wynikające z wymagań rynku oraz wprowadzanego prawa energetycznego zmieniały funkcje budynków administracyjnych, lub ich części w kierunku rozwoju centrów obsługi klientów oraz poszerzenia i przekształcenia obiektów, które pierwotnie służyły do wytwarzania energii dla potrzeb biurowych. Zaznaczyć należy, że wraz z rozwojem technologii związanych z wytwarzaniem energii elektrycznej, rozwojem sieci dystrybucyjnych zmieniło się pierwotne przeznaczenie budynków. Rozwój usług zewnętrznych takich jak dostawy na czas elementów sieci elektroenergetycznych, rozwój procesów w tym procesów związanych z outsourcingiem usług wykonawstwa wpłynął na zmiany funkcji budynków (Atkin and Brooks, 2021).

Zwiększyło się znaczenie funkcji magazynowo - garażowej budynków, zmniejszył się obszar oraz znaczenie funkcji warsztatowej. Zanikło znaczenie pierwotnej funkcji produkcyjnej. Rozwój automatyki sieciowej oraz zmiany wielkości przedsiębiorstw wpłynęły także na decyzje dotyczące sposobu użytkowania budynków. Pojawiała się potrzeba wydzielenia części obiektów dla potrzeb transmisji danych. W okresie późniejszym, aż do chwili obecnej funkcja ta wpływa na zmiany w zakresie użytkowania budynków coraz bardziej znacząco. Pojawiły się budynki realizujące funkcje dostosowane transmisji i gromadzenia danych IT i OT.

3.2. Wpływ zmian przeznaczenia budynku na systemy zarządzania komfortem cieplnym

Technologia utrzymania komfortu cieplnego w heterogenicznych zespołach budynków komercyjnych ewoluowała wraz ze zmianami okresów ich budowy oraz prowadzonych modernizacji i adaptacji. Częstą praktyką wpływającą na różnorodność stosowanych rozwiązań była modernizacja części adaptowanych budynków do nowych funkcji pozostawiając pozostały obszar w dotychczasowym stanie (Yang, Yan and Lam, 2014).

Pierwotnie komfort cieplny budynków zapewniany był – tam, gdzie to było niezbędne poprzez ich ogrzewanie. Początkiem XX wieku nierzadkim rozwiązaniem było stosowanie lokalnych pieców węglowych. W kolejnych okresach stosowano instalacje centralnego ogrzewania budynków oparte o różne źródła zasilania, często zależne od lokalnych możliwości. Wytwarzanie ciepłej wody użytkowej oparte było tych samych rozwiązaniach centralnego „podgrzewania wody” (Taleghani *et al.*, 2013).

W obszarach miejskich, gdzie występowały sieci ciepłownicze instalacje grzewcze przyłączane były poprzez węzły cieplne do miejskich instalacji ciepłowniczych. W tym przypadku zależnie od lokalnych możliwości technicznych i podjętych decyzji w stosunku do konkretnego zespołu budynków budowane były wymiennikownie zasilające jeden lub więcej budynków w ciepło.

Na pozostałych terenach zasilanie w ciepło odbywało się pierwotnie w znaczącej mierze poprzez kotłownie węglowe, które zamieniane były wraz z rozwojem sieci gazowniczej na kotłownie gazowe, lub elektryczne, rezystancyjne kotły grzewcze. Wytwarzanie ciepłej wody użytkowej w małych jednostkach terenowych mogło opierać się także o lokalne elektryczne ogrzewacze wody. W budynkach technicznych, tam gdzie występowały procesy wymagające odprowadzania gazów z procesów warsztatowych stosowano wentylację wywiewną.

Kolejną istotną zmianą była możliwość schładzania pomieszczeń przy użyciu klimatyzacji. Pierwotnie wybierano istotne pomieszczenia i w tych częściach budynków instalowane były lokalne systemy klimatyzacyjne. W kolejnych okresach częstą praktyką było rozszerzanie klimatyzacji o kolejny zakres pomieszczeń w budynku, co powodowało stosowanie rozwiązań innego producenta nie sterowanych wspólnie z uprzednio wykonanymi instalacjami (Yang, Yan and Lam, 2014).

Z kolei w budynkach realizujących funkcję garażową, w celu utrzymania gotowości do szybkiego wyjazdu, ze względów bezpieczeństwa związanych z odladzaniem pojazdów użytkowanych do serwisowania sieci dystrybucyjnej, budynki wyposażano w rezystancyjne grzejniki elektryczne - pierwotnie załączane i wyłączane ręcznie, a w okresie późniejszym z regulatorem temperaturowym. Warto zaznaczyć, że opisywane systemy nie posiadały możliwości integracji w zakresie sterowania zespołami instalacji.

Zmiana technologii budowlanych, przepisów związanych z ograniczeniem emisji CO₂ w budynkach przyczyniła się w pierwotnie do obniżenia kosztów utrzymania komfortu cieplnego poprzez lepszą izolacyjność przegród, drzwi i okien, a następnie poprzez stosowanie centralnych systemów wentylacji z odzyskiem ciepła i centralnych zespołów klimatyzacji. Systemy te nie muszą być integrowane centralnie w jeden spójnie zarządzany system, lecz mogą pracować jako indywidualne źródła regulowane przez użytkownika. Ze względu na koszty integracji ww. systemów utrzymania komfortu cieplnego w małych nieruchomościach, niejednokrotnie decyzja o zastosowaniu systemu BMS nie została podjęta (Yang, Yan and Lam, 2014).

Zwrócić należy także uwagę na różnorodność źródeł zasilania w ciepło nowych budynków, które obecnie wykorzystuje się do zasilania. Są to zarówno powietrzne jak i gruntowe pompy ciepła pracujące jako źródła sterowane lokalnie, ogrzewanie przez klimatyzację, ogrzewanie z miejskiej sieci ciepłowniczej (węzły cieplne) ogrzewacze gazowe, elektryczne - zarówno rezystancyjne jak i indukcyjne piece grzewcze.

W systemach wykorzystujących wentylację istotnym źródłem wpływającym na utrzymanie bilansu cieplnego budynku jest odzysk ciepła w wymiennikach krzyżowych, lub rotacyjnych systemów wentylacyjnych. W opisywanych zespołach budynków - szczególnie

w przypadku budynków biurowych nie stosuje się okien nieotwieralnych. Jest to uwarunkowane doświadczeniami wynikającymi z wynajmu biurowca z tego typu oknami oraz wpływu dostępu tzw. świeżego powietrza na samopoczucie osób ciągle pracujących w pomieszczeniach.

W tym miejscu wspomnieć należy o systemach zabezpieczenia technicznego budynków, które pierwotnie sprowadzały się do zabezpieczeń mechanicznych, a wraz z rozwojem tej dziedziny wiedzy przekształcały się w aktywne systemy zabezpieczeń obiektów. Obecnie w przypadku stosowania systemów zarządzania budynkami część czujników związanych z systemami zabezpieczeń technicznych jest wykorzystywana dla dostarczania informacji dotyczącej warunków pracy w pomieszczeniu, a co za tym idzie danych sterowniczych dla systemów utrzymania komfortu cieplnego. Przykładem mogą być dane z kontaktronów dostarczających informacji o statusie otwarcia okna.

Systemy zabezpieczenia technicznego obiektów i systemy zarządzania komfortem cieplnym w nowoczesnych budynkach, lub zespołach budynków zaczynają stanowić w omawianej grupie integralną całość. Przy czym, zaznaczyć należy, że aby w istniejących obiektach uzyskać tego typu stan należy dokonać gruntownych modernizacji przygotowanych w oparciu o zestandaryzowane wymagania.

3.3. Administrowanie i serwisowanie zespołów budynków

W celu obsługi administracyjnej oraz serwisowej w heterogenicznych rozproszonych lokalizacjach, które w większości nie posiadają zdalnych systemów sterowania oraz zdalnych systemów nadzoru należy zatrudnić większą grupę administratorów obiektów niż w przypadku nieruchomości jednorodnych, dużych, lub skoncentrowanych w jednym miejscu. Istotne znaczenie w heterogenicznych rozproszonych zespołach nieruchomości ma czas dojazdu na miejsce zarówno administratora w celu przykładowo dokonania regulacji w systemach lokalnych lub serwisu, czy w celu dokonania przeglądu lub usunięcia awarii. W przypadku awarii dodatkowo należy zaznaczyć, że częstą praktyką jest wcześniejszy przyjazd administratora w celu zdiagnozowania zakresu awarii na miejscu i dopiero zespoły serwisowe na podstawie tej informacji są odpowiednio dobierane pod kątem profilu kompetencyjnego jak również w zakresie niezbędnego wyposażenia (Azman *et al.*, 2014).

Dla właściwej obsługi administracyjnej przyjąć należy, że zależnie od terenowego rozlokowania zespołów nieruchomości jedna osoba może administrować zakresem około 15 tysięcy metrów kwadratowych powierzchni budynków. Oczywiście tego typu wyznacznik jest zależny od struktury funkcji administrowanych obiektów w konkretnej nieruchomości. Ewolucyjna zmiana funkcji obiektów opisywana powyżej, jak również zastosowanie w nich wyposażenia technicznego z różnych okresów czasu, będącego na różnym etapie życia powoduje, że zarówno diagnozowanie przyczyn awarii jak również ich usuwanie wiąże się z koniecznością poświęcenia większej ilości czasu, a niejednokrotnie posiadania części zamiennych dostosowanych do użytkowanego urządzenia. Także kompetencje administratorów na tego typu obiektach muszą opierać się na szerokim doświadczeniu w zakresie sterowania urządzeniami. Przykładem mogą tutaj być wymiennikownie - w nowych

posiadających sterowniki sprawdzamy parametry i zmieniamy charakterystykę, lecz w zupełnie niezmodernizowanych musimy dokonać także regulacji zaworami, co w przypadku braku doświadczenia może powodować zaburzenia w funkcjonowaniu obiektu (Atkin and Brooks, 2021).

Opisane powyżej działania sprowadzają się do zwiększonych kosztów zarówno administrowania jak również serwisowania urządzeń zamontowanych w opisywanych nieruchomościach. Standaryzacja nie tylko procedur, ale i narzędzi pozwalających diagnozować, lub nawet tylko wstępnie diagnozować problemy wiąże się z oszczędnością czasu i kosztów. Nadmienić należy, że wykorzystując nowoczesne systemy sterowania parametrami automatyki budynkowej, a nawet półautomatyczne systemy sterowania uzyskujemy znaczące oszczędności kosztów. Kontynuując przykład węzłów cieplnych - jeśli zmiana charakterystyki grzewczej na sterowniku może zostać dokonana zdalnie, bez potrzeby wyjazdu administratora na miejsce, to poprzez samo takie działania uzyskujemy znaczące oszczędności i poprawiamy efektywność administrowania.

Przegląd potrzeb w zakresie możliwości wykorzystania metod predykcji uszkodzeń w automatyce budynkowej

Zastosowanie właściwych metod oraz algorytmów wykrywania uszkodzeń, dostosowanych do konkretnych rozwiązań pozwala ograniczyć koszty napraw oraz koszty przestojów urządzeń wynikłych z niespodziewanych awarii. Planowa realizacja prac mających na celu poprawę stanu technicznego urządzeń, w tym, ich naprawa lub modernizacja ma kluczowe znaczenie dla usprawnienia działań serwisowych oraz dla poprawy procesów serwisowych. Pozwala polepszyć funkcjonowanie budynków oraz planowanie kosztów serwisowych. Dobór właściwych metod predykcji uszkodzeń na liniach produkcyjnych ma szerokie praktyczne zastosowanie.

Natomiast w procesach zarządzania nieruchomościami, zwłaszcza heterogenicznymi oraz rozproszonymi predykcja uszkodzeń wraz z doбором właściwych metod jest procesem znacząco mniej rozpowszechnionym. Biorąc pod uwagę nieruchomości znacząco zróżnicowane pod kątem wielkości, przeznaczenia, będące na różnych etapach istnienia oraz wyposażone w różnym stopniu i zakresie w automatykę budynkową, dla prawidłowego wdrożenia narzędzi umożliwiających predykcję uszkodzeń pojawia się konieczność przeprowadzenia poszerzonej analizy dla dokonania właściwego doboru metod i zakresu predykcji uszkodzeń, uwzględniając spodziewane korzyści oraz niezbędne koszty.

Dodatkowo, aby zoptymalizować proces utrzymania i zarządzania nieruchomościami rozproszonymi należy brać pod uwagę potrzebę przygotowania i wdrożenia odpowiedniego narzędzia. Narzędzie to musi gromadzić dane i zarządzać automatyką budynkową, w sposób możliwie scentralizowany. Wykorzystanie narzędzia centralizującego zarządzanie nieruchomościami daje potencjał dla optymalizacji wielkości zespołu zarządzającego budynkami.

Odpowiednio przeszkolony zespół, posiadający umiejętności analizy uzyskanych w systemie wyników, podejmujący prewencyjne działania naprawcze może jednocześnie

stanowić bazę dla doskonalenia i implementacji w oprogramowaniu coraz lepszych algorytmów i metod predykcji uszkodzeń.

Cel i zakres przeglądu

Biorąc pod uwagę zróżnicowaną infrastrukturę budynkową realizującą różnorodne potrzeby użytkowników należy dokonać analizy możliwego oraz niezbędnego z przyczyn ekonomicznych zakresu diagnostyki automatyki budynkowej.

W badanej próbie nieruchomości brane są pod uwagę nieruchomości o charakterze komercyjnym funkcjonujące na terenie południowej Polski w przedsiębiorstwie o profilu energetycznym. Ze względu na przeznaczenie próbkę badawczą budynków należy podzielić na budynki:

1. biurowe,
2. magazynowe,
3. archiwalno – biurowe,
4. warsztatowe oraz garażowe.

Wszystkie wyżej wymienione typy budynków mogą łączyć się w różnorodne lokalizacje realizujące dla Spółki różne cele biznesowe. Definiując zakres dobru właściwych metod predykcji uszkodzeń urządzeń automatyki budynkowej należy brać pod uwagę cele biznesowe i funkcje realizowane przez poszczególne lokalizacje budynków oraz zakres urządzeń automatyki, w które wyposażony jest dany zespół budynków.

Cele uzasadniające szczegółowe podejście do badania możliwości zastosowania predykcji uszkodzeń można zdefiniować następująco:

1. obniżenie kosztów funkcjonowania nieruchomości,
2. bardziej precyzyjne planowanie nakładów na eksploatację i usuwanie uszkodzeń infrastruktury technicznej,
3. możliwość centralnego nadzoru infrastruktury technicznej, diagnostyki zdalnej oraz analizy danych rozproszonych, heterogenicznych nieruchomości, skutkującą optymalizacją planów przeglądów realizowanych na miejscu,
4. optymalizacja ilości oraz kompetencji osób administrujących obiektami lokalnie,
5. pozyskanie bazy danych dla analiz awaryjności poszczególnych rozwiązań, skutkującej zmianami wymagań dla infrastruktury technicznej w modernizowanych oraz nowobudowanych obiektach,
6. zastosowanie algorytmów oraz metod stosowanych w predykcji uszkodzeń automatyki budynkowej.

W celu usprawnienia procesów serwisowych w rozproszonych lokalizacjach budynkowych pod kątem minimalizacji czasu uszkodzeń oraz kosztów uszkodzeń należy przeprowadzić analizę obszaru stosowania automatyki budynkowej, oraz wskazać na podstawie krajobrazu dostępnych danych zakres możliwości predykcyjnych oraz dobrać właściwe metody predykcji uszkodzeń dla następujących grup/typów urządzeń:

- Urządzenia utrzymania komfortu cieplnego oraz wymiany powietrza niezintegrowane systemami zarządzania budynkami (BMS), jak również urządzenia zintegrowane za pomocą BMS - predykcja w zakresie uszkodzeń łożysk rotorów, sprężarek, pomp (o małej mocy), alarmowanie o wyłączeniu rotora realizującego funkcję mieszania powietrza i wymiennika ciepła w wentylacji realizowane na podstawie analizy różnicy temperatur powietrza występującej na rotorze, automatyczna ocena stanu filtrów, związana z tym regulacja nawiewu oraz właściwy zakres alarmowania/informowania,
- Węzły cieplne zarządzane w porozumieniu z lokalnymi przedsiębiorstwami energetyki cieplnej – informowanie o braku zmian temperatury wody w zależności od temperatury zewnętrznej i przyjętej charakterystyki grzewczej, lub długotrwałe nieosiągnięcie zadanych parametrów przy właściwie ustawionej charakterystyce grzewczej (możliwa awaria urządzeń utrzymujących ciśnienie, zanieczyszczenie wymienników ciepła mogące mieć przyczynę w zaniedbaniu prac eksploatacyjnych, awaria sterowania pompą obiegową, itp.),
- Systemy pomiaru temperatury, wilgotności, CO₂ - analiza uszkodzeń na podstawie zmienności parametrów w czasie z uwzględnieniem sygnałów z systemów zabezpieczenia obiektów, predykcja pogorszenia warunków pracy w budynku np. w związku z otwarciem okna w dni, w które zanieczyszczenie na zewnątrz jest wysokie,
- Elementy elektromechaniczne systemów zabezpieczenia technicznego budynków - predykcja uszkodzeń zamków,
- Akumulatory oraz systemy i urządzenia zasilania awaryjnego - predykcja w zakresie zmian pojemności akumulatorów, możliwość realizacji zdalnych przeglądów, predykcja uszkodzeń urządzeń utrzymujących warunki termiczne pomieszczeń i zasilaczy,
- Systemy sygnalizacji pożaru oraz systemy gaszenia pożarów - predykcja uszkodzeń czujek ppoż. (w tym w zakresie potrzeby przeprowadzenia ich czyszczenia związanego z gniazdowaniem insektów),
- Rozdzielnie elektryczne (również w zakresie zadziałania bezpieczników liniowych) - predykcja uszkodzeń na podstawie zmian temperatury urządzeń oraz rejestrowanie zmian w układzie zasilania, zadziałania bezpieczników liniowych.

Powyższy zakres urządzeń i instalacji automatyki niezbędny jest dla monitorowania ciągłości i poprawności funkcjonowania nieruchomości, lub ich części. Przy czym należy mieć na uwadze przeznaczenie poszczególnych budynków, zakres ich wyposażenia oraz funkcję realizowaną przez zespół budynków w danej lokalizacji. Do wyżej wymienionego zakresu systemów należy dobrać właściwe metody detekcji uszkodzeń, uwzględniając rodzaje systemów zainstalowanych w danej lokalizacji, ich wielkość oraz poziom integracji.

Inwentaryzacja stanu obecnego w zakresie urządzeń zabezpieczenia technicznego oraz sterowanie komfortem cieplnym

Źródła danych

Dla prowadzenia integracji systemowej brana jest pod uwagę cała populacja heterogennych budynków komercyjnych, która stanowi ponad 1000 różnorodnych budynków rozlokowanych na terenie południowej Polski. Tak jak zostało napisane powyżej budynki te wyposażone są w różnym stopniu w automatykę budynkową.

Sterowanie systemami zarządzania komfortem użytkowników realizowane jest lokalnie z wykorzystaniem systemów BMS, albo sterowników poszczególnych instalacji, lub bezpośrednio wykorzystując sterowanie urządzenia. Wszystkie budynki wyposażane są w systemy zabezpieczenia technicznego (SZT) obiektów realizujące funkcje monitorowania obiektów, sygnalizacji włamania, kontroli dostępu. Systemy te integrowane są z narzędziem centralnym umożliwiającym monitorowanie alarmów SZT. Narzędziem umożliwiającym integrację lokalnych SZT jest system SCS WiN firmy EP&M. SCS WiN umożliwia integrację w zakresie:

- systemów sygnalizacji włamania i napadu,
- systemów kontroli dostępu,
- systemu dozoru wizyjnego,
- systemu sygnalizacji pożaru,
- monitoringu pracy urządzeń technicznych, takich jak klimatyzacje, siłownie, prostowniki, UPS, agregaty prądotwórcze, czujniki temperatury, wilgoci oraz sygnały techniczne od innych urządzeń.

Lokalne systemy zarządzania budynkami

Systemy BMS funkcjonują na bazie centralnego systemu komputerowego zarządzającego budynkiem. Wszystkie informacje zbierane przez BMS rejestrowane są w bazach danych zainstalowanych na serwerach. Obsługa obiektu korzysta ze zdalnych stacji roboczych. Dodatkowo systemy te mogą być zaopatrzone w możliwość zdalnego nadzoru z dowolnego komputera za pomocą przeglądarki internetowej lub zintegrowane z systemem SCS WiN. Dostęp do systemów BMS oparty jest na wielopoziomowym interfejsie umożliwiającym nadawanie użytkownikom określonych uprawnień do zarządzania. Zadania systemu to:

- monitorowanie warunków środowiskowych pomieszczeń,
- detekcja wycieków;
- monitoring funkcjonowania układów zasilania,
- monitoring agregatów prądotwórczych,
- monitoring układów klimatyzacji i wentylacji,
- monitoring poprawności działania instalacji teletechnicznych.

Systemy zabezpieczenia technicznego budynków

W celu zapewnienia odpowiedniego poziomu ochrony sprzętu, ludzi oraz przechowywanych informacji budynki wyposażone są w zintegrowane systemy bezpieczeństwa. Systemy te w oparciu o zespół reguł, procedur i instalacji technicznych zapewniają i kontrolują postępowanie pracowników zgodnie z wewnętrzną polityką bezpieczeństwa Spółki. Systemy te składają się ze współpracujących ze sobą podsystemów:

- Systemu kontroli dostępu (SKD),
- Systemu sygnalizacji włamania i napadu (SSWiN),
- Systemu telewizji dozorowej (CCTV).
- Systemu sygnalizacji pożaru i w jednym przypadku systemu automatycznego gaszenia pomieszczeń chronionych.

Na system zabezpieczeń technicznych składają się również odpowiednie zabezpieczenia mechaniczne: ogrodzenia, bramy, drzwi, szyby itd. System Kontroli Dostępu umożliwia kontrolę oraz nadawanie uprawnień do przemieszczania się osób pomiędzy pomieszczeniami w budynkach. Kontrola przemieszczania odbywa się przy pomocy identyfikacji danych z kart magnetycznych, kodów PIN oraz czytników biometrycznych.

System sygnalizacji włamania i napadu sygnalizuje naruszenie odpowiednich stref bezpieczeństwa. System telewizji dozorowej umożliwia monitorowanie obiektów przez ochronę oraz gromadzi dane wizualne ze stref chronionych. System sygnalizacji pożaru pozwala na sygnalizowanie pożarów, które mogą się pojawić na nieruchomości, steruje urządzeniami ograniczającego dostęp do wyznaczonych stref oraz urządzeniami wspomagającymi ewakuację.

Sterowanie komfortem cieplnym budynków niewyposażonych w systemy BMS

W budynkach niewyposażonych w Systemy BMS, systemy ogrzewania, wytwarzania chłodu działają autonomicznie. Systemy klimatyzacji i wentylacji sterowane są przez własne moduły sterujące zlokalizowane najczęściej w pomieszczeniach technicznych w najbliższym sąsiedztwie szaf sterujących i zasilających centrale wentylacyjne. Źródłami ogrzewania budynków są odpowiednio:

- instalacje ogrzewania elektrycznego,
- źródła gazowe,
- wymiennikownie zasilane poprzez węzły cieplne ciepłem systemowym z lokalnych przedsiębiorstw ciepłowniczych,
- pompy ciepła.

Wyżej wymienione źródła ciepła posiadają własne moduły sterujące dokonujące pomiarów parametrów temperaturowych w budynkach oraz temperatur zewnętrznych. Moduły sterujące w pompach ciepła, źródłach elektrycznych i gazowych umożliwiają realizację zadanych programów ogrzewania. Źródła ciepła zasilane ciepłem systemowym z lokalnych przedsiębiorstw ciepłowniczych pracują w oparciu o wymiennik ciepła oraz są sterowane zależnie od temperatury zewnętrznej.

W zakresie wytwarzania chłodu wiele lokalizacji wyposażonych jest wyłącznie w urządzenia klimatyzacyjne. Takie rozwiązania stosowane są szczególnie w zabytkowych oraz starszych budynkach.

Systemy HVAC

Budynki zbudowane w różnych okresach posiadają różny zakres systemów odpowiedzialnych za utrzymanie komfortu cieplnego dla użytkowników. Charakterystyka różnic w tym zakresie opisana została w poprzednim rozdziale. Celem niniejszego rozdziału jest przedstawienie budowy systemów utrzymania komfortu cieplnego.

Na systemy utrzymania komfortu cieplnego składają się systemy wentylacji, klimatyzacji oraz systemy ogrzewania. Głównym celem funkcjonowania tych systemów jest zapewnienie komfortu cieplnego użytkownikom oraz dostarczenie odpowiedniej ilości świeżego powietrza dla użytkowników. Systemy możemy podzielić na systemy lokalne oraz systemy centralne (Dincer, 2002). Systemy lokalne instalowane są w strefach budynków, które lokalnie powinny realizować cele w zakresie komfortu cieplnego charakterystyczne dla danej strefy budynku. Systemy centralne ukierunkowane są na zapewnienie właściwych warunków cieplnych w całym budynku (Pérez-Lombard *et al.*, 2011). Systemy HVAC mogą być stosowane w różnych typach budynków: biurowych, magazynowych warsztatowych, przemysłowych oraz mieszkalnych.

Systemy HVAC mogą być budowane jako (Seyam, 2018):

- bezkanałowe – stosowane często jako rozwiązania w tymczasowych obiektach np. na placach budowy oraz w mniejszych konstrukcjach,
- kanałowe – stosowane w dużych budynkach.

Systemy HVAC mogą być realizowane w postaci hybrydowej – tj. system wentylacji i przygotowania powietrza może zostać zrealizowany jako system centralny, a dodatkowo dla schładzania powietrza w poszczególnych strefach budynku mogą zostać zainstalowane lokalne systemy chłodzące umożliwiające dokładną regulację temperatury powietrza nawiewanego do pomieszczeń.

Głównymi komponentami składającymi się na system HVAC są (Seyam, 2018):

- Systemy wentylacji i przygotowania powietrza nawiewanego składające się z elementów:
 - komora powietrza mieszanego, w tym wymiennik ciepła,
 - sterownik urządzenia wraz z systemem czujników, oraz przepustnic regulujących nawiew,
 - filtry międzysekcyjne,
 - sekcje nagrzewania,
 - sekcje chłodzenia,
 - nawilżacze/osuszacze powietrza,
 - czerpnia, wyrzut powietrza oraz kanały powietrzne.
- Systemy klimatyzacji składające się z:

- źródła ciepłego i/lub chłodnego powietrza,
- systemu dystrybucji powietrza,
- jednostka sterująca (np. termostat do regulacji systemu).
- Źródła ciepła i źródła chłodu:
 - Pompy ciepła,
 - Zasilanie ciepłem ze źródeł zewnętrznych (węzły cieplne)
 - Instalacje wytwarzania wody lodowej,
 - Pompy ciepła, kolektory słoneczne,
 - Kotły elektryczne lub gazowe,
 - Nagrzewnice.

Czynniki wpływające na koszt systemu HVAC:

Projektowanie systemu HVAC obejmuje trzy podstawowe kroki:

- obliczenie strat i zysków ciepła,
- dobór sprzętu,
- zaprojektowanie przebiegów kanałów.

Pierwszy krok polega na przeprowadzeniu obliczenia obciążenia chłodniczego i grzewczego dla poszczególnych pomieszczeń, a następnie doborze odpowiedniego rozmiaru systemu. Projekt kanałów przygotowuje się mając na uwadze utrzymanie właściwego ciśnienia powietrza transportowanego do poszczególnych pomieszczeń.

Projekt systemu HVAC jest powiązany w głównej mierze projektem konstrukcji i wchodzących w jego skład komponentów. Konstrukcja o złożonej geometrii może wiązać się z dużymi kosztami komponentów HVAC, podczas gdy system o prostszej konstrukcji wiąże się ze stosunkowo niższymi kosztami (Farouk *et al.*, 2022; Hou *et al.*, 2022a).

Na koszty budowy systemu mają wpływ:

- Wielkość wybudowanego obiektu,
- Wydajność systemu.

Źródła ciepła i chłodu używane w systemach HVAC

Systemy HVAC dla uzyskania właściwych parametrów przygotowywanego powietrza potrzebują właściwie dobranych źródeł chłodu oraz ciepła. Istotna przy tym jest przede wszystkim moc źródła oraz charakterystyka jego pracy.

W systemach HVAC wykorzystuje się następujące rodzaje źródeł (D’Orazio, 2018):

- pompy ciepła,
- piece elektryczne,
- nagrzewnice elektryczne,
- zewnętrzne węzły cieplne dostarczające ciepło z zewnętrznych źródeł systemowych,
- klimatyzatory,
- instalacje wody lodowej.

Wyżej wymienione źródła ciepła i chłodu dobiera się indywidualnie dla każdego budynku wyposażonego w system utrzymania komfortu cieplnego. Nagrzewnice, jak również chłodnice w systemach wentylacji projektowane są w sposób umożliwiający dołączanie w razie

potrzeb poszczególnych sekcji grzewczych lub chłodzących. Takie działanie przyczynia się do szybszego nagrzania/ słodzenia powietrza, a w sytuacji, gdy nie dokonujemy zmian temperatury i ilości potrzebnego powietrza umożliwia pracę na włączonej przykładowo tylko jednej sekcji. Takie działanie sprzyja oszczędnościom energii. W wielu budynkach systemy utrzymania komfortu cieplnego posiadają zdublowane źródła ciepła zasilane różnymi mediami. Takie rozwiązania wpływają na większą niezawodność systemu oraz w niektórych sytuacjach pozwalają stosować źródła tańsze. Rozwiązanie takie jednak powoduje wzrost nakładów niezbędnych na budowę systemu (Belafi, Hong and Reith, 2017a).

W obszarach klimatu chłodnego, w wielu budynkach, których ciągłość pracy jest szczególnie ważna oprócz systemów zintegrowanych przygotowujących kompleksowo powietrze stosuje się dodatkowe systemy grzewcze. Systemy takie mogą być wykonane w postaci:

- centralnego ogrzewania podłogowego,
- centralnego systemu ogrzewania wykorzystującego grzejniki konwekcyjne (wodne lub elektryczne),
- nagrzewnice (w częściach technicznych, holach itp.),
- systemy dogrzewania z wykorzystaniem klimatyzacji.

Systemy te powinny być integrowane poprzez podłączenie do BMS, lecz w praktyce w wielu przypadkach są systemami, które należy oddzielnie uruchomić.

Charakterystyka źródeł ciepła

Źródła ciepła można podzielić najprościej ze względu na temperaturę dostarczanego czynnika grzewczego na źródła niskotemperaturowe i wysokotemperaturowe. Innym oczywistym podziałem może być podział źródeł ciepła ze względu na czynnik zasilający. I tutaj możemy rozróżnić źródła gazowe, elektryczne, węzły cieplne zasilane z lokalnych ciepłowni, źródła odnawialne pozyskujące energię ze środowiska naturalnego takie jak kolektory słoneczne lub pompy ciepła.

Dla potrzeb niniejszej pracy opis poszczególnych źródeł ciepła sprowadzi się do podania podstawowych informacji związanych ze sposobem działania, gdyż szczegóły przykładowo o charakterze konstrukcyjnym nie są przydatne biorąc pod uwagę przedmiot niniejszej rozprawy.

Pompy ciepła

Pompa ciepła jest urządzeniem, które wykorzystuje energię elektryczną do sprężania czynnika przenoszącego ciepło ze źródła o niskiej temperaturze do źródła o wyższej temperaturze. Przesył ciepła w pompie ciepła odbywa się w specjalnych wymiennikach ciepła (parowniku i skraplaczu). Cały proces przekazywania energii możliwy jest dzięki przemianom termodynamicznym zachodzącym w obiegu zamkniętym urządzenia. Pompy ciepła posiadają interfejsy do współpracy z innymi źródłami ciepła odpowiedzialne przykładowo za wyłączenie pompy w chwili, gdy rolę źródła przejmuje inne urządzenie. Sterowniki pomp ciepła posiadają

interfejsy do współpracy z innymi modułami pomp oraz wyposażone są (mogą być) w szynę danych umożliwiającą zdalny odczyt i zdalne sterowanie urządzeniem, z tej szyny danych pozyskać można także informację na temat kodów błędów generowanych podczas pracy urządzenia (Chua, Chou and Yang, 2010).

Cechy pomp ciepła:

- są bardzo wydajne energetycznie – produkują nawet 4-5-krotnie więcej energii niż jest pobierane do ich zasilania,
- są w pełni zautomatyzowane,
- są zeroemisyjne – co oznacza, że ogrzewanie przy pomocy pompy ciepła nie powoduje emisji szkodliwych związków do atmosfery,
- pozwalają zasilac system grzewczy i instalację ciepłej wody użytkowej,
- są kompaktowe przez co pozwalają zaoszczędzić miejsce,
- niektóre pompy ciepła mogą pełnić także funkcje klimatyzacji w okresie letnim.

Najczęściej użyteczne pompy ciepła można podzielić na urządzenia typu powietrze – woda oraz grunt – woda (Chua, Chou and Yang, 2010). Oczywiście używane są także pompy ciepła typu woda – woda, solana – woda, itp. Generalnie podział ten sprowadza się do wskazania środowiska z którego pobierana jest energia oraz środowiska do którego oddawana jest energia.

Najważniejszymi parametrami technicznymi, tych urządzeń są:

- moc znamionowa w danych warunkach klimatycznych - np. w warunkach klimatu umiarkowanego,
- sezonowa efektywność ogrzewania w danych warunkach klimatycznych,
- wskaźnik efektywności energetycznej,
- pobór mocy elektrycznej w różnych stanach działania.

Węzły cieplne zasilane ze źródeł zewnętrznych (lokalnych ciepłowni)

Na węzły cieplne składają się zespoły urządzeń i wyposażenia, których celem jest przekazanie energii cieplnej z sieci o wysokich parametrach temperatury i ciśnienia do instalacji grzewczej budynków, lub zespołów budynków. Obwody wysokiego parametru i niskiego parametru są od siebie odizolowane poprzez zastosowanie wymienników ciepła. Węzły cieplne wyposażone są w pompy obiegowe utrzymujące obieg po stronie niskiego parametru. Dla konkretnych zastosowań należy odpowiednio dobrać wydajność pompy oraz wybrać właściwy rodzaj pracy pompy. Ciepło w węzłach cieplnych przekazywane jest poprzez wymiennik (najczęściej płytowy), a prędkością przepływu czynnika grzewczego po stronie niskiego parametru reguluje sterownik ustawiony według właściwej krzywej grzewczej stanowiącej jeden z parametrów projektowych dla węzła cieplnego. Krzywa grzewcza przedstawia zależność między temperaturą zasilania instalacji grzewczej a temperaturą powietrza zewnętrznego. Określa ona do jakiej temperatury źródło ciepła ma podgrzać wodę w instalacji grzewczej przy danej temperaturze zewnętrznej, tak aby w pomieszczeniu był odczuwany komfort cieplny (Joniec, 2007).

Istotnymi parametrami technicznymi charakteryzującymi węzeł cieplny są:

- moc cieplna węzła, a w przypadku układu wielowymennikowego stanowiącego oddzielne obiegi grzewcze moc cieplną poszczególnych obwodów grzewczych,
- wartość przepływu wody po stronie niskiego parametru,
- krzywa grzewcza przy której węzeł osiąga największą sprawność.

W tym miejscu zaznaczyć należy, że węzeł cieplny nie jest integralnym elementem instalacji grzewczej – w rozumieniu umów przyłączeniowych zawieranych z przedsiębiorstwami energetyki cieplnej stanowi on element sieci ciepłowniczej. Biorąc pod uwagę możliwości zastosowania go jako element zasilający instalacje i urządzenia w ciepło na potrzeby niniejszych rozważań traktujemy go jak źródło.

Ogrzewacze gazowe

Ogrzewacz gazowe przekształcają energię dostarczaną w postaci gazu w energię cieplną poprzez spalanie dostarczanego paliwa. Grzejniki te oprócz energii pozyskanej ze spalania gazu wykorzystując zjawisko kondensacji przekazują do systemu grzewczego dodatkową energię uwalnianą podczas uwalniania się pary wodnej zawartej w spalinach. W wyniku tego procesu wzrasta efektywność instalacji i maleją koszty ogrzewania. Sprawność kondensacyjnych kotłów gazowych może wynosić 98%.

Kotły gazowe ze względu na przeznaczenie podzielić można na (Pieprzyk, 2002):

- dwufunkcyjne – do zasilania obwodów grzewczych oraz obwodów ciepłej wody użytkowej,
- jednofunkcyjne – stosowane do zasilania obwodów grzewczych.

Najważniejszymi parametrami technicznymi kotłów grzewczych są:

- moc znamionowa,
- sprawność kotła,
- rodzaj paliwa zasilającego.

Ogrzewacze gazowe znajdują zastosowanie w funkcjonujących obiektach. Nowych obiektów nie wyposaża się w tego typu źródła.

Ogrzewacze elektryczne

Kotły elektrycznych można podzielić na następujące rodzaje:

- indukcyjne,
- rezystancyjne,
- elektrodowe,
- akumulacyjne,
- konwekcyjne i promiennikowe,
- dmuchawy i kurtyny.

Kotły indukcyjne - wykorzystują zjawisko indukcji elektromagnetycznej. Prąd płynący przez cewkę indukcyjną kotła wytwarza pole magnetyczne, które nagrzewa metalowy rdzeń

kotła. Wytwarzane ciepło jest przekazywane do przepływającego medium – najczęściej wody, która dystrybuuje je do instalacji grzewczej.

Piec elektrodowy - składa się z korpusu z króćcami wlotowymi i wylotowymi, elektrod umieszczonych w korpusie poprzez izolatory oraz z zacisków w osłonach do podłączenia przewodów zasilających. Zasada działania pieca elektrodowego polega na bezpośrednim przekształcaniu energii elektrycznej w ciepło, gdy prąd przemienny przepływa przez chłodziwo o niskiej przewodności z jednej elektrody na drugą. Stosowany jest do centralnego zasilania systemów grzewczych.

Piece akumulacyjne - składają się z wysokotemperaturowych elementów grzewczych o charakterze rezystancyjnym, wkładu akumulującego ciepło, izolacji termicznej oraz systemu sterowania. Piece akumulacyjne można podzielić na statyczne i dynamiczne. Statyczne piece akumulacyjne zaprojektowane są tak, że około 85% ciepła zawartego w rdzeniu uwalnia się poprzez procesy radiacji i konwekcji zachodzących na powierzchni grzejnika. Użytkownik ma bardzo ograniczoną kontrolę w zakresie oddawania ciepła. W piecach akumulacyjnych dynamicznych jedynie około 20% ciepła zawartego w rdzeniu uwalnia się poprzez procesy radiacji i konwekcji zachodzących na powierzchni grzejnika, pozostała część ciepła oddawana jest do otoczenia w wyniku ogrzewania powietrza przebywającego przez piec w wyniku wymuszonego obiegu. Użytkownik ma możliwość sterowania oddawaniem zgromadzonego ciepła, dochodzącą do 80% w nowoczesnych konstrukcjach. Piece te są możliwe do zastosowania lokalnie w pomieszczeniach. W ramach systemów sterowania tych urządzeń możliwe jest łączenie ich ze stacją pogodowa dostosowującą (oprócz sterownika lokalnego) ich działanie do zewnętrznych warunków pogodowych.

Grzejniki konwekcyjne - podgrzewają powietrze za pomocą grzałki elektrycznej, a ciepłe powietrze rozchodzi się po pomieszczeniu dzięki efektowi kominowemu. Stosowane są jako lokalne źródła ciepła.

Grzejniki promiennikowe podobnie jak konwekcyjne są instalowane jako lokalne źródło ciepła. Ich zasada działania opiera się na emitowaniu promieniowania podczerwonego absorbowanego przez przedmioty, ściany osoby, które to ciepło oddają do otoczenia.

Klimatyzacja

Zasada działania klimatyzatora opiera się na zmianie stanu skupienia czynnika chłodniczego ze stanu ciekłego na gazowy. Czynnik chłodzący nieustannie zmienia stan skupienia oraz swoje ciśnienie. Dzięki temu cały układ może schładzać pomieszczenia. Klimatyzacja stosowana w budynkach podobnie jak pompa ciepła składa się z jednostki wewnętrznej oraz z jednostki zewnętrznej. Rolą jednostki wewnętrznej jest schładzanie pomieszczeń, a jednostka zewnętrzna pełni rolę wymiennika schładzającego czynnika chłodzącego. Dodać należy, że do jednej jednostki zewnętrznej można podłączyć kilka jednostek wewnętrznych. Innym rozwiązaniem stosowanym w budynkowych systemach klimatyzacji są instalacje oparte o systemy wody lodowej. Instalacja taka działa podobnie do instalacji centralnego ogrzewania rozprowadzając po układzie chłodzenia wodę schłodzoną do temperatury najczęściej 5-8° C zasilając klimakonwektory. Przy wykorzystaniu instalacji

wody lodowej zasilane są także chodnice powietrza w systemach wentylacyjnych, gdzie powietrze jest chłodzone przepływając przez chłodnice.

Podsumowanie

Scharakteryzowane pokrótce powyżej zarówno systemy zarządzania bezpieczeństwem oraz komfortem cieplnym, jak i ich komponenty takie jak na przykład źródła ciepła mają wpływ na ilość energii zużywanej przez budynek. Ich cechy wpływają na możliwości ich stosowania w systemach zarządzania komfortem cieplnym w postaci źródeł centralnych lub zlokalizowanych bezpośrednio w pomieszczeniach. Dla budowy systemów utrzymania komfortu cieplnego częściej wykorzystywane są centralne źródła ciepła i chłodu. Źródła te można z sobą integrować tworząc hybrydy lub stopnie grzewcze, aby jak najlepiej wykorzystać energię pochodzącą ze źródeł odnawialnych. Budując systemy zarządzające komfortem cieplnym budynku lub zespołów budynków uzyskujemy oszczędności energii, jednak aby to było możliwe należy zwrócić uwagę na możliwość standaryzacji rozwiązań instalowanych w budynkach z uwzględnieniem aspektów związanych z możliwością integracji różnych rozwiązań oraz zdalnego zarządzania nimi. Zaznaczyć należy, że źródła wykorzystujące jako zasilanie paliwa kopalne nie powinny być stosowane w ramach prowadzonych modernizacji budynków, pomimo możliwości ich integracji z innymi rozwiązaniami.

3.4. Możliwość standaryzacji w zakresie budowy budynków lub ich części oraz ich wpływ na systemy automatyki budynkowej

Budowa nowych budynków lub całych zespołów nieruchomości wymaga zaprojektowania zarówno w aspektach architektonicznych, konstrukcyjnych jak również w zakresie dotyczącym utrzymania komfortu cieplnego, bezpieczeństwa obiektu, zasilania w energię oraz wymagań funkcjonalnych. Przygotowując się do zaprojektowania budynku lub zespołu budynków w taki sposób, aby budynek spełniał wymagania inwestora w zarówno funkcjonalne jak i w zakresie późniejszych kosztów utrzymania etap przygotowania projektu warto podzielić na dwa podetapy: przygotowanie koncepcji architektonicznej oraz wykonanie projektu konstrukcyjnego, projektów instalacji i systemów. Podział taki powoduje, że stawiając wymagania dla wyboru projektanta oraz wymagania ogólne dla projektu możemy na etapie przygotowania koncepcji architektonicznej zwrócić uwagę na wiele aspektów użytkowych budynku i dokonać korekt przed procesem projektowania konstrukcji oraz instalacji. Podejście tego typu jest istotne na etapie przygotowania opisu przedmiotu zamówienia dla projektowania.

Mając na uwadze wymagania inwestora można zestandaryzować oczekiwania w zakresie:

- kompetencji branżowych projektantów wszystkich branż,
- preferencji co do usytuowania budynku lub zespołu budynków,
- preferencji w zakresie wykorzystania działki,
- metodyki oceny zagrożeń i ryzyka oraz strategii w zakresie zastosowań technicznych będących odpowiedzią na te ryzyka,

- wymagań stosowania norm dla systemów zabezpieczenia technicznego budynków - w tym dla zabezpieczeń mechanicznych,
- potrzeby stosowania zabudowy szklanej i zabezpieczeń mechanicznych o odpowiedniej klasie odporności na włamanie,
- możliwości stosowania powłoki elewacyjnej wytwarzającej energię elektryczną,
- kolorystyki oraz możliwości stosowania na przeszkleniach folii wytwarzających energię elektryczną,
- źródeł i typów ogrzewania i chłodzenia,
- możliwości sterowania źródłami ciepła oraz ich integracji z zewnętrznym systemem (w tym wymagań w zakresie protokołów transmisji danych, możliwości sterowania).
- narzędzia IT zarządzającego integrującego systemy zabezpieczenia technicznego budynków oraz systemy utrzymania komfortu cieplnego.

Dla właściwego wdrożenia standardów należy już na etapie przygotowania wytycznych projektowych uwzględnić potrzeby użytkowe, ograniczenie emisyjności budynku, ryzyka wynikające z miejsca posadowienia budynku, planowanej funkcji budynku oraz posiadane zasoby ekonomiczne. Dla właściwego przygotowania ww. wytycznych należy co do zasady:

- uzgodnić przeznaczenie obiektu z głównym użytkownikiem biorąc pod uwagę przeznaczenie poszczególnych części budynku, zasoby przechowywane w tym budynku, procesy, które będą realizowane oraz sposób jego użytkowania,
- zastosować wytyczne związane z lokowaniem budynku lub zespołu budynków, aby efektywnie osiągnąć cele powiązane z możliwie najlepszym pozyskaniem energii ze źródeł odnawialnych,
- określić wymagania w zakresie zarządzania wodą w budynku lub w zespole budynków,
- dokonać analizy ryzyka wynikającego z otoczenia i przekazać standardowe wytyczne dotyczące zabezpieczeń mechanicznych (np. wytyczne dotyczące ogrodzeń, okien, drzwi, stosowania zieleni utrudniającej przejście, itp.),
- przekazać standardowe wytyczne dotyczące zasilania w zakresie ilości linii zasilających miejsc lokowania urządzeń, akumulatorni, stosowania systemów załączenia rezerwy, agregatów prądotwórczych, sposobu i miejsc przyłączenia źródeł energii odnawialnej, sposobu i formy jej gromadzenia, itp.,
- zawrzeć wytyczne dotyczące sieci strukturalnych, radiowych oraz lokowania pomieszczeń technicznych niezbędnych dla zapewnienia bezpieczeństwa w zakresie transmisji oraz gromadzenia danych,
- przekazać dane dotyczące wytycznych standaryzacyjnych dla systemów utrzymania komfortu cieplnego, uwzględniając potrzeby standaryzacji rozwiązań w zakresie telesterowania urządzeniami, interfejsów danych, zakresu niezbędnych danych sterujących i zakresu informacji o błędach. Ponadto należy uwzględnić wytyczne dotyczące stosowania podziału budynku na strefy oraz ewentualne wytyczne dotyczące stosowania urządzeń nierozpraszających np. wirusów podczas uzdatniania powietrza,
- przekazać standardy w zakresie stosowania napięcia gwarantowanego dla zasilania obiektu lub właściwych stref ze szczególnym uwzględnieniem potrzeb związanych z lokowaniem i zasilaniem kontrolerów systemów automatyki budynkowej oraz systemów zabezpieczenia technicznego budynku,

- uwzględnić standard (lub potrzebę) stosowania systemów ppoż. oraz ewentualnego zakresu stosowania rozwiązań dedykowanych dla poszczególnych stref pożarowych uwzględniając realne zagrożenie pożarowe, możliwość rozprzestrzeniania się ognia oraz potrzebę stosowania automatycznego alarmowania odpowiednich służb i systemów gaszenia. W tym przypadku zakres systemu może znacząco wpływać na nakłady potrzebne na jego budowę oraz koszty jego przeglądów, utrzymania i eksploatacji, dlatego należy dokonać szczególnej analizy pod kątem adekwatności stosowanych zabezpieczeń do istotności chronionych zasobów uwzględniając przykładowo kwestię standardowego duplikowania chronionych zasobów (danych),
- przekazać standardy dotyczące podziału na strefy bezpieczeństwa oraz wytyczne związane z zakresem danych niezbędnych dla systemów zabezpieczenia technicznego budynków, biorąc pod uwagę wytyczne dotyczące zabezpieczeń mechanicznych.
- umieścić wymagania związane z organizacją ruchu osobowego oraz kwestiami dostępu do określonych stref i pomieszczeń. Ponadto mając na uwadze bezpieczeństwo należy doprecyzować zakres integracji systemów zarządzania dostępem z narzędziami centralnymi. Należy także przekazać wytyczne dotyczące miejsc administrowania systemami oraz miejsc nadzoru obiektów z wykorzystaniem systemów zabezpieczeń technicznych oraz miejsc dla ochrony i potrzeb technicznych związanych z nadzorem budynku przez ochronę,
- doprecyzować zakres integracji systemów lokalnych z systemami centralnymi oraz zakres danych niezbędnych dla centralnych systemów zarządzających budynkami. W tym przypadku należy przekazać także zakres podziału budynku na ewentualne strefy pomiarowe oraz wymagania w zakresie kontrolera integrującego dane z systemów oraz zakres danych niezbędnych dla integracji,
- doprecyzować standardy dotyczące wyposażenia, w szczególności wyposażenia zbudowanego (np. mebli, wind, itp.),
- doprecyzować wymagania kompetencyjne dla projektantów,
- przekazać standardy w zakresie przygotowania dokumentacji 3D i poziomu jej szczegółowości.

Etap projektowania najlepiej jest podzielić na etapy przygotowania wstępnej koncepcji architektonicznej, z wykorzystaniem której możliwa będzie poprawa właściwości funkcjonalnych budynku, oraz na etap projektowania. Na każdym z etapów przygotowania projektu osoby kompetentne muszą prowadzić dialog z branżystami projektującymi poszczególne warstwy budynku oraz dokonywać odbiorów biorąc pod uwagę stosowanie standardów, lub zaprojektowanie rozwiązań opisanych w wytycznych projektowanych na zasadzie funkcji realizacji konkretnego celu.

Na etapie wyboru wykonawcy należy standaryzować kwestie dotyczące wymagań w zakresie kwalifikacji wykonawców i podwykonawców oraz kwestie związane z trybem postępowania w zakresie kontroli istotnych robót zakrywanych. Ponadto w zakresie właściwego prowadzenia projektu budowlanego niezmiernie istotne jest właściwe określenie standardowych etapów budowy, w tym także kontroli montowanych systemów zasilających, zabezpieczeń, automatyki oraz ich integracji z narzędziami centralnymi.

Podsumowanie

Mając na uwadze powyższe wymagania stwierdzić należy, że standaryzacja i jej zakres jest kluczowy dla właściwego zarządzania zespołami rozproszonych heterogenicznych nieruchomości komercyjnych. Jej zakres wpływa zarówno na właściwości użytkowe budynku jak również na koszty budowy i późniejszego utrzymania. Standaryzacja w zakresie określonych zadań w strukturze planu rzeczowo – terminowo – finansowego wpływa na właściwe zarządzanie ryzykami związanymi z terminowością prowadzenia poszczególnych etapów budowy oraz przyczynia się ograniczenia ryzyka finansowego inwestora w przypadku sporu pomiędzy stronami.

3.5. Wpływ kolejności decyzji zarządczych dotyczących modernizacji zespołów budynków na korzyści finansowe

Mając na uwadze ekonomikę stosowanych rozwiązań oraz dążąc do ograniczenia negatywnego wpływu budynków na środowisko naturalne należy brać pod uwagę w ramach prowadzonych modernizacji budynków kolejność działań, która najbardziej przyczyni się do przyniesienia oszczędności finansowych w zakresie późniejszego utrzymania budynku. Co do zasady w pierwszej kolejności należy brać pod uwagę możliwości ograniczenia strat energii w budynku przy zastosowaniu rozwiązań pasywnych takich jak okna o niskim współczynniku przenikania ciepła, izolacje stropów, piwnic i ścian budynku oraz drzwi. Następnie do właściwej izolacyjności budynku należy dostawać moc źródeł dostarczających ciepło i chłód dla potrzeb budynku, następnie należy dostosować systemy dystrybucji ciepła chłodu i świeżego powietrza oraz zapewnić dostarczenie do budynku możliwie dużej ilości energii odnawialnej wykorzystując w tym zakresie dostępne rozwiązania (Szparkowski, 2017).

W obszarach takich jak przykładowo przygotowanie ciepłej wody użytkowej należy wziąć pod uwagę możliwość akumulacji ciepła. Także w zakresie zarządzania energią elektryczną pożądane jest magazynowanie energii elektrycznej biorąc pod uwagę zarówno potrzeby w zakresie utrzymania ciągłości działania budynku oraz potrzeby związane z obniżeniem kosztów jego funkcjonowania. W następnej kolejności należy brać pod uwagę sterowanie systemami automatyki budynkowej w taki sposób, aby uzyskać oszczędności energii. Takie podejście do modernizacji stanowi niejako klasyczną ścieżkę dla modernizacji przynoszącej wymierne oszczędności ekonomiczne.

Jednak nie w każdym przypadku ścieżka modernizacji opisana powyżej jest właściwa biorąc pod uwagę posiadany budżet. Przykładowo - w budynkach zabytkowych docieplenie elewacji niejednokrotnie wymaga odtworzenia detali architektonicznych, które pochłaniają znaczącą część budżetu, który może być wykorzystany na inne rozwiązania aktywne poprawiające ekonomikę utrzymania budynku. W takim przypadku można pominąć etap modernizacji elewacji, przeznaczając nakłady na inne, przynoszące większe korzyści etapy modernizacji. Kolejnym przykładem, gdzie opisany powyżej schemat podejmowania działań modernizacyjnych można zmienić jest przykład doposażenia węzłów cieplnych w automatykę uzyskując minimalnym kosztem znaczącą poprawę wykorzystania energii zużywanej na utrzymanie budynku (Szparkowski, 2017).

Również dobre efekty ekonomiczne, przy zaangażowaniu małych zasobów daje modernizacja starych układów przygotowania wody użytkowej dla budynku. Wprowadzenie w tym systemie źródeł sterowanych wyposażonych w odpowiednie sekcje grzejne przynosi efekty w postaci obniżenia zużycia energii nawet ponad 50% w stosunku do stanu przed modernizacją. Modernizując budynki należy zawsze brać pod uwagę jeszcze jeden element ściśle powiązany z kosztami eksploatacji budynku – koszt administrowania. Szczególnie w heterogenicznych rozproszonych nieruchomościach komercyjnych jest to niewątpliwie istotny parametr, gdyż ilość wizyt administratora na obiekcie wpływa wydatnie na koszt jego utrzymania. Dlatego modernizując systemy utrzymania komfortu cieplnego budynku oraz systemy zabezpieczenia technicznego budynku – w szczególności zabezpieczenia techniczne o charakterze aktywnym należy przewidzieć możliwość transmisji danych do sterowania i monitorowania zdalnego.

Zakres tych aktywności jest niezmiernie istotny dla zmniejszenia kosztów utrzymania nieruchomości. Jednak – tak jak opisano powyżej nawet proste narzędzia półautomatyczne regulujące i kontrolne przynoszą oszczędności zarówno energii jak również możliwość poprawy efektywności pracy administratorów.

3.6. Wnioski

Zarządzając zespołami heterogenicznych, rozproszonych budynków komercyjnych należy mieć na uwadze indywidualne podejście w zakresie modernizacji konkretnego zespołu nieruchomości, analizując szczególnie zespoły budynków pod kątem stosowanych rozwiązań technicznych oraz możliwości zastosowania usprawnień, przy niskich nakładach niezbędnych dla ich wdrożenia. Biorąc pod uwagę cel polegający na właściwym zalokowaniu nakładów finansowych przy wykorzystaniu pewnych standaryzowanych rozwiązań, lub etapów prac dla projektowania i wdrażania zmiany stwierdzić należy, że przygotowanie pewnej metodyki oraz zestandaryzowanych wymagań wydatnie poprawia proces modernizacji obiektu zmniejszając jednocześnie ryzyka niewłaściwego alokowania nakładów przeznaczonych na modernizację.

Rozdział przedstawia szczegółową analizę systemów ogrzewania, w tym centralnego ogrzewania, klimatyzacji oraz zarządzania ciepłem zewnętrznym, z uwzględnieniem takich źródeł jak kotły gazowe, pompy ciepła, kotły elektryczne oraz wymiennikownie ciepłne. Zawarto również omówienie, w jaki sposób różne źródła energii wpływają na koszty eksploatacji budynków oraz jakie wyzwania niesie za sobą integracja systemów HVAC w nieruchomościach heterogenicznych.

W kontekście zmian technologicznych rozdział podejmuje również zagadnienie predykcji uszkodzeń w systemach automatyki budynkowej, szczególnie w zakresie utrzymania systemów HVAC, które w przypadku niespodziewanych awarii mogą generować duże koszty serwisowe i eksploatacyjne. Przedstawiono tutaj propozycje metod predykcyjnych, które mogą być zastosowane w budynkach wyposażonych w systemy automatyki, w tym BMS (Building Management Systems), aby optymalizować koszty operacyjne oraz zarządzanie ryzykiem technologicznym.

Podsumowując, rozdział wskazuje na konieczność standaryzacji w zakresie stosowanych systemów technicznych oraz metod zarządzania budynkami, szczególnie w kontekście systemów zarządzania komfortem cieplnym i bezpieczeństwem. Zaproponowano tu również podejście ewolucyjne do modernizacji budynków, uwzględniając kolejność podejmowanych działań, które mogą przyczynić się do większej efektywności energetycznej oraz ekonomicznej w kontekście zarządzania nieruchomościami o różnym stopniu złożoności technicznej.

4. Badanie możliwości wykorzystania rozwiązań dla standaryzacji wymagań w zakresie automatyki budynkowej

W celu zbadania możliwości i opłacalności zastosowania metod predykcyjnych i narzędzi sterujących jako rozwiązań powtarzalnych, mogących przynieść korzyści ekonomiczne na etapie wdrożenia, bazując na grupie nieruchomości TAURON Dystrybucja S.A. przeprowadzono badania w następującym zakresie:

- korzyści ze standaryzacji rozwiązań w zakresie sterowania węzłami cieplnymi,
- predykcja konsumpcji mediów, w tym w szczególności energii elektrycznej,
- predykcja uszkodzeń systemów automatyki budynkowej.

Poniższe podrozdziały ukazują wyniki badań i wnioski w każdym z ww. zakresów.

4.1. Sterowanie sieciami cieplnymi

Niniejszy rozdział przygotowany został na bazie własnego artykułu zamieszczonego w „Przeglądzie elektrotechnicznym” .

Wstęp

Optymalizacja kosztów utrzymania budynków przy zachowaniu właściwego środowiska pracy jest dużym wyzwaniem dla firm eksploatujących nieruchomości. Obniżenie kosztów funkcjonowania budynków powinno być realizowane poprzez odpowiednią modernizację dostarczającą narzędzi i rozwiązań dla poprawy parametrów termicznych budynku, optymalizację funkcjonowania systemów utrzymania komfortu termicznego budynku oraz zmianę nawyków użytkowników obiektu.

Modernizacja parametrów termicznych budynków wiąże się ze znaczącym zaangażowaniem środków finansowych w poprawę właściwości termicznych przegród budynków. Aby uzyskać zadowalające efekty należy zastosować odpowiednie materiały posiadające dobre właściwości termiczne, zmodernizować ściany, stropy, wymienić okna, drzwi, zastosować rolety okienne. Wówczas można zmniejszać zapotrzebowanie na energię potrzebną do utrzymania komfortu cieplnego budynku (Ray, Samal and Panigrahi, 2023).

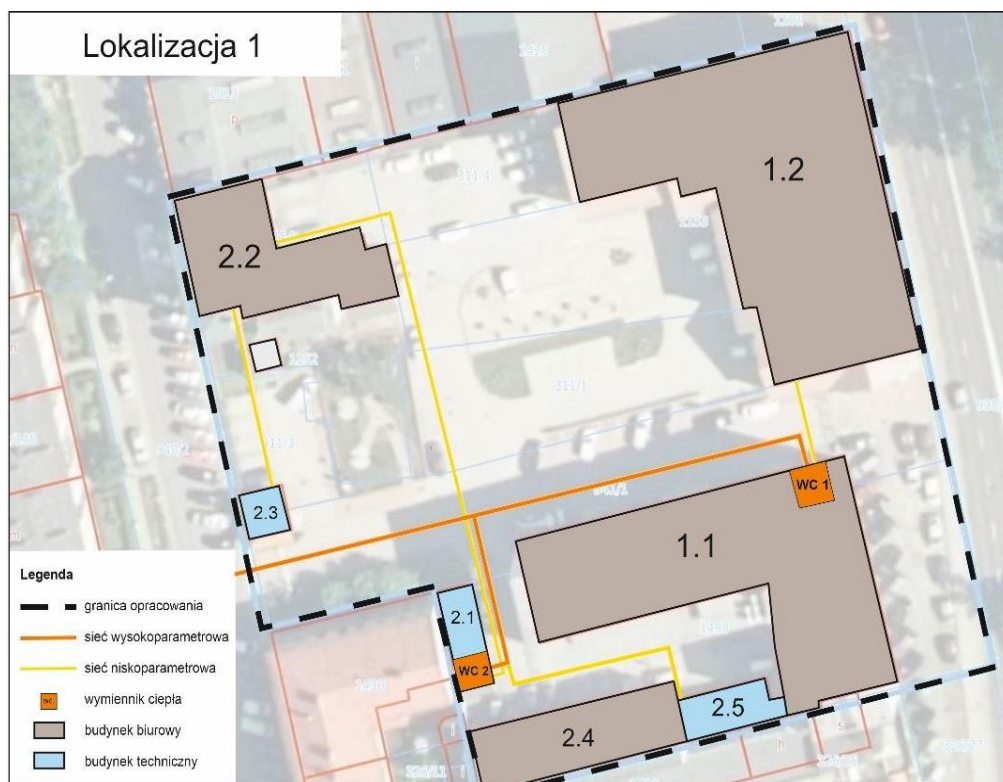
Inną istotną kwestią służącą zapewnieniu dobrej wydajności systemu HVAC i tym samym wpływającą na obniżenie zużycia energii niezbędnej dla utrzymania komfortu cieplnego budynku jest wydajność systemu sterowania systemem HVAC. Sterowanie jest niezbędne dla działania systemów HVAC i można je podzielić na lokalne sterowanie i nadzór oraz kontrolę. Lokalne sterowanie służy do śledzenia predefiniowanych wartości zadanych dla lokalnych procesów i realizowany może być z wykorzystaniem algorytmów takich jak PI/PID, sterowanie rozmyte, lub sterowanie predykcyjne. Kontrola w czasie rzeczywistym, jako kontrola nadzorcza, jest skutecznym narzędziem poprawy efektywności energetycznej systemów HVAC. Zużycie energii lub koszty operacyjne systemów HVAC są wykorzystywane jako funkcje kosztowe, które należy zminimalizować lub zmaksymalizować. Opisane zostały relacje pomiędzy zmiennymi decyzyjnymi (takimi jak nastawy dla lokalnych pętli sterowania) a funkcją kosztu oraz w celu optymalizacji wykorzystania energii i tym samym optymalizacją kosztów energii (Hou *et al.*, 2022b).

Kolejnym czynnikiem wpływającym na zużycie energii niezbędnej dla utrzymania komfortu cieplnego są zachowania użytkowników budynku. Użytkownicy budynków mogą ze względu na swoje nawyki otwierać okna wpływając tym samym na zwiększenie zużycia energii. Poznanie realistycznych zachowań użytkowników pozwala lepiej zrozumieć wpływ użytkowników na zużycie energii potrzebnej dla utrzymania komfortu cieplnego budynku (Belafi, Hong and Reith, 2017b). Oprócz zachowań użytkowników mających wpływ na zużycie energii należy brać pod uwagę kwestię obłożenia budynku w danym czasie. Informacja o obłożeniu budynku przekazana do systemu sterowania wpływa także na obniżenie energii zużywanej do utrzymania komfortu cieplnego. Dostosowanie harmonogramów pracy systemów HVAC do zadań realizowanych przez użytkowników oraz stałego utrzymania komfortu cieplnego wpływa na długofalowe oszczędności energii (Bagheri-Esfeh and Dehghan, 2022).

Opis badanego obiektu

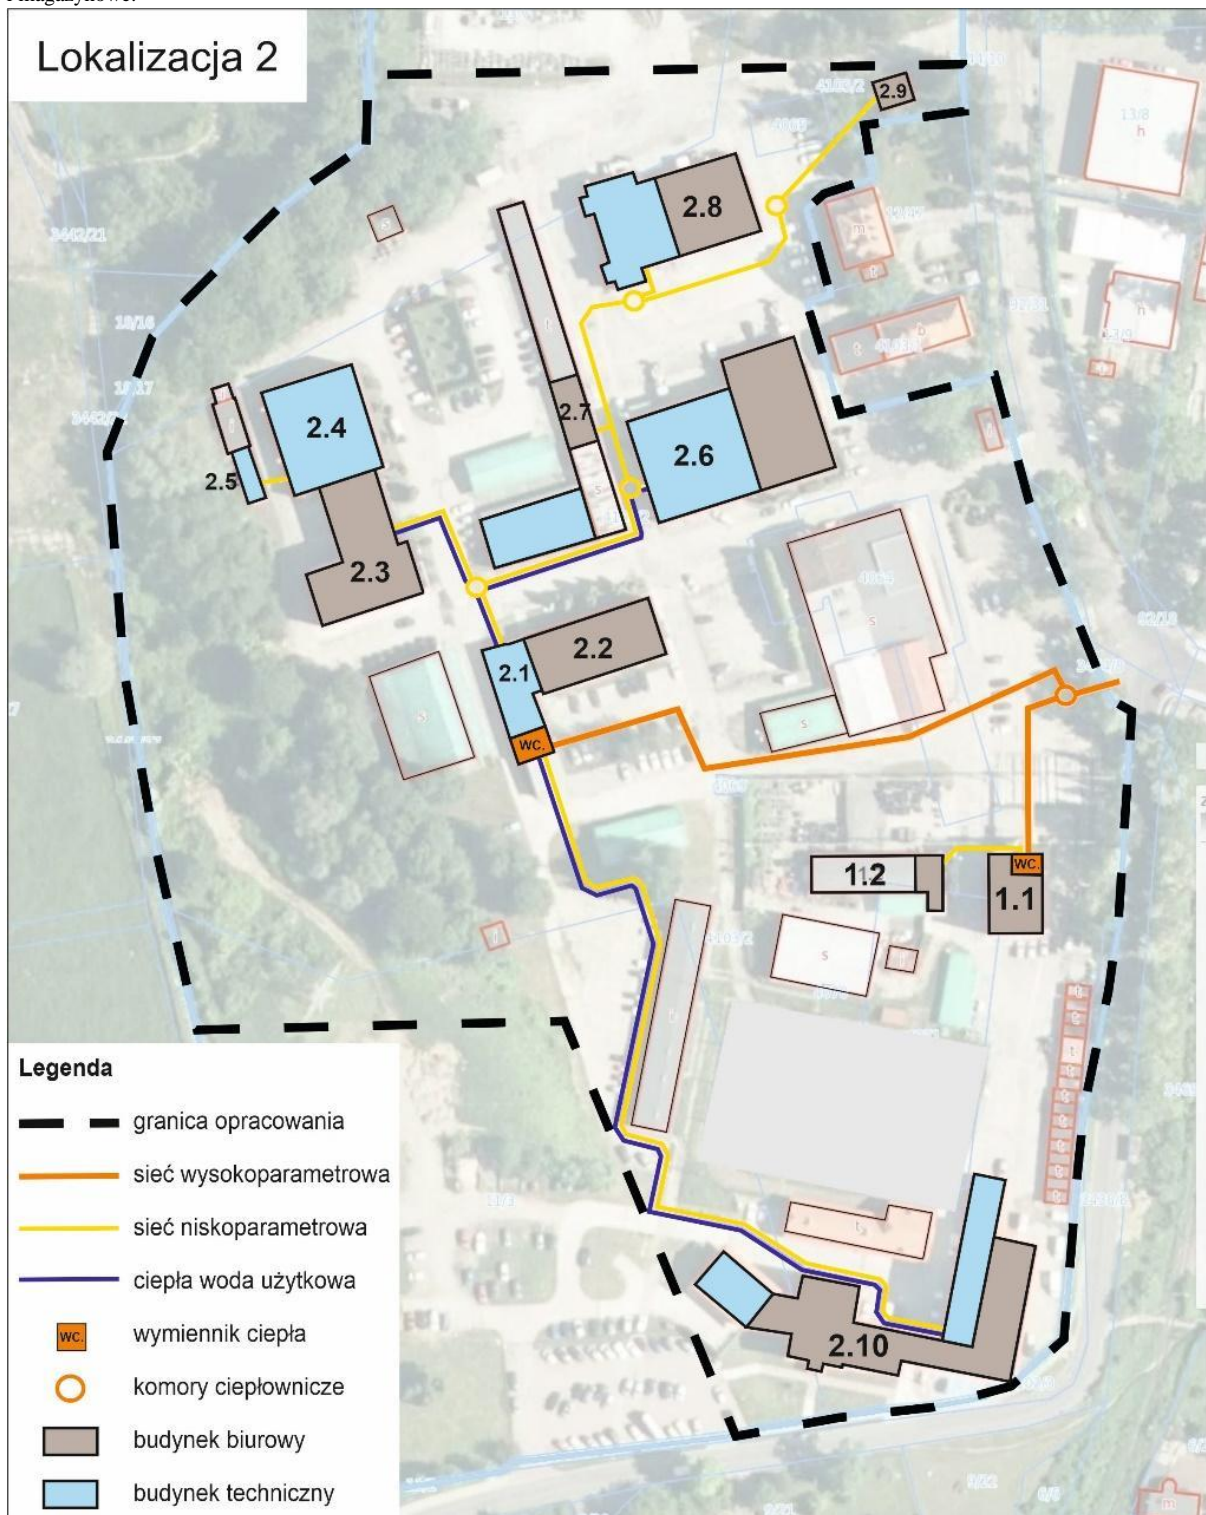
Badania wpływu zdalnego sterowania komfortem cieplnym na zróżnicowanych nieruchomościach komercyjnych przeprowadzono na przykładzie obiektów zlokalizowanych w południowej Polsce w obszarze województwa śląskiego. W celu przeprowadzenia obserwacji i pomiarów w pierwszym etapie prowadzenia badania wytypowano zespół budynków położonych w dwóch różnych miastach w Obszarze Podbeskidzia. Wytypowano do badań złożone obiekty (lokalizacje) realizujące zadania budynków biurowych oraz warsztatowo – magazynowych. Wszystkie opisywane lokalizacje zasilane są z miejskich sieci ciepłowniczych. Miejscem dostarczenia energii cieplnej przez dostawcę są wymiennikownie centralne dla danej lokalizacji. Poszczególne budynki w każdej z lokalizacji zasilane są z wymiennikowni centralnej wewnętrznymi rurociągami, które doprowadzają ciepło do wymiennikowni poszczególnych budynków, gdzie jest ono rozprowadzane do lokalnych systemów ciepłowniczych. Rysunki 1 i 2 obrazują dwie z badanych lokalizacji.

Rysunek 1. Zespół budynków użyty do przeprowadzenia analizy zawierający głównie budynki biurowe



Źródło: opracowanie własne

Rysunek 2. zespół budynków użyty do przeprowadzenia analizy zawierający budynki realizujące funkcje biurowe, warsztatowe i magazynowe.



Źródło: opracowanie własne

Jak widać na rysunkach 1 i 2 badane obiekty posiadają różną ilość budynków realizujących różne funkcje użytkowe. W zależności od przeznaczenia budynku niektóre budynki realizują dwie funkcje – biurową oraz warsztatową lub magazynową. W każdym z omawianych budynków rozprowadzone zostały instalacje centralnego ogrzewania oparte

o system grzejników konwekcyjnych, utrzymujących temperatury dostosowane do funkcji realizowanej przez dany budynek lub jego część.

We wszystkich badanych lokalizacjach budynki zbudowane zostały w różnych okresach począwszy od wczesnych lat dwudziestego wieku skończywszy na budynkach wybudowanych na początku dwudziestego pierwszego wieku. Taka rozpiętość w zakresie lat budowy budynków powoduje, że posiadamy populację obiektów wykonanych w różnych technologiach, z użyciem różnorodnych materiałów konstrukcyjnych oraz w różnym stopniu zmodernizowanych termicznie. Tabela 1 stanowi zestawienie podstawowych paramentów technicznych obiektów przedstawionych na rysunkach 1 i 2.

Tabela 1. Charakterystyka podstawowych parametrów technicznych obiektów przedstawionych na rysunkach 1 i 2.

Oznaczenie na mapie	Funkcja budynku/ogrzewanej części budynku	Zasilanie z wymiennika	Rok budowy	Powierzchnia użytkowa	Ilość kondygnacji	Konstrukcja ścian	Ocieplenie ścian	Dach	Stolarka okienna i drzwiowa
1.1	budynek biurowy	W1	1963	3056,47	5	murowana cegła/pustak	Styropian 10 cm	strop monolityczny żelbetowy, dach z płyt korytkowych krytych papą	PCV, AL. i drewniana
1.2	budynek biurowy	W1	1910	1206,37	3	murowana cegła pełna	Brak	strop żelbetowy kryty blachą	drewniana i stalowa
2.1	budynek techniczny	W2	1946	36,92	1	murowana	Styropian 10 cm	stropodach kryty papą	drewniana i stalowa
2.2	budynek biurowy	W2	1910	689,44	4	murowana	Brak	strop drewniany kryty blachą	drewniana i AL.
2.3	budynek biurowy	W2	1947	23,32	1	murowana cegła pełna	Brak	strop drewniany kryty dachówką ceramiczną	drewniana
2.4	budynek biurowy	W2	1924	339,28	2	murowana cegła	Styropian 10 cm	strop żelbetowy kryty papą	PCV i AL.
2.5	budynek techniczny	W2	1952	49,34	1	murowana siporeks	Brak	blacha trapezowa T-35	drewniana
1.1	budynek biurowo-techniczny	W1	1951	764,00	4	konstrukcja żelbetowa wykonana na mokro, ściany cegła pełna	Styropian 10 cm	żelbetowy, docieplony, pokrycie z papy	PCV, drewniana i AL.
1.2	budynek biurowy	W1	1965	254,00	1	pustak gazobetonowy	Brak	dach w konstrukcji stalowej, płyty żelbetowe dachowe kryte papą	PCV
2.1	budynek techniczny	W2	1965	294,45	1	tradycyjna cegła ceramiczna pełna	Brak	strop monolityczny gęsto żebrowany typu DZ, kryty papą	

2.2	budynek biurowy	W2	1965	678,12	2	murowana cegła pełna	Brak	strop monolityczny gęsto żebrowany typu DZ	
2.3	budynek biurowy	W2	1982	403,79	2	tradycyjna, pustak	Brak	strop z płyt kanałowych w izolacji termicznej	PCV, drewniana i AL.
	budynek biurowy	W2	1982	859,79	3	konstrukcja żelbetowa	Brak	żelbetowe płyty panwiowe ocieplone wełną min.15cm, kryty papą	drewniana i AL.
2.4	budynek techniczny	W2	1982	501,83	2	konstrukcja żelbetowa	Styropian 10 cm	strop w konstrukcji stalowej z belek dwuetowych, kryty blachą trapezową z ociepleniem,	stalowa (ocieplana) i AL.
2.5	budynek techniczny	W2	2002	48,46	1	tradycyjna	Styropian 10 cm	blacha trapezowa ocieplona wełną mineralną	stalowa
2.6	budynek biurowo-techniczny	W2	1979	1451,68	2	konstrukcja żelbetowa	Brak	płyty dachowe panwiowe, dach kryty papą	drewniana i metalowa
2.7	budynek biurowy	W2	2004	81,40	1	murowana cegła pełna	Styropian 10 cm		
2.8	budynek techniczny	W2	1980	175,00	1	konstrukcja żelbetowa, ściany z pustaków PGS, fragment osłonięty blachą trapezową	Brak		AL.
	budynek techniczny	W3	1980	313,73	1	konstrukcja żelbetowa	Brak	płyty dachowe panwiowe, dach kryty papą	
	budynek techniczny	W4	1980	195,78	1	konstrukcja żelbetowa	Brak	płyty dachowe panwiowe, dach kryty papą	
2.9	budynek biurowy	W2	1980	37,20	1	murowane gazobeton	Brak	strop z płyty P2 kryty papą na lepiku	drewniana
2.10	budynek biurowo-techniczny	W2	1954	2666,18	3	przyziemie żelbetowe i w części z betonu B-15, pozostałe murowane cegła pełna 25cm+styropian 3cm+cegła dziurawka 12cm	Brak	strop żelbetowy monolityczny żebrowo-płytkowy, więźba drewniana, pokrycie dachówka typu alpejskiego	drewniana, stalowa i AL

Źródło: opracowanie własne

Opis zastosowanego narzędzia (systemu)

Narzędzie niezbędne do realizacji celów związanych z optymalizacją kosztów powinno umożliwiać zdalną regulację parametrów węzłów zasilających, funkcjonujących w wielu lokalizacjach z użyciem łączności internetowej i z wykorzystaniem przeglądarki internetowej. Ponadto powinno umożliwiać realizację zmian charakterystyki grzewczej oraz przepływu wody w możliwie najprostszy sposób. Po analizie dostępnych rozwiązań wybrano system z regulatorami TRAVOS.

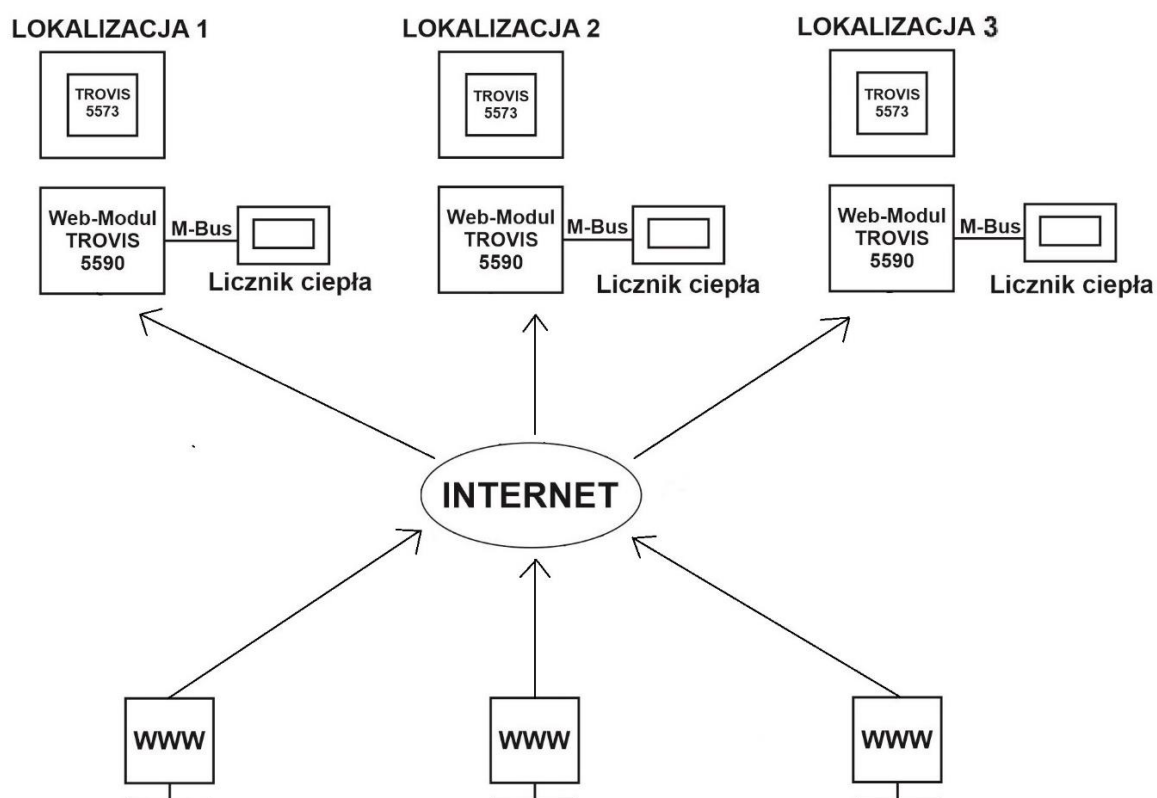
W wyniku wdrożenia wybranego rozwiązania, w celu uzyskania możliwości zdalnego sterowania węzłami cieplnymi istniejące regulatory pogodowe zastąpiono regulatorami TROVIS 5573-1, które mogą sterować węzłami jedno- i dwufunkcyjnymi (co + cwu).

Przedstawione rozwiązania telemetrii węzłów cieplnych umożliwiają zarówno podgląd, jak i zdalną zmianę parametrów. Użytkownik posiada dostęp do danych bieżących, historycznych i alarmów.

W każdym obiekcie zastosowany został moduł telemetryczny Web-Moduł TROVIS 5590-1 będący serwerem WWW, zapewniającym bezpieczny dostęp do danych z nielimitowanej liczby komputerów wyposażonych w przeglądarkę internetową. Web-Moduł TROVIS 5590-1 pozwala na podłączenie regulatora pogodowego TROVIS 5573-1 oraz maksymalnie 6 liczników ciepła wyposażonych w moduł komunikacji M-Bus.

Poniżej przedstawiono schemat ideowy zastosowanego rozwiązania.

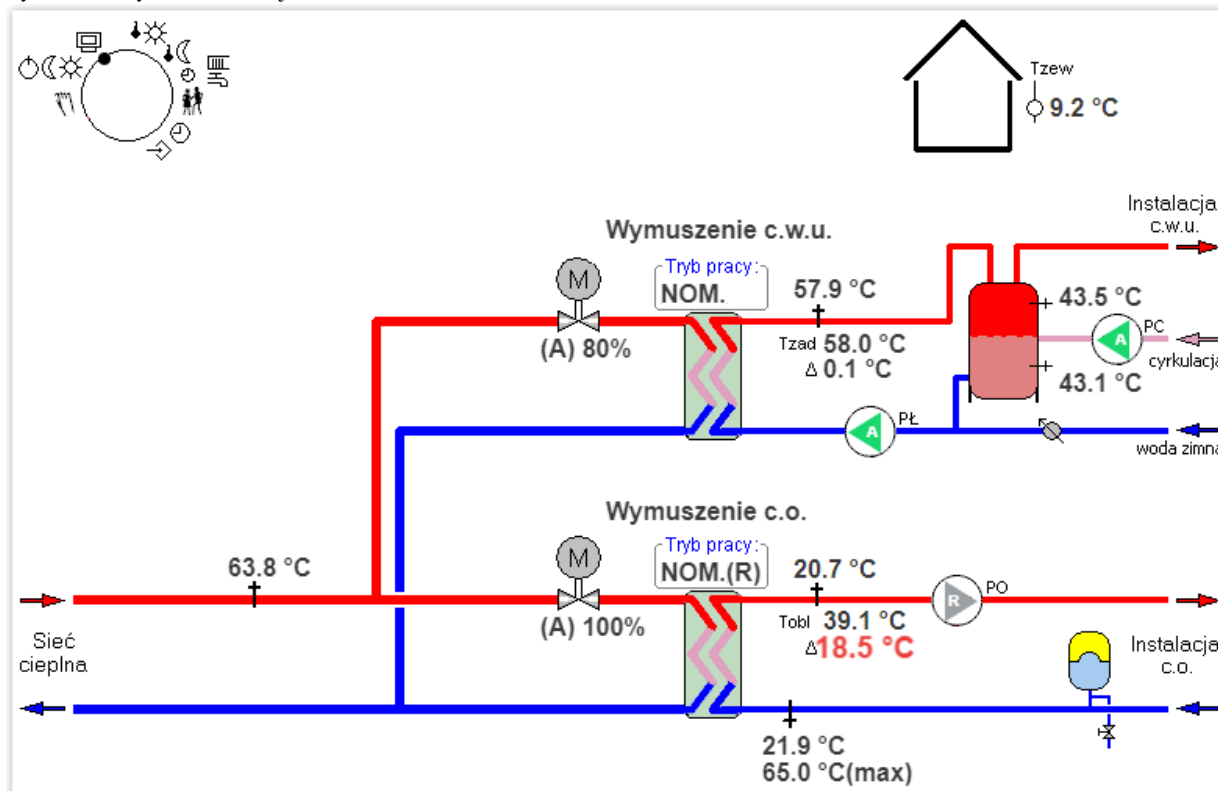
Rysunek 3. schemat ideowy systemu telemetrii węzłów cieplnych.



Źródło: opracowanie własne

Na potrzeby telemetrii w wymiennikowni zastosowano moduł telemetryczny Modbus IO. Moduły telemetryczne Modbus IO podłączono do odpowiedniego modułu komunikacyjnego: Web-Modul TROVIS 5590-1. Jeżeli w wymiennikowniach występowały liczniki ciepła, zostały one będą doposażone w płytki MBus i podłączone do systemu. Proponowane rozwiązanie pozwala na podgląd parametrów wymiennikowni.

Rysunek 4. Przykład wizualizacji Web-Modul TROVIS 5590-1 8



Źródło: program „Web-Modul-Editor”

Opis metod regulacji

Przed wdrożeniem opisywanego w powyższym rozdziale rozwiązania regulacja temperatury obiektów sprowadzała się do ustawienia przepływu wody obiegowej w taki sposób, aby w najgorzej docieplonym obiekcie w danej lokalizacji uzyskać wymagane przepisami prawa temperatury. W zależności od lokalizacji oraz ilości węzłów centralnych (wysokociśnieniowych) regulacja prowadzona była dla wszystkich obiektów centralnie (jeden węzeł wysokociśnieniowych dla wszystkich budynków) lub odrębnie dla części budynków podpiętych do tego samego węzła obiektu.

Pomiar temperatury prowadzony był lokalnie. Działania wyżej opisane prowadzone były lokalnie i wymagały wizyty administratora, który cyklicznie z częstotliwością zależną od zmian temperatury większych niż 10°C dokonywał regulacji nastaw.

Działanie takie powodowało, że budynki posiadające znacząco lepsze właściwości izolacyjne były w większości czasu przegrzane.

Przegrzanie budynku wpływa na zachowania użytkowników. W przypadku powierzchni biurowych użytkownicy obniżali lub odcinali temperaturę z wykorzystaniem dostępnych regulatorów, a następnie otwierali okna. Nie obserwowano załączania klimatyzacji w okresie zimowym.

W przypadku budynków warsztatowych lub magazynowych użytkownicy nie używali kurtyn cieplnych redukujących dopływ zimnego powietrza podczas otwarcia bram wjazdowych, a czas otwarcia bram był dużo dłuższy niż wymagały tego konkretne potrzeby.

Działanie takie powodowało nadmierne zużycie energii.

Obecna metoda regulacji polega na połączeniu doświadczenia administratora obiektu oraz możliwości sterowania zdalnego. Dla sterowania systemami cieplnymi wykorzystuje się prognozę pogody oraz zdalne pomiary temperatury zewnętrznej i wewnętrznej w budynkach. Nadal sterowanie prowadzone jest na węźle centralnym zasilającym część lub wszystkie budynki w danej lokalizacji. Polega ono na regulacji temperatury czynnika roboczego niskiego parametru na wyjściu wymiennika.

Zmiana sterowania polega na zastosowaniu narzędzia umożliwianego administratorowi obiektu zdalną regulację nastaw, ich kontrolę, zmianę charakterystyki grzewczej oraz gromadzenie danych historycznych.

Pozyskane w narzędziu dane umożliwiają analizę wpływu temperatury zewnętrznej na odbiór ciepła z węzła cieplnego. Analizując różnice temperatury można dokonywać regulacji przepływu czynnika, tak aby różnica temperatur na zasilaniu i powrocie do wymiennika po stronie niskiego ciśnienia oscylowała w granicach 10°C. Wówczas budynki odbierają ciepło i nie następuje ich przegrzanie. Gdy różnica temperatury zasilania i powrotu jest mniejsza od 5°C należy dokonać zmiany przepływu zaworem regulacyjnym.

Przykład regulacji temperaturowej na węzłach cieplnych w analizowanych obiektach obrazuje poniższa tabela.

Tabela 2. dobór charakterystyk grzewczych, stopnia otwarcia zaworów regulacyjnych przepływu oraz charakterystyki grzewczej przy temperaturach zewnętrznych poniżej - 10°C na węzłach cieplnych badanych obiektów.

lokalizacja	Temp. Zasilania [°C] (Dostawca)	Temp. Zasilania [°C] (Odbiorca)	Temp. powrotu [°C]	Różnica [°C]	Otwarcie zaworu [%]	Krzywa grzania
1A	105,5	76,2	65,0	11,2	54,0	1,6
1B	87,8	79,0	65,9	13,1	100,0	1,4
2	105,5	74,0	65,1	8,9	100,0	1,4
3	105,4	46,4	43,1	3,3	100,0	2,0
4A	105,4	74,2	65,4	8,8	100,0	1,4
4B	105,4	68,3	58,4	9,9	81,0	1,1

Źródło: opracowanie własne

W celu właściwego doboru nastaw w zakresie stopnia otwarcia zaworu zasilającego oraz doboru charakterystyki grzewczej niezbędne jest uzyskanie doświadczenia przez osobę dokonującą regulacji. Oprócz doświadczenia w zakresie obsługi narzędzia związanego

z przygotowaniem stref czasowych niezbędnym jest poznanie dobowego i tygodniowego cyklu pracy budynków w danej lokalizacji, a co za tym idzie potrzeb użytkowników. W badanych obiektach, w celu rozpoznawania możliwości ułożenia harmonogramów automatycznej regulacji temperatury zanalizowano: godziny pracy pracowników biurowych, oraz potrzeby w zakresie statystycznej długości pracy w nadgodzinach, czas pracy serwisów sprzątających, zakres budynków i pomieszczeń w których praca prowadzona jest zmianowo, zakres działań realizowanych na poszczególnych zmianach i na tej podstawie zostały przygotowane harmonogramy sterowania temperaturą w zakresie godzinowym poszczególnych dni tygodnia.

Pierwotnie harmonogramy te przygotowane zostały w uzgodnieniu z kluczowymi użytkownikami obiektów, zakładając nagrzanie budynków w przestrzeniach biurowych do 22°C, a następnie iteracyjnie zostały doprecyzowane – głównie w kierunku zmniejszenia temperatury. Ustalanie optymalnych parametrów regulacyjnych prowadzone było we współpracy z głównymi użytkownikami obiektów. Na podstawie powyżej opisanych prac ustalono dla badanych obiektów podstawowe czynności regulacyjne, które powinny być podejmowane przy tworzeniu harmonogramów regulacji temperatury.

Tabela 3. Czynności regulacyjne wpływające na zmiany harmonogramów grzewczych

L.p.	Nazwa parametru	Wartości w badanym układzie	Czynności regulacyjne
1.	T-zewn. Wyłączenie C.O. dla dnia	15,0°C	Korekta tego parametru następuje w zależności od prognozy pogody przyjmuje się okres max. 7 dni.
2.	T-zewn. Wyłączenie C.O. dla nocy	10,0°C	Korekta tego parametru następuje w zależności od prognozy pogody przyjmuje się okres max. 7 dni.
3.	Krzywa grzania - nachylenie	1,2°C	Przedział nachylenia krzywej grzania dla omawianego układu w zakresie od 1,0-1,2 w badanym okresie
4.	Krzywa grzania - przesunięcie	0,0°C	Należy przesunąć ją w górę, pamiętając jednak, że każda zmiana grzania o 1 st. wiąże się ze wzrostem zużycia ciepła. W sytuacji, gdy temperatura odczuwalna wystarczająco się podniesie należy wybrać krzywą o większym nachyleniu.
5.	Maksymalna Temp. Zasilania C.O.	90,0°C	Parametry zależne od typu układu zasilania
6.	Minimalna Temp. Zasilania instalacji C.O.	20,0°C	Parametry zależne od typu układu zasilania


7.	Programy czasowe	Godz. 3.30 – temperatura załączenie	Czas załączenia i wyłączenia układu dobrany empirycznie na podstawie analizy zużycia ciepła przez obiekty
		Godz.21.30 temperatura wyłączenie	

Źródło: opracowanie własne

Analiza mocy zamówionej dla obiektów oraz redukcja kosztów

W wyniku wprowadzonych zmian w systemie sterowania po okresie jednego sezonu dokonano zmiany mocy cieplnej dla analizowanych obiektów. Zakres zmian mocy cieplnej przedstawiono na poniższym wykresie.

Rysunek 5. Zamówiona moc cieplna w wybranych lokalizacjach w latach 2016-2017




Źródło: opracowanie własne

Redukcja mocy cieplnej dla analizowanych obiektów kształtowała się w zakresie 16 – 52% mocy cieplnej zamawianej przed dokonaniem zmiany. Przy czym tylko w dwóch z pięciu analizowanych lokalizacji zmiana mocy zamówionej kształtowała się na poziomie kilkunastu procent.

Zmiana mocy zamówionej powodowała redukcję kosztów utrzymania obiektów o ponad 1600 tys. zł w pierwszym roku funkcjonowania systemu. Redukcje kosztów w podziale na lokalizacje prezentuje poniższy wykres.

Rysunek 6. Oszczędność z tytułu obniżenia mocy zamówionej w wybranych lokalizacjach (po stałych cenach za MW w latach 2016-2017)



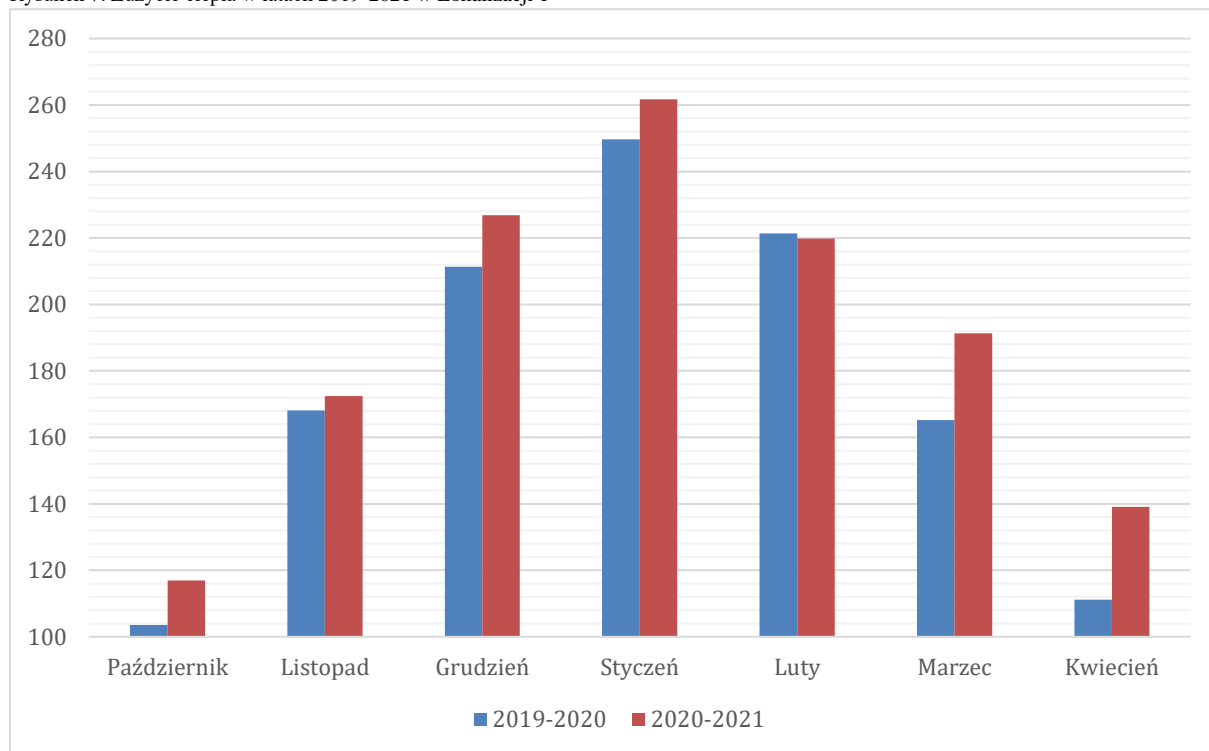
Źródło: opracowanie własne

Sezon zimowy 2016/2017 na podstawie średnich temperatur podawanych przez IMiGW jest porównywalny z zimą 2012/2013 - ze średnią temperaturą około minus 2C. Sezony poprzedzające wg danych IMiGW były w Polsce najcieplejszymi w ostatnim dwudziestoleciu, z temperaturami dodatnimi. Telemetria węzłów CO w analizowanych lokalizacjach: 1; 3; 4A i 4B działa od 01.01.2017 r. Z uwagi na powyższe możliwy porównywalny okres I kwartał 2013 r. do I kwartał 2017 r.

Analiza wykazała, że zabudowa telemetrii węzłów CO miała wpływ na obniżenie zużycia energii CO o **1 265,87 GJ** - o wartości **52 182,85 zł** wg cen dostawców z 2017 r. Zabudowa telemetrii węzłów CO koszt **34 900,00 zł**. Wartość spadku zużycia energii w pełni pokrywa poniesione nakłady.

W celu weryfikacji danych uzyskanych w pierwszych latach funkcjonowania systemu przeprowadzono analizę zużycia ciepła dla dwóch dużych lokalizacji, w których dokonano znaczących redukcji mocy zamówionej. Zestawienie danych związanych z mocą zużywaną w sezonach grzewczych 2019/2020 oraz 2020/2021 pokazano na poniższych wykresach.

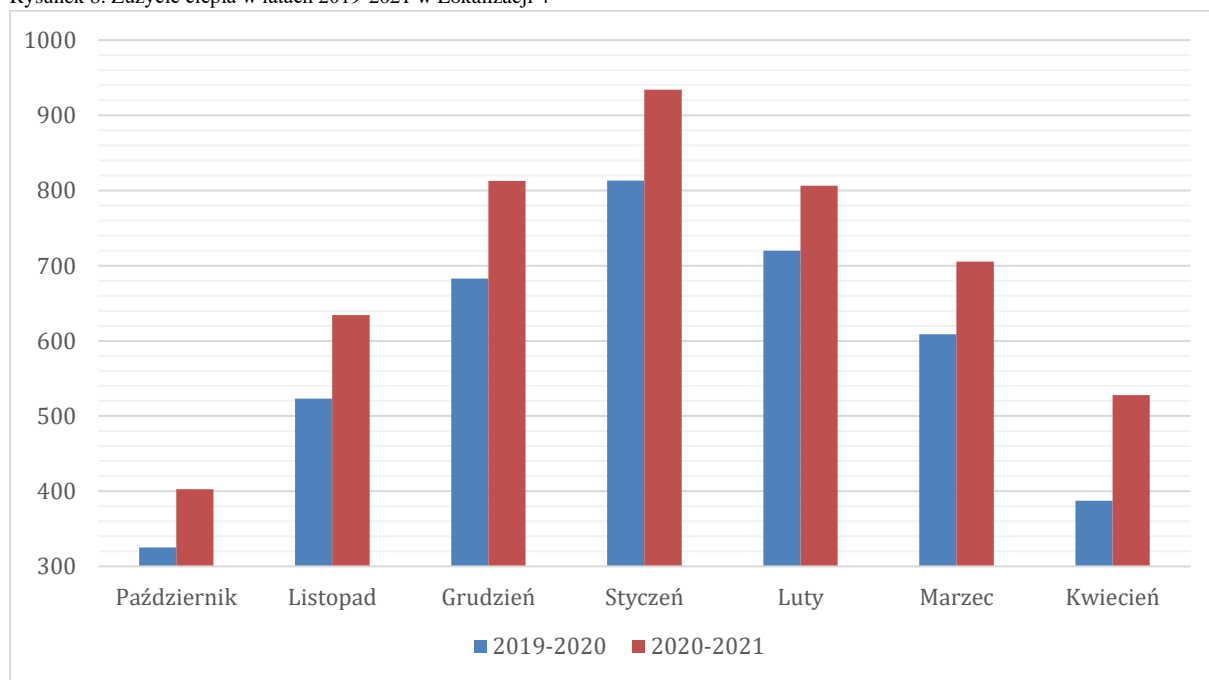
Rysunek 7. Zużycie ciepła w latach 2019-2021 w Lokalizacji 1



	Październik	Listopad	Grudzień	Styczeń	Luty	Marzec	Kwiecień
2019-2020	103,53	168,07	211,35	249,7	221,36	165,24	111,21
2020-2021	116,99	172,42	226,81	261,73	219,82	191,29	139,14

Źródło: opracowanie własne

Rysunek 8. Zużycie ciepła w latach 2019-2021 w Lokalizacji 4



	Październik	Listopad	Grudzień	Styczeń	Luty	Marzec	Kwiecień
2019-2020	325,26	523,33	682,68	813	720	608,89	387,13
2020-2021	402,8	634,34	812,66	934,08	806,46	705,4	527,69

Źródło: opracowanie własne

Analizując powyższe dane należy stwierdzić, że zamówiona w latach poprzednich moc jest nadal wystarczająca dla sprawnego funkcjonowania obiektów, co potwierdza jej właściwy dobór oraz sprawność opisywanych powyżej prostych systemów i metod regulacji temperatury. Dodać należy, że analizowane lokalizacje nie zostały zmodernizowane termicznie.

Wnioski

W wyniku przeprowadzenia zmian sposobu sterowania węzłami cieplnymi wprowadzonymi w 6 różnorodnych zespołach budynków położonych w południowej części Polski zaobserwowano spadek zużycia energii w każdej z nich. Spadek zużycia energii kształtował się w granicach 12 -50% i był wynikiem eksperymentalnego dostosowania charakterystyk grzewczych przez administratora do odczuć użytkowników oraz różnych funkcji realizowanych przez poszczególne budynki, lub ich części.

Fakt zmniejszenia mocy przyłączeniowych dla poszczególnych obiektów wpływa korzystnie na efekty finansowe realizowanego przedsięwzięcia. W dużych miastach zmniejszenie mocy przyłączeniowej przez odbiorcę może być także korzystne dla dostawcy ciepła, ze względu na możliwość lepszego wykorzystania posiadanej infrastruktury sieciowej dla obsługi większej ilości odbiorców.

Stołość wyników została potwierdzona analizą wyników prowadzoną w okresie 3 lat i dowiodła możliwości obniżenia kosztów średnio o 32% na badanych budynkach, bez potrzeby ponownej korekty mocy umownej oraz bez przeprowadzenia termomodernizacji. Biorąc pod uwagę nakłady poniesione na wdrożenie zaproponowanego rozwiązania, koszty związane z utrzymaniem systemu oraz czas życia systemu zaplanowany na 8 -10 lat stwierdzić należy, że w stosunku do poniesionych nakładów przedsięwzięcie przynosi dobre efekty ekonomiczne.

Biorąc pod uwagę fakt, że przy poniesieniu nieznacznych nakładów, można uzyskiwać znaczące efekty ekonomiczne podejście tego typu może zostać sukcesywnie wykorzystane w innych budynkach przed wykonaniem gruntownej modernizacji substancji budynku poprawiającej przenikalność cieplną ścian. Ponadto nie bez wpływu na straty ciepłe są zachowania użytkowników obiektów. Administrator zarządzając przy użyciu prostego oprogramowania procesem ogrzewania budynku, może dobrać i ustabilizować temperaturę bez zmiany przyzwyczajzeń oraz wprowadzania znaczących nakładów w taki sposób, że użytkownicy będą posiadali wymagany komfort cieplny, a ilość energii zużywanej do ogrzewania budynków zostanie ograniczona.

Dodać należy, że modernizując dodatkowo obiekt w zakresie poprawy pasywnych parametrów przenikalności cieplnej budynku można poprawić opisywane powyżej efekty. W takim przypadku, posiadany system pozwoli na sprawne monitorowanie zużywanej energii oraz przygotuje realne dane umożliwiające modyfikację zaprojektowanego zapotrzebowania na moc podczas wprowadzanej zmiany w budynku w zakresie dodatkowego pomniejszenia mocy wykorzystując możliwości regulacyjne systemu prowadzone przez administratora dostosowującego elastycznie nastawy do potrzeb użytkowników budynku.

Na podstawie przeprowadzonej analizy można potwierdzić tezę, że zmniejszenie kosztów przekłada się na redukcję CO₂, co w warunkach Polski - gdzie znaczna ilość energii

służącej ogrzewaniu budynków pozyskiwana jest nadal z paliw kopalnych, ma istotne znaczenie.

Kolejnym etapem badań w zakresie zarządzania węzłami cieplnymi mogą być rozważania nt. rozwoju analizy i predykcji uszkodzeń urządzeń automatyki węzłów cieplnych.

4.2. Środowisko użyte do budowy narzędzia do predykcji

W opisywanym projekcie zastosowano zestaw narzędzi i technologii, które zapewniają nie tylko dokładność i niezawodność modelu, ale także łatwość jego wdrożenia i utrzymania. Poniżej znajduje się szczegółowy opis środowiska, w którym model został opracowany.

Technologie i narzędzia wykorzystane do budowy narzędzia do predykcji to:

- Python:
 - Python jest wysokopoziomowym językiem programowania, który dzięki swojej prostocie i wszechstronności stał się standardem w dziedzinie analizy danych i uczenia maszynowego.
 - Biblioteki: Do budowy modelu predykcyjnego wykorzystano popularne biblioteki takie jak Pandas, NumPy, scikit-learn oraz TensorFlow/Keras (w zależności od złożoności modelu).
- Docker:
 - Docker jest platformą do tworzenia, dystrybucji i uruchamiania aplikacji w kontenerach. Dzięki Dockerowi, możliwe było zapewnienie spójnego środowiska uruchomieniowego niezależnie od maszyny, na której model był uruchamiany.
 - Zastosowanie: Użyto Dockerfile do zdefiniowania obrazu kontenera, który zawiera wszystkie niezbędne zależności, biblioteki oraz konfiguracje środowiska. Dzięki temu cały proces budowy, testowania i wdrażania modelu był zautomatyzowany i replikowalny.
- IDE Anaconda:
 - Anaconda jest środowiskiem programistycznym dedykowanym naukowcom danych i analitykom. Zawiera setki popularnych bibliotek i narzędzi do analizy danych oraz uczenia maszynowego.
 - Zastosowanie: Kod modelu predykcyjnego był pisany i testowany w Anaconda IDE (Spyder lub Jupyter Notebook). Anaconda zapewniała łatwe zarządzanie pakietami i wirtualnymi środowiskami, co znacząco ułatwiło proces programowania i testowania modelu.
- Streamlit:
 - Streamlit to framework open-source do szybkiego tworzenia interaktywnych aplikacji webowych w Pythonie, które są szczególnie przydatne do wizualizacji danych i wyników modeli uczenia maszynowego.

- Zastosowanie: Do wizualizacji danych oraz prezentacji wyników modelu predykcyjnego wykorzystano Streamlit. Umożliwiło to stworzenie interaktywnego interfejsu użytkownika, gdzie można było w prosty sposób przeprowadzać eksplorację danych, weryfikację wyników modelu oraz testowanie różnych scenariuszy predykcyjnych.

Środowisko do budowy modelu predykcyjnego zostało skonstruowane z wykorzystaniem najnowocześniejszych narzędzi i technologii, zapewniających wysoką jakość kodu, łatwość zarządzania zależnościami oraz replikowalność procesu budowy modelu.

4.3. Narzędzie do gromadzenia danych oraz rozwoju w zakresie predykcji

W celu stworzenia narzędzia do prognozowania uszkodzeń jako systemowej platformy bazowej wykorzystano istniejący system monitoringu obiektów budowlanych, zwanych również systemami zabezpieczenia technicznego, o nazwie SCSWin.

Ogólny opis systemu monitoringu infrastruktury technicznej

System monitoringu infrastruktury technicznej składa się z dwóch głównych elementów:

1. Urządzeń kontrolno-pomiarowych zainstalowanych w pomieszczeniach technicznych serwerowni.
2. Oprogramowania nadzorującego o nazwie SCSWin, które umożliwia rejestrację danych pomiarowych, ich prezentację, przygotowywanie raportów oraz automatyczne powiadamianie o sytuacjach alarmowych.

Centralnym komponentem tego systemu jest Serwer, którego główne zadania obejmują:

- Komunikację z monitorowanymi urządzeniami i kontrolerami obiektowymi.
- Gromadzenie i przetwarzanie danych monitoringu.
- Udostępnianie danych dla stacji operatorskich.
- Udostępnianie danych dla użytkowników.

Serwer komunikuje się z kontrolerami obiektowymi za pomocą sieci LAN, natomiast stacja operatorska, znana jako Centrum Nadzoru, komunikuje się z Serwerem również przez sieć LAN. W przypadku wystąpienia sytuacji alarmowej w obiekcie, oprogramowanie stacji operatorskiej informuje operatora Centrum Nadzoru odpowiednim komunikatem.

Oprogramowanie SCSWin umożliwia nadzór nad urządzeniami technicznymi oraz integruje monitorowanie urządzeń zasilających, klimatyzacyjnych i systemów bezpieczeństwa w jednym zintegrowanym systemie zarządzania. Monitoruje określone parametry urządzeń technicznych i przesyła automatycznie informacje o ich stanie za pomocą kontrolerów nadzoru do Centrum Nadzoru.

System nadzoru infrastruktury technicznej SCSWin stanowi kompleksowe rozwiązanie oparte na jednolitej platformie sprzętowej i oprogramowaniu. Oprogramowanie SCSWin realizuje następujące funkcje:

1. Natychmiastowe alarmowanie odpowiednich służb w przypadku wystąpienia zdefiniowanego zdarzenia alarmowego.
2. Ostrzeganie przed możliwością wystąpienia zdarzenia alarmowego.

3. Gromadzenie danych dotyczących historii zdarzeń umożliwiające analizę sytuacji poprzedzających wystąpienie zdarzenia alarmowego.
4. Monitorowanie pracy infrastruktury technicznej utrzymującej komfort cieplny w pomieszczeniach.
5. Predykcję uszkodzeń infrastruktury technicznej służącej utrzymaniu komfortu cieplnego, urządzeń i urządzeń zasilania gwarantowanego.

Zalety oprogramowania SCSWin:

- Możliwość przeprowadzenia zdalnej diagnozy.
- Redukcja liczby godzin wyjazdowych.
- Możliwość zintegrowania w jednym środowisku programistycznym urządzeń/systemów różnych producentów.
- Możliwość objęcia monitoringiem dużej ilości obiektów.
- Analiza danych archiwalnych (historia zdarzeń).
- Skrócenie czasu naprawy awarii poprzez szczegółowe rozpoznanie rodzaju awarii.

Wady oprogramowania SCSWin:

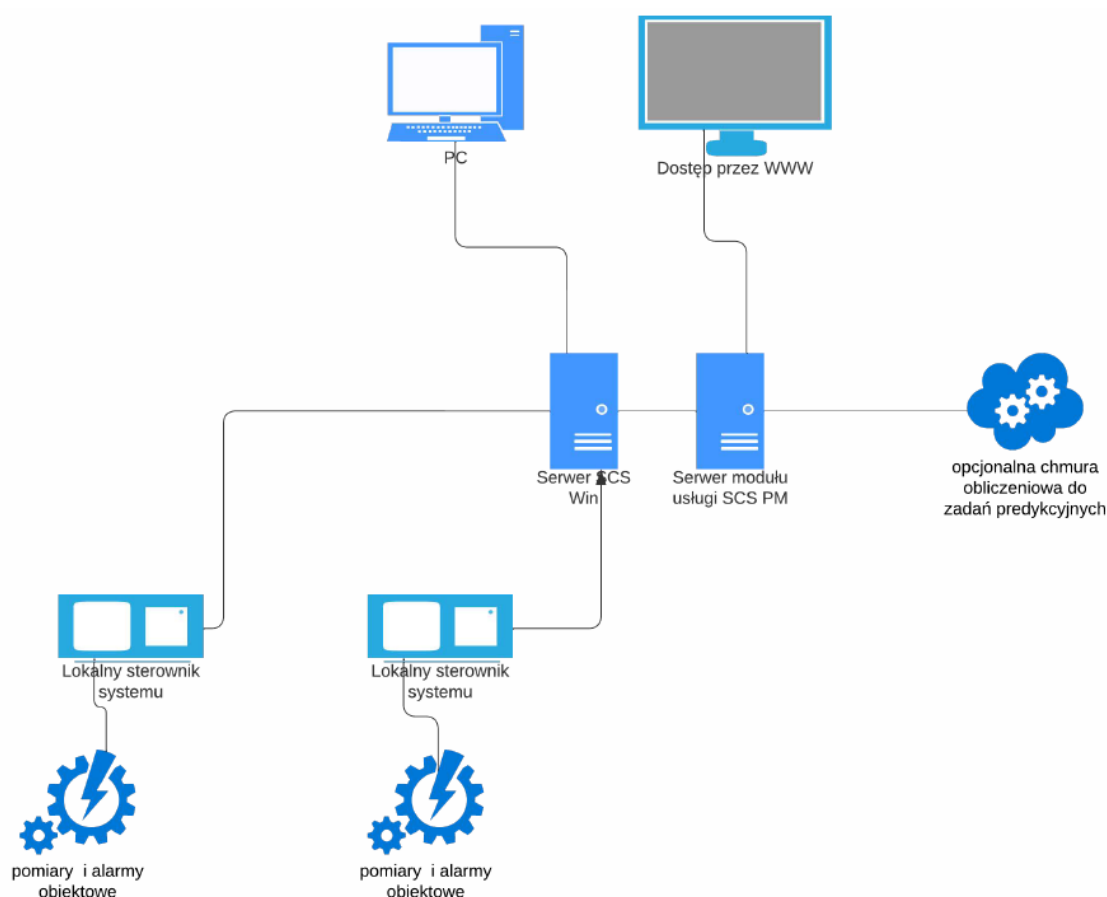
- Brak struktury i funkcjonalności w zakresie prowadzenia predykcji zużycia energii oraz predykcji uszkodzeń.
- Konieczność rozwoju we współpracy z producentem.
- Dedykowane urządzenia fizyczne, np. kontrolery.

Platforma sprzętowa:

Aby wdrożyć i zainstalować system SCSWin, niezbędna jest dedykowana platforma sprzętowa, która składa się z kontrolerów przeznaczonych do monitoringu infrastruktury teletechnicznej. Urządzenie to umożliwia monitorowanie parametrów klimatycznych pomieszczenia, takich jak temperatura i wilgotność. W zależności od wersji, może obsługiwać czujniki 1-Wire lub czujniki RS-485. Użytkownik ma możliwość konfiguracji progów alarmowych dla pomiarów górnych i dolnych. Po wykryciu stanu alarmowego, sterownik może automatycznie wysłać powiadomienia do systemu nadrzędnego (np. SCSWin) w postaci SNMP-Trap lub SMS-a, oraz e-maila. Kontroler jest w stanie monitorować różne parametry, takie jak wyciek wody, zasilanie, klimatyzacja, UPS, itp.

Moduł analityczno-predykcyjny SCS PM:

Moduł SCS-PM, będący integralną częścią systemu SCSWin, wykorzystuje zaawansowane algorytmy uczenia maszynowego, takie jak Gradient Boosting Machine (GBM), do przetwarzania i analizy danych pozyskiwanych przez lokalne sterowniki.



Rysunek 9. Sposób rozbudowy systemu SCSWin o moduł PM
Źródło: opracowanie własne

Głównym celem jest generowanie prognoz i trendów pomiarów dla wybranych grup urządzeń, co umożliwia implementację technik konserwacji predykcyjnej. Dzięki temu, konserwacja odbywa się tylko wtedy, gdy analiza danych wskazuje na tę konieczność, co znacząco redukuje koszty w porównaniu do konserwacji rutynowej lub zapobiegawczej.

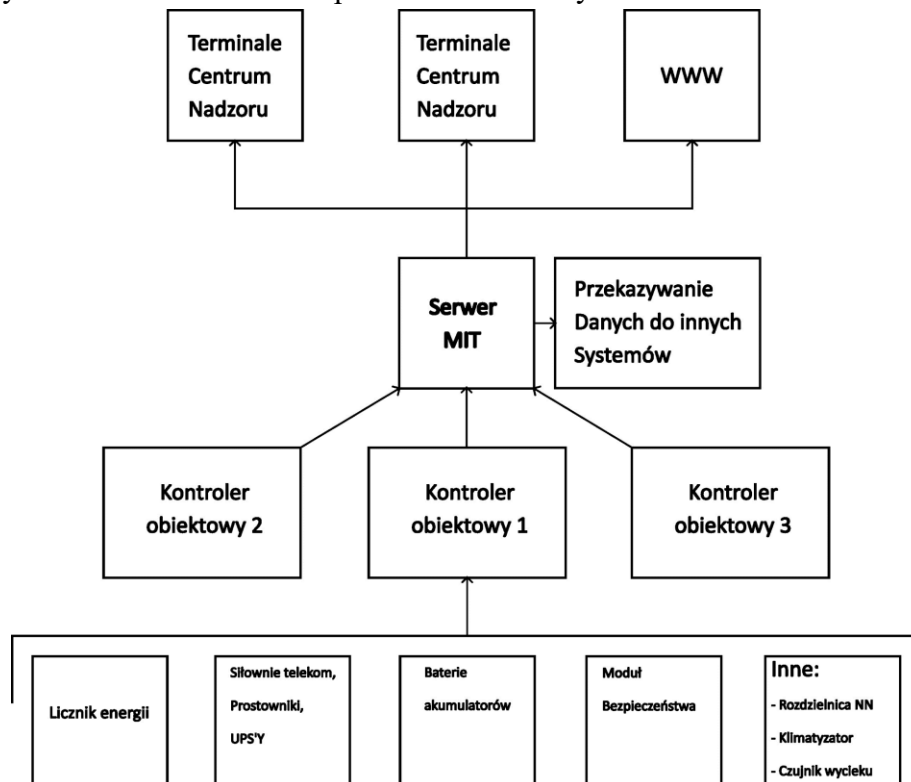
Moduł SCS-PM regularnie odbiera i analizuje dane, co pozwala na ciągły monitoring stanu sprzętu i planowanie konserwacji w oparciu o precyzyjne prognozy. Wyniki analiz są dostępne przez stronę internetową i dedykowaną aplikację, co ułatwia efektywne zarządzanie sprzętem i unikanie nieplanowanych awarii.

Moduł SCS- PM jest narzędziem opracowanym na bazie języka Phyton wykorzystującym wszechstronność tego języka oraz ogromny zasób przygotowanych bibliotek, które można wykorzystać w różnych projektach. W przypadku predykcji uszkodzeń, predykcji konsumpcji energii oraz predykcji innych parametrów wykorzystano standardowe biblioteki z zakresu:

- XGBoost (eXtreme Gradient Boosting)
- model ARIMA
- regresji liniowej

Lista pakietów Phyton stanowi załącznik nr 1.

Struktura systemu SCS WiN została przedstawiona na rysunku 10.



Rys. 10 Struktura funkcjonalna systemu SCS WiN
Źródło: Opracowanie własne

Architektura typu klient - serwer pozwala na zarządzanie tym systemem z dowolnego miejsca w sieci. Struktura oprogramowania pozwala na jednoczesną pracę na wielu stanowiskach, co ma tę zaletę, że system monitoringu umożliwia elastyczne przypisywanie obiektów do różnych grup monitorujących, udostępniając im sygnały interesujące dany zespół. Opisywana struktura pozwala na rozbudowę o nowe integracje w każdym miejscu systemu. W ten sposób możliwe jest monitorowanie systemu z wielu stanowisk.

4.4. Model predykcji zużycia mediów

Modele predykcji danych w zakresie przewidywania parametrów o charakterze ciągłym zmieniających się w sposób przyrostowy, jak również okresowo zmiennym opisane zostały szeroko w literaturze. Celem rozważań zawartych w niniejszym rozdziale jest wykazanie możliwości:

- zastosowania Modeli regresji liniowej dla przewidywania zużycia wody w nieruchomościach komercyjnych,
- zastosowania modelu ARIMA dla przewidywania konsumpcji energii w heterogenicznych nieruchomościach komercyjnych,
- zastosowania modelu ARIMA dla przewidywania pogody w nieruchomościach zlokalizowanych na obszarach z mikroklimatem w oparciu o dane ze stacji pogodowych,

- o optymalizacji zakresu oraz częstotliwości zbierania danych niezbędnych dla prowadzenia predykcji zużycia mediów z wykorzystaniem przygotowanych metod,
- o zgromadzenia zakresu danych predykcyjnych oraz pogodowych niezbędnych w celu rozwoju narzędzi sterujących zdalnie urządzeniami HVAC,
- o standaryzacji wymagań w zakresie opomiarowania budynków i zespołów budynków oraz wymagań w zakresie danych z urządzeń automatyki budynkowej - niezbędnych zarówno dla przewidywania konsumpcji energii jak również dla właściwego, ekonomicznie uzasadnionego sterowania budynkami, lub ich wyodrębnionymi częściami.

Właściwy dobór opisanych w literaturze modeli predykcyjnych, ich badanie na szerokim zakresie heterogenicznych zespołów budynków oraz wdrożenie narzędzi predykcyjnych zintegrowanych z systemami zabezpieczenia technicznego zespołów nieruchomości, korzystających z danych tych systemów jest stanowi istotną korzyść prowadzonych badań.

4.5. Opis źródeł danych i przygotowanie do modelowania

Doboru właściwych modeli predykcji zużycia energii dokonano biorąc analizując dwa przypadki:

1. zagregowane dane zużycia energii w postaci zbiorów odczytów liczników energii elektrycznej z kilku grup kilku nieruchomości,
2. pojedyncza nieruchomość podzielona na strefy pomiarowe dla pomiarów parametrów energii, gromadząca dane pogodowe, konsumpcje wody oraz dane z systemów zabezpieczeń technicznych.

4.6. Badania predykcyjne zużycia energii elektrycznej na zbiorach danych z odczytów liczników energii

Charakterystyka budynków i danych analizowanych w postaci zbiorów odczytów zużycia energii elektrycznej pochodzących z liczników energii elektrycznej (pomiar całości konsumowanej energii).

Do badania przyjęto grupę pięciu różnorodnych budynków zlokalizowanych w różnych częściach Polski południowej. Budynki te budowane były w różnych okresach czasu oraz wyposażone są w zróżnicowaną ilość urządzeń automatyki.

Tabela. 4. Charakterystyka użytkowa budynków:

Oznaczenie obiektu	Typ budynku	Kubatura	Powierzchnia użytkowa	Wiek i lokalizacja	Sposób użytkowania
Budynek nr 1	budynek biurowy posiadający 4 kondygnacje oraz podpiwniczenie	14040 m ³	3230 m ²	oddany do użytku 2017 r. i jest zlokalizowany w centrum miasta nieopodal rzeki	w znacznej części wykorzystywany jest przez 24 h/dobę. W pozostałej części - co

					najmniej przez 12h/dobę
Budynek nr 2	budynek biurowy posiadający 2 kondygnacje	7778 m ³	1962 m ²	oddany do użytku 2015r. i jest zlokalizowany na obrzeżach miasta nieopodal rzeki	w większości wykorzystywany jest przez 24 h/dobę. W pozostałej części - co najmniej przez 12h/dobę.
Budynek nr 3	budynek biurowo – garażowy posiadający 2 kondygnacje	7503 m ³ ,	1178 m ²	oddany do użytku 2017 r. i jest zlokalizowany na obrzeżach miasta	wykorzystywany jest przez 11 h/dobę
Budynek nr 4	budynek biurowy posiadający 3 kondygnacje	4308 m ³ ,	1099 m ²	oddany do użytku 2017r. i jest zlokalizowany w centrum miasta	wykorzystywany jest przez 11 h/dobę
Zespół budynków nr 5 – budynek A	budynek biurowy posiadający 4 kondygnacje	8 399,8 m ³ ,	742,0 m ²	oddany do użytku 1972 r. i jest zlokalizowany na obrzeżach miasta	w większości wykorzystywany jest przez 8 h/dobę
Zespół budynków nr 5 – budynek B	budynek biurowo – magazynowy, parterowy	2 505,2 m ³	556,7m ²	oddany do użytku 1972 r. i jest zlokalizowany na obrzeżach miasta	wykorzystywany jest przez 12 h/dobę
Zespół budynków nr 5 – budynek C	biurowo (socjalno) – magazynowy, posiadający 2 kondygnacje	5707,4 m ³	713,8 m ²	oddany do użytku 2017 r. i jest zlokalizowany na obrzeżach miasta	wykorzystywany jest przez 12 h/dobę
Zespół budynków nr 5 – budynek D	budynek biurowo – garażowy, parterowy	3 837,7 m ³	645,60 m ²	oddany do użytku 1972 r. i jest zlokalizowany na obrzeżach miasta	wykorzystywany jest przez 12 h/dobę
Zespół budynków nr 5 – budynek E	budynek garażowo - magazynowy, parterowy	2 198,1 m ³	399,6 m ² ,	oddany do użytku 1972 r. i jest zlokalizowany na obrzeżach miasta	wykorzystywany jest przez 12 h/dobę.

Charakterystyka techniczna budynków

Budynek nr 1 - charakterystyka techniczna:

- System utrzymania komfortu cieplnego, na który składa się wentylacja, klimatyzacja oraz ogrzewanie zarządzane przez BMS.

- System grzewczy oparty na o źródła ciepła systemowego zasilane z miejskiej sieci ciepłowniczej o mocy 140 kW. Ciepło sieciowe wykorzystywane jest do ogrzewania budynku z wykorzystaniem kaloryferów oraz do zasilania nagrzewnic w systemach wentylacyjnych. Ponadto centrala wentylacyjna została wyposażona w 4 sekcyjną nagrzewnicę elektryczną o mocy 45 kW, załączaną w sytuacji, gdy nie działają nagrzewnice zasilane ze źródeł ciepła sieciowego.
- Wentylacja wyposażona jest 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 posiada instalację fotowoltaiczną o mocy 40 kW oraz wyposażony jest w instalację służącą minimalizacji wpływu na środowisko jak np. system związany z wykorzystaniem wody szarej oraz system inteligentnego dozowania wody w instalacjach kanalizacyjnych.

Budynek nr 2 - charakterystyka techniczna:

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie. System ten zasilany jest w oparciu o pompy ciepła o łącznej mocy grzewczej 69,6 kW oraz mocy chłodzącej 58,8 kW. Dolne źródło ciepła to 16 odwiertów pionowych po 100 m. górne źródło ciepła to obieg wodny. Bufor pompy ciepła to dwa zbiorniki o pojemności 1500 dm³.
- Wentylacja wyposażona jest system rekuperacji oparty o wymienniki krzyżowe. Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany na podstawie wymagań normatywnych dla określonych dla ilości osób pracujących w budynku.
- 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.
- Budynek posiada instalację fotowoltaiczną o mocy 53 kWp oraz 3 turbiny wiatrowe o mocy 6 kW.

Budynek nr 3 – charakterystyka techniczna:

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie. System ten zasilany jest w oparciu o 2 pompy ciepła powietrze – woda o łącznej mocy grzewczej 67,20 kW. Bufor pompy ciepła to zbiornik o pojemności 800 dm³. Garaż ogrzewany nadmuchem powietrza podgrzewanym z pompy ciepła.
- Wentylacja wyposażona jest system rekuperacji oparty o wymienniki krzyżowe. Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany na podstawie wymagań normatywnych dla określonych dla ilości osób pracujących w budynku. Wentylacja wyposażona w nagrzewnice zasilana z pompy ciepła.
- 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 jedno zasilanie z sieci elektroenergetycznej. Wyposażony jest w systemy zabezpieczenia technicznego obiektu, w tym CCTV, SKD, p.poż – oddymianie klatki schodowej.
- Budynek posiada instalację fotowoltaiczną o mocy 20 kW.

Budynek nr 4 - charakterystyka techniczna:

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie. System ten zasilany jest w oparciu o pompy ciepła o łącznej mocy grzewczej 67,20 kW. Bufor pompy ciepła to zbiornik o pojemności 800 dm³.
- Wentylacja wyposażona jest system rekuperacji oparty o wymienniki krzyżowe. Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany na podstawie wymagań normatywnych dla określonych dla ilości osób pracujących w budynku. Wentylacja wyposażona w nagrzewnice zasilana z pompy ciepła.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w systemy zabezpieczenia technicznego obiektu, w tym CCTV, SKD, p.poż – oddymianie klatki schodowej.
- Budynek posiada instalację fotowoltaiczną o mocy 8,16 kW.

Zespół budynków nr 5 - charakterystyka techniczna:

Budynek A

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie CO zasilane piecami elektrycznymi o łącznej mocy 48 KW.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w systemy zabezpieczenia technicznego obiektu, w tym CCTV, p.poż. – oddymianie klatki schodowej.
- Budynek pobiera energię elektryczną z instalacji ze wspólnej fotowoltaicznej o mocy 20,91 kWp., która dostarcza energię dla całej posesji.

Budynek B

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie piecami akumulacyjnymi o łącznej mocy 30 kW.
- Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany na podstawie wymagań normatywnych dla określonych dla ilości osób pracujących w budynku.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w system ppoż. – oddymianie klatki schodowej.
- Budynek pobiera energię elektryczną z instalacji ze wspólnej fotowoltaicznej o mocy 20,91 kWp., która dostarcza energię dla całej posesji.

Budynek C

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja oraz ogrzewanie piecami akumulacyjnymi. Łączna moc grzewcza 45 kW.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w system ppoż. – oddymianie klatki schodowej.
- Budynek pobiera energię elektryczną z instalacji ze wspólnej fotowoltaicznej o mocy 20,91 kWp., która dostarcza energię dla całej posesji.

Budynek D

- System utrzymania komfortu cieplnego na który składa się wentylacja, klimatyzacja (dla części biurowej) oraz ogrzewanie piecami akumulacyjnymi i grzejnikami konwekcyjnymi. Nadmienić należy, że powierzchnia biurowa zajmuje 50 m², a pozostała część stanowią nieogrzewane garaże. Moc urządzeń potrzebnych do utrzymania komfortu cieplnego powierzchni biurowej to 4 KW.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w system ppoż. – oddymianie klatki schodowej.
- Budynek pobiera energię elektryczną z instalacji ze wspólnej fotowoltaicznej o mocy 20,91 kWp., która dostarcza energię dla całej posesji.

Budynek E

- Budynek nieogrzewany.
- Dobór ilości przygotowanego i dostarczanego do budynku świeżego powietrza realizowany na podstawie wymagań normatywnych dla określonych dla ilości osób pracujących w budynku.
- Obiekt posiada zasilanie z dwóch niezależnych obwodów sieci elektroenergetycznej. Wyposażony jest w system ppoż. – oddymianie klatki schodowej.
- Budynek pobiera energię elektryczną z instalacji ze wspólnej fotowoltaicznej o mocy 20,91 kWp., która dostarcza energię dla całej posesji

Analiza danych

Źródła danych pomiarowych wykorzystanych do badań stanowiły dane z zainstalowanych na obiektach liczników energii elektrycznej służących do rozliczeń z dostawcą energii zawierające następujący zakres danych:

1. numer punktu poboru,
2. datę pomiaru (dzień, miesiąc i rok),


3. godzinę pomiaru (pomiar realizowany co 15 min),
4. informacje o pobraniu lub oddaniu energii
5. informację o czasie licznika (letni /zimowy)
6. informacje o ilości energii (wyrażona w kWh).

Dane źródłowe do narzędzia obliczeniowego importowane były w postaci pliku Excel. Dodać należy, że na każdym z wyżej wymienionych zespołów nieruchomości mógł być zainstalowany jeden lub więcej liczników energii elektrycznej. Pliki danych dla każdej z omawianych nieruchomości zawierały dane pomiarowe z wszystkich liczników zainstalowanych na tej nieruchomości. Dokładność pomiarów zużycia energii zawiera się w klasie urządzeń technicznych instalowany dla rozliczeń odbiorców energii elektrycznej.

Analiza danych z wykorzystaniem dostępnych metod predykcji

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 oraz sieci neuronowe: DNN, RNN, LSTM.

Badania eksperymentalne wykonano na zestawie danych uzyskanych z liczników poboru energii zainstalowanych w opisanych zespołach budynków. Dane zebrano w okresie 4 lat, od 01.01.2018 do 31.12.2021. Odczyt danych następował (próbki) 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 COVID19 (marzec 2020- grudzień 2021).



Rys.11. 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. 11). 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.12.

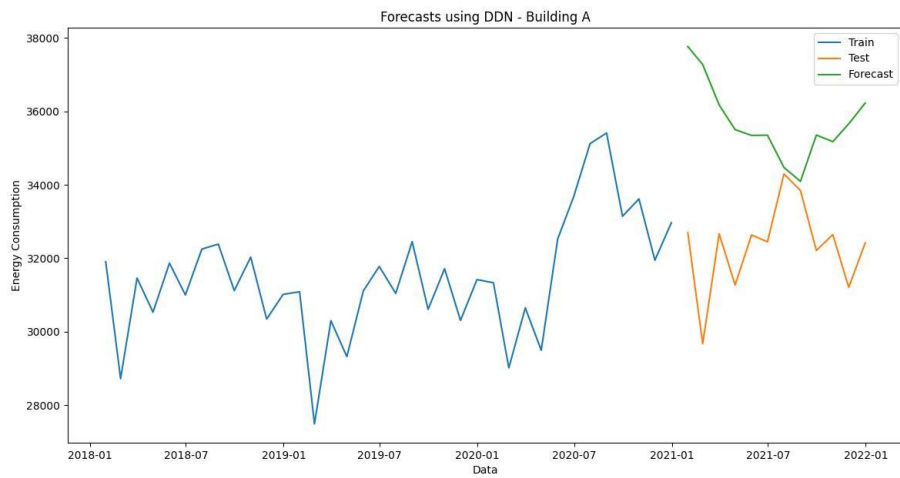


Rys.12. Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie (po wstępnej obróbce danych wejściowych).

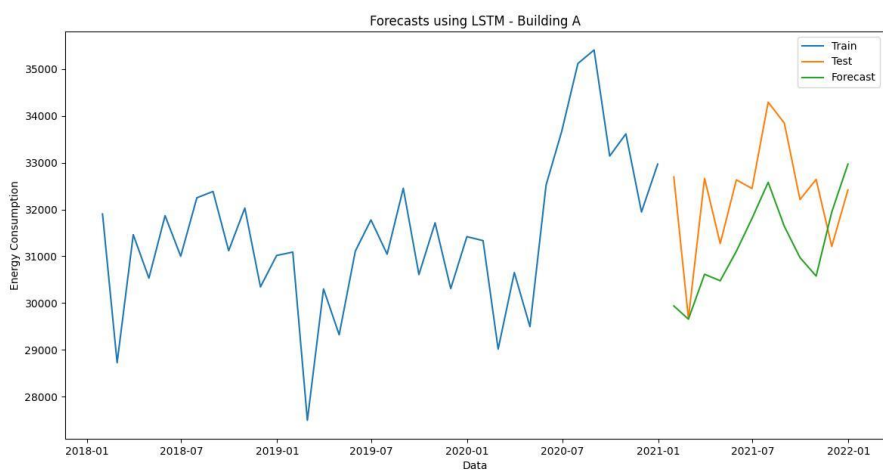
Analiza danych zużycia energii

Ze względu na wymagania biznesowe, dane zostały zagregowane w okresach miesięcznych w celu wykonania prognozy na rok do przodu w ujęciu miesięcznym. Dane dotyczące zużycia energii podzielono na zestaw treningowy i zestaw testowy. Zestaw treningowy zawierał dane z lat 2018-2020. Prognoza została ustalona na rok 2021 na podstawie danych ze zbioru treningowego. Poniższe rysunki przedstawiają zużycie energii elektrycznej przez wybrane badane budynki w badanym okresie wraz z prognozą. Dane z lat 2018-2020, na których trenowano modele, są zaznaczone na wykresach kolorem niebieskim. Dane testowe są wyświetlane na pomarańczowo. Kolor zielony oznacza dane predykcyjne na rok 2021. Dostrajanie hiperparametrów dla wszystkich eksperymentów opisanych w artykule przeprowadzono przy użyciu metody wyszukiwania w siatce (Grid Search).

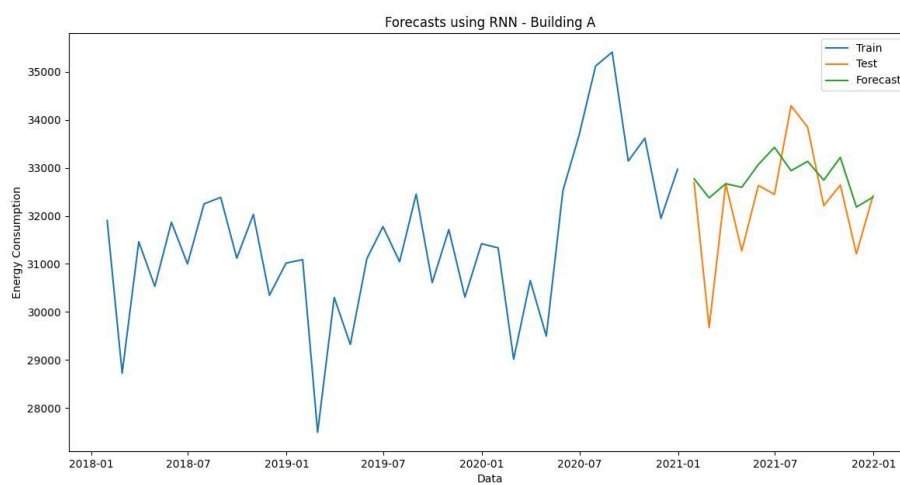
Budynek A



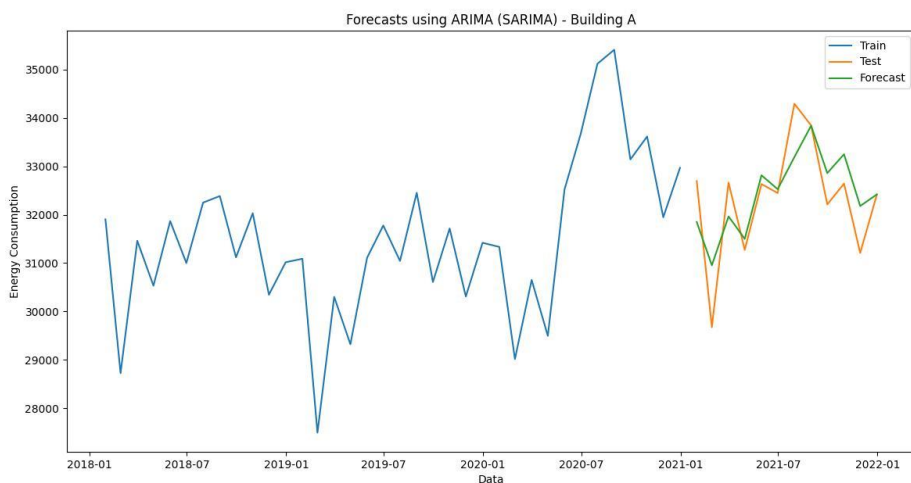
Rysunek 13. Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku A,



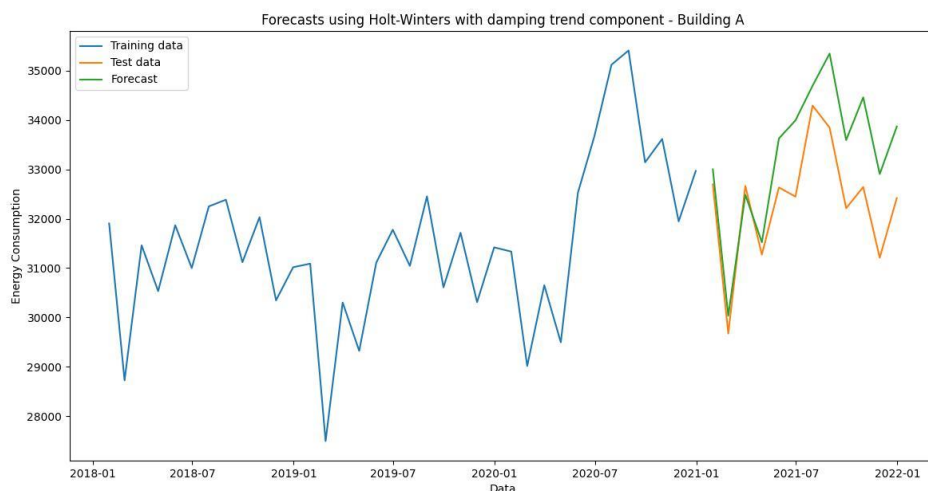
Rysunek 14. Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku A



Rysunek 15. Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku A



Rysunek 16. Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku A




Rys. 17. Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa - budynek A


Dla budynku A analizowany szereg czasowy wykazuje zarówno element sezonowy, jak i zauważalną trajektorię wzrostową. Ze względu na te cechy konwencjonalne modele statystyczne, takie jak ARIMA/SARIMA i model Holta-Wintersa, okazały się skuteczniejsze w przewidywaniu przyszłych wartości dla szeregu. Modele te zawierają komponenty, które uchwycą zarówno sezonowość, jak i trend, co skutkuje zwiększoną dokładnością podczas prognozowania danych z tym konkretnym wzorcem. DDN kładło nadmierny nacisk na trend, co prowadziło do przeceniania przyszłych prognoz, ponieważ skupiało się zbyt mocno na tym aspekcie danych. RNN wygładziło dane, co przesłoniło istotne wzorce sezonowe i trend, czyniąc je najmniej skutecznymi spośród badanych modeli, ponieważ nie udało mu się dokładnie przedstawić skomplikowanej struktury danych. Pomimo zaprojektowania w celu uchwycenia długoterminowych zależności w danych, LSTM nie uwzględnił trendu wzrostowego. LSTM daje najlepszy wynik wśród sieci neurownych. Pomimo ich potencjału

do modelowania nieliniowych relacji, sieci neuronowe nie działały tak skutecznie, prawdopodobnie z powodu trudności w uchwyceniu złożonej struktury danych i wyzwań w propagowaniu informacji o trendzie i sezonowości w modelu.

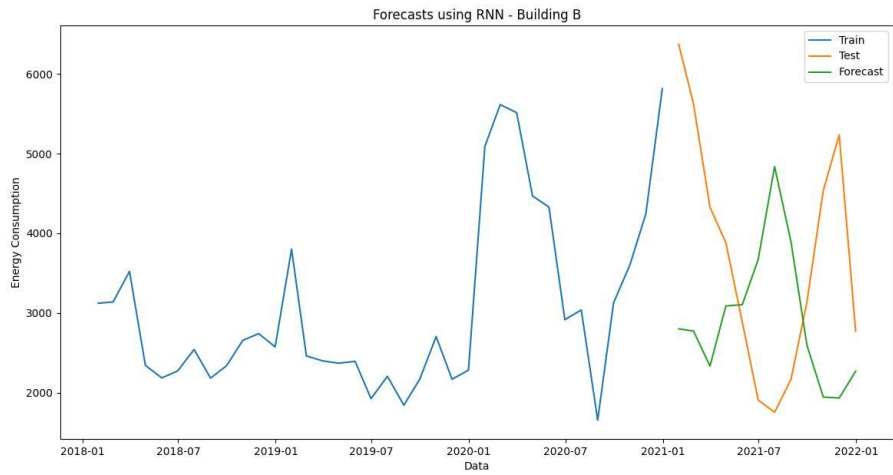
Budynek B



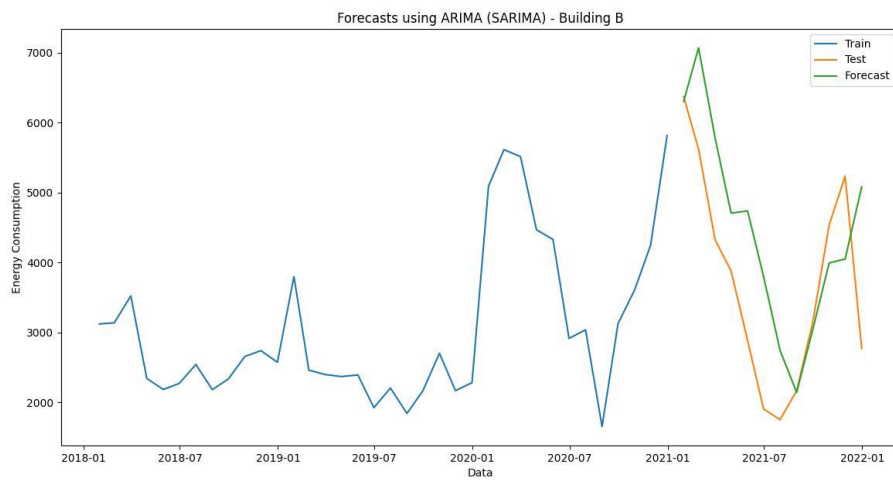
Rysunek 18. Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku B



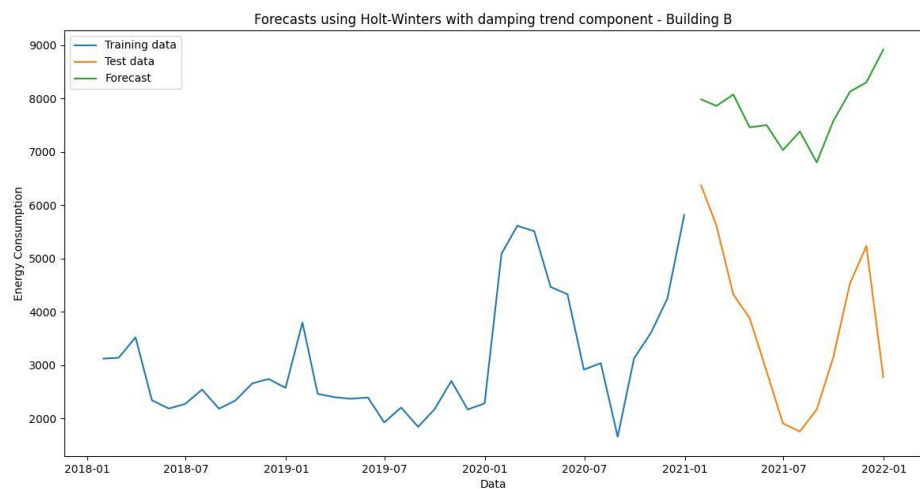
Rysunek 19. Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku B



Rysunek 20. Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku B



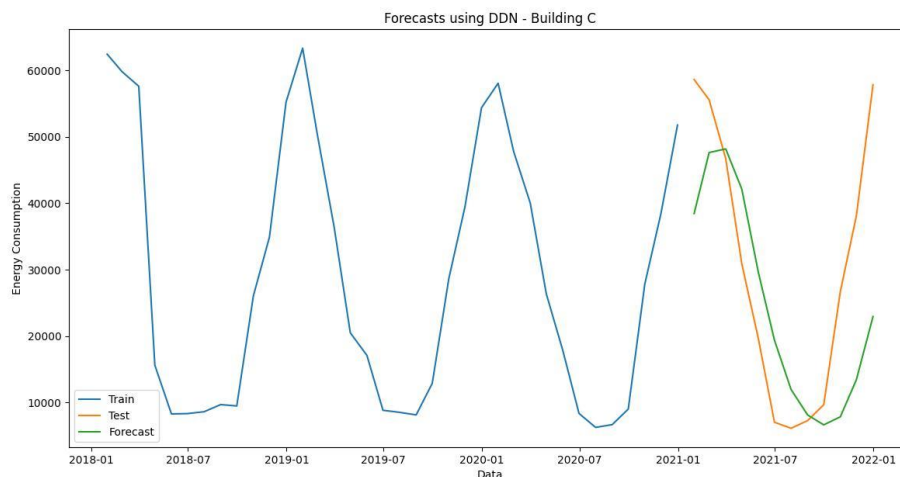
Rysunek 21. Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku B



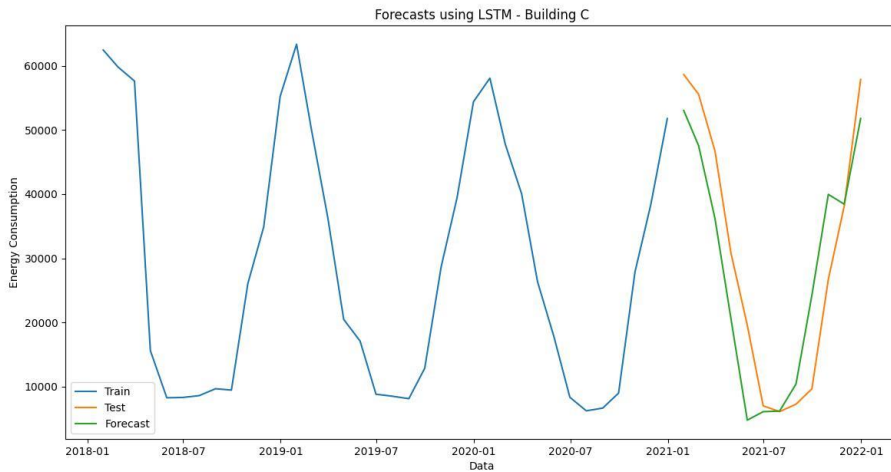
Rysunek 22. Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku B

W przypadku Budynku B analizowane szeregi czasowe wykazują okresowe zachowanie, ale nie wykazują wyraźnych wzorców sezonowych. To sugeruje obecność powtarzających się trendów, które nie pokrywają się z regularnymi cyklami sezonowymi, takimi jak cykle roczne. Ponadto seria ukazuje zmienny trend, któremu brakuje spójności i stabilności w czasie, co zwiększa złożoność procesu modelowania i wymaga dostosowania się do zmieniającego się trendu. Pomimo wysiłków mających na celu dostosowanie parametrów modelu, takich jak współczynniki wygładzania dla poziomu, trendu i sezonowości, model Holta-Wintersa nie osiągnął pożądanego poziomu dokładności, prawdopodobnie z powodu założenia stałego trendu i sezonowości w czasie, co nie jest zgodne z obserwowanym zmieniającym się trendem w analizowanym szeregu czasowym. Model SARIMA dał najkorzystniejsze wyniki. Ten model, rozszerzenie ARIMA o składnik sezonowy, lepiej uwzględnia złożone wzorce czasowe, w tym zmieniający się trend. Wyniki predykcji przez sieci neuronowych są niezadowolające. Pomimo ich zdolności do modelowania nieliniowych relacji, modele te miały problemy z dobrym działaniem w tym konkretnym szeregu czasowym. DNN napotkał wyzwania w dokładnym przewidywaniu przyszłych wartości szeregów czasowych, wskazując na znaczne opóźnienia w przewidywaniach. Z drugiej strony RNN, zaprojektowany do modelowania danych sekwencyjnych, wygładził dane w tym przypadku, co spowodowało uśrednienie przewidywań i utratę krytycznych wzorców czasowych. Z drugiej strony, LSTM, jako sieć neuronowa, skutecznie reprezentowała dane w analizie szeregów czasowych. Jej architektura, która ułatwiała zachowanie długoterminowych zależności, umożliwiła skuteczne uchwycenie zmienności trendu i odzwierciedlenie złożoności danych.

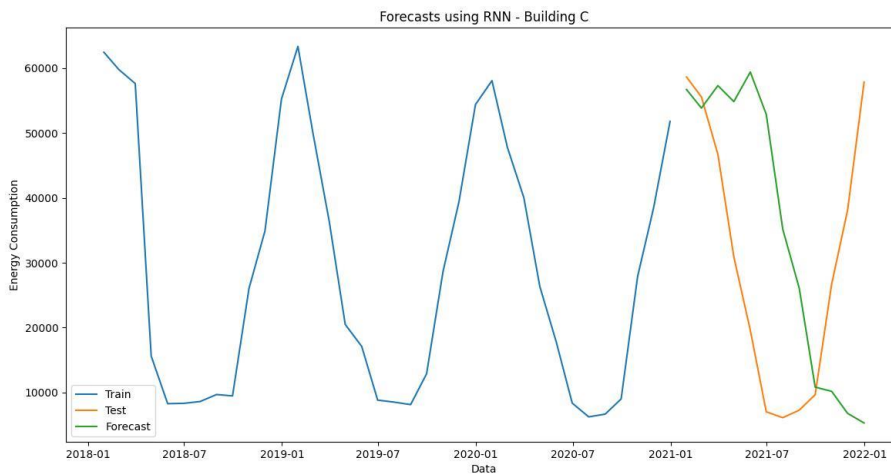
Budynek C



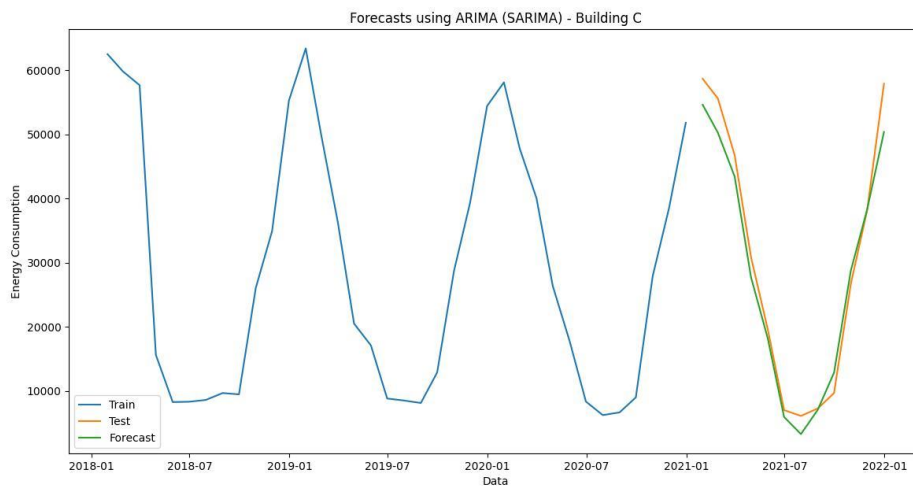
Rysunek 23. Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku C



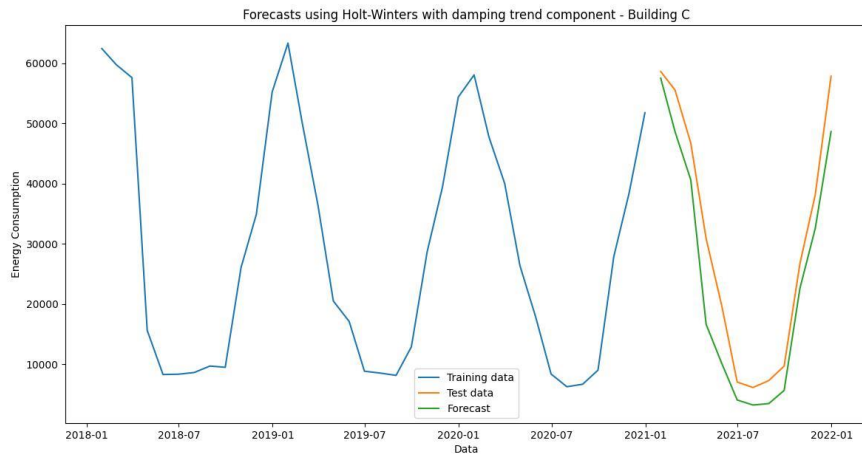
Rysunek 24. Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku C



Rysunek 25. Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku C

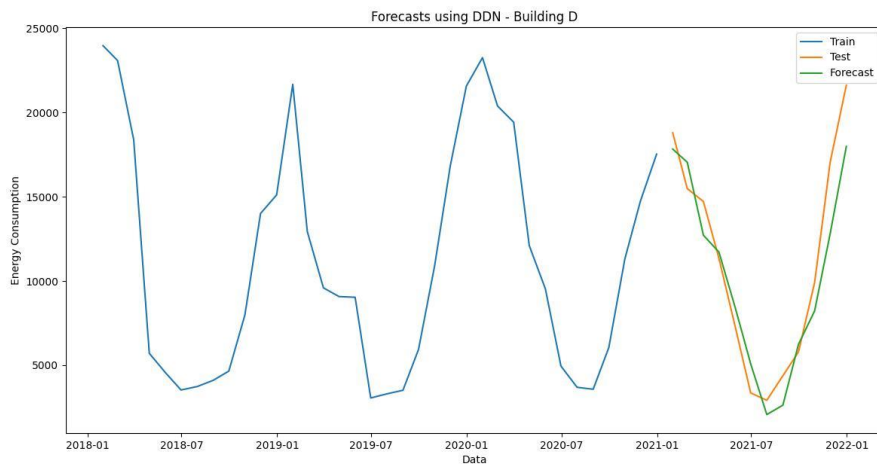


Rysunek 26. Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku C

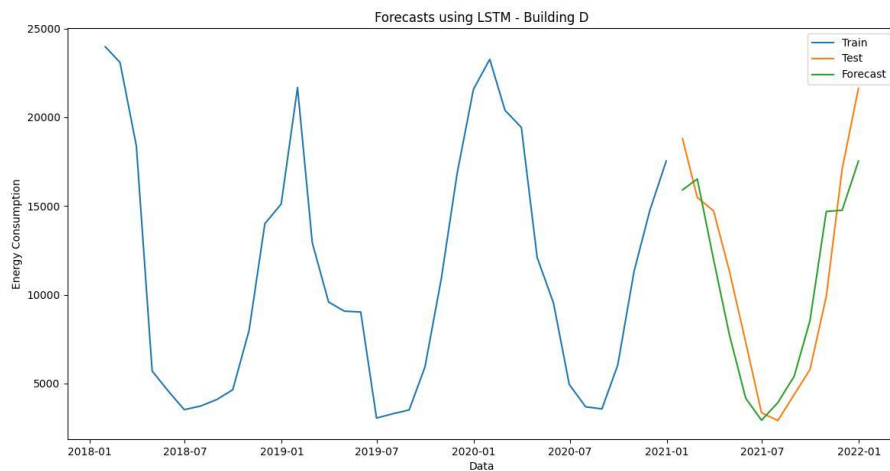


Rysunek 27. Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku C

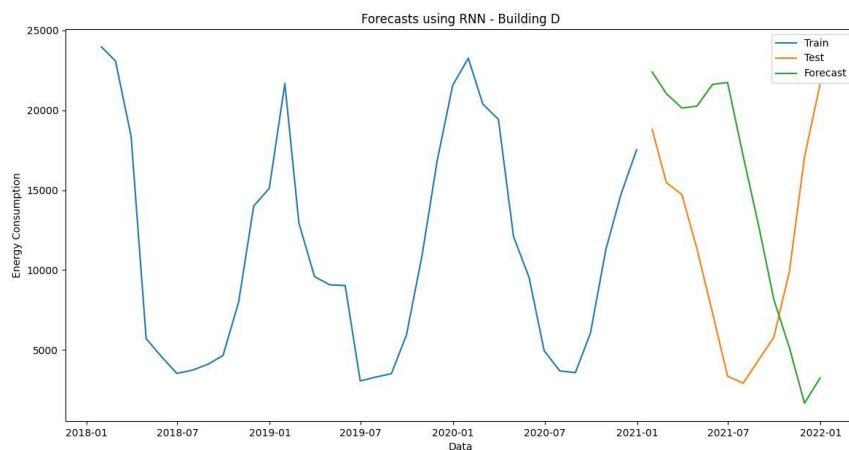
Budynek D




Rysunek 28. Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku D



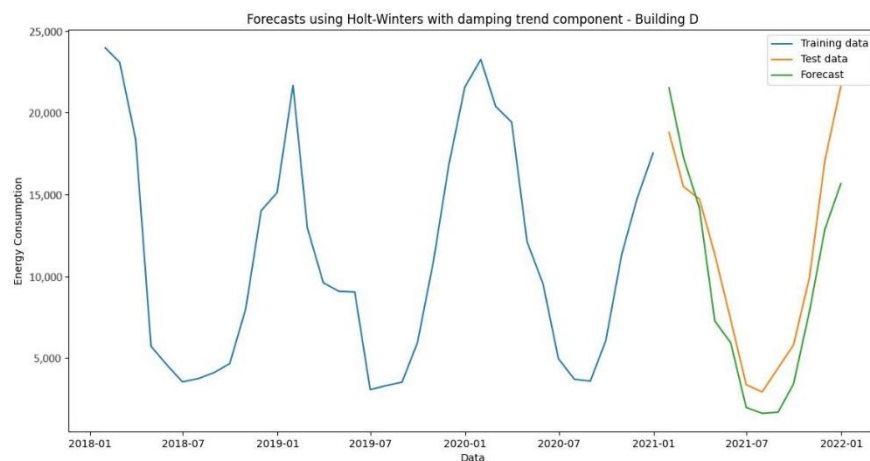
Rysunek 29. Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku D



Rysunek 30. Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku D



Rysunek 31. Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku D

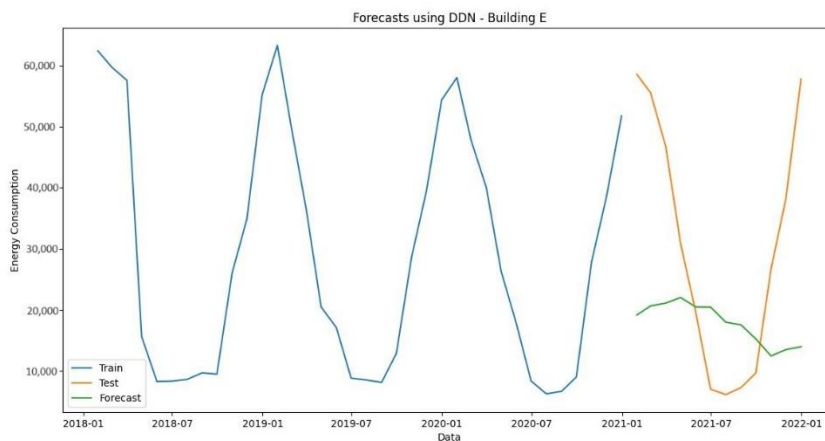


Rysunek 32. Wyniki dla metody Holta-Wintersa dla budynku D

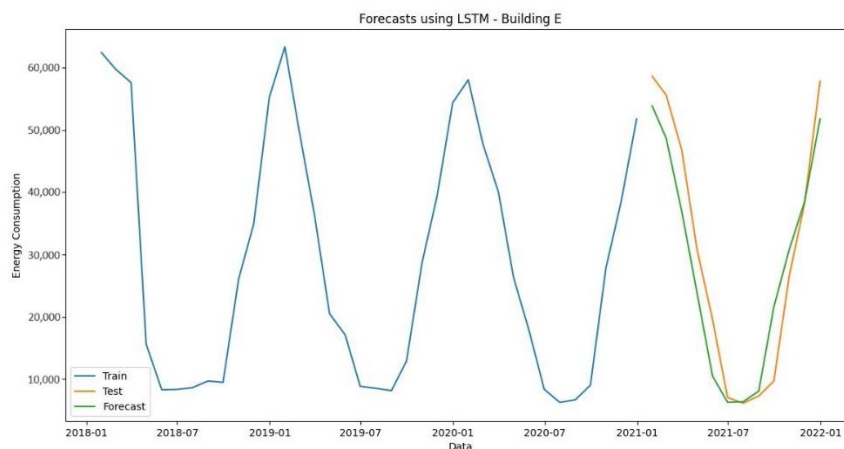
W przypadku budynków C i D mamy zbliżone szeregi czasowe. Analizowane szeregi czasowe wykazują spójną wartość bazową i powtarzające się trendy sezonowe, wskazujące na regularne cykliczne wahania. Aby odpowiednio uchwycić zarówno stabilny poziom bazowy, jak

i okresowe zmiany, niezbędne jest zastosowanie odpowiednich modeli. SARIMA okazała się skuteczniejsza niż model Holta-Wintersa w uchwyceniu potencjalnych trendów w szeregu czasowym, co skutkuje dokładniejszą długoterminową reprezentacją danych. Wykorzystując odpowiednie mechanizmy różnicowania, autoregresji i średniej ruchomej, SARIMA jest lepiej przygotowana do radzenia sobie z niestacjonarnością w danych, co prowadzi do lepszej replikacji trendów. Podczas gdy model Holta-Wintersa wykazał dobrą dokładność, dobrze dopasowując się do danych o stabilnym poziomie i powtarzających się wzorcach sezonowych, jego zdolność do uchwycenia dynamicznych trendów była ograniczona, co mogło skutkować nieco gorszymi prognozami. Sieci neuronowe, takie jak DNN i RNN, nie działały dobrze, przy czym DNN wygładzała dane i traciła ważne wzorce, podczas gdy RNN wprowadzała opóźnienia w przewidywaniach. Spośród modeli neuronowych najlepszą wydajność wykazał LSTM, wykorzystujący swoją architekturę do efektywnego wychwytywania zmienności danych i dokładnego przedstawiania zarówno poziomu, jak i sezonowości.


Budynek E



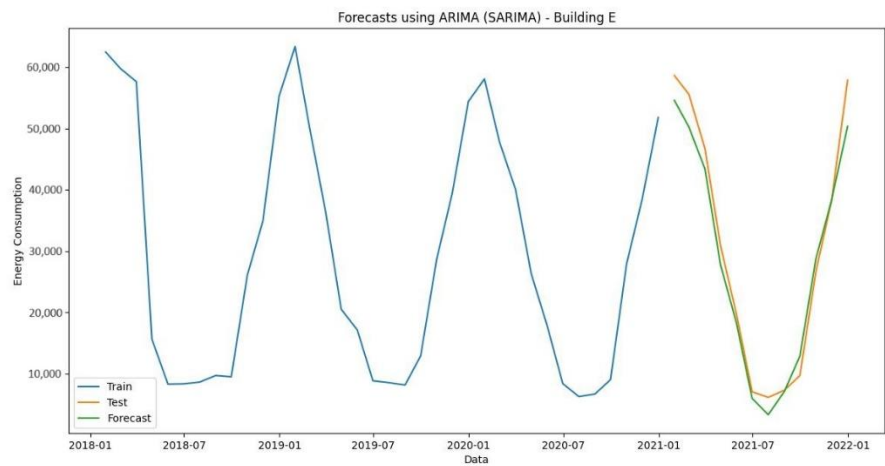
Rysunek 33. Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku E




Rysunek 34. Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku E



Rysunek 35. Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku E



Rysunek 36. Wyniki predykcji danych z wykorzystaniem metody ARIMA (SARIMA) dla budynku E



Rysunek 37. Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku E

Szeregi czasowe w przypadku kompleksu budynków E charakteryzują się sezonowością i tendencją spadkową. Prognozowanie z wykorzystaniem modelu ARIMA/SARIMA zapewniło niemal idealne pokrycie danymi testowymi dla danego szeregu czasowego. Szereg czasowy charakteryzuje się sezonowość i tendencja spadkowa szeregu czasowego powoduje, że prostszy model Holta-Wintersa jest dokładniejszy niż inne modele. Natomiast model DNN w ogóle nie poradził sobie z prognozowaniem tego typu danych. Dane zostały spłaszczone i mocno uśrednione. Model RNN dał najgorsze wyniki ze wszystkich badanych metod. Uzyskane dane zostały spłaszczone, poniżej najniższej wartości rzeczywistej. Model LSTM dał najlepsze wyniki ze wszystkich trzech metod sztucznej inteligencji. Wyniki były podobne do modelu Holta-Wintersa.

Ocena błędu wynikowego

Poniżej w tabelach zostały przedstawione wartości uzyskane dla wszystkich testowanych budynków. Dla każdego z budynków podano wartości oceny prognozy określone przy użyciu metod MAE, RMSE i MAPE dla wszystkich modeli prognostycznych, kolejno modelu Holta-Wintersa, modelu ARIMA/SARIMA, sieci neuronowej DNN, RNN oraz LSTM.

Tabela 5. Wartości błędu prognozy dla budynku nr A.

Metoda	MAE	RMSE	MAPE
HW	989.88	1165.22	0.78
ARIMA	554.56	700.59	0.44
DNN	2764.66	3261.27	8.55
RNN	1270.44	1596.91	47.15
LSTM	1261.78	1447.78	3.90

Tabela 6. P Wartości błędu prognozy dla budynku nr B

Metoda	MAE	RMSE	MAPE
HW	4037.18	4233.92	31.39
ARIMA	1057.31	1287.97	8.22
DNN	1403.80	1565.40	44.97
RNN	1256.56	1536.99	444.74
LSTM	682.89	1014.07	15.96

Tabela 7. Wartości błędu prognozy dla budynku nr C

Metoda	MAE	RMSE	MAPE
HW	2546.50	2939.17	5.71
ARIMA	1941.05	2254.62	4.35
DNN	2738.11	3426.65	17.33
RNN	8490.28	10,318.1	872.49
LSTM	3024.02	3457.38	27.35

Tabela 8. Wartości błędu prognozy dla budynku nr D

Metoda	MAE	RMSE	MAPE
HW	3337.76	4061.03	7.07
ARIMA	3009.39	4496.48	6.38
DNN	3657.68	5061.1	20.90
RNN	6482.95	8346.98	608.43
LSTM	2301.19	3515.51	17.99

Tabela 9. Wartości błędu prognozy dla kompleksu budynków nr. E

Metoda	MAE	RMSE	MAPE
HW	5885.33	6847.08	5.02
ARIMA	2854.90	3509.47	2.44
DNN	14,070.78	17,225.94	33.49
RNN	24,295.17	30,226.85	960.62
LSTM	5017.83	6252.26	16.53

Wnioski

Zużycie energii w badanych budynkach (biuro, magazyn) charakteryzuje się sezonowością w okresach miesięcznych. Klasyczne modele dobrze radzą sobie z przewidywaniem zużycia energii w tego typu budynkach. Dla badanych danych najlepsze wyniki dał model ARIMA (wyniki MAPE są bardzo małe, co oznacza, że jest to najlepsze dopasowanie). Dla budynków charakteryzujących się sezonowością i trendami, prognoza była niemal idealna z rzeczywistymi wartościami. Sieci neuronowe nie działały dobrze pomimo regularnych szeregów czasowych. Powodem uzyskania gorszych wyników może być zbyt mała ilość danych do trenowania sieci). W szczególności model RNN przyniósł wyniki, które w żaden sposób nie pokrywały się z rzeczywistymi danymi.

Opisane metody nie wyczerpują dyskusji na temat możliwych innych, bardziej złożonych modeli predykcyjnych, które uwzględniałyby np. warunki pogodowe, które również mają wpływ na ogólne zużycie energii elektrycznej z sieci w budynkach z panelami fotowoltaicznymi. Predykcja zużycia energii elektrycznej służy do prognozowania zakupu odpowiedniej ilości energii dla całego kompleksu budynków w długim okresie – pozwala na właściwe zaplanowanie zarówno zużycia energii w kolejnych dniach, jak i miesiącach.

Prezentowane badania wpisują się w prace nad opracowaniem i wdrożeniem systemu wspomagania decyzji, który jest łatwy w obsłudze dla osoby bez wiedzy naukowej i prognozuje zakup odpowiedniej ilości energii dla całego kompleksu budynków w perspektywie długoterminowej. Uzyskane wyniki mają na celu ułatwienie zarządzania systemami utrzymania komfortu cieplnego, czy też wykorzystania w niektórych lokalizacjach innych źródeł ciepła do wspomagania ogrzewania budynków, gdy wytwarzane wartości wskazują na przekroczenie zamówionej wartości energetycznej. Takie działanie ogranicza możliwość naliczania i zapłaty ewentualnych kar umownych i sprawia, że osoby zarządzające zużyciem energii mogą faktycznie z góry wpływać na zużycie energii. Uzyskane wyniki badań mogą zatem z powodzeniem zostać wdrożone w przedsiębiorstwie do zarządzania nieruchomościami niesieciowymi. Ponadto, możliwe są dalsze badania, zwłaszcza związane są z wykorzystaniem danych dziennych lub tygodniowych do trenowania sieci neuronowych i sprawdzeniem skuteczności ich działania dla takich okresów. Zastosowanie w badaniach zagregowanych

danych podyktowane było tym, aby dane nie były spowodowane były tym, żeby nie były zbyt rozdrobnione i można je było wykorzystać do prostych metod prognozowania. Innym kierunkiem badań jest zastosowanie modeli probabilistycznych i bayesowskich w celu przewidywania długoterminowych trendów.

Kwestia dotycząca analizy i predykcji zużycia energii zostanie omówiona również poniżej na przykładzie innej nieruchomości, podzielonej na opomiarowane strefy. Na podstawie danych dotyczących całkowitego zużycia energii w badanych nieruchomościach dla dalszych analiz prowadzonych w kolejnym rozdziale przyjęto, że właściwą metodą dla analiz z zakresu energii elektrycznej jest model ARIMA.

4.7. Badania predycyjne na pojedynczej nieruchomości z niehomogeniczną infrastrukturą techniczną

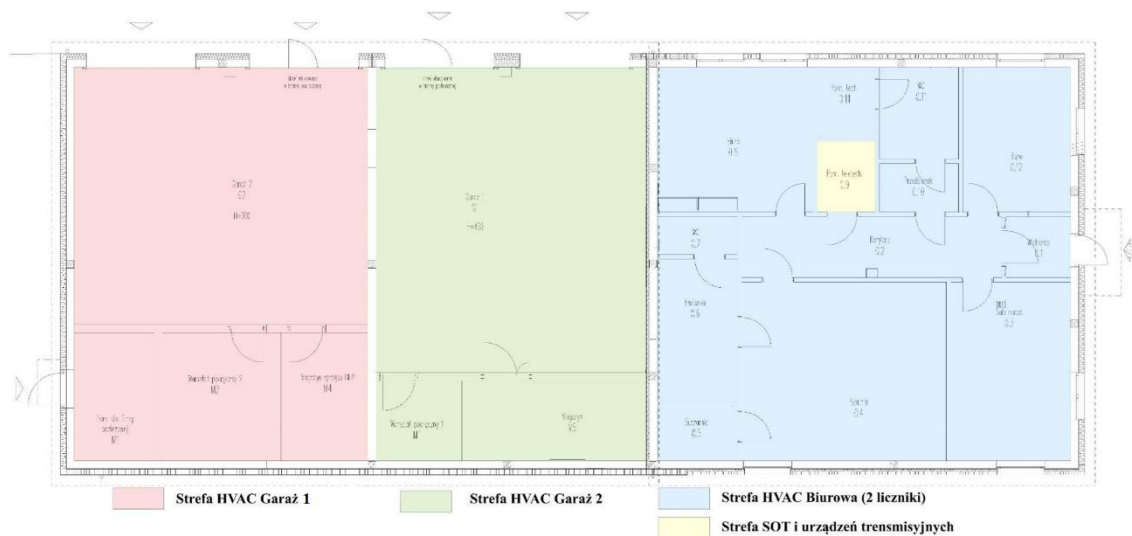
Dla prowadzenia badań w zakresie analizy zużycia energii na konkretnym obiekcie wytypowano niewielki obiekt będący na etapie projektowania. W obiekcie tym przewidziano podział budynku na strefy pomiarowe umożliwiające dokonanie pomiarów obciążeń i zużycia energii w poszczególnych strefach budynku (Rys. 38). Strefy te obejmowały pomiar zużycia energii elektrycznej na potrzeby utrzymania komfortu termicznego budynku, przygotowania ciepłej wody użytkowej, suszenia odzieży roboczej, itp. Dodać należy, że podział stref pomiarowych służył nie tylko celom predykcji energii, lecz był niezbędny dla gromadzenia danych dla badań możliwości wykorzystania opisanych w literaturze metodyk predykcji uszkodzeń w zakresie urządzeń HVAC oraz systemów zabezpieczeń technicznych.

Charakterystyka użytkowa badanego budynku:

- parterowy budynek biurowo - garażowy,
- powierzchnia użytkowa – 2000 m²,
- sposób użytkowania - praca w systemie 12 godzin na dobę,
- data budowy – 2022 r.

Charakterystyka techniczna badanego budynku:

- system HVAC:
 - pompa ciepła,
 - centrala wentylacyjna,
 - klimatyzacja,
- instalacja fotowoltaiczna 15 kW,
- system zabezpieczenia technicznego obiektu:
 - system sygnalizacji pożaru (SSP),,
 - system sygnalizacji włamania i napadu (SSWiN),
 - system monitoringu (CCTV),
 - system kontroli dostępu (SKD),
 - system domofonowy,
 - zabezpieczenia mechaniczne drzwi i okien.



Rys. 38. Podział budynku na strefy pomiarowe

Zainstalowane urządzenia pomiarowe

Strefy pomiarowe wyposażone zostały w liczniki typu NMID30-2 marki LUMEL.

NMID30-2 jest przyrządem pomiarowym przeznaczonym do monitorowania parametrów elektrycznych. Jest wyposażony w wyjście impulsowe i łącze cyfrowe RS-485 do zdalnego monitoringu mierzonych parametrów lub dla współpracy z systemami BMS.

Mierzone parametry:

- Napięcie międzyfazowe
- Napięcie fazowe
- Częstotliwość
- THD prądu i napięcia
- Prąd w przewodzie neutralnym (wyliczalny)
- Prąd maksymalny uśredniony
- Moc czynna, bierna, pozorna
- Moc czynna maksymalna uśredniona
- Współczynnik mocy
- Energia czynna pobierana
- Energia czynna oddawana
- Energia bierna indukcyjna
- Energia bierna pojemnościowa
- Energia czynna całkowita
- Energia bierna całkowita

Licznik do pomiaru wody jest przyrządem tego samego producenta, dokonuje pomiaru zużycia wody w sposób przyrostowy, jest urządzeniem tej samej klasy jak przyrząd mierzący parametry energii elektrycznej. Dane pozyskiwane z urządzeń pomiarowych gromadzone są w bazie danych system SCSWin firmy EP&M, użytkowanego pierwotnie jako narzędzie

służące do nadzoru systemów zabezpieczenia technicznego obiektów. W celu gromadzenia danych w uzgodnieniu z producentem - system ten został rozbudowany o dodatkowy moduł dla prowadzenia predykcji.

Stacja pogodowa

Ze względu na fakt, że badany obiekt znajduje się w obszarze górskim, zlokalizowany jest poza terenem miasta, w miejscu narażonym w szczególności na działanie wiatru, w którym temperatury zwłaszcza w okresie zimowym są niższe niż w pobliskiej miejscowości – dla pomiaru parametrów pogodowych zastosowana została stacja pogodowa Atmesys 5G NB-IoT. Stacja ta umożliwia pomiary w zakresie:

- wietrzności,
- ciśnienia,
- wielkości opadów,
- wilgotności powietrza,
- temperatury.

Jej dokładność zależy od zastosowanych czujników.

Stacja pogodowa, tak jak urządzenia monitorujące parametry elektryczne i zużycia wody, zapisuje dane z interwałem czasowym 15 minut w bazie danych systemu SCSWin.

Komunikacja z kontrolerem systemu SCSWin odbywa się przy wykorzystaniu interfejsu RS 485.


Analiza wykorzystanych danych

Na kolejnych wykresach przedstawiono przykłady zgromadzonych danych dla:

- dziennej sumy opadów (Rys. 39),
- prędkości wiatru (Rys. 40),
- przebiegu wartości ciśnienia atmosferycznego (Rys. 41),
- dziennej zmiany wilgotności (Rys. 42),
- dziennej zmiany temperatury (Rys. 43),
- przyrostu energii czynnej z produkcji fotowoltaiki (Rys. 44),
- zmiany temperatur powietrza w rekuperatorze (Rys. 45),
- zmiany prądów faz L1, L2, L3 Garażu nr 1 (Rys. 46),
- zmiany mocy czynnej faz L1, L2, L3 (Rys. 47),
- skumulowanego zużycia wody (Rys. 48).

W celu przygotowania bazy danych niezbędnych dla analizy zużycia energii, konsumpcji wody, produkcji energii elektrycznej, warunków pogodowych zgromadzone zostały dane z następujących urządzeń:


- Stacja pogodowa (parametrów pogodowych)




Rys. 39. Wykres dziennej sumy opadów




Rys. 40. Wykres prędkości wiatru



Rys. 41. Wykres przebiegu wartości ciśnienia atmosferycznego




Rys. 42. Dzienny wykres wilgotności powietrza




Rys. 43. Dzienny wykres przebiegu temperatury

o Liczników energii elektrycznej oraz wody




Rys. 44 Wykres miesięczny narastający energii czynnej całkowitej z produkcji fotowoltaiki

o Rekuperatora




Rys. 45. Wykres przebiegu temperatur powietrza w rekuperatorze

○ Licznik Prądu




Rys. 46. Wykres prądów faz L1, L2, L3

○ Licznik Mocy czynnej



Rys. 47. Wykres mocy czynnej faz L1, L2, L3

○ Licznik zużycia wody



Rys. 48. Wykres skumulowanego zużycia wody

Dla potrzeb predykcji zużycia energii elektrycznej, paramentów energii elektrycznej, konsumpcji wody, parametrów pogodowych dane zbierane są z urządzeń pomiarowych co 15 minut. Dane są zapisywane w bazie danych systemu SCSWin.

Ponadto, dla potrzeb predykcji zużycia energii oraz wody elektrycznej przez budynek niezbędne są dane zbiorcze z wszystkich ster pomiarowych. W celu analizy oraz predykowania zużycia energii elektrycznej w poszczególnych strefach budynku niezbędne są dane z urządzeń rejestrujących parametry energii elektrycznej w tych strefach. Analogiczna sytuacja dotyczy danych pogodowych.

15 minutowy okres dla zbierania i analizy danych jest wystarczający dla przygotowania narzędzi dla predykcji zużycia mediów w okresie 1 jednego roku. Biorąc pod uwagę format danych oraz rozmiar pojedynczej próbki danych system SCSWin gromadzi dane odczytowane z zakresu 5 lat. Po tym okresie dane są usuwane. Mając na uwadze fakt, że zapisujemy wszystkie parametry energii elektrycznej dostarczane przez urządzenia pomiarowe należy podkreślić, że w przypadku nadmiernego obciążenia bazy danych można zaniechać zbierania danych z zakresu napięcia, prądu, częstotliwości, mocy czynnej, biernej oraz współczynnika mocy, gdyż nie stanowią danych istotnych dla predykcji zużycia energii.

Dla potrzeb niniejszych badań przygotowano spójną bazę danych obejmującą okres 6 kolejnych miesięcy. Dokonano podziału danych na dane treningowe i testowe w proporcji 80% -20%. Dane treningowe i testowe są z tego samego okresu.

W zakresie danych pogodowych najistotniejszą daną dla sterowania jest temperatura zewnętrzna. Dana o mniejszej istotności niż temperatura jest wilgotność. Pozostałe dane ze stacji pogodowej nie są istotne dla funkcjonowania systemu automatyki budynkowej oraz predykcji zużycia mediów.

Prognozowanie Zużycia Energii Elektrycznej

Mechanizmy predykcji zużycia mediów zbudowane zostały w środowisku python i wykorzystują model ARIMA dla prowadzenia predykcji zdarzeń zmiennych (okresowo) oraz regresji liniowej dla predykcji zdarzeń o charakterze przerostowym.

Model Arima

Poniżej przedstawiono implementację modelu ARIMA w narzędziu służącym predykcji uszkodzeń. Kolejno podano fragmenty kodu wraz z wyjaśnieniem poszczególnych funkcji i ich parametrów.

Importowanie niezbędnych bibliotek

```
import pandas as pd
import plotly.graph_objects as go
import streamlit as st
from pmdarima import auto_arima
from sklearn.metrics import mean_squared_error, mean_absolute_error
import numpy as np
```

Funkcja przygotowywania danych

```
def prepare_data(df):
    df['Datetime'] = pd.to_datetime(df['Data'].astype(str) + ' ' + df['Czas'].astype(str))
    df.drop(['Data', 'Czas'], axis=1, inplace=True)
    df.set_index('Datetime', inplace=True)
    return df
```

Fragment kodu przedstawia definicję funkcji `prepare_data`, która jest zaprojektowana do przygotowania danych w ramach DataFrame'u `df` z biblioteki pandas.

Definicja funkcji: `def prepare_data(df):` - funkcja `prepare_data` jest zdefiniowana z jednym parametrem wejściowym, `df`, który reprezentuje DataFrame pandas.

Tworzenie kolumny 'Datetime': `df['Datetime'] = pd.to_datetime(df['Data'].astype(str) + ' ' + df['Czas'].astype(str))` - w tej linii kodu tworzona jest nowa kolumna o nazwie 'Datetime' w DataFrame'ie `df`. Do tego celu wykorzystywana jest funkcja `pd.to_datetime` z biblioteki pandas. Funkcja ta konwertuje ciągi znaków na obiekty datetime. Ciągi te są tworzone przez połączenie wartości z kolumn 'Data' i 'Czas', które są najpierw konwertowane na ciągi znaków (za pomocą metody `astype(str)`), a następnie łączone ze sobą.

Usuwanie kolumn 'Data' i 'Czas': `df.drop(['Data', 'Czas'], axis=1, inplace=True)` - ta linia kodu usuwa kolumny 'Data' i 'Czas' z DataFrame'u `df`. Parametr `axis=1` wskazuje, że usuwane są kolumny (a nie wiersze), a `inplace=True` modyfikuje oryginalny DataFrame zamiast tworzyć nowy.

Ustawienie kolumny 'Datetime' jako indeksu: `df.set_index('Datetime', inplace=True)` - w tej linii kodu kolumna 'Datetime' jest ustawiana jako indeks DataFrame'u `df`. Podobnie jak wcześniej, `inplace=True` modyfikuje oryginalny DataFrame.

Zwracanie zmodyfikowanego DataFrame'u: `return df` - na końcu funkcja zwraca zmodyfikowany DataFrame.

Funkcja `prepare_data` przekształca DataFrame `df`, tworząc nową kolumnę datetime (poprzez połączenie dwóch innych kolumn i konwersję na format datetime), usuwa oryginalne kolumny daty i czasu, a następnie ustawia nowo utworzoną kolumnę datetime jako indeks DataFrame'u.

Funkcje do obliczania metryk błędów dla prognoz modeli

```
def calculate_metrics(actual, predicted):
    mse = mean_squared_error(actual, predicted)
    mae = mean_absolute_error(actual, predicted)
    rmse = np.sqrt(mse)
    return mse, mae, rmse
```

Definicja funkcji: `def calculate_metrics(actual, predicted):` - funkcja `calculate_metrics` jest zdefiniowana z dwoma parametrami wejściowymi, `actual` i `predicted`. Parametr `actual` zawiera rzeczywiste wartości, które model miał przewidzieć, natomiast `predicted` zawiera wartości przewidziane przez model.

Obliczanie błędów średniokwadratowych (MSE): `mse = mean_squared_error(actual, predicted)` - w tej linii kodu obliczany jest błąd średniokwadratowy (Mean Squared Error, MSE) pomiędzy rzeczywistymi wartościami a przewidzianymi. MSE jest popularną metryką w modelowaniu predykcyjnym, mierzącą średni kwadrat różnic między przewidzianymi a rzeczywistymi wartościami. Im mniejsza wartość MSE, tym lepszy model.

Obliczanie średniego błędów bezwzględnych (MAE): `mae = mean_absolute_error(actual, predicted)` - ta linia kodu oblicza średni błąd bezwzględny (Mean Absolute Error, MAE). MAE mierzy średnią wartość bezwzględnych różnic między

przewidywaniami a rzeczywistymi wartościami. Podobnie jak w przypadku MSE, mniejsza wartość MAE wskazuje na lepszą dokładność modelu.

Obliczanie pierwiastka błędu średniokwadratowego (RMSE): ``rmse = np.sqrt(mse)`` - w tej linii kodu obliczany jest pierwiastek kwadratowy z wartości MSE, co daje pierwiastek błędu średniokwadratowego (Root Mean Squared Error, RMSE). RMSE jest użyteczny, ponieważ ma tę samą jednostkę co zmienne, które model próbuje przewidzieć, co ułatwia interpretację.

Zwracanie obliczonych metryk: ``return mse, mae, rmse`` - na końcu funkcja zwraca obliczone metryki: MSE, MAE i RMSE.

Funkcja ``calculate_metrics`` służy do obliczania i zwracania kluczowych metryk błędu wykorzystywanych w ocenie modeli predykcyjnych, które są niezbędne do zrozumienia dokładności i efektywności modelu.

Tworzenie interfejsu użytkownika za pomocą Streamlit

```
Streamlit - user interface
st.title("Predykcja wartości odczytów prądu")
```

Fragment kodu to jednolinijkowy skrypt napisany z użyciem biblioteki Streamlit, która jest popularnym narzędziem do tworzenia interaktywnych aplikacji webowych dla analizy danych i uczenia maszynowego.

Opis kodu:

-Streamlit - user interface: Jest to komentarz w kodzie, który wskazuje, że poniższa część kodu dotyczy tworzenia interfejsu użytkownika za pomocą Streamlit.

``st.title("Predykcja wartości odczytów prądu")``: Ta linia kodu wykorzystuje funkcję ``title`` z biblioteki Streamlit, oznaczoną jako ``st``. Funkcja ``title`` służy do wyświetlania tytułu w aplikacji webowej. W tym przypadku tytuł, który zostanie wyświetlony na stronie, to "Predykcja wartości odczytów prądu".

Interfejs użytkownika umożliwiający wybór daty dla prognozy

```
Date picker for prediction

selected_date = st.date_input("Wybierz datę dla prognozy")

Ensure selected_date is defined
if not selected_date:
    selected_date = pd.to_datetime("today")
```

Fragment kodu, napisany przy użyciu biblioteki Streamlit, tworzy interfejs użytkownika umożliwiający wybór daty dla prognozy, a także zawiera logikę zapewniającą, że data zostanie zdefiniowana.

Wybór daty dla prognozy:

- ``selected_date = st.date_input("Wybierz datę dla prognozy")``:
 - Ta linia kodu używa funkcji ``date_input`` z biblioteki Streamlit (``st``), aby utworzyć widget wyboru daty w interfejsie użytkownika.
 - Użytkownikowi wyświetlany jest komunikat "Wybierz datę dla prognozy", który zachęca do wyboru określonej daty. Wybrana data jest następnie przypisywana do zmiennej ``selected_date``.

Sprawdzenie, czy data została wybrana:

- `if not selected_date:`:
 - Ta linia kodu sprawdza, czy zmienna `selected_date` jest pusta lub niezdefiniowana. Jeśli użytkownik nie wybierze żadnej daty, `selected_date` będzie miała wartość `None` lub podobną, co spowoduje wejście do bloku instrukcji wewnątrz warunku `if`.
 - `selected_date = pd.to_datetime("today")`:
 - Jeśli żadna data nie została wybrana, to domyślnie przypisuje się do zmiennej `selected_date` aktualną datę. Używa do tego funkcji `to_datetime` z biblioteki pandas, konwertując string `"today"` na obiekt daty odpowiadający bieżącemu dniowi.

Omówiony kod pozwala użytkownikowi na wybranie daty prognozy za pomocą interaktywnego widgetu w aplikacji Streamlit. Jeśli użytkownik nie wybierze żadnej daty, automatycznie przyjmuje się bieżącą datę jako wartość domyślną. To zapewnia, że zmienna `selected_date` zawsze będzie miała zdefiniowaną wartość, co jest ważne dla dalszej logiki programu, która wykorzystuje tę datę do generowania prognoz.

Konwersji wybranej daty na obiekt typu `Timestamp`

```
Convert selected_date to pandas.Timestamp
selected_date = pd.Timestamp(selected_date)
```

Fragment kodu to kontynuacja wcześniejszego skryptu i dotyczy konwersji wybranej daty na obiekt typu `Timestamp` z biblioteki pandas.

- `selected_date = pd.Timestamp(selected_date)`:
 - W tej linii kodu, zmienna `selected_date`, która została wcześniej zdefiniowana (przez użytkownika lub jako data bieżąca, jeśli użytkownik nie dokonał wyboru), jest przekształcana w obiekt typu `Timestamp` z biblioteki pandas.
 - Funkcja `pd.Timestamp` konwertuje różne formaty czasu i daty na jednolity typ `Timestamp`, który jest szeroko stosowany w pandas do obsługi dat i czasów. Jest to przydatne, szczególnie w analizie danych czasowych, gdzie spójność formatów daty i czasu jest kluczowa.
 - Po tej konwersji, `selected_date` będzie reprezentować konkretną chwilę czasową z dokładnością do nanosekund, co pozwala na bardziej precyzyjne i spójne operacje na danych związanych z czasem.

Omówiony kod konwertuje wybraną datę na typ `Timestamp` z biblioteki pandas, zapewniając odpowiedni i spójny format daty, który jest niezbędny w dalszej analizie i przetwarzaniu danych w aplikacji.

Znalezienie najlepszych parametrów za pomocą `auto_arima`

```
Use auto_arima to find the best parameters
model = auto_arima(data['Pomiar'], seasonal=False, stepwise=True,
suppress_warnings=True, error_action="ignore")
st.write(f"Najlepsze znalezione parametry ARIMA: (p={model.order[0]},
d={model.order[1]}, q={model.order[2]})")

Adjust the number of periods based on the selected date
periods_to_predict = (selected_date - data.index[-1]).days * 24

Training the ARIMA model
predictions = model.predict(n_periods=periods_to_predict)

Calculating metrics
```

```
mse, mae, rmse = calculate_metrics(data['Pomiar'][-24:], predictions[:24])

    Displaying metrics
    st.write("MSE:", mse)
    st.write("MAE:", mae)
    st.write("RMSE:", rmse)
```

```
- `model = auto_arima(data['Pomiar'], seasonal=False, stepwise=True,
suppress_warnings=True, error_action="ignore")`:
```

- Używając funkcji `auto_arima` z biblioteki, która automatycznie wybiera najlepsze parametry dla modelu ARIMA, tworzy się model prognozujący. Funkcja ta analizuje podaną serię czasową (`data['Pomiar']`) i szuka optymalnych parametrów modelu (p, d, q) bez uwzględniania sezonowości (`seasonal=False`). Używa podejścia krokowego (`stepwise=True`) do szybszego przeszukiwania przestrzeni parametrów, ignoruje ostrzeżenia (`suppress_warnings=True`) i nie przerywa działania przy napotkaniu błędów (`error_action="ignore").

```
- `st.write(f"Najlepsze znalezione parametry ARIMA: (p={model.order[0]},
d={model.order[1]}, q={model.order[2]})")`:
```

- Wyświetla w aplikacji Streamlit najlepsze znalezione parametry modelu ARIMA.

Dostosowanie liczby okresów na podstawie wybranej daty:

```
- `periods_to_predict = (selected_date - data.index[-1]).days * 24`:
```

- Oblicza liczbę okresów do prognozowania (w godzinach) na podstawie różnicy między wybraną datą a ostatnią datą w danych.

Trenowanie modelu ARIMA:

```
- `predictions = model.predict(n_periods=periods_to_predict)`:
```

- Używając utworzonego modelu, dokonuje prognoz na liczbę okresów wyliczoną wcześniej.

Obliczanie metryk:

```
- `mse, mae, rmse = calculate_metrics(data['Pomiar'][-24:], predictions[:24])`:
```

- Wywołuje funkcję `calculate_metrics` (zdefiniowaną wcześniej), aby obliczyć metryki błędu (MSE, MAE, RMSE) dla prognoz modelu. Porównuje ostatnie 24 pomiary z rzeczywistymi danymi z pierwszymi 24 prognozowanymi wartościami.

Wyświetlanie metryk:

```
- `st.write("MSE:", mse)`, `st.write("MAE:", mae)`, `st.write("RMSE:", rmse)`:
```

Powyższy fragment kodu tworzy model ARIMA do prognozowania wartości w serii czasowej, wybiera najlepsze parametry modelu, trenuje go do przewidywania przyszłych wartości, a następnie oblicza i wyświetla kluczowe metryki błędu, aby ocenić dokładność modelu. Jest to typowe podejście w analizie danych czasowych, szczególnie w aplikacjach, które mają za zadanie przewidywanie przyszłych trendów czy wartości na podstawie historycznych danych.

Tworzenie interaktywnego wykresu w aplikacji Streamlit

```
Creating an interactive chart
fig = go.Figure()
fig.add_trace(go.Scatter(x=data.index, y=data['Pomiar'], mode='lines',
name='Rzeczywiste'))
prediction_index = pd.date_range(start=data.index[-1], periods=periods_to_predict +
1, closed='right')
fig.add_trace(go.Scatter(x=prediction_index, y=predictions, mode='lines',
name='Predykcja'))
fig.update_layout(title_text="Rzeczywiste i przewidywane wartości pomiarów prądu")
st.plotly_chart(fig)
```

Fragment kodu dotyczy tworzenia interaktywnego wykresu w aplikacji Streamlit, który będzie przedstawiał rzeczywiste i przewidywane wartości pomiarów prądu.

Tworzenie pustego wykresu:

- `fig = go.Figure()`:
- Inicjuje nowy, pusty wykres przy użyciu biblioteki Plotly (wskazanej jako `go`).

Dodanie rzeczywistych danych do wykresu:

- `fig.add_trace(go.Scatter(x=data.index, y=data['Pomiar'], mode='lines', name='Rzeczywiste'))`:
- Dodaje do wykresu serię danych rzeczywistych (`data['Pomiar']`), gdzie osią x jest indeks danych (`data.index`), a osią y są wartości pomiarów prądu. Dane te są przedstawiane jako linie (`mode='lines'`) i oznaczone etykietą 'Rzeczywiste'.

Przygotowanie indeksu dla danych prognozowanych:

- `prediction_index = pd.date_range(start=data.index[-1], periods=periods_to_predict + 1, closed='right')`:
- Tworzy serię dat, która zaczyna się od ostatniej daty w rzeczywistych danych i obejmuje liczbę okresów prognozowanych. Jest to niezbędne do skorelowania prognoz z odpowiadającymi im datami.

Dodanie przewidywanych danych do wykresu:

- `fig.add_trace(go.Scatter(x=prediction_index, y=predictions, mode='lines', name='Predykcja'))`:
- Dodaje serię danych przewidywanych (`predictions`) do wykresu. Oś x jest określona przez `prediction_index`, a oś y przez wartości przewidywane. Dane te są również przedstawiane jako linie i oznaczone etykietą 'Predykcja'.

Aktualizacja układu wykresu:

- `fig.update_layout(title_text="Rzeczywiste i przewidywane wartości pomiarów prądu")`:

Aktualizuje układ wykresu, dodając tytuł "Rzeczywiste i przewidywane wartości pomiarów prądu".

Wyświetlanie wykresu w Streamlit:

- `st.plotly_chart(fig)`:

Ta linia kodu wykorzystuje funkcję `plotly_chart` z Streamlit, aby wyświetlić wykres `fig` w aplikacji. Umożliwia to interaktywne przeglądanie danych – użytkownicy mogą na przykład przybliżać wykres, przesuwać się po nim lub wyświetlać wartości danych w poszczególnych punktach.

Powyższy fragment kodu tworzy i prezentuje interaktywny wykres za pomocą biblioteki Plotly w aplikacji Streamlit. Wykres ten przedstawia zarówno rzeczywiste wartości pomiarów prądu, jak i wartości przewidywane przez model, co pozwala na wizualne porównanie i ocenę dokładności modelu prognozującego.

Ocena i walidacja modelu

Ocena i walidacja modelu w zakresie predykcji energii elektrycznej przedstawiona zostanie na przykładzie systemu zasilania dla pomieszczenia kotłowni.

Predykcje dotyczące systemu zasilania w pomieszczeniu kotłowni obejmowały prognozowanie jego wydajności. Dzięki analizie trendów i monitorowaniu kluczowych wskaźników, możliwe jest planowanie konserwacji oraz unikanie nieoczekiwanych przerw w dostawie energii.

Wykorzystano model ARIMA (autoregresyjna zintegrowana średnia krocząca) do analizy i prognozowania szeregów czasowych. Implementacja skupia się na interaktywnym interfejsie użytkownika stworzonym za pomocą frameworka Streamlit, ułatwiającym przetwarzanie i wizualizację danych.

Prognozowanie zużycia energii elektrycznej jest kluczowym elementem zarządzania i planowania w sektorze energetycznym. W podejściu wykorzystano model ARIMA, który jest powszechnie stosowany w analizie szeregów czasowych ze względu na jego skuteczność w modelowaniu danych z różnymi trendami i wzorcami sezonowości.

Kod jest zaimplementowany w Pythonie, z wykorzystaniem bibliotek takich jak Pandas, Plotly, Streamlit oraz pmdarima.

Prezentowane narzędzie wyróżnia się elastycznością i łatwością użycia. Możliwość przesyłania plików danych i wybierania daty prognozy przez użytkownika sprawia, że aplikacja jest praktyczna w różnorodnych scenariuszach wykorzystania. Model ARIMA dostosowuje się do różnych wzorców danych, co czyni go odpowiednim dla zróżnicowanych zbiorów danych dotyczących zużycia energii.

Analiza Wyników Miar Jakości dla Modelu ARIMA w Prognozowaniu Zużycia Energii Elektrycznej

Parametryzacja Modelu

W badaniach zastosowano model ARIMA z parametrami ($p=5$, $d=1$, $q=3$). Wybór takiej konfiguracji był podyktowany chęcią uchwycenia istotnych autoregresyjnych właściwości szeregu czasowego oraz adekwatnego uwzględnienia wpływu błędów prognozy. Parametr ($p=5$) implikuje wykorzystanie pięciu poprzednich obserwacji w celu prognozowania przyszłych wartości. Jednokrotne różnicowanie ($d=1$) ma na celu uzyskanie stacjonarności szeregu, co jest kluczowym założeniem w modelowaniu ARIMA. Trzy opóźnienia błędu prognozy ($q=3$) pozwalają na uwzględnienie niedawnych innowacji w prognozie.

Dane od lutego do września porównanie zbioru treningowego do testowego 80 do 20 %

Ocena Jakości Prognozy

Analiza jakości prognoz została przeprowadzona przy użyciu trzech kluczowych wskaźników:

- Błąd Średniokwadratowy (MSE): Wartość MSE wyniosła 0.01224, sugerując, że model cechuje się znaczną precyzją prognoz. Niska wartość MSE świadczy o małym błędzie prognoz, co jest pożądane w analizie szeregów czasowych, szczególnie w kontekście prognozowania wartości energetycznych.
- Średni Błąd Bezwzględny (MAE): Uzyskany wynik MAE wynoszący 0.09804 wskazuje na umiarkowaną średnią różnicę między wartościami przewidywanymi a obserwowanymi. W kontekście analizowanych danych, MAE na tym poziomie może być interpretowane jako wskaźnik satysfakcjonującej dokładności modelu.
- Pierwiastek Błędu Średniokwadratowego (RMSE): Wartość RMSE, wynosząca 0.11063, reprezentuje średnią wielkość błędu prognoz. Niska wartość RMSE w kontekście badania wskazuje na wysoką zdolność modelu do generowania precyzyjnych prognoz.

Dyskusja

Wyniki badań pokazują, że model ARIMA z wybranymi parametrami efektywnie prognozuje zużycie energii elektrycznej dla badanego budynku. Metody i rozwiązania zastosowane w obiekcie badanym mogą zostać użyte w innych budynkach. Wysoka dokładność modelu, widoczna poprzez niskie wartości MSE i RMSE, pozwala na efektywne przewidywanie przyszłych wartości zużycia energii, co ma istotne znaczenie dla zarządzania zasobami energetycznymi. Jednocześnie, umiarkowana wartość MAE potwierdza praktyczną użyteczność modelu w realistycznych scenariuszach operacyjnych.

Wnioski

Model ARIMA z parametrami ($p=5$, $d=1$, $q=3$) wykazuje się znaczącą skutecznością w prognozowaniu zużycia energii elektrycznej. Niskie wartości MSE i RMSE świadczą o wysokiej dokładności modelu, co jest kluczowe dla niezawodności prognoz w sektorze energetycznym. Wyniki te podkreślają potencjał wykorzystania modelu ARIMA w zaawansowanej analizie szeregów czasowych, szczególnie w dziedzinie prognozowania zużycia energii.

4.8. Model predykcji zużycia wody

Do prognozowania zużycia wody w pracy wykorzystano model regresji liniowej, z użyciem interfejsu użytkownika opartego na Streamlit. Metoda regresji liniowej umożliwia modelowanie związku między czasem a zużyciem wody, co jest kluczowe w zarządzaniu zasobami wodnymi.

Metodologia

- Ładowanie Danych: Dane są wczytywane z pliku Excel i przetwarzane, przy czym daty i czasy są konwertowane na znaczniki czasu.
- Wizualizacja: Używając Plotly Express, prezentowane jest zużycie wody w czasie.
- Model Regresji Liniowej: Model wykorzystuje znaczniki czasu do prognozowania zużycia wody.
- Ocena Modelu: Model oceniany jest na podstawie Współczynnika Determinacji (R^2) i Średniego Błędu Bezwzględnego (MAE).
- Prognozowanie Kumulatywnego Zużycia: Model prognozuje kumulatywne zużycie wody do określonej daty.

Importowanie niezbędnych bibliotek

```
import streamlit as st
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
import numpy as np
import matplotlib.pyplot as plt
from matplotlib.dates import DateFormatter
import datetime as dt
```

Na początku importowane są wszystkie niezbędne biblioteki:

- `streamlit` do tworzenia interaktywnej aplikacji webowej,
- `pandas` do pracy z danymi w formacie tabelarycznym,
- `sklearn` do budowy i oceny modelu predykcyjnego,
- `numpy` do operacji numerycznych,
- `matplotlib` do wizualizacji danych,
- `datetime` do pracy z datami.

Funkcja do wczytywania danych

```
def load_data(uploaded_file):
    df = pd.read_excel(uploaded_file)
    df['data'] = pd.to_datetime(df['data']) # konwersja kolumny 'data' na typ datetime
    df['zuzycie'] = pd.to_numeric(df['zuzycie'], errors='coerce') # konwersja kolumny
    'zuzycie' na numeryczną
    df = df.dropna().reset_index(drop=True)
    return df
```

Funkcja `load_data` wczytuje dane z pliku Excel, konwertuje kolumnę 'data' na typ datetime oraz kolumnę 'zuzycie' na typ numeryczny. Usuwa także brakujące wartości i resetuje indeksy.

Główna funkcja aplikacji

```
def main():
    st.title('Predykcja zużycia wody')
    st.write('Aplikacja do przewidywania zużycia wody na podstawie wcześniejszych danych.')
```

Funkcja `main` ustawia tytuł aplikacji oraz krótki opis jej funkcji.

Wczytanie pliku

```
uploaded_file = st.file_uploader("Wybierz plik Excel", type=["xls", "xlsx"])
if uploaded_file is not None:
```

```
df = load_data(uploaded_file)

st.write("Wyświetlanie pierwszych 5 wierszy danych:")
st.write(df.head())
```

Użytkownik może wczytać plik Excel za pomocą widgetu `file_uploader`. Jeśli plik został załadowany, dane są wczytywane i wyświetlane są pierwsze 5 wierszy.

Przygotowanie danych do modelu

```
df['timestamp'] = df['data'].map(dt.datetime.toordinal)

X = df['timestamp'].values.reshape(-1,1)
y = df['zuzycie'].values
```

Konwertowanie daty na liczby całkowite, co umożliwia ich wykorzystanie w modelu regresji. `X` zawiera przekształcone daty, a `y` wartości zużycia wody.

Podział danych na zestaw treningowy i testowy

```
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

Dane są dzielone na zestawy treningowe i testowe w stosunku 80/20.

Trenowanie modelu

```
model = LinearRegression()
model.fit(X_train, y_train)
```

Tworzony jest model regresji liniowej i trenowany jest na danych treningowych.

Przewidywania na podstawie modelu

```
y_pred = model.predict(X_test)
```

Model przewiduje wartości zużycia wody na podstawie danych testowych.

Obliczanie i wyświetlanie błędu średniokwadratowego i współczynnika determinacji R^2

```
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

st.write(f'Błąd średniokwadratowy (MSE): {mse:.2f}')
st.write(f'Współczynnik determinacji ( $R^2$ ): {r2:.2f}')
```

Obliczanie i wyświetlanie wartości błędu średniokwadratowego (MSE) oraz współczynnika determinacji (R^2), które oceniają dokładność modelu.

Wykres danych

```
fig, ax = plt.subplots()
ax.scatter(df['data'], df['zuzycie'], color='black', label='Dane rzeczywiste')
ax.plot(df['data'], model.predict(df['timestamp'].values.reshape(-1,1)),
color='blue', linewidth=3, label='Linia trendu')
ax.set_xlabel('Data')
ax.set_ylabel('Zużycie wody')
ax.xaxis.set_major_formatter(DateFormatter('%Y-%m-%d'))
plt.xticks(rotation=45)
plt.tight_layout()
plt.legend()
st.pyplot(fig)
```

Tworzenie wykresu rozrzutu rzeczywistych danych oraz linię trendu przewidywaną przez model. Data jest formatowana do czytelnego formatu.

Wybór daty do predykcji

```
selected_date = st.date_input("Wybierz datę do predykcji zużycia wody")
if st.button('Przewiduj'):
    selected_date = dt.datetime.strptime(str(selected_date), '%Y-%m-%d')
    selected_date_ordinal = selected_date.toordinal()
    predicted_consumption = model.predict([[selected_date_ordinal]])
    st.write(f'Przewidywane zużycie wody na dzień {selected_date.date()}:
{predicted_consumption[0]:.2f}')
```

Użytkownik może wybrać datę do przewidywania zużycia wody. Po naciśnięciu przycisku `Przewiduj`, aplikacja wylicza przewidywane zużycie na podstawie wybranej daty i wyświetla wynik.

Uruchomienie aplikacji

```
if __name__ == '__main__':
    main()
```

Jeśli skrypt jest uruchamiany bezpośrednio, wykonywana jest funkcja `main`, co uruchamia aplikację Streamlit.

Prezentowany powyżej kod pozwala użytkownikowi na interaktywne wczytywanie danych, trenowanie modelu predykcyjnego oraz wizualizację wyników w przystępnej formie webowej.

Predykcje dotyczące zużycia wody pozwoliły na monitorowanie i prognozowanie ilości wody zużywanej w obiekcie. To istotne zarówno z ekonomicznego punktu widzenia, jak i z perspektywy zrównoważonego zarządzania zasobami.



Rys. 49. Rzeczywiste vs prognozowane zużycie wody

Ocena Modelu i omówienie Rzeczywistych Miary Jakości

Model został oceniony przy użyciu dwóch miar jakości (Rys. 49):

- Współczynnik Determinacji (R^2): Wartość R^2 wynosi 0.9821117054751802, co wskazuje, że model skutecznie wyjaśnia większość zmienności danych. Wysoka wartość R^2 , bliska 1, sugeruje, że model jest efektywny w prognozowaniu trendów zużycia wody.
- Średni Błąd Bezwzględny (MAE): MAE, wynoszący 814.0891197523532, reprezentuje średnią wartość błędów prognoz. Jest to wskaźnik, który pokazuje umiarkowaną różnicę między prognozowanymi a rzeczywistymi wartościami zużycia wody, oferując bardziej zrównoważony pomiar błędów niż MSE.

Dyskusja

Wysoki współczynnik R^2 wskazuje na ogólną skuteczność modelu w prognozowaniu trendów zużycia wody. MAE zapewnia użyteczny wgląd w dokładność modelu, wskazując na umiarkowaną różnicę między prognozowanymi a rzeczywistymi wartościami. Te miary jakości sugerują, że model regresji liniowej może być efektywnie wykorzystany w zarządzaniu zasobami wodnymi, chociaż może wymagać dalszych dostosowań w celu optymalizacji prognoz.

Wnioski

Model regresji liniowej prezentuje dobrą zdolność do prognozowania ogólnych trendów zużycia wody, co jest potwierdzone przez wysoki współczynnik R^2 . Umiarkowany MAE wskazuje na praktyczną użyteczność modelu w prognozowaniu zużycia wody, co jest istotne dla efektywnego zarządzania zasobami wodnymi. Wyniki te mogą być przydatne dla instytucji i przedsiębiorstw zajmujących się dystrybucją i zarządzaniem wodą.

4.9. Analiza przebiegów temperatury pompy ciepła i jej otoczenia

Analiza przebiegów temperatury pompy ciepła oraz jej otoczenia pozwoliła na monitorowanie efektywności działania tego systemu oraz planowanie ewentualnych interwencji w przypadku awarii lub nieprawidłowego funkcjonowania.

Random Forest to renomowany algorytm uczenia maszynowego, stosowany zarówno w problemach regresji, jak i klasyfikacji. Jest to typowy algorytm ensemble, który łączy wyniki wielu drzew decyzyjnych, celem uzyskania bardziej precyzyjnych prognoz. W kontekście tego badania, algorytm Random Forest jest wykorzystywany do przewidywania temperatury na podstawie danych historycznych.

Metodologia

Aby prognozować temperaturę, przeprowadzane jest zbieranie danych historycznych, obejmujących odczyty temperatury w różnych punktach czasowych, a także inne informacje dotyczące warunków środowiska. Następnie implementowany jest algorytm Random Forest za pomocą biblioteki scikit-learn w języku Python. Skrypt wczytuje dane, dokonuje ich analizy oraz trenuje model Random Forest na podstawie zebranych danych.

Sekcja importów

```
import streamlit as st
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import mean_squared_error, r2_score, mean_absolute_error
import plotly.express as px
import datetime
```

Na początku importowane są wszystkie niezbędne biblioteki:

- `streamlit` do tworzenia interaktywnej aplikacji webowej,
- `pandas` do pracy z danymi w formacie tabelarycznym,
- `sklearn` do budowy i oceny modelu predykcyjnego,
- `plotly.express` do tworzenia interaktywnych wykresów,
- `datetime` do pracy z datami.

Wczytanie danych

```
def load_data(uploaded_file):
    data = pd.read_excel(uploaded_file, parse_dates={'data_czas': ['Data', 'Czas']},
    decimal=',')
    data['timestamp'] = data['data_czas'].apply(lambda x: datetime.datetime.timestamp(x))
    return data
```

Funkcja `load_data` wczytuje dane z pliku Excel, łączy kolumny 'Data' i 'Czas' w jedną kolumnę 'data_czas', a następnie konwertuje tę kolumnę na znacznik czasu (`timestamp`).

Funkcja do wizualizacji danych

```
def plot_data(df, selected_column):
    fig = px.line(df, x='data_czas', y=selected_column, title=f'{selected_column} w czasie')
    st.plotly_chart(fig, use_container_width=True)
```

Funkcja `plot_data` tworzy wykres liniowy dla wybranej kolumny danych w czasie, używając biblioteki Plotly.

Funkcja do przeprowadzenia regresji

```
def perform_regression(df, selected_column):
    X = df[['timestamp']]
    y = df[selected_column]
    model = RandomForestRegressor(n_estimators=100) # Używamy Random Forest z 100 drzewami
    model.fit(X, y)
    y_pred = model.predict(X)

    mse = mean_squared_error(y, y_pred)
    r2 = r2_score(y, y_pred)
    mae = mean_absolute_error(y, y_pred)

    return model, mse, r2, mae, y_pred
```

Funkcja `perform_regression` przygotowuje dane, trenuje model regresji Random Forest, a następnie oblicza metryki błędów (MSE, R^2 , MAE) oraz zwraca przewidywane wartości.

Funkcja do przewidywania wartości

```
def predict_value(model, df, date):
    timestamp = datetime.datetime.timestamp(date)
    predicted_value = model.predict([[timestamp]])
    return predicted_value[0]
```

Funkcja `predict_value` przyjmuje model, dane oraz datę, a następnie przewiduje wartość dla tej daty.

Główna część aplikacji

```
uploaded_file = st.file_uploader("Wybierz plik xlsx", type=["xlsx"])
if uploaded_file is not None:
    data = load_data(uploaded_file)
    if st.button('Pokaż dane'):
        st.write(data.head())

    selected_column = st.selectbox('Wybierz kolumnę do przewidywania', data.columns[2:])

    if st.button('Przewiduj'):
        plot_data(data, selected_column)

    model, mse, r2, mae, y_pred = perform_regression(data, selected_column)
    st.write(f"Błąd średniokwadratowy (MSE): {mse}")
    st.write(f"Współczynnik determinacji ( $R^2$ ): {r2}")
    st.write(f"Mean Absolute Error (MAE): {mae}")

    data['Predykcja'] = y_pred
    fig2 = px.line(data, x='data_czas', y=[selected_column, 'Predykcja'], title='Rzeczywiste vs Prognozowane dane')
    st.plotly_chart(fig2, use_container_width=True)

    selected_date = st.date_input("Wybierz datę do prognozowania", datetime.date.today())
    if st.button('Prognozuj wartość'):
        predicted_value = predict_value(model, data,
datetime.datetime.combine(selected_date, datetime.datetime.min.time()))
        st.write(f"Prognozowana wartość dla {selected_date}: {predicted_value}")

    fig3 = px.line(data, x='data_czas', y=selected_column, title=f'Prognoza dla {selected_column}')
    fig3.add_scatter(x=[selected_date], y=[predicted_value], mode='markers+text',
text=["Prognoza"], name="Prognoza")
    st.plotly_chart(fig3, use_container_width=True)
```

- Wczytanie pliku Excel.
- Wyświetlanie danych: Po wczytaniu pliku użytkownik może kliknąć przycisk, aby zobaczyć pierwsze pięć wierszy danych.
- Wybór kolumny: Użytkownik może wybrać kolumnę do przewidywania.
- Wizualizacja danych: Użytkownik może kliknąć przycisk, aby wyświetlić wykres danych wybranej kolumny w czasie.
- Trenowanie modelu i wyświetlanie metryk: Model jest trenowany na wybranej kolumnie, a następnie wyświetlane są metryki błędów (MSE, R^2 , MAE).
- Wykres rzeczywistych i prognozowanych danych: Wykres porównujący rzeczywiste dane z prognozowanymi wartościami.
- Prognozowanie wartości dla wybranej daty: Użytkownik wybiera datę, a aplikacja przewiduje wartość dla tej daty oraz wyświetla wynik na wykresie.

Przedstawiony powyżej kod pozwala użytkownikowi na interaktywne wczytywanie danych, trenowanie modelu Random Forest oraz wizualizację wyników w przystępnej formie webowej. Na rysunkach Rys. 50-52 przedstawiono przykładowe ekrany aplikacji. Pokazano widok ekranu głównego aplikacji po załadowaniu pliku z danymi z SCSWiN, widok ekranu aplikacji z wykresem przebiegu danych rzeczywistych i prognozowanych temperatury wody pompy ciepła. Widok ekranu głównego aplikacji wraz z wynikami miar jakości predykcji temperatury zewnętrznej.

Ocena uzyskanych wyników

Przeprowadzenie analizy danych oraz prognozowanie temperatury przy wykorzystaniu algorytmu Random Forest przynosi wyniki pozwalające zrozumieć zmienność temperatury w przeszłości oraz prognozować jej przyszłe zmiany. Otrzymane wyniki stanowią istotne źródło informacji przy podejmowaniu decyzji związanych z zarządzaniem systemami grzewczymi, chłodniczymi oraz klimatyzacyjnymi.

Ocena jakości przewidywania temperatury zewnętrznej za pomocą algorytmu Random Forest dostarcza ważnych informacji dotyczących dokładności modelu:

- Błąd średniokwadratowy (MSE) wynosi 0.6260. MSE mierzy średnią kwadratową różnicę między rzeczywistymi danymi a prognozami modelu. Wartość ta wskazuje, że model osiąga relatywnie niski poziom błędu kwadratowego, co sugeruje dobrą zdolność modelu do dokładnego przewidywania temperatury zewnętrznej.
- Współczynnik determinacji (R^2) wynosi 0.9893. R^2 jest miarą, która wskazuje, jak dobrze model dostosowuje się do rzeczywistych danych. Wartość bliska 1 oznacza, że model doskonale dopasowuje się do danych, a więc w tym przypadku model wykazuje bardzo wysoką zdolność do wyjaśniania zmienności w temperaturze zewnętrznej.
- Średni błąd bezwzględny (MAE) wynosi 0.5169. MAE jest miarą bezwzględnego odchylenia przewidywanych wartości od rzeczywistych danych. Wartość MAE wskazuje, że model ma tendencję do przewidywania temperatury zewnętrznej z niewielkim błędem bezwzględnym, co jest korzystnym wynikiem.

Dyskusja

Podsumowując, wyniki oceny jakości modelu Random Forest w przypadku przewidywania temperatury zewnętrznej są bardzo obiecujące. Niskie wartości MSE i MAE oraz wysoki współczynnik determinacji R^2 sugerują, że model jest w stanie dokładnie prognozować temperaturę zewnętrzną na podstawie dostępnych danych historycznych. Jest to istotne narzędzie w dziedzinach takich jak zarządzanie systemami klimatyzacji, gdzie dokładne prognozy temperatury są kluczowe dla efektywnego działania systemów.

Wnioski

Metoda przewidywania temperatury, bazująca na algorytmie Random Forest, okazuje się być efektywnym narzędziem do analizy danych temperaturowych oraz do przewidywania ich przyszłych zmian. Przedstawiony skrypt stanowi praktyczną implementację tej metody,

co może być szczególnie użyteczne w różnych dziedzinach, takich jak budownictwo, energetyka czy zarządzanie nieruchomościami

Analiza danych

Wybierz plik xlsx

Drag and drop file here
Limit 200MB per file • XLSX

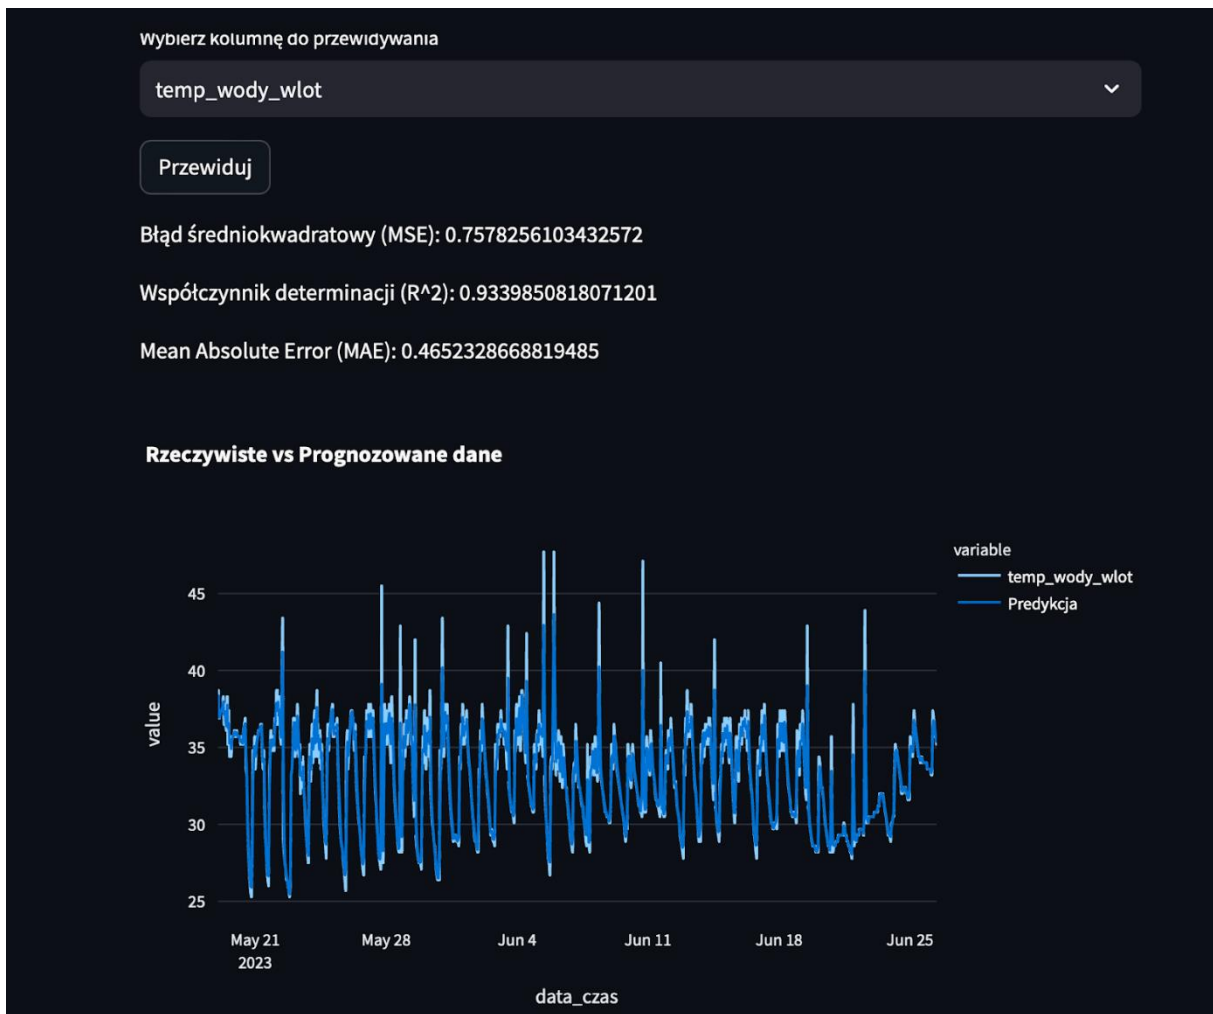
Browse files

Pompa_temperatura_wewnatrz2.xlsx 46.9KB

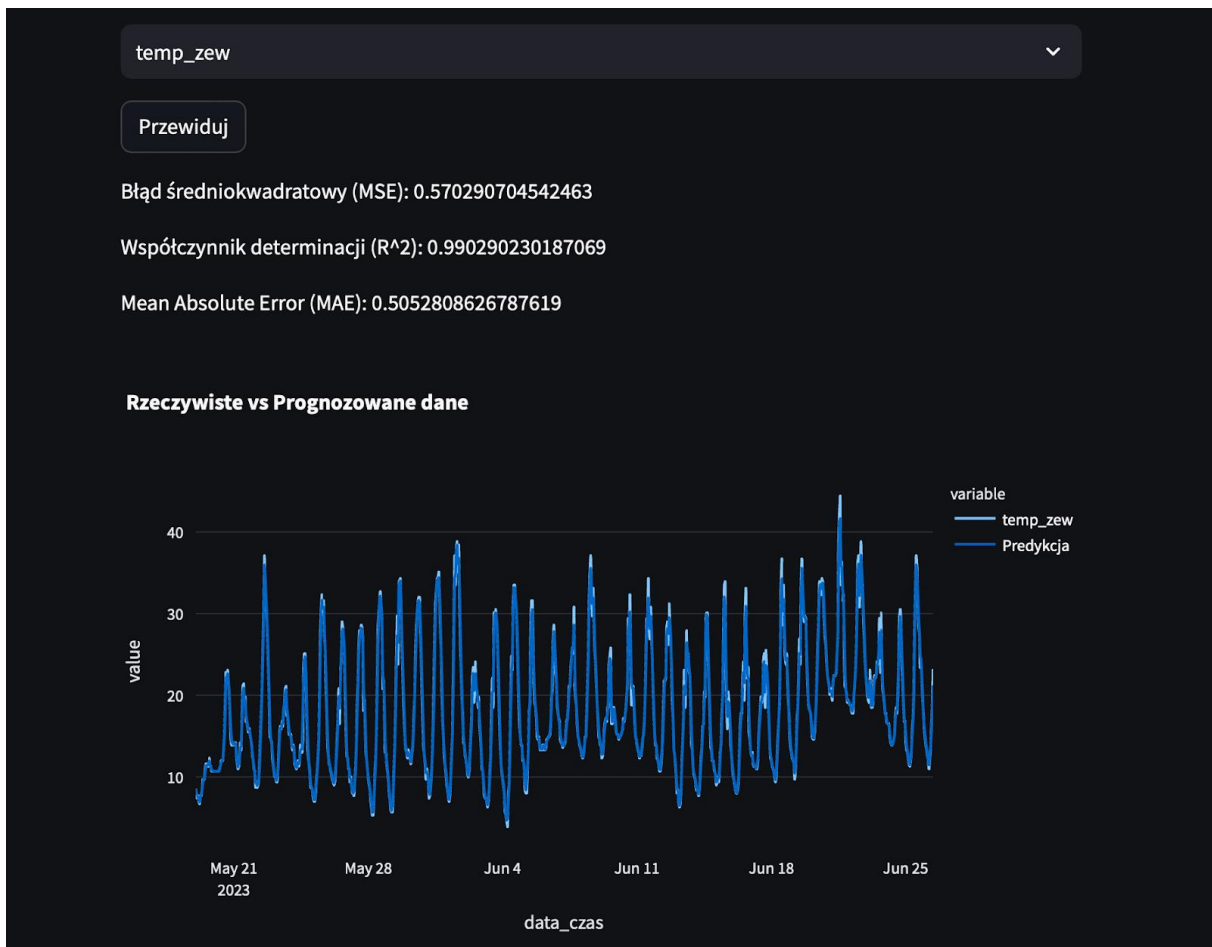
Pokaż dane

	data_czas	temp_pomieszczenia	temp_zew	temp_wody_wlot	temp_wody_wylot	temp_wy
0	2023-05-19 00:11:25	0	8.4	38.3	38.7	
1	2023-05-19 00:15:00	29	8.4	37.8	38.3	
2	2023-05-19 00:20:27	29	8.4	37.4	37.8	
3	2023-05-19 00:23:58	29	8.4	36.9	37.4	
4	2023-05-19 00:49:23	29	7.7	38.7	39.2	

Rys. 50 Widok ekranu głównego aplikacji po załadowaniu pliku z danymi z SCSWiN



Rys.51 Widok ekranu aplikacji z wykresem przebiegu danych rzeczywistych i prognozowanych temperatury wody pompy ciepła.



Rys. 52 Widok ekranu głównego aplikacji wraz z wynikami miar jakości predykcji w zakresie temperatury zewnętrznej.

Podsumowanie wyników i uzasadnienie biznesowe

TAURON, jako jedna z największych grup energetycznych w Polsce, zarządza rozbudowaną infrastrukturą budynków, w tym biurami, centrami operacyjnymi i innymi obiektami użyteczności publicznej. Skuteczne zarządzanie zużyciem wody w tych budynkach jest kluczowe dla zrównoważonego rozwoju, optymalizacji kosztów operacyjnych oraz zwiększenia efektywności energetycznej.

Cel i korzyści

Zastosowanie modelu predykcyjnego do prognozowania zużycia wody w budynkach administrowanych przez TAURON Dystrybucja S.A. przyniesie liczne korzyści biznesowe, w tym:

- Optymalizacja kosztów operacyjnych:
 - Prognozowanie zużycia wody umożliwi dokładniejsze planowanie budżetu oraz redukcję kosztów związanych z nadmiernym zużyciem.
 - Zidentyfikowanie wzorców zużycia pozwala na lepsze zarządzanie zasobami wodnymi oraz minimalizowanie strat.
- Poprawa efektywności zarządzania:

- Dostarczanie precyzyjnych prognoz zużycia wody umożliwi bardziej efektywne planowanie prac konserwacyjnych oraz napraw.
- Predykcja zużycia wody pozwala na szybszą identyfikację anomalii, co może prowadzić do szybszej interwencji w przypadku wycieków lub awarii.
- Wsparcie zrównoważonego rozwoju:
 - Redukcja zużycia wody przyczynia się do zmniejszenia śladu wodnego TAURON Dystrybucja S.A., wspierając cele zrównoważonego rozwoju firmy.
 - Model predykcyjny może być używany do oceny skuteczności działań proekologicznych, takich jak instalacja urządzeń oszczędzających wodę.
- Poprawa komfortu użytkowników budynków:
 - Prognozowanie zużycia wody umożliwi lepsze zarządzanie dostarczaniem wody, co może poprawić komfort pracowników i mieszkańców budynków.
 - Zapewnienie stabilnego i przewidywalnego dostępu do wody przyczynia się do zwiększenia zadowolenia użytkowników.
- Identyfikacja i zapobieganie awariom:
 - Analiza odchyłeń od prognozowanego zużycia może pomóc w szybkim wykrywaniu i naprawie wycieków lub innych problemów technicznych, zanim staną się one poważnym problemem.
- Wsparcie decyzji inwestycyjnych:
 - Informacje z modelu mogą być używane do podejmowania decyzji o inwestycjach w technologie oszczędzania wody, takie jak nowoczesne systemy irygacyjne, urządzenia do recyklingu wody, czy systemy monitoringu zużycia wody.

Wnioski

Implementacja modelu predykcyjnego do prognozowania zużycia wody w budynkach administrowanych przez TAURON Dystrybucja S.A. przyniesie wymierne korzyści, takie jak optymalizacja kosztów, poprawa efektywności zarządzania, wsparcie zrównoważonego rozwoju oraz zwiększenie komfortu użytkowników. Dzięki zaawansowanej analizie danych i precyzyjnym prognozom, TAURON Dystrybucja S.A. będzie mógł lepiej zarządzać swoimi zasobami wodnymi, co przyczyni się do poprawy operacyjnej i finansowej firmy.

4.10. Model predykcji uszkodzeń

Predykcja uszkodzeń systemów w zakresie systemów zabezpieczenia technicznego zespołów budynków oraz w zakresie funkcjonowania różnorodnych, współpracujących ze sobą systemów utrzymania komfortu cieplnego budynków, w szczególności w nieruchomościach

zarządzanych jako zbiór obiektów o heterogenicznym charakterze w znacznym stopniu nie został zbadany i udokumentowany. Dlatego niniejsza praca przedstawia:

- możliwości zastosowania predykcji uszkodzeń w zakresie systemów zabezpieczenia technicznego obiektów komercyjnych,
- możliwość wykorzystania metod stosowanych w predykcji uszkodzeń systemów zabezpieczenia technicznego obiektów na różnorodnych obiektach,
- ekonomicznie zasadną „głębokość stosowania predykcji uszkodzeń” na systemach zabezpieczeń technicznych obiektów,
- wyniki zastosowania algorytmów predykcji uszkodzeń w zakresie predykcji uszkodzeń w systemach utrzymania komfortu cieplnego budynków,
- możliwość wykorzystania jednego narzędzia, jednej spójnej bazy danych i rejestrowanych w niej zdarzeń dla predykcji uszkodzeń zarówno w systemach zabezpieczenia technicznego obiektów jak również w systemach utrzymania komfortu cieplnego budynków.

Opis źródeł danych i przygotowanie do modelowania

W zakresie danych niezbędnych dla prowadzenia predykcji uszkodzeń systemów utrzymania komfortu cieplnego w budynkach oraz systemów zabezpieczenia technicznego budynków należy zgromadzić dane z zakresu:

- parametrów zasilania urządzeń utrzymania komfortu cieplnego,
- statusu pracy urządzeń oraz błędów przekazywanych na szyny danych przez sterowniki poszczególnych urządzeń składających się na system utrzymania komfortu cieplnego,
- informacji na temat alarmów i zdarzeń rejestrowanych przez systemy zabezpieczenia technicznego obiektów.

Dane w zakresie zasilania urządzeń utrzymania komfortu cieplnego zaprezentowane zostały w poprzednim rozdziale dotyczącym predykcji konsumpcji mediów, w części dotyczącej opisu pojedynczej badanej nieruchomości. Częstotliwość pomiaru, dokładność pomiaru, urządzenia pomiarowe oraz sposób gromadzenia tych danych zawarty został w ww. rozdziale.

Dane dotyczące błędów, statusu pracy urządzeń składających się na system utrzymania komfortu cieplnego oraz dane w zakresie alarmów i zdarzeń rejestrowanych przez systemy zabezpieczenia technicznego obiektów zapisywane są w bazie danych w interwale 15 minutowym.

Sposób transmisji danych do narzędzia informatycznego, baza danych, jak również samo narzędzie zostało szerzej opisane w rozdziale poprzednim dotyczącym predykcji konsumpcji mediów.

Analiza rodzajów danych źródłowych

Dane z systemu utrzymania komfortu cieplnego budynku (pompa ciepła, wentylacja i klimatyzacja) mają na celu zgromadzenie informacji o aktualnym stanie pracy urządzeń oraz ewentualnych awariach oraz alertach (Tabela 10).

Tabela. 10. Dane z systemu utrzymania komfortu cieplnego budynku - przykład z szyn Modbus

Rejestr	Opis	Objaśnienie wartości
10001	Status przepływu wody	0: prawidłowy przepływ/1: zbyt niski przepływ
10002	Stan Pompy Wodnej	0: Pompy Wodnej WYŁ./1: Pompy Wodnej WŁ.
10003	Roz. Stan Pompy Wodnej	0: Pompy Wodnej WYŁ./1: Pompy Wodnej WŁ.
10004	Status sprężarki	0: sprężarka WYŁ./1: sprężarka WŁ.
10005	Status odmrażania	0: odmrażanie WYŁ. / 1: odmrażanie WŁ.
10006	Stan ogrzewania DHW (Termiczne DHW Włączone/Wyłączone)	0 : DHW nieaktywne / 1 : DHW aktywne

Dane z systemu zabezpieczenia technicznego obiektu dotyczą zablokowania i rozblokowania obiektu i są pomocne w określeniu okresu przebywania osób w obiekcie oraz ewentualnych zdarzeń związanych z użytkowaniem obiektu przez pracowników (Tabela 11).

Tabela. 11. Dane z systemu zabezpieczenia technicznego obiektu

ID	Sygnal
1	WE 1 - RS 1.3 zanik fazy L1
2	WE 2 - RS 1.3 zanik fazy L2
3	WE 3 - RS 1.3 zanik fazy L3
4	WE 4 - RS UPS monitoring, SSWiN, KD zadziałanie zabezpieczenia
5	WE 5 - RWP - awaria zasilania wyłącznika pożarowego
6	WE 6 - SSP zadziałanie zabezpieczenia
7	WE 7 - Klimatyzacja serwerownia zadziałanie zabezpieczenia
8	WE 8 - UDK rozbrojony
9	WE 9 - SSP usterka ogólna
10	WE 10 - SSP awaria zasilania
11	WE 11 - SSP alarm drugiego stopnia
12	WE 12 - SSP alarm pierwszego stopnia
13	WE 13 - UDK włamanie
14	WE 14 - UDK sabotaż
15	WE 15 - UDK awaria zasilania
16	WE 16 - UDK awaria ogólna

W ramach niniejszego projektu badawczego opracowano aplikację Streamlit, wykorzystującą model XGBoost (eXtreme Gradient Boosting) do analizy regresyjnej w celu przewidywania awarii. Aplikacja ta, zaimplementowana w języku Python, integruje funkcjonalność bibliotek Streamlit, Pandas i Scikit-learn, służąc do interaktywnego przetwarzania danych i analizy predykcyjnej. Wykorzystanie `st.session_state` pozwala na przechowywanie modelu XGBoost oraz obliczonych metryk jakości między różnymi interakcjami użytkownika z interfejsem aplikacji. Aplikacja oferuje możliwość przesyłania danych w formacie Excel, ich wyświetlania oraz interaktywnego dostosowywania hiperparametrów modelu, takich jak liczba drzew, tempo uczenia się, czy głębokość drzew. Dane są dzielone na zbiory treningowy i testowy, a następnie

wykorzystywane do trenowania modelu XGBoost. Po wytrenowaniu model jest zapisywany w stanie sesji, umożliwiając późniejsze jego wykorzystanie do predykcji.

Implementacja modelu XGBoost (eXtreme Gradient Boosting)

Poniżej przedstawiono implementację modelu XGBoost (eXtreme Gradient Boosting) w narzędziu służącym predykcji uszkodzeń.

Sekcja importów

```
import streamlit as st
import pandas as pd
from sklearn.ensemble import RandomForestRegressor
from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error
from datetime import datetime
import base64
import pickle
```

Na początku importowane są wszystkie niezbędne biblioteki:

- `streamlit` do tworzenia interaktywnej aplikacji webowej,
- `pandas` do pracy z danymi w formacie tabelarycznym,
- `sklearn` do budowy i oceny modelu predykcyjnego,
- `datetime` do pracy z datami,
- `base64` i `pickle` do serializacji modelu i umożliwienia jego pobrania.

Funkcja do wczytywania danych i ich przetwarzania

```
def load_data(uploaded_file):
    Read the data
    data = pd.read_excel(uploaded_file)

    #Convert date to datetime and extract features
    data['date'] = pd.to_datetime(data['date'])
    data['hour'] = data['date'].dt.hour
    data['day'] = data['date'].dt.day
    data['month'] = data['date'].dt.month
    data['dayofweek'] = data['date'].dt.dayofweek

    Drop the original date column
    data.drop('date', axis=1, inplace=True)

    return data
```

Funkcja `load_data` wczytuje dane z pliku Excel, konwertuje kolumnę 'date' na typ datetime, a następnie ekstrahuje dodatkowe cechy (hour, day, month, dayofweek). Oryginalna kolumna 'date' jest usuwana, a przetworzone dane są zwracane.

Funkcja do trenowania modelu

```
def train_model(data):
    Split the data into features and target
    X = data.drop('failures', axis=1)
    y = data['failures']

    Split the data into training and test sets
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42)

    Initialize and train the model
```

```

model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)

Predict on the test set
y_pred = model.predict(X_test)

Calculate RMSE
rmse = mean_squared_error(y_test, y_pred, squared=False)

return model, rmse

```

Funkcja `train_model` dzieli dane na cechy (features) i cel (target), a następnie na zestawy treningowe i testowe. Model RandomForestRegressor jest trenowany na danych treningowych, a jego skuteczność oceniana jest na podstawie zestawu testowego przy użyciu metryki RMSE (Root Mean Squared Error).

Funkcja do przewidywania awarii

```

def predict(model, features):
    return model.predict([features])

```

Funkcja `predict` przyjmuje model oraz cechy (features) i zwraca przewidywaną liczbę awarii.

Funkcja do zapisywania modelu jako plik pickle

```

def save_model(model):
    pickle_bytes = pickle.dumps(model) # Dangerous to use pickle if you're not 100% sure of
    the source
    b64_bytes = base64.b64encode(pickle_bytes).decode()
    href = f"<a href='\"data:file/pickle;base64,{b64_bytes}\"' download='\"model.pkl\"'>Download
    Trained Model</a>"
    return href

```

Funkcja `save_model` serializuje model przy użyciu pickle i koduje go w formacie base64, co umożliwia jego pobranie jako plik z linkiem HTML.

Główna część aplikacji Streamlit

```

st.title('Failure Prediction Model Trainer')

Upload the dataset and save as csv
st.markdown("## Train your own model")
uploaded_file = st.file_uploader("Upload your input Excel file", type=["xlsx"])

if uploaded_file is not None:
    Load and preprocess the data
    data = load_data(uploaded_file)

    Train the model
    model, rmse = train_model(data)

    Show the RMSE
    st.write(f"Model trained with RMSE: {rmse}")

    Let the user download the trained model
    st.markdown(save_model(model), unsafe_allow_html=True)

    st.markdown("## Make predictions")
    Predicting failures
    Assuming that we have a form with the features required for prediction
    feature_1 = st.number_input('feature_1', min_value=0, max_value=1, value=0)

```

```

feature_2 = st.number_input('feature_2', min_value=0, max_value=1, value=0)
feature_3 = st.number_input('feature_3', min_value=0, max_value=1, value=0)
Assuming that the user inputs the date and time for which they want to predict failures
date = st.date_input("Date for prediction")
time = st.time_input("Time for prediction")
timestamp = datetime.combine(date, time)
hour = timestamp.hour
day = timestamp.day
month = timestamp.month
dayofweek = timestamp.weekday()

The button to make prediction
if st.button('Predict Failures'):
    features = [hour, day, month, dayofweek, feature_1, feature_2, feature_3]
    prediction = predict(model, features)
    st.write(f"Predicted number of failures: {prediction[0]}")

```

Wczytanie danych użytkownika w formacie pliku Excel.

Przetwarzanie danych i trenowanie modelu: Dane są przetwarzane i trenowany jest model.

Wyświetlany jest wynik RMSE modelu.

Pobieranie modelu: Użytkownik może pobrać wytrenowany model jako plik pickle.

Prognozowanie awarii: Użytkownik może wprowadzić cechy i datę, aby prognozować liczbę awarii. Wynik prognozy jest wyświetlany.

Powyżej przedstawiony kod pozwala użytkownikowi na interaktywne wczytywanie danych, trenowanie modelu Random Forest, pobieranie wytrenowanego modelu oraz prognozowanie liczby awarii w przystępnej formie webowej.

Ocena predykcji awarii Systemu Kontroli Dostępu

Predykcje dotyczące awarii systemu kontroli dostępu umożliwiają szybką reakcję na potencjalne problemy z bezpieczeństwem i dostępem do obiektu. Dzięki temu można minimalizować ryzyko nieuprawnionego dostępu i utraty danych.

Monitoring_test2.xlsx 55.7KB

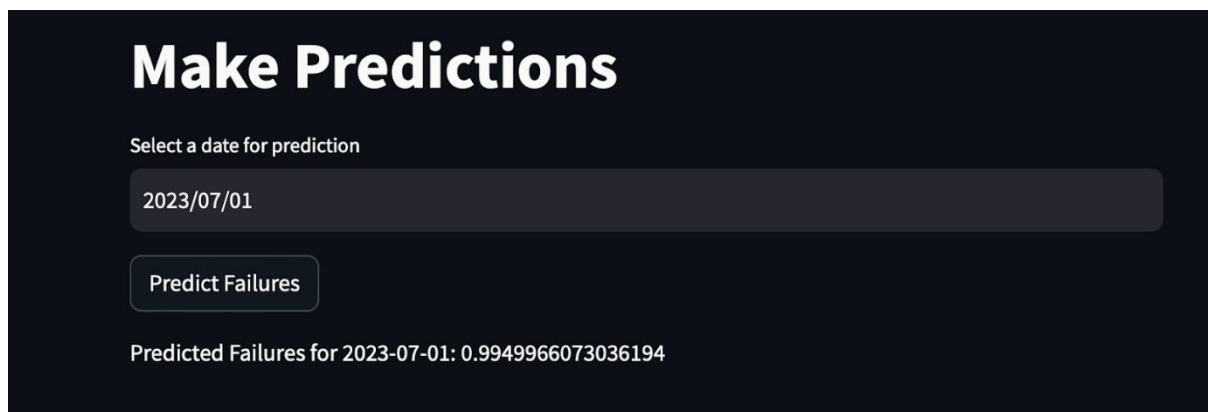
Data Overview

	date	feature1	feature2	feature3	failure
0	2023-03-02 00:00:00	0	0	0	0
1	2023-03-02 00:00:00	0	0	0	0
2	2023-03-02 00:00:00	0	0	0	0
3	2023-03-02 00:00:00	0	0	0	0
4	2023-03-02 00:00:00	0	0	0	0

Train Model

Model has been trained!

Rys. 53. Ekran główny aplikacji do predykcji awarii systemu SKD



Rys. 54. Widok ekranu głównego aplikacji po przeprowadzeniu predykcji

Do oceny wydajności modelu w tym przypadku wykorzystano trzy kluczowe metryki:

- - RMSE (Root Mean Squared Error – Błąd Średniokwadratowy): Jego wartość 11.594657948927123 odzwierciedla średnią wielkość błędów modelu; im niższa wartość RMSE, tym mniejsza różnica między przewidywaniami a rzeczywistymi wynikami. RMSE jest szczególnie użyteczny w kontekście modeli regresyjnych, ponieważ penalizuje duże błędy bardziej niż mniejsze, dając wgląd w ekstremalne przypadki błędów modelu.
- - MAE (Mean Absolute Error – Średni Błąd Bezwzględny): Z wartością 0.5822648538276554, MAE reprezentuje średnią wartość bezwzględnych błędów między przewidywaniami modelu a rzeczywistymi wartościami, dostarczając intuicyjnego pomiaru średniej wielkości błędu. W przeciwieństwie do RMSE, MAE traktuje wszystkie błędy równo, nie nadając większego ciężaru większym błędom.
- - R^2 Score (Współczynnik Determinacji): Z wynikiem 0,82, ta metryka określa, jak dobrze przewidywania modelu korelują z rzeczywistymi wartościami. Wartość R^2 w zakresie 0-1 ocenia, jaki procent wariancji zmiennej zależnej jest wyjaśniony przez model. Wynik 0,82 wskazuje na to, że model skutecznie wyjaśnia znaczącą część wariancji danych, co świadczy o jego dobrej zdolności predykcyjnej.

Podsumowanie modelu i uzasadnienie biznesowe

Zastosowanie algorytmu XGBoost do predykcji uszkodzeń w nowych systemach monitoringu infrastruktury stanowiło przedmiot przedstawionych badań. Algorytm XGBoost, będący zaawansowanym modelem uczenia maszynowego, wykazał obiecujące wyniki w wielu aplikacjach. W ramach badań, model XGBoost został dostosowany do przewidywania uszkodzeń, wykorzystując duże zbiory danych dotyczące warunków pracy i parametrów technicznych systemu monitoringu. Wyniki testów modelu wykazały wysokie wskaźniki jakości, w tym dokładność i precyzję w predykcji uszkodzeń.

Mimo tych pozytywnych wyników, zauważono konieczność ponownego wytrenowania modelu. Powodem tego jest fakt, że analizowany nowy system monitoringu infrastruktury (powstały w 2022 roku) praktycznie nie generował alarmów w badanym okresie. Oznacza to, że dane, na których opierał się model, mogą nie odzwierciedlać rzeczywistych warunków eksploatacji systemu w przyszłości. Brak wystarczającej liczby zdarzeń alarmowych w danych

historycznych może prowadzić do niepełnej lub nieprecyzyjnej reprezentacji potencjalnych scenariuszy uszkodzeń.

W związku z tym, planowane jest dalsze działania, które obejmują ponowne uczenie modelu XGBoost z wykorzystaniem nowo zebranych danych, co pozwoli na lepszą kalibrację modelu do specyfiki nowego systemu monitoringu infrastruktury.

Dyskusja

Rozdział prezentuje szczegółową analizę i ocenę systemów wspomaganie decyzji (SWD) w kontekście zarządzania złożonymi i rozproszonymi nieruchomościami, skupiając się na efektywnym zarządzaniu mediami oraz predykcji uszkodzeń systemów technicznych. Opracowane rozwiązania obejmują implementację algorytmów predykcyjnych, takich jak ARIMA, XGBoost, regresja liniowa i Random Forest, które wspierają proces podejmowania decyzji i poprawiają zarządzanie kluczowymi zasobami w nieruchomościach.

Jednym z głównych osiągnięć tego rozdziału jest stworzenie modeli predykcyjnych, które skutecznie prognozują zużycie energii elektrycznej i wody, a także przewidują potencjalne awarie systemów technicznych, takich jak systemy HVAC (ogrzewanie, wentylacja, klimatyzacja) oraz systemy zabezpieczeń technicznych (SSP, SSWiN, CCTV). Zastosowane algorytmy są odpowiedzialne za przetwarzanie dużych ilości danych, które są gromadzone przez liczniki energii i wody, a także stacje pogodowe, rejestrując dane w regularnych interwałach czasowych.

Rozdział szczegółowo opisuje, jak system SWD przyczynia się do optymalizacji zużycia energii i wody w budynkach. Dzięki możliwości prognozowania na podstawie historycznych danych, system pozwala na bardziej precyzyjne planowanie budżetów operacyjnych i zakupów energii, co skutkuje redukcją kosztów operacyjnych i uniknięciem kar związanych z niewłaściwym planowaniem zasobów. Modele predykcyjne, takie jak ARIMA, są wykorzystywane do prognozowania zmiennych w czasie, co pozwala na analizę i przewidywanie przyszłego zużycia energii w poszczególnych strefach budynku.

Kolejnym istotnym osiągnięciem opisanym w rozdziale jest predykcja uszkodzeń systemów technicznych, co umożliwi bardziej efektywne zarządzanie konserwacją i utrzymaniem budynków. Modele takie jak XGBoost i Random Forest są stosowane do analizy danych dotyczących awarii systemów technicznych, co pozwala na planowanie działań prewencyjnych i minimalizację ryzyka wystąpienia poważniejszych usterek. Dzięki temu zarządzający budynkami mogą szybciej reagować na pojawiające się problemy, co z kolei prowadzi do zwiększenia bezpieczeństwa i komfortu użytkowników nieruchomości.

Rozdział podkreśla także znaczenie standaryzacji automatyki budynkowej i systemów ochrony technicznej w celu zapewnienia długoterminowej, bezawaryjnej eksploatacji obiektów oraz optymalizacji kosztów operacyjnych. Standaryzacja procesów i procedur w zarządzaniu różnorodnymi budynkami sprzyja większej efektywności operacyjnej i łatwiejszemu monitorowaniu oraz konserwacji systemów technicznych. Zastosowanie jednolitych

wytycznych pozwala na szybsze reagowanie na problemy techniczne oraz zwiększa spójność działań zarządczych.

Dzięki wykorzystaniu technologii IoT oraz przetwarzania danych, system wspomagania decyzji umożliwia zbieranie i analizowanie danych z różnych źródeł w czasie rzeczywistym. Takie podejście wspiera dynamiczne i proaktywne zarządzanie zasobami budynków, co jest kluczowe dla utrzymania wysokiej efektywności operacyjnej oraz zadowolenia użytkowników nieruchomości. Monitorowanie parametrów budynków, takich jak temperatura, wilgotność, zużycie energii i wody, pozwala na lepsze dostosowanie warunków eksploatacji do potrzeb użytkowników oraz na optymalizację kosztów związanych z eksploatacją.

Podsumowując, rozdział ukazuje, jak zastosowanie systemów wspomagania decyzji w zarządzaniu nieruchomościami przynosi wymierne korzyści, takie jak optymalizacja kosztów, zwiększenie efektywności operacyjnej, poprawa bezpieczeństwa oraz komfortu użytkowników budynków. Zastosowanie zaawansowanych algorytmów predykcyjnych umożliwia lepsze planowanie działań operacyjnych i konserwacyjnych, co przekłada się na redukcję awarii i zwiększenie ciągłości pracy systemów technicznych. Implementacja opisywanych rozwiązań pozwala także na lepsze zarządzanie zużyciem energii i wody, co jest kluczowe w kontekście zrównoważonego rozwoju i odpowiedzialnego gospodarowania zasobami.

Kierunki badań i rozwoju

Biorąc pod uwagę zakres przeprowadzonych badań oraz zakres wdrożenia narzędzi możliwe jest prowadzenie prac rozwojowych w następujących obszarach:

- badanie możliwości sprzężenia zwrotnego w zakresie wyników predykcji ze sterowaniem urządzeniami, w tym badanie efektów ekonomicznych i wpływu narzędzia organizację zespołów odpowiedzialnych za utrzymanie nieruchomości,
- badanie wpływu skalowania rozwiązania, - w zakresie rozbudowy modułu na kolejne lokalizacje – opłacalność, wydajność algorytmów, itp.,
- zastosowanie nowych algorytmów predykcyjnych i analiza porównawcza z obecnymi algorytmami.

W kontekście dalszego rozwoju wdrożonego systemu wspomagania decyzji, kluczowe obszary, które wymagają szczegółowej analizy, obejmują integrację sprzężenia zwrotnego wyników predykcji ze sterowaniem urządzeniami, skalowanie rozwiązania do nowych lokalizacji oraz analizę porównawczą różnych algorytmów predykcyjnych. Poniżej przedstawiono szczegółowe omówienie każdego z tych aspektów.

4.11. Sprzężenie Zwrotne Wyników Predykcji ze Sterowaniem Urządzeniami

Integracja sprzężenia zwrotnego wyników predykcji ze sterowaniem urządzeniami jest istotnym krokiem w kierunku zwiększenia efektywności systemu wspomagania decyzji. Aktualnie stosowane systemy predykcyjne generują prognozy, które mogą być wykorzystane do optymalizacji decyzji operacyjnych. Wprowadzenie mechanizmu sprzężenia zwrotnego

umożliwia dynamiczne dostosowanie parametrów sterowania urządzeniami w odpowiedzi na rzeczywiste wyniki predykcji.

Z teoretycznego punktu widzenia, sprzężenie zwrotne może być opisane za pomocą modelu kontrolera adaptacyjnego. Takie podejście pozwala na korekcję działań sterujących na podstawie różnicy między wartością prognozowaną a rzeczywistą. W literaturze przedmiotu, badania nad kontrolą adaptacyjną wykazują, że takie mechanizmy mogą znacznie poprawić stabilność i efektywność systemów dynamicznych.

W praktyce, przykład zastosowania sprzężenia zwrotnego można zaobserwować w systemach zarządzania energią, gdzie predykcje zapotrzebowania na energię są używane do automatycznego sterowania generatorami, magazynami energii i urządzeniami energochłonnymi. Implementacja sprzężenia zwrotnego wymaga jednak zaawansowanych algorytmów kontrolnych oraz testów w różnych warunkach operacyjnych, aby zapewnić stabilność i niezawodność systemu.

Skalowanie rozwiązania oraz rozbudowa systemu na nowe lokalizacje są kluczowymi etapami w dalszym rozwoju systemu wspomagania decyzji. Wdrożenie systemu w wielu lokalizacjach wymaga uwzględnienia kilku istotnych aspektów technicznych i organizacyjnych.

Architektura systemu musi być elastyczna i modułarna, aby umożliwić bezproblemowe rozszerzanie funkcjonalności oraz integrację z istniejącymi systemami. Architektury oparte na mikroserwisach i konteneryzacji mogą ułatwić skalowanie systemu oraz zarządzanie różnorodnymi komponentami.

Efektywne zarządzanie danymi z różnych lokalizacji jest kluczowe dla utrzymania spójności i jakości informacji. Konieczne jest wdrożenie rozwiązań do centralnego gromadzenia, przechowywania oraz przetwarzania danych, które zapewnią wysoką wydajność i bezpieczeństwo.

Bezpieczeństwo i niezawodność komunikacji między lokalizacjami są krytyczne dla ochrony danych i zapewnienia integralności systemu. Implementacja rozwiązań takich jak szyfrowanie end-to-end i protokoły odporne na awarie może zminimalizować ryzyko nieautoryzowanego dostępu i utraty danych.

Analiza porównawcza algorytmów predykcyjnych stanowi fundament dalszego doskonalenia systemu wspomagania decyzji. Porównanie różnych algorytmów umożliwia wybór najbardziej efektywnych metod w kontekście specyficznych zadań i warunków operacyjnych.

Ocena algorytmów powinna obejmować kilka kluczowych kryteriów: dokładność prognoz, szybkość przetwarzania oraz efektywność w zmieniających się warunkach. W literaturze naukowej, wiele badań koncentruje się na porównywaniu algorytmów takich jak regresja liniowa, drzewa decyzyjne oraz sieci neuronowe w różnych scenariuszach aplikacyjnych.

Ważnym aspektem jest również analiza kosztów operacyjnych związanych z wdrożeniem i utrzymaniem algorytmów, w tym wymagania dotyczące zasobów

obliczeniowych oraz przechowywania danych. Wybór algorytmu powinien być uzależniony od analizy kosztów i korzyści, co pozwala na optymalizację wydatków oraz efektywności (Hastie i in., 2009).

Rozwój systemu wspomaganie decyzji w kierunkach omówionych w niniejszym rozdziale – integracja sprzężenia zwrotnego wyników predykcji, skalowanie rozwiązania oraz analiza porównawcza algorytmów – stanowi klucz do zwiększenia jego efektywności i funkcjonalności. Wdrożenie tych działań wymaga dokładnej analizy teoretycznej i praktycznej, a także ścisłego monitorowania w celu zapewnienia ich skuteczności i niezawodności w różnych kontekstach operacyjnych. W przyszłości, dalsze badania i rozwój w tych obszarach mogą przyczynić się do znaczącej poprawy wyników i możliwości systemów wspomaganie decyzji.

5. Podsumowanie

Niniejsza praca stanowi kompleksową analizę i ocenę systemów wspomaganie decyzji (SWD) w zarządzaniu heterogenicznymi, rozproszonymi nieruchomościami. W szczególności praca koncentruje się na identyfikacji kluczowych czynników wpływających na efektywność zarządzania zespołem nieruchomości, opracowaniu standardów i wytycznych dla projektowania rozwiązań z zakresu automatyki budynkowej oraz systemów ochrony technicznej, a także na ocenie możliwości predykcji uszkodzeń i zużycia mediów za pomocą zaawansowanych algorytmów uczenia maszynowego.

Celem pracy była analiza możliwości zastosowania metod predykcji danych do wspomaganie zarządzania rozproszonych, heterogenicznych zespołów nieruchomości komercyjnych, wyposażonych w systemy o różnorodnych parametrach technicznych i eksploatacyjnych, zidentyfikowanie zakresu danych pozyskiwanych z budynków niezbędnych dla przeprowadzania predykcji oraz opracowanie odpowiednich procedur wdrożenia tych metod do sprawnego zarządzania obiektami oraz przewidywania zapotrzebowania na energię, kosztów utrzymania i ryzyka awarii.

Za najważniejsze osiągnięcia pracy autor uważa:

- przeprowadzenie badań w zakresie przewidywania awarii systemów automatyki budynkowej, w szczególności systemów HVAC oraz systemów zabezpieczeń technicznych budynków,
- potwierdzenie możliwości i dokładności prognozowania zużycia energii elektrycznej, zarówno dla pojedynczych nieruchomości, jak i całych ich zespołów przy pomocy modelu ARIMA (SARIMA),
- potwierdzenie możliwości i dokładności prognozowania zużycia wody przy pomocy modelu regresji liniowej,
- prognozowania pogody dla nieruchomości zlokalizowanych na obszarach o specyficznych warunkach mikroklimatycznych przy pomocy modelu ARIMA,
- wdrożenie zestandaryzowanych technologii, które pozwolą na monitorowanie i przewidywanie zużycia energii oraz przewidywanie awarii, co bezpośrednio przekłada się na optymalizację procesów zarządzania budynkami.

W ramach pracy wdrożono wielodomenowy system wspomaganie decyzji zarządczych utrzymania budynków komercyjnych TAURON Dystrybucja S.A.

System wykorzystuje algorytmy predykcyjne do szacowania przyszłego zużycia mediów, efektywności energetycznej obiektów, a także umożliwia poprawę planowania pracy oraz możliwość reakcji na zaistniałe uszkodzenia zespołów nadzorujących eksploatację i utrzymanie obiektów. System wykorzystuje zastaną infrastrukturę techniczną oraz portfolio algorytmów dopasowanych do kontekstu danych. System wykorzystuje algorytmy predykcyjne w następującym zakresie:

- Regresja liniowa – w zakresie konsumpcji wody,
- ARIMA – dla analiz danych zmiennych takich jak np. zużycie energii elektrycznej,

- Random forest – dla przewidywania parametrów pompy ciepła,
- Xboost – w zakresie analizy uszkodzeń systemów zabezpieczenia technicznego.

Współczesne organizacje, zarządzające dużymi zasobami nieruchomości, stają przed wyzwaniem skutecznego monitorowania, zarządzania i optymalizacji kosztów operacyjnych. SWD, integrujące technologie IoT oraz przetwarzanie danych w chmurze, oferują narzędzia do analizy danych w czasie rzeczywistym, co umożliwia podejmowanie bardziej świadomych i efektywnych decyzji. Implementacja SWD w zarządzaniu nieruchomościami pozwala na lepsze planowanie konserwacji, szybkie wykrywanie i naprawę awarii, a także na optymalizację zużycia energii i innych zasobów.

Badania wykazały, że zaawansowane modele predykcyjne, takie jak XGBoost, są efektywne w przewidywaniu uszkodzeń systemów technicznych oraz zużycia energii i wody.

Predykcyjne podejście umożliwia planowanie działań prewencyjnych, co znacząco redukuje koszty operacyjne i minimalizuje ryzyko przestojów. Modele te pozwalają na monitorowanie stanu technicznego nieruchomości i przewidywanie potencjalnych awarii, co jest kluczowe dla utrzymania ciągłości operacyjnej.

Opracowanie standaryzowanych wytycznych dla automatyki budynkowej i systemów ochrony technicznej jest kluczowe dla zapewnienia długoterminowej bezawaryjnej eksploatacji oraz optymalizacji kosztów. Standaryzacja pozwala na jednolite podejście do zarządzania różnorodnymi obiektami, co zwiększa efektywność operacyjną i ułatwia monitorowanie oraz konserwację. Standaryzowane procedury umożliwiają szybkie i efektywne reagowanie na problemy techniczne oraz zapewniają spójność w zarządzaniu nieruchomościami.

Integracja technologii IoT i przetwarzania w chmurze w systemach SWD umożliwia zbieranie i analizowanie danych z różnych źródeł w czasie rzeczywistym. Takie podejście wspiera bardziej responsywne i proaktywne zarządzanie zasobami, co jest kluczowe dla utrzymania wysokiego poziomu efektywności operacyjnej oraz zadowolenia użytkowników nieruchomości. Systemy te umożliwiają monitorowanie różnych parametrów budynków, takich jak temperatura, wilgotność, zużycie energii, co pozwala na bieżące dostosowywanie warunków do potrzeb użytkowników.

Wyniki przeprowadzonych badań mają istotne implikacje dla praktyki zarządzania nieruchomościami. Implementacja systemów wspomaganego decydowania w zarządzaniu nieruchomościami przynosi szereg korzyści, takich jak:

- Lepsze Zarządzanie Zasobami: SWD umożliwiają bardziej precyzyjne i efektywne zarządzanie zużyciem energii, wody oraz innymi zasobami, co przyczynia się do redukcji kosztów operacyjnych i zwiększenia efektywności energetycznej budynków. Analiza danych w czasie rzeczywistym pozwala na identyfikowanie obszarów, gdzie możliwe są oszczędności i wprowadzanie odpowiednich działań optymalizacyjnych.
- Zwiększenie Bezpieczeństwa: Systemy monitorowania i analizy danych w czasie rzeczywistym pozwalają na szybkie wykrywanie i reakcję na potencjalne zagrożenia, co zwiększa bezpieczeństwo użytkowników nieruchomości. Technologie takie jak systemy

zarządzania alarmami, monitorowanie wideo, czy kontrola dostępu, są kluczowe dla zapewnienia bezpieczeństwa zarówno budynków, jak i ich użytkowników.

- Optymalizacja Kosztów Konserwacji: Predykcyjne modele konserwacji pozwalają na planowanie działań prewencyjnych, co minimalizuje koszty związane z naprawami awaryjnymi oraz przedłuża żywotność urządzeń i systemów technicznych. Dzięki temu możliwe jest zapobieganie kosztownym awariom i zapewnienie ciągłości operacyjnej.
- Poprawa Efektywności Operacyjnej: SWD przyczyniają się do zwiększenia efektywności operacyjnej poprzez automatyzację procesów decyzyjnych, co pozwala na szybsze i bardziej precyzyjne podejmowanie decyzji. Automatyzacja rutynowych zadań administracyjnych i technicznych uwalnia zasoby ludzkie do realizacji bardziej strategicznych zadań.

Przeprowadzona praca doktorska skupiła się na usprawnieniu zarządzania rozproszonymi zespołami nieruchomości wyposażonych w zróżnicowane systemy techniczne utrzymania komfortu cieplnego, zabezpieczenia technicznego budynku oraz kontroli dostępu. Wdrożenie zestandaryzowanych technologii pozwoli Spółce na monitorowanie i przewidywanie zużycia energii oraz przewidywanie awarii, co bezpośrednio przekłada się na optymalizację procesów zarządzania budynkami.

Przeprowadzone badania potwierdziły tezę, że zastosowanie metod predykcyjnych w zarządzaniu heterogenicznymi zespołami nieruchomości komercyjnych zwiększa efektywność procesów zarządzania, przyczynia się do redukcji kosztów operacyjnych oraz pozwala na lepsze przewidywanie i zarządzanie ryzykiem awarii.

Kierunki Dalszych Badań

Niniejsza praca wskazuje również na potrzebę dalszych badań w obszarze integracji zaawansowanych technologii analizy danych oraz automatyki budynkowej.

Przyszłe badania powinny koncentrować się na rozwijaniu algorytmów predykcyjnych, które mogą uwzględniać większą ilość zmiennych i bardziej złożone relacje między nimi. Algorytmy te powinny być zdolne do uczenia się na bieżąco i adaptacji do zmieniających się warunków operacyjnych.

Istotnym kierunkiem badań jest integracja danych pochodzących z różnych systemów i urządzeń, w tym systemów automatyki budynkowej, systemów zarządzania energią, systemów bezpieczeństwa oraz danych zewnętrznych, takich jak prognozy pogody. Taka integracja umożliwi bardziej kompleksową analizę i lepsze podejmowanie decyzji.

Podsumowanie

Podsumowując, wdrożenie systemów wspomaganie decyzji w zarządzaniu nieruchomościami przynosi wymierne korzyści w zakresie optymalizacji kosztów, zwiększenia efektywności operacyjnej oraz poprawy bezpieczeństwa i komfortu użytkowników. Przedstawione w pracy wyniki badań i rekomendacje stanowią solidną podstawę dla dalszego rozwoju i implementacji zaawansowanych technologii w zarządzaniu rozproszonymi zasobami nieruchomości.

Systemy wspomaganie decyzji odgrywają kluczową rolę w umożliwianiu organizacjom efektywnego i skutecznego reagowania na wyzwania współczesnego świata. Ich ciągły rozwój i adaptacja do zmieniających się potrzeb biznesowych i technologicznych będzie miała istotny wpływ na przyszłość zarządzania i podejmowania decyzji w organizacjach. W związku z tym dalsze badania nad SWD, ich zastosowaniami i wpływem na praktyki zarządcze, a także ich integracją z modelami zarządzania predykcyjnego, stanowią ważne pole do eksploracji dla naukowców i praktyków zarządzania.

Wprowadzenie tych technologii do codziennej praktyki zarządzania nieruchomościami nie tylko poprawi efektywność operacyjną, ale także przyczyni się do bardziej zrównoważonego i odpowiedzialnego zarządzania zasobami, co jest kluczowe w obliczu rosnących wyzwań związanych z ochroną środowiska i zrównoważonym rozwojem.

W TAURON Dystrybucja S.A. system wspomaganie decyzji umożliwia zdalny nadzór, regulację oraz diagnostykę systemów utrzymania komfortu cieplnego heterogenicznych, rozporoszonych budynków komercyjnych. Działanie takie powoduje obniżenie kosztów utrzymania nieruchomości oraz umożliwia szybszą reakcję na zaistniałe uszkodzenia. Predykcja uszkodzeń powoduje, że utrzymanie ciągłości pracy systemów utrzymania komfortu termicznego budynków oraz systemów zabezpieczenia technicznego pozwoli uniknąć incydentów bezpieczeństwa związanych z uszkodzeniem SZT, kosztów ewentualnej ochrony fizycznej wybranych nieruchomości na czas awarii SZT, sprzyja utrzymaniu ciągłości pracy systemów utrzymania komfortu cieplnego użytkowników - nie dezorganizując pracy pracowników realizujących procesy podstawowe dla Spółki.

Predykcja zużycia energii elektrycznej z wykorzystaniem zakresu standardowych dostępnych danych pomiarowych pozwala lepiej planować zakup energii elektrycznej na potrzeby całej populacji budynków, sprzyjając w ten sposób właściwemu budżetowaniu środków finansowych oraz zmniejszając ewentualne kary wynikające z niewłaściwego planowania potrzeb zakupu energii elektrycznej.

Bibliografia

A Brief History of Decision Support Systems (no date). Available at:

<https://dssresources.com/history/dsshistoryv28.html> (Accessed: 8 September 2024).

Aaltonen *et al.*, (2013)

Aaltonen, A. *et al.* (2013) 'Facilities management driving green building certification: A case from Finland', *Facilities*, 31(7), pp. 328–342. doi:10.1108/02632771311317475.

Abed, A.M. (2024)

Abed, A.M. (2024) 'Accelerate demand forecasting by hybridizing CatBoost with the dingo optimization algorithm to support supply chain conceptual framework precisely', *Frontiers in Sustainability*, 5, p. 1388771. doi:10.3389/FRSUS.2024.1388771.

Alfalah, G. and Zayed, T. (2020)

Alfalah, G. and Zayed, T. (2020) 'A review of sustainable facility management research', *Sustainable Cities and Society*, 55, p. 102073. doi:10.1016/J.SCS.2020.102073.

Araszkievicz, K. (2017)

Araszkievicz, K. (2017) 'Digital Technologies in Facility Management – The state of Practice and Research Challenges', *Procedia Engineering*, 196, pp. 1034–1042. doi: 10.1016/J.PROENG.2017.08.059.

Arnott, D. and Pervan, G. (2008)

Arnott, D. and Pervan, G. (2008) 'Eight key issues for the decision support systems discipline', *Decision Support Systems*, 44(3), pp. 657–672. doi: 10.1016/J.DSS.2007.09.003.

Atkin, Brian. and Brooks, Adrian. (2021)

Atkin, Brian. and Brooks, Adrian. (2021) 'Total facility management', p. 450. Available at: https://books.google.com/books/about/Total_Facility_Management.html?hl=pl&id=09QnEAAQBAJ (Accessed: 9 September 2024).

Aziz, N.D., Nawawi, A.H. and Ariff, N.R.M. (2016)

Aziz, N.D., Nawawi, A.H. and Ariff, N.R.M. (2016) 'ICT Evolution in Facilities Management (FM): Building Information Modelling (BIM) as the Latest Technology', *Procedia - Social and Behavioral Sciences*, 234, pp. 363–371. doi: 10.1016/J.SBSPRO.2016.10.253.

Azman, N. *et al.* (2014)

Azman, N. *et al.* (2014) 'Facility Management History and Evolution', 5(1).

Bagheri-Esfah, H. and Dehghan, M.R. (2022)

Bagheri-Esfah, H. and Dehghan, M.R. (2022) 'Multi-objective optimization of setpoint temperature of thermostats in residential buildings', *Energy and Buildings*, 261, p. 111955. doi: 10.1016/J.ENBUILD.2022.111955.

Barua, S. et al. (2021)

Barua, S. et al. (2021) ‘Swindle: Predicting the Probability of Loan Defaults using CatBoost Algorithm’, *Proceedings - 5th International Conference on Computing Methodologies and Communication, ICCMC 2021*, pp. 1710–1715. doi:10.1109/ICCMC51019.2021.9418277.

Barzehkar, M. et al. (2021)

Barzehkar, M. et al. (2021) ‘Decision support tools, systems and indices for sustainable coastal planning and management: A review’, *Ocean & Coastal Management*, 212, p. 105813. doi: 10.1016/J.OCECOAMAN.2021.105813.

Belafi, Z., Hong, T. and Reith, A. (2017a)

Belafi, Z., Hong, T. and Reith, A. (2017a) ‘Smart building management vs. intuitive human control—Lessons learnt from an office building in Hungary’, *Building Simulation*, 10(6), pp. 811–828. doi:10.1007/S12273-017-0361-4/METRICS.

Belafi, Z., Hong, T. and Reith, A. (2017b)

Belafi, Z., Hong, T. and Reith, A. (2017b) ‘Smart building management vs. intuitive human control—Lessons learnt from an office building in Hungary’, *Building Simulation*, 10(6), pp. 811–828. doi:10.1007/S12273-017-0361-4/METRICS.

Bentéjac, C., Csörgő, A. and Martínez-Muñoz, G. (2021)

Bentéjac, C., Csörgő, A. and Martínez-Muñoz, G. (2021) ‘A comparative analysis of gradient boosting algorithms’, *Artificial Intelligence Review*, 54(3), pp. 1937–1967. doi:10.1007/S10462-020-09896-5/METRICS.

Biau, G. and Scornet, E. (2016)

Biau, G. and Scornet, E. (2016) ‘A random forest guided tour’, *Test*, 25(2), pp. 197–227. doi:10.1007/S11749-016-0481-7/METRICS.

Biswas, T. and Samanta, S. (2016)

Biswas, T. and Samanta, S. (2016) ‘A strategic decision support system for logistics and supply chain network design’, *Sadhana - Academy Proceedings in Engineering Sciences*, 41(6), pp. 583–588. doi:10.1007/S12046-016-0496-5/METRICS.

Botchkarev, A. (2018)

Botchkarev, A. (2018) ‘Performance Metrics (Error Measures) in Machine Learning Regression, Forecasting and Prognostics: Properties and Typology’, *Interdisciplinary Journal of Information, Knowledge, and Management*, 14, pp. 45–76. doi:10.28945/4184.

Bouabdallaoui, Y. et al. (2021)

Bouabdallaoui, Y. et al. (2021) ‘Predictive Maintenance in Building Facilities: A Machine Learning-Based Approach’, *Sensors 2021, Vol. 21, Page 1044*, 21(4), p. 1044. doi:10.3390/S21041044.

Brandi, S. et al. (2020)

Brandi, S. et al. (2020) ‘Deep reinforcement learning to optimise indoor temperature control and heating energy consumption in buildings’, *Energy and Buildings*, 224, p. 110225. doi:10.1016/J.ENBUILD.2020.110225.

Braun, M. *et al.* (2021)

Braun, M. *et al.* (2021) 'Primer on an ethics of AI-based decision support systems in the clinic', *Journal of Medical Ethics*, 47(12), pp. e3–e3. doi:10.1136/MEDETHICS-2019-105860.

CAO, Y. *et al.* (2013)

CAO, Y. *et al.* (2013) 'Advance and Prospects of AdaBoost Algorithm', *Acta Automatica Sinica*, 39(6), pp. 745–758. doi:10.1016/S1874-1029(13)60052-X.

Chen, T. and Guestrin, C. (2016)

Chen, T. and Guestrin, C. (2016) 'XGBoost: A scalable tree boosting system', *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 13-17-August-2016, pp. 785–794. doi: 10.1145/2939672.2939785/SUPPL_FILE/KDD2016_CHEN_BOOSTING_SYSTEM_01-ACM.MP4.

Chen, Y. and Han, X. (2021)

Chen, Y. and Han, X. (2021) 'CatBoost for Fraud Detection in Financial Transactions', *2021 IEEE International Conference on Consumer Electronics and Computer Engineering, ICCECE 2021*, pp. 176–179. doi:10.1109/ICCECE51280.2021.9342475.

Cheng, J.C.P. *et al.* (2020)

Cheng, J.C.P. *et al.* (2020) 'Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms', *Automation in Construction*, 112, p. 103087. doi: 10.1016/J.AUTCON.2020.103087.

Chicco, D., Warrens, M.J. and Jurman, G. (2021)

Chicco, D., Warrens, M.J. and Jurman, G. (2021) 'The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation', *PeerJ Computer Science*, 7, pp. 1–24. doi:10.7717/PEERJ-CS.623/SUPP-1.

Chua, K.J., Chou, S.K. and Yang, W.M. (2010)

Chua, K.J., Chou, S.K. and Yang, W.M. (2010) 'Advances in heat pump systems: A review', *Applied Energy*, 87(12), pp. 3611–3624. doi: 10.1016/J.APENERGY.2010.06.014.

Çinar, Z.M. *et al.* (2020)

Çinar, Z.M. *et al.* (2020) 'Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0', *Sustainability 2020, Vol. 12, Page 8211*, 12(19), p. 8211. doi:10.3390/SU12198211.

Compare, M., Baraldi, P. and Zio, E. (2020)

Compare, M., Baraldi, P. and Zio, E. (2020) 'Challenges to IoT-Enabled Predictive Maintenance for Industry 4.0', *IEEE Internet of Things Journal*, 7(5), pp. 4585–4597. doi:10.1109/JIOT.2019.2957029.

Dalzochio, J. *et al.* (2020)

Dalzochio, J. *et al.* (2020) 'Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges', *Computers in Industry*, 123, p. 103298. doi: 10.1016/J.COMPIND.2020.103298.

- Daraghmeh, M. *et al.* (2021)
 Daraghmeh, M. *et al.* (2021) ‘Time Series Forecasting using Facebook Prophet for Cloud Resource Management’, *2021 IEEE International Conference on Communications Workshops, ICC Workshops 2021 - Proceedings* [Preprint].
 doi:10.1109/ICCSWORKSHOPS50388.2021.9473607.
- Dhananjay, B. and Sivaraman, J. (2021)
 Dhananjay, B. and Sivaraman, J. (2021) ‘Analysis and classification of heart rate using CatBoost feature ranking model’, *Biomedical Signal Processing and Control*, 68, p. 102610.
 doi: 10.1016/J.BSPC.2021.102610.
- Dincer, I. (2002)
 Dincer, I. (2002) ‘On thermal energy storage systems and applications in buildings’, *Energy and Buildings*, 34(4), pp. 377–388. doi:10.1016/S0378-7788(01)00126-8.
- Ding, R.X. *et al.* (2020)
 Ding, R.X. *et al.* (2020) ‘Large-Scale decision-making: Characterization, taxonomy, challenges and future directions from an Artificial Intelligence and applications perspective’, *Information Fusion*, 59, pp. 84–102. doi: 10.1016/J.INFFUS.2020.01.006.
- van Dinter, R., Tekinerdogan, B. and Catal, C. (2022)
 van Dinter, R., Tekinerdogan, B. and Catal, C. (2022) ‘Predictive maintenance using digital twins: A systematic literature review’, *Information and Software Technology*, 151, p. 107008.
 doi: 10.1016/J.INFSOF.2022.107008.
- D’Orazio, A. (2018)
 D’Orazio, A. (2018) ‘Air Conditioning Systems with Dual Ducts: Innovative Approaches for the Design of the Transport Network of the Air’, *HVAC System* [Preprint].
 doi:10.5772/INTECHOPEN.80093.
- Dorogush, A.V., Ershov, V. and Yandex, A.G. (2018)
 Dorogush, A.V., Ershov, V. and Yandex, A.G. (2018) ‘CatBoost: gradient boosting with categorical features support’. Available at: <https://arxiv.org/abs/1810.11363v1> (Accessed: 9 September 2024).
- Durdyev, S. *et al.* (2022)
 Durdyev, S. *et al.* (2022) ‘Barriers to the implementation of Building Information Modelling (BIM) for facility management’, *Journal of Building Engineering*, 46, p. 103736. doi: 10.1016/J.JOBE.2021.103736.
- Esrafilian-Najafabadi, M. and Haghghat, F. (2021)
 Esrafilian-Najafabadi, M. and Haghghat, F. (2021) ‘Occupancy-based HVAC control systems in buildings: A state-of-the-art review’, *Building and Environment*, 197, p. 107810.
 doi: 10.1016/J.BUILDENV.2021.107810.
- Fang, T. and Lahdelma, R. (2016)
 Fang, T. and Lahdelma, R. (2016) ‘Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system’, *Applied Energy*, 179, pp. 544–552. doi: 10.1016/J.APENERGY.2016.06.133.

Farouk, N. *et al.* (2022)

Farouk, N. *et al.* (2022) ‘Using PCM in buildings to reduce HVAC energy usage taking into account Saudi Arabia climate region’, *Journal of Building Engineering*, 50, p. 104073. doi: 10.1016/J.JOBE.2022.104073.

Ferbar Tratar, L. and Strmčnik, E. (2016)

Ferbar Tratar, L. and Strmčnik, E. (2016) ‘The comparison of Holt–Winters method and Multiple regression method: A case study’, *Energy*, 109, pp. 266–276. doi: 10.1016/J.ENERGY.2016.04.115.

Freund, Y. and Schapire, R.E. (1997)

Freund, Y. and Schapire, R.E. (1997) ‘A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting’, *Journal of Computer and System Sciences*, 55(1), pp. 119–139. doi:10.1006/JCSS.1997.1504.

Friedman, J.H. (2002)

Friedman, J.H. (2002) ‘Stochastic gradient boosting’, *Computational Statistics & Data Analysis*, 38(4), pp. 367–378. doi:10.1016/S0167-9473(01)00065-2.

Gao, X. *et al.* (2019) ‘A Human Activity Recognition Algorithm Based on Stacking Denoising Autoencoder and LightGBM’, *Sensors 2019, Vol. 19, Page 947*, 19(4), p. 947. doi:10.3390/S19040947.

Gottschlich, J. and Hinz, O. (2014)

Gottschlich, J. and Hinz, O. (2014) ‘A decision support system for stock investment recommendations using collective wisdom’, *Decision Support Systems*, 59(1), pp. 52–62. doi: 10.1016/J.DSS.2013.10.005.

Govindan, K., Mina, H. and Alavi, B. (2020)

Govindan, K., Mina, H. and Alavi, B. (2020) ‘A decision support system for demand management in healthcare supply chains considering the epidemic outbreaks: A case study of coronavirus disease 2019 (COVID-19)’, *Transportation Research Part E: Logistics and Transportation Review*, 138, p. 101967. doi: 10.1016/J.TRE.2020.101967.

Gupta, A. *et al.* (2021)

Gupta, A. *et al.* (2021) ‘Energy-efficient heating control for smart buildings with deep reinforcement learning’, *Journal of Building Engineering*, 34, p. 101739. doi: 10.1016/J.JOBE.2020.101739.

Gupta, J., Forgionne, G. and Mora, M. (2007)

Gupta, J., Forgionne, G. and Mora, M. (2007) ‘Intelligent decision-making support systems: foundations, applications and challenges’. doi:10.1007/1-84628-231-4_13.

Halhoul Merabet, G. *et al.* (2021)

Halhoul Merabet, G. *et al.* (2021) ‘Intelligent building control systems for thermal comfort and energy-efficiency: A systematic review of artificial intelligence-assisted techniques’, *Renewable and Sustainable Energy Reviews*, 144, p. 110969. doi: 10.1016/J.RSER.2021.110969.

- Hancock, J.T. and Khoshgoftaar, T.M. (2020)
Hancock, J.T. and Khoshgoftaar, T.M. (2020) ‘CatBoost for big data: an interdisciplinary review’, *Journal of Big Data*, 7(1), pp. 1–45. doi:10.1186/S40537-020-00369-8/FIGURES/9.
- Hansun, S. *et al.* (1AD)
Hansun, S. *et al.* (1AD) ‘Revisiting the Holt-Winters’ Additive Method for Better Forecasting’, <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/IJEIS.2019040103>, 15(2), pp. 43–57. doi:10.4018/IJEIS.2019040103.
- Hasan, R. *et al.* (2024)
Hasan, R. *et al.* (2024) ‘Explainable AI in Credit Card Fraud Detection: Interpretable Models and Transparent Decision-making for Enhanced Trust and Compliance in the USA’, *Journal of Computer Science and Technology Studies*, 6(2), pp. 01–12. doi:10.32996/JCSTS.2024.6.2.1.
- Hashemian, H.M. (2011)
Hashemian, H.M. (2011) ‘State-of-the-art predictive maintenance techniques’, *IEEE Transactions on Instrumentation and Measurement*, 60(1), pp. 226–236. doi:10.1109/TIM.2010.2047662.
- Hernández-Nieves, E. *et al.* (2020)
Hernández-Nieves, E. *et al.* (2020) ‘Fog computing architecture for personalized recommendation of banking products’, *Expert Systems with Applications*, 140, p. 112900. doi: 10.1016/J.ESWA.2019.112900.
- Hou, J. *et al.* (2022a)
Hou, J. *et al.* (2022a) ‘Real-time optimal control of HVAC systems: Model accuracy and optimization reward’, *Journal of Building Engineering*, 50, p. 104159. doi: 10.1016/J.JOBE.2022.104159.
- Hou, J. *et al.* (2022b)
Hou, J. *et al.* (2022b) ‘Real-time optimal control of HVAC systems: Model accuracy and optimization reward’, *Journal of Building Engineering*, 50, p. 104159. doi: 10.1016/J.JOBE.2022.104159.
- Huang, Z. *et al.* (2015)
Huang, Z. *et al.* (2015) ‘Bidirectional LSTM-CRF Models for Sequence Tagging’. Available at: <https://arxiv.org/abs/1508.01991v1> (Accessed: 9 September 2024).
- Ibrahim, A.A. *et al.* (2020)
Ibrahim, A.A. *et al.* (2020) ‘Comparison of the CatBoost Classifier with other Machine Learning Methods’, *International Journal of Advanced Computer Science and Applications*, 11(11), pp. 738–748. doi:10.14569/IJACSA.2020.0111190.
- Jagatheesaperumal, S.K. *et al.* (2023)
Jagatheesaperumal, S.K. *et al.* (2023) ‘An IoT-Based Framework for Personalized Health Assessment and Recommendations Using Machine Learning’, *Mathematics 2023, Vol. 11, Page 2758*, 11(12), p. 2758. doi:10.3390/MATH11122758.

Joniec, W. (2007)

Joniec, W. (2007) 'Nowoczesne węzły ciepłne', *Rynek Instalacyjny*, (Nr 6), pp. 44--45, 49. Available at: <https://www.infona.pl/resource/bwmeta1.element.baztech-27b3453a-ecb6-49e5-9927-82db9c1b81a9> (Accessed: 9 September 2024).

Kanawaday, A. and Sane, A. (2017)

Kanawaday, A. and Sane, A. (2017) 'Machine learning for predictive maintenance of industrial machines using IoT sensor data', *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS*, 2017-November, pp. 87–90. doi:10.1109/ICSESS.2017.8342870.

Ke, G. *et al.* (2017)

Ke, G. *et al.* (2017) 'LightGBM: A Highly Efficient Gradient Boosting Decision Tree', *Advances in Neural Information Processing Systems*, 30. Available at: <https://github.com/Microsoft/LightGBM>. (Accessed: 9 September 2024).

Koehler, A.B., Snyder, R.D. and Ord, J.K. (2001)

Koehler, A.B., Snyder, R.D. and Ord, J.K. (2001) 'Forecasting models and prediction intervals for the multiplicative Holt–Winters method', *International Journal of Forecasting*, 17(2), pp. 269–286. doi:10.1016/S0169-2070(01)00081-4.

Kuziemski, M. and Misuraca, G. (2020)

Kuziemski, M. and Misuraca, G. (2020) 'AI governance in the public sector: Three tales from the frontiers of automated decision-making in democratic settings', *Telecommunications Policy*, 44(6), p. 101976. doi: 10.1016/J.TELPOL.2020.101976.

Lei, L. *et al.* (2021)

Lei, L. *et al.* (2021) 'A building energy consumption prediction model based on rough set theory and deep learning algorithms', *Energy and Buildings*, 240, p. 110886. doi: 10.1016/J.ENBUILD.2021.110886.

Leicht-Deobald, U. *et al.* (2022)

Leicht-Deobald, U. *et al.* (2022) 'The Challenges of Algorithm-Based HR Decision-Making for Personal Integrity', *Business and the Ethical Implications of Technology*, pp. 71–86. doi:10.1007/978-3-031-18794-0_5.

Li, H., Zhao, Y. and Zheng, F. (2020)

Li, H., Zhao, Y. and Zheng, F. (2020) 'The framework of an agricultural land-use decision support system based on ecological environmental constraints', *Science of The Total Environment*, 717, p. 137149. doi: 10.1016/J.SCITOTENV.2020.137149.

Li, S. *et al.* (2018)

Li, S. *et al.* (2018) 'Independently Recurrent Neural Network (IndRNN): Building a Longer and Deeper RNN', pp. 5457–5466.

Li, Z., Wang, Y. and Wang, K.S. (2017)

Li, Z., Wang, Y. and Wang, K.S. (2017) 'Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario', *Advances in Manufacturing*, 5(4), pp. 377–387. doi:10.1007/S40436-017-0203-8/METRICS.

- Liang, R. *et al.* (2024)
Liang, R. *et al.* (2024) ‘The applications of building information modeling in the life-cycle of green buildings: a comprehensive review’, *Science and Technology for the Built Environment* [Preprint]. doi:10.1080/23744731.2024.2351310.
- Liang, Y. *et al.* (2019)
Liang, Y. *et al.* (2019) ‘Product marketing prediction based on XGboost and LightGBM algorithm’, *ACM International Conference Proceeding Series*, pp. 150–153. doi:10.1145/3357254.3357290.
- Liberati, E.G. *et al.* (2017)
Liberati, E.G. *et al.* (2017) ‘What hinders the uptake of computerized decision support systems in hospitals? A qualitative study and framework for implementation’, *Implementation Science*, 12(1), pp. 1–13. doi:10.1186/S13012-017-0644-2/FIGURES/2.
- Library, W.O. and Valipour, M. (2015)
Library, W.O. and Valipour, M. (2015) ‘Long-term runoff study using SARIMA and ARIMA models in the United States’, *Meteorological Applications*, 22(3), pp. 592–598. doi:10.1002/MET.1491.
- Lin, X. (2020)
Lin, X. (2020) ‘Sentiment Analysis of E-commerce Customer Reviews Based on Natural Language Processing’, *ACM International Conference Proceeding Series*, pp. 32–36. doi:10.1145/3436286.3436293.
- Lu, J. *et al.* (2018)
Lu, J. *et al.* (2018) ‘Seasonal Time Series Forecasting using SARIMA and Holt Winter’s Exponential Smoothing’, *IOP Conference Series: Materials Science and Engineering*, 407(1), p. 012153. doi:10.1088/1757-899X/407/1/012153.
- Lu, Y. *et al.* (2018)
Lu, Y. *et al.* (2018) ‘TRANSITION TOWARDS GREEN FACILITY MANAGEMENT: BRIDGING THE KNOWLEDGE GAPS OF FACILITIES MANAGERS’, *Journal of Green Building*, 13(3), pp. 122–143. doi:10.3992/1943-4618.13.3.122.
- Marocco, M. and Garofolo, I. (2021)
Marocco, M. and Garofolo, I. (2021) ‘Integrating disruptive technologies with facilities management: A literature review and future research directions’, *Automation in Construction*, 131, p. 103917. doi: 10.1016/J.AUTCON.2021.103917.
- Matthies, M., Giupponi, C. and Ostendorf, B. (2007)
Matthies, M., Giupponi, C. and Ostendorf, B. (2007) ‘Environmental decision support systems: Current issues, methods and tools’, *Environmental Modelling & Software*, 22(2), pp. 123–127. doi: 10.1016/J.ENVSOFT.2005.09.005.
- Mittal, S. (2020)
Mittal, S. (2020) ‘A survey on modeling and improving reliability of DNN algorithms and accelerators’, *Journal of Systems Architecture*, 104, p. 101689. doi: 10.1016/J.SYSARC.2019.101689.

- Natekin, A. and Knoll, A. (2013)
 Natekin, A. and Knoll, A. (2013) ‘Gradient boosting machines, a tutorial’, *Frontiers in Neurorobotics*, 7(DEC), p. 63623. doi:10.3389/FNBOT.2013.00021/BIBTEX.
- Nguyen, Q.-T. *et al.* (2022)
 Nguyen, Q.-T. *et al.* (2022) ‘Decision Support Systems for Anomaly Detection with the Applications in Smart Manufacturing: A Survey and Perspective’, *Machine Learning and Probabilistic Graphical Models for Decision Support Systems*, pp. 34–61. doi:10.1201/9781003189886-3.
- Nielsen, D. (no date)
 Nielsen, D. (no date) ‘Tree Boosting With XGBoost Why Does XGBoost Win “Every” Machine Learning Competition?’
- Nobre, F.F. *et al.* (2001)
 Nobre, F.F. *et al.* (2001) ‘Dynamic linear model and SARIMA: a comparison of their forecasting performance in epidemiology’, *Statistics in Medicine*, 20(20), pp. 3051–3069. doi:10.1002/SIM.963.
- Nunes, P., Santos, J. and Rocha, E. (2023)
 Nunes, P., Santos, J. and Rocha, E. (2023) ‘Challenges in predictive maintenance – A review’, *CIRP Journal of Manufacturing Science and Technology*, 40, pp. 53–67. doi: 10.1016/J.CIRPJ.2022.11.004.
- Olaniyi, O.O., Okunleye, O.J. and Olabanji, S.O. (2023)
 Olaniyi, O.O., Okunleye, O.J. and Olabanji, S.O. (2023) ‘Advancing Data-Driven Decision-Making in Smart Cities through Big Data Analytics: A Comprehensive Review of Existing Literature’. Available at: <https://papers.ssrn.com/abstract=4546193> (Accessed: 8 September 2024).
- Olu-Ajayi, R. *et al.* (2022)
 Olu-Ajayi, R. *et al.* (2022) ‘Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques’, *Journal of Building Engineering*, 45, p. 103406. doi: 10.1016/J.JOBE.2021.103406.
- Oshiro, T.M., Perez, P.S. and Baranauskas, J.A. (2012)
 Oshiro, T.M., Perez, P.S. and Baranauskas, J.A. (2012) ‘How Many Trees in a Random Forest?’, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7376 LNAI, pp. 154–168. doi:10.1007/978-3-642-31537-4_13.
- Paolanti, M. *et al.* (2018)
 Paolanti, M. *et al.* (2018) ‘Machine Learning approach for Predictive Maintenance in Industry 4.0’, *2018 14th IEEE/ASME International Conference on Mechatronic and Embedded Systems and Applications, MESA 2018* [Preprint]. doi:10.1109/MESA.2018.8449150.
- Parashar, A. *et al.* (2019)
 Parashar, A. *et al.* (2019) ‘Timeloop: A Systematic Approach to DNN Accelerator Evaluation’, *Proceedings - 2019 IEEE International Symposium on Performance Analysis of Systems and Software, ISPASS 2019*, pp. 304–315. doi:10.1109/ISPASS.2019.00042.

- Parmar, A., Katariya, R. and Patel, V. (2019)
 Parmar, A., Katariya, R. and Patel, V. (2019) ‘A Review on Random Forest: An Ensemble Classifier’, *Lecture Notes on Data Engineering and Communications Technologies*, 26, pp. 758–763. doi:10.1007/978-3-030-03146-6_86.
- Pegoraro, F., Alves Portela Santos, E. and de Freitas Rocha Loures, E. (2020)
 Pegoraro, F., Alves Portela Santos, E. and de Freitas Rocha Loures, E. (2020) ‘A support framework for decision making in emergency department management’, *Computers & Industrial Engineering*, 146, p. 106477. doi: 10.1016/J.CIE.2020.106477.
- Pérez-Lombard, L. *et al.* (2011)
 Pérez-Lombard, L. *et al.* (2011) ‘A review of HVAC systems requirements in building energy regulations’, *Energy and Buildings*, 43(2–3), pp. 255–268. doi: 10.1016/J.ENBUILD.2010.10.025.
- Pham, A.D. *et al.* (2020)
 Pham, A.D. *et al.* (2020) ‘Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability’, *Journal of Cleaner Production*, 260, p. 121082. doi: 10.1016/J.JCLEPRO.2020.121082.
- Pieprzyk, R. (2002)
 Pieprzyk, R. (2002) ‘Gazowe kotły kondensacyjne’, *Rynek Instalacyjny*, Nr 7-8.
- Power, D. and Power, D.J. (2004) ‘Association for Information Systems AIS Electronic Library (AISeL) Decision Support Systems: From the Past to the Future Recommended Citation Decision Support Systems: From the Past to the Future’, *Future* [Preprint]. Available at: <http://aisel.aisnet.org/amcis2004><http://aisel.aisnet.org/amcis2004/242> (Accessed: 8 September 2024).
- Power, D. and Power, D.J. (2004)
 Power, D.J. (2008) ‘Decision Support Systems: A Historical Overview’, *Handbook on Decision Support Systems 1*, pp. 121–140. doi:10.1007/978-3-540-48713-5_7.
- Prokhorenkova, L. *et al.* (2018)
 Prokhorenkova, L. *et al.* (2018) ‘CatBoost: unbiased boosting with categorical features’, *Advances in Neural Information Processing Systems*, 31. Available at: <https://github.com/catboost/catboost> (Accessed: 9 September 2024).
- Ray, M., Samal, P. and Panigrahi, C.K. (2023)
 Ray, M., Samal, P. and Panigrahi, C.K. (2023) ‘The influencing factors on efficacy enhancement of HVAC systems – A review’, *Materials Today: Proceedings*, 80, pp. 3423–3432. doi: 10.1016/J.MATPR.2021.07.264.
- Razmak, J. and Aouni, B. (2015)
 Razmak, J. and Aouni, B. (2015) ‘Decision Support System and Multi-Criteria Decision Aid: A State of the Art and Perspectives’, *Journal of Multi-Criteria Decision Analysis*, 22(1–2), pp. 101–117. doi:10.1002/MCDA.1530.

- Ridgeway, G. (2024)
 Ridgeway, G. (2024) ‘Generalized Boosted Models: A guide to the gbm package’.
- Rigatti, S.J. (2017) ‘Random Forest’, *Journal of Insurance Medicine*, 47(1), pp. 31–39. doi:10.17849/INSM-47-01-31-39.1.
- Robert H. Bonczek, C.W.H.A.B.W. (2014)
 Robert H. Bonczek, C.W.H.A.B.W. (2014) *Foundations of Decision Support Systems*. Academic Press. Available at:
https://books.google.pl/books?hl=pl&lr=&id=bzGjBQAAQBAJ&oi=fnd&pg=PP1&dq=decision+support+systems+classification&ots=5pyQDoEH58&sig=w8oxR354oZ-7hcdLG4z6xiWIVyU&redir_esc=y#v=onepage&q=decision%20support%20systems%20classification&f=false (Accessed: 8 September 2024).
- Romanssini, M. *et al.* (2023)
 Romanssini, M. *et al.* (2023) ‘A Review on Vibration Monitoring Techniques for Predictive Maintenance of Rotating Machinery’, *Eng 2023, Vol. 4, Pages 1797-1817*, 4(3), pp. 1797–1817. doi:10.3390/ENG4030102.
- Sachan, S. *et al.* (2020)
 Sachan, S. *et al.* (2020) ‘An explainable AI decision-support-system to automate loan underwriting’, *Expert Systems with Applications*, 144, p. 113100. doi: 10.1016/J.ESWA.2019.113100.
- Samat, A. *et al.* (2022)
 Samat, A. *et al.* (2022) ‘CatBoost for RS Image Classification with Pseudo Label Support from Neighbor Patches-Based Clustering’, *IEEE Geoscience and Remote Sensing Letters*, 19. doi:10.1109/LGRS.2020.3038771.
- Schapire, R.E. (2013)
 Schapire, R.E. (2013) ‘Explaining AdaBoost’, *Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik*, pp. 37–52. doi:10.1007/978-3-642-41136-6_5.
- Seyam, S. (2018)
 Seyam, S. (2018) ‘Types of HVAC Systems’, *HVAC System* [Preprint]. doi:10.5772/INTECHOPEN.78942.
- Sezer, E. *et al.* (2018)
 Sezer, E. *et al.* (2018) ‘An Industry 4.0-Enabled Low Cost Predictive Maintenance Approach for SMEs’, *2018 IEEE International Conference on Engineering, Technology and Innovation, ICE/ITMC 2018 - Proceedings* [Preprint]. doi:10.1109/ICE.2018.8436307.
- Shim, J.P. *et al.* (2002)
 Sherstinsky, A. (2020)
 Sherstinsky, A. (2020) ‘Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network’, *Physica D: Nonlinear Phenomena*, 404, p. 132306. doi: 10.1016/J.PHYSD.2019.132306.
- Shim, J.P. *et al.* (2002)
 Shim, J.P. *et al.* (2002) ‘Past, present, and future of decision support technology’, *Decision Support Systems*, 33(2), pp. 111–126. doi:10.1016/S0167-9236(01)00139-7.

- Sivaramakrishnan, S. *et al.* (2021)
 Sivaramakrishnan, S. *et al.* (2021) ‘Forecasting Time Series Data Using ARIMA and Facebook Prophet Models’, *Big Data Management in Sensing: Applications in AI and IoT*, pp. 75–87. doi:10.1201/9781003337355-4/FORECASTING-TIME-SERIES-DATA-USING-ARIMA-FACEBOOK-PROPHET-MODELS-SIVARAMAKRISHNAN-TERRANCE-FREDERICK-FERNANDEZ-BABUKARTHIK-PREMALATHA.
- Smagulova, K. and James, A.P. (2019)
 Smagulova, K. and James, A.P. (2019) ‘A survey on LSTM memristive neural network architectures and applications’, *The European Physical Journal Special Topics* 2019 228:10, 228(10), pp. 2313–2324. doi:10.1140/EPJST/E2019-900046-X.
- Song, J. *et al.* (2021)
 Song, J. *et al.* (2021) ‘Prediction of Protein–ATP Binding Residues Based on Ensemble of Deep Convolutional Neural Networks and LightGBM Algorithm’, *International Journal of Molecular Sciences* 2021, Vol. 22, Page 939, 22(2), p. 939. doi:10.3390/IJMS22020939.
- Soroudi, A. and Amraee, T. (2013)
 Soroudi, A. and Amraee, T. (2013) ‘Decision making under uncertainty in energy systems: State of the art’, *Renewable and Sustainable Energy Reviews*, 28, pp. 376–384. doi: 10.1016/J.RSER.2013.08.039.
- Sun, W., Bocchini, P. and Davison, B.D. (2020)
 Sun, W., Bocchini, P. and Davison, B.D. (2020) ‘Applications of artificial intelligence for disaster management’, *Natural Hazards* 2020 103:3, 103(3), pp. 2631–2689. doi:10.1007/S11069-020-04124-3.
- Sutton, R.T. *et al.* (2020)
 Sutton, R.T. *et al.* (2020) ‘An overview of clinical decision support systems: benefits, risks, and strategies for success’, *npj Digital Medicine* 2020 3:1, 3(1), pp. 1–10. doi:10.1038/s41746-020-0221-y.
- Szparkowski, Z. (2017)
 Szparkowski, Z. (2017) ‘MODERNIZACJA PRZESTRZENI ARCHITEKTONICZNEJ – ZASADY I STRATEGIE’, *Przestrzeń, Ekonomia, Społeczeństwo*, (12/II), pp. 141–162. doi:10.23830/12II2017/141162.
- Taleghani, M. *et al.* (2013)
 Taleghani, M. *et al.* (2013) ‘A review into thermal comfort in buildings’, *Renewable and Sustainable Energy Reviews*, 26, pp. 201–215. doi: 10.1016/J.RSER.2013.05.050.
- Tang, M. and Liao, H. (2021)
 Tang, M. and Liao, H. (2021) ‘From conventional group decision making to large-scale group decision making: What are the challenges and how to meet them in big data era? A state-of-the-art survey’, *Omega*, 100, p. 102141. doi: 10.1016/J.OMEGA.2019.102141.
- Theissler, A. *et al.* (2021)
 Theissler, A. *et al.* (2021) ‘Predictive maintenance enabled by machine learning: Use cases and challenges in the automotive industry’, *Reliability Engineering & System Safety*, 215, p. 107864. doi:10.1016/J.RESS.2021.107864.

Toharudin, T. *et al.* (2023)

Toharudin, T. *et al.* (2023) 'Employing long short-term memory and Facebook prophet model in air temperature forecasting', *Communications in Statistics - Simulation and Computation*, 52(2), pp. 279–290. doi:10.1080/03610918.2020.1854302.

Trull, O., García-Díaz, J.C. and Troncoso, A. (2020)

Trull, O., García-Díaz, J.C. and Troncoso, A. (2020) 'Initialization Methods for Multiple Seasonal Holt–Winters Forecasting Models', *Mathematics 2020*, Vol. 8, Page 268, 8(2), p. 268. doi:10.3390/MATH8020268.

Turner, C.J. *et al.* (2019)

Turner, C.J. *et al.* (2019) 'Intelligent decision support for maintenance: an overview and future trends', *International Journal of Computer Integrated Manufacturing*, 32(10), pp. 936–959. doi:10.1080/0951192X.2019.1667033.

Uzir, N. *et al.* (2016)

Uzir, N. *et al.* (2016) 'Experimenting XGBoost Algorithm for Prediction and Classification of Different Datasets Experimenting XGBoost Algorithm for Prediction and Classification of Different Datasets', *International Journal of Control Theory and Applications*, 9. Available at: <https://www.researchgate.net/publication/318132203> (Accessed: 9 September 2024).

Velasco, R.B. *et al.* (2021)

Velasco, R.B. *et al.* (2021) 'A decision support system for fraud detection in public procurement', *International Transactions in Operational Research*, 28(1), pp. 27–47. doi:10.1111/ITOR.12811.

Verma, J. (2022)

Verma, J. (2022) 'Application of Machine Learning for Fraud Detection-A Decision Support System in the Insurance Sector', *Big Data Analytics in the Insurance Market*, pp. 251–262. doi:10.1108/978-1-80262-637-720221014/FULL/XML.

Vijayan, D.S. *et al.* (2020)

Vijayan, D.S. *et al.* (2020) 'Automation systems in smart buildings: a review', *Journal of Ambient Intelligence and Humanized Computing*, pp. 1–13. doi:10.1007/S12652-020-02666-9/METRICS.

Wang, D. ni, Li, L. and Zhao, D. (2022)

Wang, D. ni, Li, L. and Zhao, D. (2022) 'Corporate finance risk prediction based on LightGBM', *Information Sciences*, 602, pp. 259–268. doi:10.1016/J.INS.2022.04.058.

Wang, D., Zhang, Y. and Zhao, Y. (2017)

Wang, D., Zhang, Y. and Zhao, Y. (2017) 'LightGBM: An effective miRNA classification method in breast cancer patients', *ACM International Conference Proceeding Series*, pp. 7–11. doi:10.1145/3155077.3155079.

Wang, D., Zhang, Y. and Zhao, Y. (2017)

Wang, D., Zhang, Y. and Zhao, Y. (2017) 'A novel improved model for building energy consumption prediction based on model integration', *Applied Energy*, 262, p. 114561. doi:10.1016/J.APENERGY.2020.114561.

- Wang, W. and Lu, Y. (2018)
Wang, W. and Lu, Y. (2018) ‘Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model’, *IOP Conference Series: Materials Science and Engineering*, 324(1), p. 012049. doi:10.1088/1757-899X/324/1/012049.
- Williams, B.M. and Hoel, L.A. (2003)
Williams, B.M. and Hoel, L.A. (2003) ‘Modeling and Forecasting Vehicular Traffic Flow as a Seasonal ARIMA Process: Theoretical Basis and Empirical Results’, *Journal of Transportation Engineering*, 129(6), pp. 664–672. doi:10.1061/(ASCE)0733-947X(2003)129:6(664).
- Wong, J.K.W., Ge, J. and He, S.X. (2018)
Wong, J.K.W., Ge, J. and He, S.X. (2018) ‘Digitisation in facilities management: A literature review and future research directions’, *Automation in Construction*, 92, pp. 312–326. doi: 10.1016/J.AUTCON.2018.04.006.
- Yan, J. *et al.* (2017) ‘Industrial Big Data in an Industry 4.0 Environment: Challenges, Schemes, and Applications for Predictive Maintenance’, *IEEE Access*, 5, pp. 23484–23491. doi:10.1109/ACCESS.2017.2765544.
- Yang, L., Yan, H. and Lam, J.C. (2014)
Yang, L., Yan, H. and Lam, J.C. (2014) ‘Thermal comfort and building energy consumption implications – A review’, *Applied Energy*, 115, pp. 164–173. doi: 10.1016/J.APENERGY.2013.10.062.
- Yazdani, M. *et al.* (2017)
Yazdani, M. *et al.* (2017) ‘A group decision making support system in logistics and supply chain management’, *Expert Systems with Applications*, 88, pp. 376–392. doi: 10.1016/J.ESWA.2017.07.014.
- Yin, W. *et al.* (2017)
Yin, W. *et al.* (2017) ‘Comparative Study of CNN and RNN for Natural Language Processing’. Available at: <https://arxiv.org/abs/1702.01923v1> (Accessed: 9 September 2024).
- Yu, Y. *et al.* (2019)
Yu, Y. *et al.* (2019) ‘A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures’, *Neural Computation*, 31(7), pp. 1235–1270. doi:10.1162/NECO_A_01199.
- Zhai, Z. *et al.* (2020)
Zhai, Z. *et al.* (2020) ‘Decision support systems for agriculture 4.0: Survey and challenges’, *Computers and Electronics in Agriculture*, 170, p. 105256. doi: 10.1016/J.COMPAG.2020.105256.
- Zhang, J. *et al.* (2016)
Zhang, J. *et al.* (2016) ‘DNN-based prediction model for spatio-temporal data’, *GIS: Proceedings of the ACM International Symposium on Advances in Geographic Information Systems* [Preprint]. doi:10.1145/2996913.2997016.

Zonta, T. *et al.* (2020)

Zonta, T. *et al.* (2020) 'Predictive maintenance in the Industry 4.0: A systematic literature review', *Computers & Industrial Engineering*, 150, p. 106889. doi: 10.1016/J.CIE.2020.106889.

Wykaz rysunków

Nr rysunku	Tytuł	Strona
1	Zespół budynków użyty do przeprowadzenia analizy zawierający głównie budynki biurowe	85
2	Zespół budynków użyty do przeprowadzenia analizy zawierający budynki realizujące funkcje biurowe, warsztatowe i magazynowe	86
3	Schemat ideowy systemu telemetrii węzłów cieplnych	89
4	Przykład wizualizacji Web-Modul TROVIS 5590-1 8	90
5	Zamówiona moc cieplna w wybranych lokalizacjach w latach 2016-2017	93
6	Oszczędność z tytułu obniżenia mocy zamówionej w wybranych lokalizacjach (po stałych cenach za MW w latach 2016-2017)	94
7	Zużycie ciepła w latach 2019-2021 w Lokalizacji 1	95
8	Zużycie ciepła w latach 2019-2021 w Lokalizacji 4	95
9	Sposób rozbudowy systemu SCSWin o moduł PM	100
10	Struktura funkcjonalna systemu SCS WiN	101
11	Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie (oryginalne dane wejściowe)	107
12	Zużycie energii elektrycznej badanego zespołu budynków w badanym okresie (po wstępnej obróbce danych wejściowych).	108
13	Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku A	109
14	Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku A	109
15	Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku A	109
16	Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku A	110
17	Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku A	110
18	Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku B	111
19	Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku B	111
20	Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku B	112
21	Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku B	112
22	Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku B	112
23	Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku C	113
24	Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku C	114
25	Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku C	114
26	Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku C	114

27	Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku C	115
28	Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku D	115
29	Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku D	115
30	Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku D	116
31	W Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku D	116
32	Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku D	116
33	Wyniki predykcji danych z wykorzystaniem metody DNN dla budynku E	117
34	Wyniki predykcji danych z wykorzystaniem metody LSTM dla budynku E	117
35	Wyniki predykcji danych z wykorzystaniem metody RNN dla budynku E	118
36	W Wyniki predykcji danych z wykorzystaniem metody ARIMA(SARIMA) dla budynku E	118
37	Wyniki predykcji danych z wykorzystaniem metody Holta-Wintersa dla budynku E	118
38	Podział budynku na strefy pomiarowe	122
39	Wykres dziennej sumy opadów	124
40	Wykres prędkości wiatru	124
41	Wykres przebiegu wartości ciśnienia atmosferycznego	124
42	Dzienny wykres wilgotności powietrza	124
43	Dzienny wykres przebiegu temperatury	125
44	Wykres miesięczny narastający energii czynnej całkowitej z produkcji fotowoltaiki	125
45	Wykres przebiegu temperatur powietrza w rekuperatorze	125
46	Wykres prądów faz L1, L2, L3	126
47	Wykres mocy czynnej faz L1, L2, L3	126
48	Wykres skumulowanego zużycia wody	126
49	Rzeczywiste vs prognozowane zużycie wody	137
50	Widok ekranu głównego aplikacji po załadowaniu pliku z danymi z SCS	142
51	Widok ekranu aplikacji z wykresem przebiegu danych rzeczywistych i prognozowanych.	143
52	Widok ekranu głównego aplikacji wraz z wynikami miar jakości predykcji.	144
53	Ekran główny aplikacji do predykcji awarii systemu SKD	150
54	Widok ekranu głównego aplikacji po przeprowadzeniu predykcji	151

Wykaz tabel

Nr tabeli	Tytuł	Strona
1	Charakterystyka podstawowych parametrów technicznych obiektów przedstawionych na rysunkach 1 i 2	87
2	Dobór charakterystyk grzewczych, stopnia otwarcia zaworów regulacyjnych przepływu oraz charakterystyki grzewczej przy temperaturach zewnętrznych poniżej - 10°C na węzłach cieplnych badanych obiektów.	91
3	Czynności regulacyjne wpływające na zmiany harmonogramów grzewczych	92
4	Charakterystyka użytkowa budynków	102
5	Wartości błędu prognozy dla budynku nr A	119
6	Wartości błędu prognozy dla budynku nr B	119
7	Wartości błędu prognozy dla budynku nr C	119
8	Wartości błędu prognozy dla budynku nr D	120
9	Wartości błędu prognozy dla budynku nr E	120
10	Dane z systemu utrzymania komfortu cieplnego budynku - przykład z szyn Modbus	147
11	Dane z systemu zabezpieczenia technicznego obiektu	147

Załączniki

Załącznik nr 1 Lista Pakietów Phyton.