



Politechnika Wrocławska

Wydział Mechaniczny
Katedra Inżynierii Produkcji i Zarządzania

Dziedzina: nauki inżynieryjno-techniczne
Dyscyplina: inżynieria mechaniczna

ROZPRAWA DOKTORSKA

**Wieloparametryczny model zużycia energii autonomicznego robota
mobilnego do predykcji wykonalności zadań transportowych**

mgr inż. Bartosz Poskart

Promotor: prof. dr hab. inż. Anna Burduk

Promotor pomocniczy: dr inż. Kamil Krot

Słowa kluczowe:

autonomiczne roboty mobilne,
predykcja zużycia energii,
intra-logistyka 4.0, modelowanie
wieloparametryczne

WROCŁAW 2026

Podziękowania

*Pragnę złożyć serdeczne podziękowania Promotorowi pracy, **Pani prof. dr hab. inż. Annie Burduk**, Kierownik Katedry, za nieustające wsparcie merytoryczne, spokój i życzliwość okazywane na każdym etapie realizacji rozprawy oraz konsekwentne motywowanie mnie do rozwoju naukowego. Dziękuję również za stworzenie przestrzeni sprzyjającej rozwojowi – zarówno mojemu, jak i nowo powstałej Katedry, w której niniejsza rozprawa stanowi pierwszą zrealizowaną pracę doktorską.*

*Wyrazy wdzięczności kieruję do Promotora pomocniczego, **dr. inż. Kamila Krota**, za wytrwałość w motywowaniu mnie do pracy badawczej nad doktoratem, cenne wskazówki dotyczące kierunków rozwoju oraz osobisty przykład konsekwentnego rozwoju naukowego, który stanowił istotne wsparcie w realizacji niniejszej rozprawy.*

Streszczenie

Wzrost zastosowań autonomicznych robotów mobilnych (AMR) w intralogistyce uwidacznia ograniczenia współczesnych systemów flotowych, które nie dysponują wiarygodnymi narzędziami do prognozowania zużycia energii. Decyzje operacyjne opierają się głównie na procentowym poziomie naładowania akumulatora, co utrudnia ocenę wykonalności misji i prowadzi do nadmiarowego powiększania flot. Dotychczasowe badania koncentrowały się na robotach prototypowych, oferujących pełny dostęp do danych, co czyni je nieprzydatnymi dla komercyjnych platform o ograniczonej obserwowalności.

Celem głównym pracy było opracowanie i weryfikacja modelu predykcyjnego zużycia energii dla komercyjnego AMR, umożliwiającego ocenę wykonalności misji oraz wsparcie decyzji operacyjnych. Cele szczegółowe obejmowały identyfikację czynników wpływających na pobór energii, opracowanie metodyki pozyskiwania danych, przygotowanie procedury eksperymentalnej oraz konstrukcję modeli predykcyjnych o różnym stopniu złożoności. W pracy zaproponowano kompletną metodykę badawczą obejmującą klasyfikację czynników energetycznych, selekcję dostępnych predyktorów oraz dwustopniowy plan eksperymentów DoE. Zbudowano stanowisko pomiarowe, które umożliwiło równoczesną rejestrację parametrów misji, danych systemowych i logów energetycznych dla różnych obciążeń, dystansów oraz dwóch akumulatorów o odmiennym stopniu zużycia.

Na podstawie zgromadzonych danych opracowano trzy modele predykcyjne: prosty model jednowymiarowy M1, model GLM (M2) oraz model M3 zbudowany za pomocą narzędzia AutoML. Walidacja wykazała, że modele wieloparametryczne znacznie przewyższają M1 pod względem dokładności i uniwersalności. Najwyższą dokładność osiągnięto dla M3 (AR-S do 0,982), natomiast największą transparentność zapewnił model M2. Wskazano także trzy główne predyktory zużycia energii: liczbę zakrętów, SoC na początku misji i długość trasy. Wyniki potwierdzają możliwość skutecznego modelowania zużycia energii w komercyjnych AMR mimo ograniczonego dostępu do danych. Metodyka może być rozszerzana na inne platformy, rozbudowana o uczenie przyrostowe i zintegrowana z systemami FMS oraz cyfrowymi bliźniakami.

Abstract

The growing usage of Autonomous Mobile Robots (AMR) in intralogistics highlights the limitations of current fleet management systems, which lack reliable tools for predicting energy consumption. Operational decisions are typically based on the battery State of Charge reported as a percentage, making it difficult to assess mission feasibility and often leading to oversizing of robot fleets. Existing research has mainly focused on prototype robots with full access to control and hardware data, rendering those approaches unsuitable for commercial platforms with restricted observability.

The main objective of this work was to develop and validate a predictive energy consumption model for a commercial AMR, enabling mission feasibility assessment and supporting operational decision-making. The specific objectives included identifying the factors influencing energy usage, designing a data acquisition methodology, preparing an experimental procedure, and constructing predictive models of varying complexity. The study proposes a complete research framework that encompasses the classification of energy-related factors, the selection of measurable predictors, and a two-stage Design of Experiments (DoE) plan. A dedicated measurement setup was developed to collect mission parameters, system data, and energy logs simultaneously for various loads, distances, and two batteries with different levels of degradation.

Based on the collected dataset, three predictive models were developed: a simple univariate model (M1), a Generalized Linear Model (M2), and a model built using AutoML (M3). Validation showed that the multiparametric models significantly outperformed M1 in terms of accuracy and generalizability. The highest accuracy was achieved by M3 (AR-S up to 0.982), while M2 offered the greatest transparency. Three key predictors of energy consumption were identified: the number of turns, initial State of Charge, and travel distance. The results confirm that effective energy prediction is feasible for commercial AMRs despite limited system-level data availability. The proposed methodology can be extended to other robot platforms, enhanced with incremental learning, and integrated with Fleet Management Systems and digital twin environments.

Spis treści

Wykaz akronimów	6
Wstęp	7
Zakres i struktura pracy	9
1. Logistyka 4.0 i autonomiczne roboty mobilne - technologie oraz systemy zarządzania flotą	11
1.1 Charakterystyka intralogistyki i Logistyki 4.0 jako obszaru zastosowań robotów mobilnych	11
1.2 Budowa i technologie robotów mobilnych w środowisku przemysłowym	16
1.3 Architektura i zarządzanie systemem robotów mobilnych	22
1.4 Źródła zasilania robotów mobilnych	30
2. Predykcyjne metody szacowania zużycia energii w oparciu o parametry misji robota	35
2.1 Modele zużycia energii oparte na opisie fizyczno-strukturalnym	38
2.2 Modele oparte na danych wykorzystujące uczenie maszynowe	46
2.3 Modele Hybrydowe	57
2.4 Porównanie modeli predykcyjnych zużycia energii przez roboty mobilne	59
3. Cel pracy, zadania i przyjęta metodyka badawcza	61
3.1 Identyfikacja luki badawczej	61
3.2 Cel główny	62
3.3 Zadania szczegółowe	62
3.4 Zastosowane metodyki i metody badawcze	64
3.5 Mapa rozdziałów rozprawy doktorskiej oraz zrealizowanych zadań badawczych i utylitarnych	66
4. Identyfikacja zmiennych wejściowych modelu predykcyjnego zużycia energii przez AMR	67
4.1 Klasyfikacja czynników wpływających na zużycie energii	68
4.2 Identyfikacja czynników zmiennych i mierzalnych	74
4.3 Selekcja czynników możliwych do obserwacji w systemie MiR	75
5. Projekt eksperymentów i stanowisko badawcze	81
5.1 Projekt eksperymentów	81
5.2 Stanowisko badawcze	95
6. Opracowanie i walidacja modeli predykcyjnych zużycia energii przez AMR	109
6.1 Model predykcyjny zużycia energii przez AMR oparty na jednowymiarowej regresji wielomianowej	111
6.2 Model predykcyjny zużycia energii przez AMR oparty na jawnym modelu statystycznym uczenia maszynowego z wieloma zmiennymi wejściowymi	125
6.3 Model predykcyjny zużycia energii przez AMR zbudowany z wykorzystaniem automatycznego doboru algorytmów (AutoML) z wieloma zmiennymi wejściowymi	134
6.4 Porównanie modelu statystycznego (M2) oraz modelu w podejściu AutoML (M3) pod kątem jakości predykcji, interpretowalności wyników, złożoność strukturalnej oraz potencjału wdrożeniowego.	145
6.5 Analiza i ocena wpływu poszczególnych zmiennych wejściowych na dokładność predykcji modeli	149
7. Podsumowanie i wnioski końcowe	153
7.1 Podsumowanie przebiegu badań	153
7.2 Osiągnięcie celów i realizacja zadań badawczych	155
7.3 Weryfikacja celu głównego i oryginalność wyników	156
7.4 Ograniczenia i zakres ważności wyników	157
7.5 Określenie potencjału rozszerzenia modeli i kierunku dalszych badań	158
7.6 Wnioski końcowe	159
8. Spis literatury	160

Wykaz akronimów

- **AGV** – *Automated Guided Vehicle* – automatycznie prowadzony pojazd transportowy
- **AI** – *Artificial Intelligence* – sztuczna inteligencja
- **AMR** – *Autonomous Mobile Robot* – autonomiczny robot mobilny
- **ANN** – *Artificial Neural Network* – sztuczna sieć neuronowa
- **API** – *Application Programming Interface* – interfejs programowania aplikacji
- **AR-S** – *Adjusted R-Square* – skorygowany współczynnik determinacji
- **AutoML** – *Automated Machine Learning* – zautomatyzowane uczenie maszynowe
- **BMS** – *Battery Management System* – system zarządzania akumulatorem
- **CNN** – *Convolutional Neural Network* – konwolucyjna sieć neuronowa
- **CPS** – *Cyber-Physical System* – system cyberfizyczny
- **DT** – *Digital Twin* – cyfrowy bliźniak
- **ERP** – *Enterprise Resource Planning* – planowanie zasobów przedsiębiorstwa
- **FMS** – *Fleet Management System* – system zarządzania flotą
- **GAM** – *Generalized Additive Model* – uogólniony model addytywny
- **GLM** – *Generalized Linear Model* – uogólniony model liniowy
- **IIoT** – *Industrial Internet of Things* – przemysłowy internet rzeczy
- **IMU** – *Inertial Measurement Unit* – inercyjna jednostka pomiarowa
- **IoT** – *Internet of Things* – internet rzeczy
- **IT** – *Information Technology* – technologie informacyjne
- **JIT** – *Just in Time* – metoda „dokładnie na czas”
- **LIDAR** – *Light Detection and Ranging* – detekcja i pomiar światłem
- **MAE** – *Mean Absolute Error* – średni błąd bezwzględny
- **ML** – *Machine Learning* – uczenie maszynowe
- **MLP** – *Multilayer Perceptron* – perceptron wielowarstwowy
- **MLR** – *Multiple Linear Regression* – regresja wieloraka
- **MoE** – *Mixture of Experts* – mieszanka ekspertów
- **MQTT** – *Message Queuing Telemetry Transport* – protokół telemetryi kolejowania wiadomości
- **MES** – *Manufacturing Execution System* – system realizacji produkcji
- **OCV** – *Open Circuit Voltage* – napięcie obwodu otwartego
- **OEE** – *Overall Equipment Effectiveness* – całkowita efektywność wyposażenia
- **OPC-UA** – *Open Platform Communications Unified Architecture* – ujednolicona architektura otwartej platformy komunikacyjnej
- **OT** – *Operational Technology* – technologie operacyjne
- **PIML** – *Physics-Informed Machine Learning* – uczenie maszynowe uwzględniające wiedzę fizyczną
- **R²** – *Coefficient of Determination* – współczynnik determinacji
- **REST** – *Representational State Transfer* – reprezentacyjny transfer stanu
- **RMSE** – *Root Mean Square Error* – pierwiastek z średniego błędu kwadratowego
- **RMSLE** – *Root Mean Squared Logarithmic Error* – pierwiastek z logarytmicznego średniego błędu kwadratowego
- **ROI** – *Return on Investment* – zwrot z inwestycji
- **ROS** – *Robot Operating System* – system operacyjny dla robotów
- **RNN** – *Recurrent Neural Network* – rekurencyjna sieć neuronowa
- **SCADA** – *Supervisory Control and Data Acquisition* – system nadzoru i akwizycji danych
- **SCM** – *Supply Chain Management* – zarządzanie łańcuchem dostaw
- **SLAM** – *Simultaneous Localization and Mapping* – jednoczesna lokalizacja i mapowanie
- **SCOR** – *Supply Chain Operations Reference* – model referencyjny procesów łańcucha dostaw
- **WMS** – *Warehouse Management System* – system zarządzania magazynem

Wstęp

Transformacja przemysłu i logistyki przebiegała etapami, odpowiadającymi kolejnym rewolucjom przemysłowym. Pierwsza rewolucja przemysłowa (koniec XVIII w.) związana była z mechanizacją produkcji dzięki energii pary. Druga (druga połowa XIX w.) wprowadziła elektryczność i produkcję masową. Trzecia rewolucja (lata 70. XX w.) przyniosła automatyzację i komputeryzację procesów przemysłowych. Obecnie obserwujemy czwartą rewolucję przemysłową, określaną jako **Przemysł 4.0**, która koncentruje się na cyfrowej integracji systemów produkcyjnych, informacyjnych i logistycznych. Przemysł 4.0 bazuje na integracji świata fizycznego z cyberprzestrzenią przy użyciu takich technologii jak Internet Rzeczy (*ang. Internet of Things, IoT*), systemy cyber-fizyczne (*ang. Cyber-Physical Systems, CPS*), analityka danych w czasie rzeczywistym, sztuczna inteligencja (*ang. Artificial Intelligence, AI*) oraz chmura obliczeniowa. Cechą charakterystyczną tej rewolucji jest możliwość autonomicznego podejmowania decyzji przez systemy, które analizują, w czasie rzeczywistym, dane pozyskiwane z czujników, systemów sterowania i platform informatycznych. Pozwala to na szybką reakcję na zmieniające się warunki operacyjne oraz na dynamiczną optymalizację procesów [1], [2], [3]. W tym kontekście szczególne znaczenie zyskuje logistyka wewnętrzna, czyli **intralogistyka**, która ewoluje od klasycznych modeli zarządzania przepływem materiałów i informacji w kierunku systemów zintegrowanych, elastycznych i opartych na analizie danych. Intralogistyka wspierana cyfrowo obejmuje zarządzanie ruchem zasobów (materiałów, komponentów, półproduktów, towarów) wewnątrz zakładu w oparciu o dane w czasie rzeczywistym, inteligentne systemy planowania, technologie lokalizacji i automatyzacji procesów transportowych [4], [5], [6], [7], [8].

W tym kontekście **autonomiczne roboty mobilne** (*ang. Autonomous Mobile Robot, AMR*) stają się kluczowymi komponentami systemów intralogistycznych nowej generacji, zapewniając adaptacyjność, bezpieczeństwo i efektywność operacyjną. W obliczu postępujących trudności kadrowych, rosnących kosztów operacyjnych, wymagań dotyczących pracy w trybie wielozmianowym oraz konieczności zwiększenia poziomu bezpieczeństwa, przedsiębiorstwa produkcyjne i logistyczne coraz częściej decydują się na wdrażanie zautomatyzowanych rozwiązań transportowych [9]. AMR umożliwiają realizację zadań wewnętrznego transportu w sposób całkowicie autonomiczny, z zachowaniem wysokiej precyzji, powtarzalności oraz zdolności adaptacyjnej do zmiennych warunków środowiskowych i operacyjnych. Zaletą AMR jest ich elastyczność operacyjna, umożliwiająca szybką rekonfigurację tras i zadań bez potrzeby ingerencji w infrastrukturę fizyczną zakładu, jak ma to miejsce w przypadku klasycznych **automatycznie prowadzonych pojazdów transportowych** (*Automated Guided Vehicle, AGV*). Wpisuje się to bezpośrednio w wymagania nowoczesnego rynku, ukierunkowanego na elastyczną produkcję i masową personalizację wyrobów, gdzie konieczna jest szybka reorganizacja kolejności procesów oraz adaptacja do zmiennego zapotrzebowania. Dzięki wyposażeniu w zaawansowane układy sensoryczne i systemy decyzyjne, roboty te potrafią samodzielnie omijać przeszkody, podejmować decyzje w czasie rzeczywistym oraz współdziałać z ludźmi, innymi jednostkami i maszynami w ramach współdzielonej przestrzeni roboczej. Z tego względu doskonale sprawdzają się w nowoczesnych, dynamicznie zmieniających się środowiskach produkcyjnych i magazynowych. Zintegrowanie ich z systemem realizacji produkcji (*ang. Manufacturing Execution System, MES*), systemem zarządzania magazynem (*ang. Warehouse Management System, WMS*) oraz systemem planowania zasobów przedsiębiorstwa (*ang. Enterprise Resource Planning, ERP*) pozwala na podniesienie poziomu autonomii procesów oraz bardziej efektywne wykorzystanie zasobów [7], [9], [10], [11].


Pomimo rosnącej popularności systemów AMR w intralogistyce, zarządzanie nimi wciąż oparte jest w dużej mierze na prostych regułach logicznych i wartościach progowych zaimplementowanych w ich systemach sterowania oraz systemach zarządzających flotami robotów (*ang. Fleet Management System, FMS*). Takie podejście prowadzi do szeregu istotnych ograniczeń. W praktyce skutkuje to nieoptymalnym przydziałem zadań, brakiem synchronizacji działań w skali floty oraz niedostosowaniem działań operacyjnych do rzeczywistych możliwości energetycznych

poszczególnych jednostek. Podejście, oparte na wartościach progowych i prostych regułach logicznych, jest z natury nieoptymalne w kontekście pracy wielorobotycznej w środowisku rzeczywistym. W szczególności brakuje w nim zaawansowanych metod planowania, które uwzględniałyby dynamiczne aspekty środowiskowe oraz stan energetyczny poszczególnych jednostek. Systemy zarządzające flotą nie są w stanie z wyprzedzeniem zaplanować, kiedy konkretny robot powinien zostać wysłany do ładowania w sposób, który minimalizowałby ryzyko przeciążeń infrastruktury ładowania lub wystąpienia zakleszczeń (*ang. deadlock*) w jej obrębie. Co więcej, obecne rozwiązania komercyjne nie oferują funkcji sprawdzania, czy zakolejkowane zadania są wykonalne w praktyce, biorąc pod uwagę aktualny stan robota, jego lokalizację, poziom naładowania akumulatora oraz warunki środowiskowe. Nie uwzględniają również faktu, że zużycie energii może zmieniać się w czasie, co może świadczyć o degradacji komponentów, pogarszającej się sprawności lub zużyciu elementów mechanicznych. W związku z tym pojawia się realna potrzeba opracowania predykcyjnych modeli zużycia energii, które pozwalałyby na estymację zapotrzebowania na energię robota dla danej misji z uwzględnieniem parametrów samego zadania (dystans, masa ładunku, trasa), jak i uwarunkowań środowiskowych [12], [13], [14].


Od 2017 roku obserwuje się wyraźny wzrost liczby publikacji naukowych (Rys. 1, Tabela 1), zgłoszeń patentowych oraz przyznanych patentów (Rys. 2) dotyczących robotów autonomicznych (*ang. Autonomous Mobile Robot, AMR*), robotów automatycznie prowadzonych (*ang. Automated Guided, AGV*) i technologii wspierających ich funkcjonowanie, takich jak systemy zarządzania flotą (FMS).

Tabela 1 Zestawienie liczby publikacji naukowych w latach 2010–2023 dla haseł „Autonomous Mobile Robots”, „Automated Guided Vehicle” oraz „Fleet Management System” według danych z baz Web of Science i Scopus. Opracowanie własne.

	Web of Science			Scopus		
	Autonomous Mobile Robots	Automated Guided Vehicle	Fleet Management System	Autonomous Mobile Robots	Automated Guided Vehicle	Fleet Management System
2010	556	62	118	714	102	218
2011	519	71	136	614	94	206
2012	522	78	181	663	103	232
2013	677	84	205	682	212	253
2014	642	90	247	659	112	273
2015	671	124	288	655	127	291
2016	816	129	307	700	131	282
2017	831	140	309	838	172	301
2018	837	197	372	848	214	300
2019	978	243	448	1028	287	430
2020	953	252	470	1077	319	440
2021	1029	296	479	1262	349	437
2022	1061	301	501	1345	401	476
2023	1055	343	502	1513	455	523
2024	1266	431	550	1777	625	565



Rys. 1 Liczba publikacji naukowych na temat robotów mobilnych typu AMR w latach 2000–2024, wyszukana w bazach Web of Science i Scopus dla zapytania „Autonomous Mobile Robots”. Opracowanie własne.



Rys. 2 Liczba zgłoszeń patentowych i przyznanych patentów dotyczących technologii związanych z AMR w latach 2000–2025. Opracowanie własne na podstawie [15].

Trend ten wskazuje, że firmy coraz bardziej interesują się wdrażaniem inteligentnych, autonomicznych metod wspierających intralogistykę, ponieważ ich wdrożenie pozwala na zwiększenie elastyczności produkcji i efektywności operacyjnej oraz obniżenie kosztów operacyjnych [16].

Zakres i struktura pracy

Rozprawa została podzielona na siedem rozdziałów, które tworzą logiczny ciąg od wprowadzenia teoretycznego, poprzez część metodologiczną i badawczą, aż po syntezę wyników i wnioski wdrożeniowe. Każdy rozdział pełni odrębną funkcję badawczą i utylitarną, wspierając realizację celu głównego, jakim jest opracowanie i walidacja modeli predykcyjnych zużycia energii autonomicznych robotów mobilnych (AMR) w zastosowaniach intralogistycznych.

Rozdział 1. Logistyka 4.0 i autonomiczne roboty mobilne – technologie oraz systemy zarządzania flotą - Rozdział wprowadzający prezentuje kontekst technologiczny i przemysłowy badań. Omówiono

w nim ewolucję współczesnych systemów intralogistycznych, rolę robotów mobilnych w środowisku Przemysłu 4.0 oraz czynniki determinujące ich efektywność operacyjną. Przedstawiono charakterystykę architektury systemów zarządzania flotą (FMS), technologie komunikacji oraz źródła zasilania robotów. Zawarte analizy umożliwiają zrozumienie, dlaczego aspekty energetyczne stanowią jeden z kluczowych problemów w eksploatacji systemów AMR.

Rozdział 2. Predykcyjne metody szacowania zużycia energii w oparciu o parametry misji robota

- W tym rozdziale dokonano kompleksowego przeglądu i klasyfikacji metod predykcji zużycia energii robotów mobilnych. Omówiono trzy główne grupy podejść: modele fizyczno-strukturalne, modele oparte na danych (z wykorzystaniem metod uczenia maszynowego) oraz modele hybrydowe. Porównano ich dokładność, wymagania obliczeniowe, interpretowalność oraz potencjał implementacyjny w środowisku przemysłowym. Wskazano również ograniczenia istniejących metod i zidentyfikowano lukę badawczą, która uzasadnia potrzebę opracowania uniwersalnych modeli możliwych do zastosowania w komercyjnych robotach AMR.

Rozdział 3. Cel pracy, zadania i przyjęta metodyka badawcza: Rozdział trzeci definiuje ramy metodologiczne pracy. Zawiera opis zidentyfikowanej luki badawczej, formułuje cel główny oraz zestaw zadań badawczych i utylitarnych, powiązanych z kolejnymi etapami realizacji rozprawy. Uzasadniono wybór zastosowanych metod badawczych oraz opisano logikę procesu badawczego w formie mapy rozdziałów, łączącej elementy poznawcze i praktyczne. Przedstawiono również przyjęte metodyki: analityczne, eksploracyjne, empiryczne i ilościowe, które tworzą spójną strukturę badania.

Rozdział 4. Identyfikacja zmiennych wejściowych modelu predykcyjnego zużycia energii przez AMR - Celem tego rozdziału jest określenie zestawu zmiennych wejściowych (predyktorów), które w największym stopniu wpływają na zużycie energii w robotach mobilnych. Analiza została przeprowadzona w oparciu o literaturę naukową, teorię bilansu energetycznego oraz analizę przyczynowo skutkową w postaci diagramu Ishikawy. Zidentyfikowano czynniki dotyczące misji, środowiska oraz stanu robota, które stanowią podstawę dalszego modelowania. Etap ten stanowi pomost między analizą teoretyczną a eksperymentalnym opracowaniem modeli.

Rozdział 5. Projekt eksperymentów i stanowisko badawcze - Rozdział piąty przedstawia koncepcję eksperymentu oraz opis autorskiego stanowiska pomiarowego, umożliwiającego rejestrację danych operacyjnych i energetycznych robotów AMR. Zastosowano podejście sekwencyjne (dwustopniowe), obejmujące eksperyment wstępny (OFAT) i eksperyment wieloczynnikowy zgodny z zasadami Design of Experiments (DoE). Szczegółowo opisano architekturę systemu pomiarowego, dobór czujników, protokoły komunikacyjne oraz środowisko testowe, w którym prowadzono badania.

Rozdział 6. Opracowanie i walidacja modeli predykcyjnych zużycia energii przez AMR W rozdziale szóstym zaprezentowano autorskie modele predykcyjne:

- model jednowymiarowy (M1) oparty na regresji wielomianowej,
- model wielowymiarowy (M2) w postaci uogólnionego modelu liniowego,
- model automatyczny (M3) opracowany przy użyciu narzędzia AutoML. Przedstawiono procedurę walidacji, ocenę dokładności predykcji, analizę wpływu poszczególnych zmiennych oraz porównanie modeli pod kątem złożoności, interpretowalności i potencjału wdrożeniowego. Wyniki stanowią realizację zasadniczego celu rozprawy i podstawę do opracowania rekomendacji wdrożeniowych.

Rozdział 7. Dyskusja wyników i wnioski końcowe- Ostatni rozdział zawiera podsumowanie rezultatów badawczych oraz ocenę stopnia realizacji celów i zadań określonych w rozdziale trzecim. Wskazano w nim praktyczne możliwości wykorzystania opracowanych modeli w systemach zarządzania flotą robotów mobilnych oraz potencjał ich rozszerzenia o funkcje adaptacyjne i diagnostyczne. Rozdział kończy się propozycją kierunków dalszych prac w obszarze predykcyjnego zarządzania energią w systemach intralogistycznych.

1. Logistyka 4.0 i autonomiczne roboty mobilne - technologie oraz systemy zarządzania flotą

Rozdział przedstawia podstawy technologiczne, organizacyjne i systemowe, które stanowią kontekst zastosowania autonomicznych robotów mobilnych w środowisku intralogistycznym. Omówiono rozwój koncepcji Logistyki 4.0 oraz znaczenie intralogistyki jako obszaru integracji technologii transportowych, informacyjnych i decyzyjnych. Przedstawiono różnice konstrukcyjne i funkcjonalne pomiędzy różnymi typami mobilnych robotów transportowych oraz ich wpływ na elastyczność wdrożeń. Scharakteryzowano również architekturę systemów zarządzania flotą, wskazując ograniczenia aktualnych rozwiązań, w szczególności brak mechanizmów predykcyjnych związanych ze stanem energetycznym robotów. Rozdział stanowi punkt wyjścia do dalszych analiz, których celem jest budowa modeli wspomagających podejmowanie decyzji operacyjnych w oparciu o prognozowane zużycie energii.

1.1 Charakterystyka intralogistyki i Logistyki 4.0 jako obszaru zastosowań robotów mobilnych

Logistykę w ujęciu klasycznym można zdefiniować jako proces planowania, wdrażania i kontrolowania przepływu towarów, usług oraz powiązanych z nimi informacji - począwszy od punktu początkowego (na przykład wydobywania lub pozyskania surowca) aż do punktu docelowego (klient końcowy) [7]. Celem logistyki jest zaspokojenie potrzeb odbiorców przy możliwie najniższych kosztach i maksymalnej efektywności (wg. organizacji Council of Supply Chain Management Professionals). W praktyce przekłada się to na trzy kluczowe elementy [7], [8], [17]:


- organizację przepływów fizycznych (transport, magazynowanie),
- organizację przepływów informacyjnych (dokumentacja, dane o zapasach, status przesyłek) ,
- kompleksowe zarządzanie i optymalizację procesów (planowanie popytu, wybór dostawców, zarządzanie zwrotami).

W zależności od rodzaju i specyfiki przedsiębiorstwa, logistyka opiera się na różnych koncepcjach i modelach zarządzania. Przykładowo, model referencyjny operacji łańcucha dostaw (*ang. Supply Chain Operations Reference, SCOR*) koncentruje się na procesach planowania, zaopatrzenia, produkcji, dostawy oraz zwrotów, ułatwiając prowadzenie benchmarkingu i identyfikację obszarów wymagających usprawnień [18]. Szczupła logistyka (*ang. Lean Logistics*) opiera się na eliminacji marnotrawstwa w przepływach materiałowych, natomiast koncepcja dostaw dokładnie na czas (*ang. Just in Time, JIT*) dąży do minimalizacji zapasów poprzez synchronizację dostaw z momentem faktycznego zużycia komponentów [19]. Z kolei zarządzanie łańcuchem dostaw (*ang. Supply Chain Management, SCM*) stanowi podejście całościowe, obejmujące integrację wszystkich ogniw i procesów w łańcuchu dostaw [17]. Uzupełniając, zasada siedmiu praw logistyki (*ang. Seven Rights of Logistics, 7R*) podkreśla konieczność zapewnienia odpowiedniego produktu, we właściwej ilości, o wymaganej jakości, dostarczonego we właściwe miejsce i czas, odpowiedniemu klientowi, przy akceptowalnym koszcie [20]. Każda z tych koncepcji skupia się na innym aspekcie zarządzania logistyką – od poziomu funkcjonalnego (np. transport, magazynowanie) do podejścia procesowego (ciągłość przepływu, współpraca w łańcuchu dostaw).

Logistyka 4.0 stanowi naturalną kontynuację i rozwinięcie klasycznych koncepcji, modeli i metod zarządzania logistyką oraz produkcją. Wywodzi się z wcześniejszych etapów integracji i cyfryzacji, reprezentowanych m.in. przez systemy planowania zapotrzebowania materiałowego (*ang. Material Requirements Planning, MRP*) oraz zintegrowane systemy zarządzania zasobami przedsiębiorstwa ERP) [21], [22]. W odróżnieniu od tradycyjnych rozwiązań, Logistyka 4.0 zakłada pełną integrację

procesów w czasie rzeczywistym, opartą na wymianie danych i zastosowaniu nowoczesnych technologii informacyjnych [3], [7], [23].

Nie jest to odrębny, zamknięty model, który zastępuje dotychczasowe podejścia, takie jak SCOR, JIT czy zasada 7R. Przeciwnie, stanowi ich rozszerzenie poprzez wdrożenie cyfrowych narzędzi analitycznych, automatyzacji i komunikacji systemów, które umożliwiają bardziej efektywne zarządzanie przepływem materiałów, informacji i kapitału [18], [19], [24]. Schematyczna idea Logistyki 4.0 została przedstawiona na Rys. 3.



Rys. 3 Integracja tradycyjnych metod zarządzania logistyką i produkcją z technologiami Przemysłu 4.0 jako fundament Logistyki 4.0, łączącej klasyczne podejścia z nowoczesnymi rozwiązaniami w celu automatyzacji, cyfryzacji i optymalizacji procesów. Opracowanie własne na podstawie: [3], [5], [7], [22]

Logistyka 4.0 opiera się na wdrażaniu zaawansowanych rozwiązań technologicznych - **filarów Przemysłu 4.0**, takich jak [3], [25], [26]:

- przemysłowy Internet Rzeczy (*ang. Industrial Internet of Things, IIoT*),
- analiza Big Data i sztuczna inteligencja (AI),
- chmura obliczeniowa (cloud computing),
- roboty mobilne,
- technologie addytywne (druk 3D),
- cyberbezpieczeństwo,
- cyfrowe bliźniaki (*ang. Digital Twins, DT*).


Wdrożenie tych rozwiązań nie ogranicza się do automatyzacji pojedynczych operacji, lecz dąży do integracji całych procesów oraz bieżącego wykorzystania danych jako podstawy do podejmowania decyzji. Przykładowo, firma stosująca zasadę 7R może rozszerzyć ją o komponenty logistyki 4.0 poprzez wykorzystanie IoT do śledzenia przesyłek w czasie rzeczywistym, analizę danych w celu poprawy prognoz popytu lub wdrożenie transportowych robotów mobilnych w logistyce magazynowej [24].

Kluczową cechą logistyki 4.0 jest przejście od zarządzania reaktywnego do podejścia proaktywnego i predykcyjnego. Proaktywność oznacza zdolność do inicjowania działań korekcyjnych i optymalizacyjnych jeszcze przed wystąpieniem zakłóceń, na podstawie monitoringu procesów i reguł decyzyjnych. Z kolei predykcyjność wykorzystuje modele prognostyczne oparte na uczeniu maszynowym (*ang. Machine Learning, ML*), analizie Big Data i cyfrowych symulacjach, umożliwiając

przewidywanie zmian popytu, obciążeń zasobów oraz ryzyka zdarzeń, a w efekcie dynamiczne planowanie i rekonfigurację przepływów [7], [11], [27], [28].

W rezultacie logistyka 4.0 przekształca tradycyjne zarządzanie łańcuchem dostaw w system zorientowany na dane, zdolny do elastycznego reagowania na zmienne warunki rynkowe, poprawy efektywności operacyjnej i realizacji celów znanych z klasycznych podejść, lecz z wykorzystaniem współczesnych środków technologicznych

Intralogistyka to dziedzina logistyki zajmująca się organizacją, optymalizacją i zarządzaniem przepływem materiałów, informacji oraz zasobów wewnątrz przedsiębiorstwa. Obejmuje szeroki zakres działań logistycznych realizowanych wewnątrz przedsiębiorstwa, transport wewnętrzny, magazynowanie oraz zarządzanie zapasami, a jej celem jest zwiększenie wydajności i minimalizacja kosztów operacyjnych [2], [29] [5], [8]. Procesy związane z zarządzaniem przepływem materiałów i informacji wewnątrz przedsiębiorstwa były realizowane od dekad w ramach szeroko rozumianej logistyki wewnętrznej. Dopiero w 2005 roku, podczas targów CeMAT w Niemczech, pojawiła się formalna definicja "intralogistyki" zaproponowana przez Związek Niemieckich Producentów Maszyn (VDMA). Nowy termin powstał w związku z rosnącą rolą automatyzacji, cyfryzacji i nowoczesnych technologii w optymalizacji procesów wewnętrznych [8]. Współczesne przedsiębiorstwa coraz częściej korzystają z zaawansowanych technologii intralogistycznych, które umożliwiają automatyzację procesów i integrację z systemami zarządzania. Współczesna intralogistyka wykracza daleko poza proste przemieszczanie komponentów i materiałów - staje się złożonym, zintegrowanym obszarem, w którym kluczową rolę odgrywają wdrożone technologie Przemysłu 4.0, takie jak transportowe roboty mobilne, Internet Rzeczy (IoT), sterowanie zdecentralizowane i cyfrowe bliźniaki. [4], [6], [30]. Analiza literatury przedmiotu, w szczególności powiązań słów kluczowych z hasłem „intralogistyka”, potwierdza ścisłą zależność między tym obszarem a technologiami Przemysłu 4.0 (Rys. 4).



Rys. 4 Mapa współwystępowania słów kluczowych w publikacjach dotyczących intralogistyki (analiza bibliometryczna). Źródło:[8]

Problemy współczesnej intralogistyki

W literaturze przedmiotu można zidentyfikować szereg kluczowych problemów obecnej intralogistyki. Poniżej przedstawiono wybrane z nich, akcentując zarówno aspekty technologiczne, jak i czynniki ludzkie oraz organizacyjne.

1. **Rosnąca zmienność i wolumen zamówień** - Wzrost liczby zamówień oraz ich rosnące zróżnicowanie w sieciach dystrybucyjnych stwarzają poważne wyzwania dla systemów intralogistycznych [8], [31]. Tradycyjne, monolityczne architektury sterowania oraz sztywne systemy transportu wewnętrznego okazują się niewystarczające w dynamicznym środowisku, które wymaga szybkiej reorganizacji stanowisk i adaptacji do zmieniających się potrzeb operacyjnych [8], [32], [33]
2. **Niedobór wykwalifikowanej siły roboczej** - Współczesna intralogistyka boryka się z narastającym niedoborem wykwalifikowanej siły roboczej, wynikającym m.in. ze starzenia się społeczeństw oraz odpływu pracowników do innych sektorów [3], [7]. Problem ten ogranicza efektywność operacyjną i prowadzi do wzrostu kosztów pracy, co wskazuje na rosnącą potrzebę automatyzacji procesów produkcyjnych i transportowych jako jednego z kluczowych kierunków dalszego rozwoju. [6], [31], [34]
3. **Niewystarczająca odporność na zakłócenia** - Wydarzenia o charakterze globalnym (takie jak pandemia COVID-19) uwypukliły wrażliwość wewnętrznych procesów logistycznych na czynniki zewnętrzne i nagłe zakłócenia (np. ograniczenie dostępności pracowników, zerwanie łańcuchów dostaw). Nieprzewidywalność rynków wymusza zatem projektowanie systemów elastycznych, zdolnych do adaptacji w warunkach dynamicznej zmienności popytu lub ograniczeń kadrowych [31], [35]
4. **Brak interoperacyjności i trudności w integracji systemów intralogistycznych** - Współczesna intralogistyka, wykorzystująca zróżnicowane technologie informacyjne (*ang. Information Technology*, IT) i technologie operacyjne (*ang. Operational Technology*, OT), napotyka na trudności związane z brakiem interoperacyjności między systemami i urządzeniami różnych producentów. Różne standardy komunikacyjne utrudniają integrację, podnosząc koszty i złożoność wdrożeń. Przyszłe rozwiązania będą musiały zmierzać w kierunku standaryzacji i tworzenia otwartych, interoperacyjnych środowisk integracyjnych [17], [22], [36], [37].
5. **Niedostosowanie układu przestrzeni do transportowych robotów mobilnych**- Wiele zakładów przemysłowych i przestrzeni logistycznych powstało w okresie poprzedzającym rozwój robotów mobilnych, przez co ich układ przestrzenny nie uwzględnia specyfiki autonomicznego transportu. Wąskie przejścia oraz obecność zmiennych przeszkód mogą stanowić ograniczenie dla efektywnego wdrażania tych technologii [32], [38]. Wobec trudnych do usunięcia barier architektonicznych rośnie potrzeba wdrażania zaawansowanych rozwiązań programowych, takich jak planowanie tras, dynamiczne rozpoznawanie przeszkód i bieżące monitorowanie poprawności realizacji zadań, które umożliwiają integrację robotów transportowych bez konieczności kosztownej przebudowy infrastruktury [4], [9], [34], [39].
6. **Niewystarczająca efektywność energetyczna transportowych robotów mobilnych** - roboty mobilne wymagają regularnego ładowania, co ogranicza ich dostępność i ciągłość operacyjną [9], [32], [40]. Główne problemy to niska pojemność akumulatorów, długi czas ładowania oraz brak precyzyjnego harmonogramowania zadań i ładowania w odniesieniu do stanu energii (predykcja zużycia energii w misjach) [9], [41], [42]. Brak skutecznego planowania prowadzi do niskiego wykorzystania dostępnych jednostek oraz powstawania luk operacyjnych, które w praktyce mogą być kompensowane przez nadmiarową liczbę pojazdów, mimo że ich faktyczna potrzeba wynika wyłącznie z nieefektywnego zarządzania [9], [43].

Przyszłość intralogistyki

W obliczu wskazanych wyzwań, rozwój intralogistyki zmierza w kierunku systemów elastycznych, samodzielnych decyzyjnie i zdolnych do działania w zmiennym otoczeniu operacyjnym, co czyni transportowe roboty mobilne jednym z kluczowych obszarów innowacji. W następstwie intensywnej cyfryzacji i automatyzacji charakterystycznej dla Przemysłu 4.0, w literaturze zaczynają pojawiać się koncepcje rozszerzające ten paradygmat, określane mianem Przemysłu 5.0. Ich wspólnym

mianownikiem jest dążenie do ściślejszej integracji technologii z potrzebami człowieka oraz celami zrównoważonego rozwoju, co przekłada się na rosnące znaczenie takich obszarów jak efektywność energetyczna, adaptacyjność i interoperacyjność mobilnych robotów transportowych [21], [44], [45]. Systemy zarządzania ładowaniem AMR będą sterowane algorytmami, które pozwolą na planowanie ładowania w godzinach niższego obciążenia sieci lub większej dostępności energii z odnawialnych źródeł, co przyczyni się do redukcji emisji CO₂ i poprawy efektywności energetycznej [9], [18], [41]. Jednocześnie, mobilna robotyka przemysłowa, zarówno kołowa, jak i krocząca, będzie rozwijana w kierunku zwiększenia autonomii operacyjnej. Humanoidalne roboty, takich firm jak, Tesla, Unitree Robotics czy Boston Dynamics, oferując zdolność działania w środowiskach zaprojektowanych dla ludzi, stanowić będą uzupełnienie tradycyjnych kołowych robotów mobilnych, szczególnie w miejscach, gdzie standardowe platformy mobilne nie są w stanie funkcjonować bez kosztownej adaptacji infrastruktury [45], [46], [47]. Czas pracy na akumulatorze będzie wciąż istotnym wyzwaniem zarówno dla robotów kołowych, jak i kroczących. Prace nad optymalizacją zużycia energii z wykorzystaniem sztucznej inteligencji, np. poprzez planowanie tras, rekuperację energii i **predykcję zużycia energii**, w przyszłości może znacząco zwiększyć autonomię robotów [41].

Przyszłość intralogistyki kształtowana będzie przez coraz szersze wykorzystanie algorytmów sztucznej inteligencji, które odegrają kluczową rolę w optymalizacji i elastycznym zarządzaniu procesami wewnętrznymi zakładów produkcyjnych i logistycznych [11], [18], [26].

W odpowiedzi na rosnące zapotrzebowanie na masową personalizację produktów oraz dynamicznie zmieniające się potrzeby klientów, systemy logistyczne (takie jak transportowe roboty mobilne) będą musiały charakteryzować się wysokim stopniem rekonfigurowalności i adaptacyjności [4], [24]. Realizacja tego podejścia wymagać będzie elastycznego i inteligentnego harmonogramowania zadań transportowych, uwzględniającego zarówno aktualne warunki operacyjne, jak i prognozowane zmiany w obciążeniu systemu [28]. Integracja sztucznej inteligencji z systemami produkcyjnymi i logistycznymi umożliwi nie tylko reorganizację przepływów materiałowych w czasie rzeczywistym, lecz także dynamiczne dostosowywanie tras i priorytetów transportowych w oparciu o dane środowiskowe, energetyczne i produkcyjne [21].

W przyszłości robotyka mobilna będzie dynamicznie rozwijana poprzez wdrażanie bardziej zaawansowanych technologii ładowania i magazynowania energii, co zwiększy autonomię i efektywność operacyjną robotów. Rozwój systemów oprogramowania umożliwi zaawansowaną predykcję operacyjną robotów, obejmującą zarządzanie energią, ocenę wykonalności zadań oraz optymalizację harmonogramów pracy, pozwalając im na samodzielne ocenianie zdolności do realizacji zadań oraz podejmowanie decyzji związanych z optymalizacją ich pracy. Dzięki temu roboty będą w stanie w sposób autonomiczny dostosowywać swoje działania do zmieniających się warunków operacyjnych, co wpłynie na zwiększenie niezawodności i efektywności procesów intralogistycznych [41], [46]. Dalsza integracja robotów mobilnych z systemami IoT umożliwi zaawansowaną wymianę i analizę danych z różnorodnych sensorów, co znacząco zwiększy precyzję oceny otoczenia. Roboty będą mogły identyfikować potencjalne przeszkody na drodze transportowej zanim jeszcze do nich dotrą oraz efektywniej monitorować obiekty znajdujące się w ich zasięgu. Wykorzystanie technologii rozszerzającej percepcję robotów przełoży się na lepsze planowanie i podejmowanie decyzji w czasie rzeczywistym, zwiększając tym samym efektywność i niezawodność procesów intralogistycznych [21], [48], [49].

Przytoczone źródła jednoznacznie wskazują, że narastające problemy kadrowe, rosnąca zmienność operacyjna oraz potrzeba zwiększenia odporności na zakłócenia stwarzają konieczność transformacji intralogistyki w kierunku elastycznych, zautomatyzowanych systemów transportu wewnętrznego. Kluczowym kierunkiem staje się nie tylko rozwój samych platform transportowych, lecz również systemów ich inteligentnego sterowania oraz pełna integracja zarządzania transportem z nadrzędnymi systemami zarządzania przedsiębiorstwem, co pozwala na spójną optymalizację przepływów materiałowych, informacyjnych i energetycznych.

1.2 Budowa i technologie robotów mobilnych w środowisku przemysłowym


W przedsiębiorstwach przemysłowych stosowane są różne technologie robotów mobilnych, zróżnicowane pod względem autonomii, sposobu nawigacji oraz funkcji. Najczęściej spotykane są **pojazdy automatycznie prowadzone (AGV)** oraz **autonomiczne roboty mobilne (AMR)** [50], [51], [52], [53]. Oprócz nich w literaturze i praktyce przemysłowej pojawiają się również mniej rozpowszechnione rozwiązania, takie jak:

- **autonomiczne inteligentne pojazdy** (*ang. Autonomous Intelligent Vehicle, AIV*) - wykorzystujące algorytmy sztucznej inteligencji do adaptacji i podejmowania decyzji w czasie rzeczywistym [54].
- **samo nawigujące pojazdy** (*ang. Self-Guided Vehicle, SGV*) - poruszające się bez infrastruktury prowadzącej, na podstawie danych z czujników i systemów wizyjnych [55].
- **pojazdy prowadzone laserowo** (*ang. Laser Guided Vehicle, LGV*) - korzystające z systemów lokalizacji opartych na skanowaniu laserowym [43].

W dalszej części pracy przyjęto dwa najczęściej spotykane typy robotów mobilnych - AGV i AMR, jako reprezentatywne dla rozwiązań odpowiednio automatycznie prowadzonego oraz autonomicznego transportu wewnętrznego. Ich rozróżnienie nabiera szczególnego znaczenia w kontekście wyzwań, przed którymi stoi współczesny przemysł, takich jak rosnąca złożoność procesów, masowa personalizacja oraz potrzeba zwiększenia elastyczności operacyjnej. Dobór właściwej technologii transportu mobilnego staje się kluczowym elementem budowy systemów zdolnych do efektywnego działania w dynamicznym i wymagającym środowisku produkcyjnym.

AGV to starsze i prostsze rozwiązanie, wykorzystujące podstawowe technologie nawigacyjne, takie jak prowadzenie mechaniczne, optyczne, indukcyjne lub punktowe w układzie kartezjańskim (Rys. 5 a-f). Mogą poruszać się wyłącznie po wyznaczonych trasach, dlatego stosowane są głównie w stabilnych i powtarzalnych procesach. Ich wdrożenie wymaga ingerencji w infrastrukturę, np. instalacji taśm, przewodów indukcyjnych czy znaczników oraz wyznaczenia stałych korytarzy ruchu. Zmiana układu produkcyjnego wiąże się z koniecznością przeprojektowania tras i rekonfiguracji infrastruktury, co generuje koszty i wymusza przerwy w pracy systemu. [9], [56].


AMR, wykorzystują zaawansowane czujniki, takie jak skanery laserowe (*ang. Light Detection and Ranging, LIDAR*) oraz systemy wizyjne, wspierane przez nowoczesne algorytmy rozpoznawania otoczenia i nawigacji (Rys. 5g). Dzięki temu mogą poruszać się swobodnie, elastycznie dostosowując trasę do zmieniających się warunków. Wykorzystują mapy cyfrowe tworzone na podstawie skanów laserowych lub obrazów z kamer, co pozwala na łatwą aktualizację tras bez ingerencji w infrastrukturę fizyczną zakładu. Przy zastosowaniu algorytmów jednoczesnej lokalizacji i mapowania (*ang. Simultaneous Localization and Mapping, SLAM*), AMR mogą samodzielnie budować i aktualizować mapy środowiska. Ich elastyczność sprawia, że są preferowanym rozwiązaniem w zmiennych warunkach produkcyjnych, gdzie wymagana jest szybka adaptacja do zmian układu przestrzennego, asortymentu lub tempa produkcji [9], [49], [56].



Rys. 5 Systemy prowadzenia dla AGV i AMR (widok z góry). Źródło: [9]


Odmierna filozofia projektowa systemów AGV i AMR znajduje odzwierciedlenie w ich architekturze sterowania oraz sposobie organizacji ruchu w przestrzeni przemysłowej. W przypadku AGV stosuje się zazwyczaj podejście scentralizowane, w którym jednostki wykonawcze są sterowane z poziomu nadrzędnego systemu zarządzania, komunikującego się z pojazdami za pośrednictwem infrastruktury sieciowej. Półkowe systemy sterowania AGV realizują głównie zadania związane z utrzymaniem trajektorii, reagowaniem na sygnały z podstawowych czujników oraz wykonaniem poleceń ruchu. W razie zakłóceń, takich jak przeszkody na trasie, pojazd wstrzymuje pracę i oczekuje na instrukcję z systemu centralnego lub interwencję operatora. Mimo prostoty wdrożeniowej i diagnostycznej, scentralizowane sterowanie charakteryzuje się ograniczoną elastycznością i skalowalnością, a także podatnością na opóźnienia reakcji [9], [49], [56].

W przeciwieństwie do tego, systemy AMR funkcjonują głównie w architekturze zdecentralizowanej (lub hybrydowej), w której każdy robot posiada zdolność autonomicznej lokalizacji w przestrzeni oraz niezależnego podejmowania decyzji w zakresie planowania trajektorii i omijania przeszkód, co znacząco zwiększa responsywność i odporność systemu. Wadą tego podejścia może być ograniczona optymalizacja globalna, wynikająca z rozproszenia informacji [9], [12], [42], [49], [56]. Zasada działania sterowania scentralizowanego i zdecentralizowanego przedstawiono na Rys. 6.



Rys. 6 Porównanie scentralizowanego sterowania pojazdami AGV z zdecentralizowanym sterowaniem robotami AMR w warstwie fizycznej i sterowania. Źródło: [9]

Stosowanie sztywno zdefiniowanych tras przejazdu robotów AGV prowadzi do znacznych utrudnień w przypadku wystąpienia przeszkody lub awarii pojedynczego pojazdu. W takiej sytuacji dochodzi do kaskadowej blokady kolejnych ogniw wewnętrznego łańcucha dostaw, co skutkuje całkowitym wstrzymaniem procesów logistycznych. Zastosowanie autonomicznych robotów mobilnych (AMR), które są zdolne do dynamicznego wyznaczania alternatywnych dróg, pozwala na znaczące zwiększenie elastyczności operacji transportowych (Rys. 7). Dzięki zdolności omijania nieprzewidzianych przeszkód roboty AMR ograniczają ryzyko tworzenia się wąskich gardeł i zatrzymań przepływu, co sprzyja utrzymaniu ciągłości transportu wewnętrznego [6], [9], [56], [57].



Rys. 7 Porównanie sposobów reagowania robotów AGV i AMR w obliczu przeszkód w środowisku intralogistycznym. Opracowanie własne.

Porównanie systemów AGV i AMR

Zarówno AGV, jak i AMR znajdują zastosowanie w nowoczesnych systemach transportu wewnętrznego. Każde z tych rozwiązań posiada swoje zalety oraz ograniczenia, które należy analizować w kontekście konkretnych warunków operacyjnych, oczekiwań względem elastyczności, integracji z systemami IT oraz kosztów wdrożenia i eksploatacji. Poniżej (Tabela 2) przedstawiono autorskie opracowanie porównania wybranych cech systemów AGV i AMR. Zestawienie to umożliwia ocenę, które z rozwiązań lepiej odpowiada na specyfikę danego środowiska produkcyjnego oraz ułatwia dobór technologii adekwatnej do wymagań operacyjnych.

Tabela 2 Porównanie systemów AGV i AMR z uwzględnieniem wielu cech. Opracowanie własne na podstawie: [9], [16], [40], [42], [46], [49], [57], [58], [59], [60], [61], [62]

Cecha / właściwość	AGV (Automated Guided Vehicle)	AMR (Autonomous Mobile Robot)
Zastosowanie	Głównie w środowiskach z ustalonymi i powtarzalnymi trasami transport	W środowiskach dynamicznych z częstymi zmianami tras; dzięki systemom bezpieczeństwa mogą bezpiecznie współpracować z ludźmi w otoczeniu przemysłowym.
Typ nawigacji	Wymaga wcześniej zainstalowanych znaczników (np. taśm, linii, znaczników magnetycznych).	Autonomiczna - wykorzystuje mapy oraz czujniki (LIDAR, kamery) do nawigacji w dynamicznym środowisku.
Elastyczność	Ograniczona - trasy są stałe, a w przypadku zmian środowiska wymagane są modyfikacje. Dobrze sprawdza się w prostych, przewidywalnych warunkach.	Wysoka - potrafi dynamicznie dostosowywać trasy do zmian w otoczeniu, dzięki czemu sprawdza się w złożonych, dynamicznych środowiskach.
Adaptacja do zmian środowiska	Ograniczona - zmiana tras lub konfiguracji często wymaga interwencji człowieka oraz modyfikacji systemu.	Wysoka - zdolność do samodzielnej adaptacji i optymalizacji trasy w czasie rzeczywistym pozwala na szybką reakcję na zmiany w otoczeniu.
Instalacja	Wymaga czasu i nakładów na instalację infrastruktury (np. taśm, znaczników).	Szybka instalacja - nie wymaga dodatkowej infrastruktury, co skraca czas wdrożenia.
Koszt początkowy infrastruktury	Wyższy - związany z koniecznością zakupu i instalacji systemów prowadzenia	Niższy - brak potrzeby instalacji specjalistycznej infrastruktury.
Koszt początkowy robota	Niższy - AGV charakteryzują się prostszą konstrukcją i technologią, co przekłada się na niższy koszt samego urządzenia.	Wyższy - AMR wykorzystują zaawansowane technologie, w tym czujniki i systemy obliczeniowe, które podnoszą koszt zakupu samego robota.
Koszt utrzymania	Niższy - prostsze systemy nawigacji i mniej zaawansowana technologia przekładają się na mniejsze koszty serwisowania.	Wyższy - zaawansowane systemy nawigacji, czujniki oraz rozwiązania oparte na AI/ML mogą generować wyższe koszty utrzymania i aktualizacji systemu.
Czas wdrożenia	Długi czas wdrożenia z powodu konieczności instalacji systemów prowadzenia	Szybszy czas wdrożenia, ze względu na łatwiejszą adaptację do istniejącego środowiska
Obsługa przeszkód	Brak - przy napotkaniu przeszkody zazwyczaj następuje zatrzymanie; standardowe czujniki.	Zaawansowana - potrafi omijać przeszkody i kontynuować zadanie, często wspierana przez technologie AI/ML.
Integracja z systemami IT	Wymaga integracji z systemami zarządzania ruchem oraz utrzymania infrastruktury.	<u>Brak ujednoliconego standardu - często współpracuje z dedykowanymi (dla danego robota / producenta) systemami zarządzania flotą.</u>
System zarządzania	Centralne zarządzanie, które może mieć trudności w koordynacji różnych typów robotów wykonujących odmienne zadania, wymagające odmiennych ścieżek i obciążenia	Zdecentralizowane lub hybrydowe systemy zarządzania, które pozwalają na bardziej elastyczną koordynację różnych typów robotów wykonujących różne zadania. Umożliwiają dynamiczne przydzielanie zadań i współpracę pomiędzy robotami
Skalowalność	Ograniczona - rozbudowa floty często wymaga modyfikacji istniejącej infrastruktury.	Wysoka - dodawanie nowych robotów do floty jest prostsze, co umożliwia skalowanie systemu w dynamicznym środowisku.
Bezpieczeństwo	Wysokie - zależy jednak od stabilności infrastruktury oraz przewidywalności środowiska; stosowane są standardowe systemy bezpieczeństwa (np. czujniki zderzakowe, odległościowe LIDAR).	Wysokie - wykorzystuje zaawansowane systemy wykrywania przeszkód i unikania kolizji, wspierane przez technologie AI/ML, co zwiększa poziom bezpieczeństwa w zmiennych warunkach.
Interakcja z ludźmi	Zazwyczaj działają w izolowanych strefach, ze względu na bezpieczeństwo.	Mogą pracować jako współpracownicy z ludźmi, wymagają zaawansowanych systemów bezpieczeństwa.
Przewidywalność zużycia energii podczas misji	Wysoka przewidywalność zużycia energii ze względu na ustalone trasy i powtarzalne operacje	<u>Mniejsza przewidywalność zużycia energii ze względu na dynamiczne trasy, omijanie przeszkód i różne obciążenia</u> Modele zużycia energii muszą <u>uwzględniać wiele zmiennych</u>

W odniesieniu do problemów zidentyfikowanych w poprzednim podrozdziale - takich jak niedobory kadrowe, praca w dynamicznie zmieniającym się otoczeniu oraz częste reorganizacje przestrzeni produkcyjnej, przyszłość inteligentnych systemów transportu wewnętrznego należy wiązać z robotami AMR. Ich wysoka elastyczność, zdolność adaptacji do zmiennych warunków oraz ograniczone wymagania infrastrukturalne sprawiają, że stanowią rozwiązanie uniwersalne, umożliwiające zarówno współpracę z człowiekiem (zgodnie z ideą Humanocentryzmu Przemysłu 5.0), jak i przejmowanie zadań dotychczas realizowanych manualnie. Jednocześnie, ze względu na brak stałej trasy przejazdu oraz możliwość występowania przeszkód na drodze transportowej, **roboty AMR charakteryzują się większą zmiennością w zużyciu energii niż klasyczne rozwiązania AGV**. Utrudnia to nie tylko planowanie wewnętrznych procesów transportowych, lecz także zarządzanie momentem ładowania oraz weryfikację wykonalności zadań zakolejkowanych w systemie. [21], [40], [58].


Wszechstronność autonomicznych robotów mobilnych - zastosowania w przemyśle

Autonomiczne roboty mobilne to uniwersalne platformy, które znajdują zastosowanie w różnorodnych środowiskach przemysłowych, znacznie wykraczając poza klasyczną intralogistykę. Dzięki modułowej konstrukcji oraz możliwości integracji z innymi technologiami (np. manipulatorami, systemami wizyjnymi, narzędziami specjalistycznymi), stanowią elastyczną bazę dla szerokiego spektrum zastosowań.

W obszarze produkcji i intralogistyki (Rys. 8a-g) AMR wspierają zadania związane z dostawą komponentów, transportem palet, obsługą stanowisk montażowych oraz realizacją przepływów materiałowych. Systemy holownicze (Rys. 8a), roboty regałowe (Rys. 8b) oraz jednostki zintegrowane z przenośnikami taśmowymi (Rys. 8f) usprawniają logistykę wewnętrzną w zakładach produkcyjnych [9], [11], [16], [42]. AMR z manipulatorami współpracującymi (Rys. 8c-d) pozwalają na wykonywanie zadań montażowych, kontrolnych i technologicznych w trybie kolaboracji z człowiekiem lub samodzielnie zwiększając elastyczność organizacji pracy [9], [40], [63].

W logistyce magazynowej (Rys. 8h-n) AMR realizują procesy kompletacji, sortowania, inwentaryzacji i autonomicznego składowania. Roboty kompletacyjne (Rys. 8h), jednostki do pobierania i transportu towarów (Rys. 8j), a także roboty sortujące (Rys. 8k) optymalizują wykorzystanie przestrzeni magazynowej i ograniczają liczbę błędów ludzkich. Ich elastyczność w dostosowywaniu tras i zdolność do współpracy z operatorami (Rys. 8i) pozwalają na szybkie reagowanie na zmiany popytu i reorganizację layoutu magazynu [9], [16], [42], [64].

Zastosowania specjalistyczne (Rys. 8o-x) pokazują, że AMR mogą być wykorzystywane jako platformy w sektorze medycznym, hotelarskim, energetycznym, rolniczym i miejskim. Przykłady obejmują roboty do transportu leków (Rys. 8q), dezynfekcji szpitali (Rys. 8t), autonomicznego zarządzania kontenerami (Rys. 8u), a także roboty przewodniki i jednostki telemedyczne wspierające opiekę nad pacjentami (Rys. 8s, Rys. 8x). W zastosowaniach miejskich rozwijane są m.in. roboty parkingowe (Rys. 8v) [6], [9], [42], [65].

	Manipulacja materiałami	Roboty współpracujące	Roboty usługowe o pełnej funkcjonalności
Produkcja	 (a) Robot holownik  (b) Robot z modulem półkowym  (e) Robot z urządzeniem podnoszącym  (f) Robot z przenośnikiem	 (c) Robot współpracujący (cobot)	 (d) Ramię robota z urządzeniem szlifującym do łopat turbin wiatrowych
Magazyinowanie	 (g) Robot realizujący zamówienia w mobilnych systemach kompletacji  (h) Robot kompletujący  (k) Robot sortujący  (l) Robot do lokalizacji i inwentaryzacji towarów  (n) Roboty w systemach magazynowych typu „puzzle”  (o) Roboty w autonomicznych systemach magazynowo-transportowych	 (i) Robot współpracujący do przenoszenia towarów  (m) Robot inspekcyjno-nadzorczy  (p) Robot współpracujący do kompletacji zamówień	 (j) Robot do kompletacji i odbioru towarów
Inne środowiska intralogistyczne	 (q) Robot do bezpiecznego transportu leków w szpitalach  (r) Robot do transportu bagażu w hotelach  (u) Robot do obsługi kontenerów w terminalach  (v) Robot parkingowy	 (s) Robot do prowadzenia pacjentów w szpitalach  (x) Robot z urządzeniem do teleobecności w szpitalach	 (t) Robot do dezynfekcji pomieszczeń szpitalnych

Rys. 8 Funkcjonalny podział AMR w środowiskach przemysłowych i usługowych. Źródło: [9]

AMR stanowią aktualnie jedną z najbardziej perspektywicznych rozwiązań w obszarze intralogistyki, logistyki magazynowej i produkcji. Ich elastyczność oraz zdolność do działania w dynamicznie zmieniających się warunkach operacyjnych czynią je uniwersalną platformą technologiczną, która dobrze wpisuje się w potrzeby nowoczesnych systemów produkcyjnych i logistycznych. Jednak efektywne wykorzystanie ich potencjału wymaga podejścia systemowego, uwzględniającego nie tylko konstrukcję pojedynczego robota, lecz także kwestie zarządzania flotą, integracji z infrastrukturą IT / OT oraz rozwiązywania problemów takich jak zarządzanie energią, niezawodna lokalizacja i koordynacja zadań wielu jednostek. W tym kontekście dalszy rozwój AMR powinien koncentrować się nie tylko na doskonaleniu platform mobilnych, ale przede wszystkim na eliminacji istniejących ograniczeń poprzez badania nad nowymi modelami zarządzania, algorytmami predykcyjnymi zużycia energii i stanu robota oraz interoperacyjnością. Obszar ten stanowi uzasadniony i wartościowy kierunek badań naukowych.

1.3 Architektura i zarządzanie systemem robotów mobilnych

Autonomiczne roboty mobilne, scharakteryzowane w poprzednim podrozdziale, stanowią elastyczne jednostki transportowe zdolne do samodzielnej nawigacji, adaptacji do zmian otoczenia oraz realizacji złożonych zadań w środowiskach przemysłowych [58]. Ich możliwości techniczne umożliwiają działanie w warunkach zmienności operacyjnej, jednak potencjał tych rozwiązań ujawnia się w pełni dopiero w ujęciu systemowym. Wprowadzenie nawet najbardziej zaawansowanych jednostek AMR nie gwarantuje wzrostu efektywności, jeżeli ich działanie pozostaje nieskoordynowane. Brak nadzoru nad harmonogramem zadań, stanem technicznym robotów oraz ich wzajemnymi relacjami operacyjnymi prowadzi do nieoptymalnego wykorzystania zasobów, lokalnych przeciążeń lub przestojów, a także trudności w skalowaniu rozwiązania. W konsekwencji, zastosowanie AMR w oderwaniu od nadrzędnej struktury sterowania prowadzi do fragmentaryzacji procesów zamiast do ich automatyzacji [42], [66]. Z tego względu niezbędne jest przejście od jednostkowego spojrzenia na roboty jako autonomiczne jednostki wykonawcze do perspektywy systemowej, w której koordynacja, nadzór i integracja stanowią podstawę efektywnego zarządzania [38], [43]. Wspomniana potrzeba centralnej koordynacji jednostek mobilnych wpisuje się w szerszy problem integracji systemów wykonawczych z nadrzędnymi warstwami zarządzania. W przedsiębiorstwach produkcyjnych zapewnienie spójności działań na poziomie maszyn, logistyki i planowania realizowane jest poprzez architekturę systemową opartą na modelu hierarchicznym tzw. piramidzie automatyzacji [67].

Standardowa piramida automatyzacji (model ISA-95, IEC 62264), przedstawia hierarchiczną strukturę systemów informatycznych i urządzeń stosowanych w przedsiębiorstwach produkcyjnych. Jej celem jest zapewnienie płynnego przepływu informacji pomiędzy poziomem fizycznym reprezentowanym przez czujniki, elementy wykonawcze i sterowniki, a poziomami odpowiedzialnymi za zarządzanie operacyjne, produkcyjne i biznesowe [67]. Taki model, zorganizowany na pięciu poziomach (od poziomu urządzeń po systemy wspierające podejmowanie decyzji), umożliwia integrację danych w skali całego zakładu oraz wspiera podejmowanie decyzji na różnych poziomach zarządzania (Rys. 9).




Rys. 9 Pięciopoziomowy model automatyzacji przedsiębiorstwa. Opracowanie własne na podstawie [67]

Współczesne systemy produkcyjne i logistyczne, oparte na elastycznych, rekonfigurowanych strukturach oraz autonomicznych jednostkach wykonawczych, przestają jednak pracować w ramach klasycznej, sztywno zdefiniowanej hierarchii. Modele oparte wyłącznie na pionowym przepływie danych okazują się niewystarczające w środowiskach dynamicznych, w których jednostki (np. AMR) muszą reagować w czasie rzeczywistym, a decyzje operacyjne są delegowane do systemów pośrednich o wysokim poziomie autonomii [68].

W tym kontekście istotną rolę odgrywa system zarządzania flotą, odpowiedzialny za koordynację pracy automatycznych i autonomicznych robotów mobilnych (AMR, AGV). **FMS pośredniczy między**

robotami a nadrzędnymi systemami informatycznymi, takimi jak system zarządzania realizacją produkcji (MES), system zarządzania gospodarką magazynową (*ang. Warehouse Management System, WMS*) czy system nadzoru i akwizycji danych (*ang. Supervisory Control and Data Acquisition, SCADA*) [68], [69]. Zamiast bezpośredniego zarządzania każdą jednostką, systemy nadrzędne przekazują do FMS zadania transportowe, które są następnie rozdzielane i nadzorowane w sposób autonomiczny, z uwzględnieniem aktualnego stanu floty, priorytetów operacyjnych i ograniczeń środowiskowych [9], [69].

FMS może współpracować z różnymi systemami wyższego poziomu np. obsługując z jednej strony zadania produkcyjne (MES), a z drugiej procesy magazynowe (WMS) **wykorzystując jedną flotę AMR do realizacji zróżnicowanych celów** [69]. Jednocześnie system ten integruje się z infrastrukturą zakładową (np. SCADA, automatyczne drzwi, windy), umożliwiając bezpieczne i zsynchronizowane działanie robotów w rzeczywistym środowisku [68]. Z tego względu w nowoczesnych systemach przemysłowych klasyczna piramida automatyzacji podlega rozszerzeniu [68], [69], [70]. W przedstawionej poniżej (Rys. 10) strukturze uzupełniono klasyczną piramidę o warstwę FMS, pełniącą rolę adaptacyjnego centrum decyzyjnego. System ten integruje poziom wykonawczy (roboty) z warstwami zarządzania, przejmując odpowiedzialność za podejmowanie decyzji operacyjnych pomiędzy sterowaniem lokalnym a systemami nadrzędnymi.



Rys. 10 Rozszerzenie pięciopoziomowej architektury systemów sterowania i zarządzania, w którym FMS współpracuje z ERP, MES, WMS i SCADA, koordynując flotę AMR. Opracowanie własne na podstawie: [30], [67], [68]

Zarządzanie stanem robotów mobilnych w komercyjnych systemach flotowych

System zarządzania flotą (FMS) pełni rolę nadrzędnego koordynatora operacyjnego robotów mobilnych, zarządzając zarówno ich zadaniami, jak i stanem technicznym oraz energetycznym [69], [70]. Kluczowe funkcje w tym zakresie obejmują:

1. **Przydzielanie zadań operacyjnych** - alokacja zadań do dostępnych robotów, biorąc pod uwagę ich lokalizację, aktualne obciążenie, poziom energii, zdolności transportowe oraz typ misji [69], [71].

2. **Planowanie i optymalizacja tras** - wyznaczanie optymalnych ścieżek przejazdu na podstawie aktualnej mapy i położenia robotów, z uwzględnieniem minimalizacji czasu realizacji, unikania kolizji oraz równoważenia obciążenia floty [69], [72], [73].
3. **Zarządzanie konfliktami ruchu** - identyfikacja potencjalnych kolizji i przecięć tras, wdrażanie mechanizmów priorytetyzacji, omijania przeszkód oraz tymczasowego wstrzymywania jednostek w celu zapewnienia płynności ruchu [68], [69], [74].
4. **Monitorowanie stanu robotów w czasie rzeczywistym** - bieżące śledzenie pozycji, statusu realizacji zadań, przebytego dystansu, czasu operacji, poziomu naładowania akumulatora oraz sygnalizowanych błędów systemowych [42], [69], [71], [75].
5. **Zarządzanie procesem ładowania** - planowanie dostępu do stacji ładowania oraz koordynacja procesu ładowania jednostek w oparciu o aktualny poziom naładowania akumulatora, dostępność ładowarek oraz priorytet przypisany zadaniu lub jednostce [42], [72], [76].
6. **Reagowanie na anomalie i awarie** - detekcja nieprawidłowości w pracy jednostek (np. zakleszczenia, przekroczenia minimalnego poziomu naładowania) oraz inicjowanie działań naprawczych, takich jak przekazanie zadania innej jednostce lub wygenerowanie alertu [69], [72].
7. **Zbieranie danych eksploatacyjnych** - rejestrowanie danych historycznych dotyczących realizowanych zadań i stanu technicznego robotów na potrzeby diagnostyki, optymalizacji operacyjnej oraz utrzymania predykcyjnego [69], [70], [72].

Pomimo jasno zdefiniowanych funkcji systemów zarządzania flotą (FMS), stopień ich realizacji w dostępnych rozwiązaniach komercyjnych pozostaje zróżnicowany. O ile architektura FMS zakłada szereg mechanizmów wspierających zarządzanie zadaniami, monitorowanie stanu jednostek i optymalizację pracy floty, o tyle ich implementacja w praktyce nie zawsze nadąża za wymaganiami stawianymi przez dynamicznie rozwijające się środowiska intralogistyczne [69], [70]. **W związku z tym zasadna jest analiza wybranych systemów FMS pod kątem ich gotowości do wspierania elastycznego zarządzania flotą robotów mobilnych AMR, zgodnego z aktualnymi wymaganiami rynkowymi oraz założeniami Przemysłu 4.0.**

Celem porównania jest ocena, w jakim stopniu dostępne na rynku systemy zarządzania flotą robotów mobilnych wspierają efektywne i elastyczne zarządzanie flotami w kontekście aktualnych wymagań przemysłu, w tym integracji technologii Przemysłu 4.0. Zestawienie obejmuje zarówno rozwiązania dedykowane, opracowywane przez producentów konkretnych robotów, jak i systemy otwarte, umożliwiające zarządzanie flotami heterogenicznymi, składającymi się z robotów różnych typów i producentów. Porównanie skoncentrowane jest na ocenie zdolności systemów FMS do utrzymania floty w dobrym stanie technicznym. Uwzględniono kluczowe funkcje operacyjne, takie jak planowanie zadań, monitorowanie parametrów robota, organizacja procesu ładowania oraz integracja z nadrzędnymi systemami zarządzania. Szczególny nacisk kładziony jest na funkcjonalności umożliwiające monitorowanie i predykcję przyszłych stanów kondycji technicznej robota oraz analizę wykonalności misji w kontekście dostępnych zasobów energetycznych. Poniżej (Tabela 3) przedstawiono autorskie opracowanie, przegląd wybranych komercyjnych systemów zarządzania misją robotów mobilnych w kontekście konkretnych wymagań operacyjnych. Zestawienie uwzględnia:

- **Wersja systemu** - odnosi się do konkretnej edycji oprogramowania, aktualnej na moment opracowania niniejszej pracy, wskazanej w celu porównania dostępności lub braku wybranych funkcjonalności.

- **Integracja z robotami różnych producentów** - określa zdolność systemu do obsługi robotów różnych producentów, umożliwiając zarządzanie heterogeniczną flotą w ramach jednej platformy.
- **Integracja z ERP/MES/WMS** - określa możliwość integracji z systemami nadrzędnymi (MES, WMS, ERP) poprzez bezpośrednią wymianę danych za pomocą interfejsu programowania aplikacji (*ang. Application Programming Interface, API*) lub standardów komunikacyjnych, takich jak MQTT (*ang. Message Queuing Telemetry Transport*) lub OPC-UA (*ang. Open Platform Communications Unified Architecture*).
- **Możliwość wdrażania własnych zaawansowanych skryptów (np. AI)** - ocenia możliwość integracji własnych algorytmów sterowania, diagnostyki i predykcji, w tym wsparcie dla implementacji w językach wysokiego poziomu oraz zastosowania AI/ML i algorytmów optymalizacyjnych w celu zwiększenia efektywności operacyjnej i niezawodności floty.
- **Ocena wykonalności misji w kolejce** - odnosi się do mechanizmów oceny czy robot może wykonać wszystkie przydzielone i zakolejkowane zadania z uwzględnieniem dostępnych zasobów oraz ograniczeń operacyjnych.
- **Diagnostyka podzespołów** - obejmuje monitorowanie kondycji technicznej robotów poprzez analizę parametrów takich jak temperatura silników, zużycie komponentów i stany awaryjne, umożliwiając bieżącą ocenę stanu floty oraz identyfikację potrzeb serwisowych.
- **Utrzymanie predykcyjne i planowanie serwisów** - ocenia możliwość analizy danych historycznych i trendów w celu predykcji awarii oraz automatycznego planowania działań konserwacyjnych.
- **Monitorowanie stanu naładowania akumulatora** - odnosi się do dostępności informacji o stanie naładowania akumulatora w interfejsie FMS i przez API, obejmując odczyt poziomu naładowania, historii ładowania oraz tempa zużycia energii w celu oceny dostępności operacyjnej robotów.
- **Algorytm wyznaczania momentu ładowania** - określa sposób podejmowania decyzji o rozpoczęciu ładowania, w tym stosowanie progów naładowania lub zaawansowanych modeli uwzględniających bieżące i przyszłe zadania oraz predykcję zużycia energii w celu optymalizacji cyklu ładowania i minimalizacji przestoju.
- **Optymalizacja kolejności i momentu ładowania** - odnosi się do sposobu zarządzania kolejnością i momentem ładowania wielu robotów, z uwzględnieniem tego, czy decyzje opierają się na prostych progach naładowania, czy na algorytmach predykcyjnych uwzględniających przyszłe zadania, harmonogram misji, odległość od stacji oraz obciążenie transportowe.

W tabeli przyjęto następującą konwencję oznaczeń:

- **„-” (czerwony)**: brak funkcjonalności w danym systemie,
- **„✓” (zielony)**: funkcjonalność dostępna natywnie (*ang. out-of-the-box*),
- **opis + (pomarańczowy)**: funkcjonalność dostępna w ograniczonym zakresie lub możliwa do samodzielnego wdrożenia.

Tabela 3 Porównanie wybranych komercyjnych systemów FMS w kontekście integracji z systemami nadrzędnymi, koordynacji pracy floty oraz metod zarządzania energią robotów mobilnych. Opracowanie własne.

FMS	Wersja systemu	Integracja z robotami różnych producentów	Integracja z ERP/MES/WMS	Możliwość wdrażania własnych zaawansowanych skryptów (np. AI)	Ocena wykonalności misji w kolejce	Diagnostyka podzespołów	Utrzymywanie predykcje i planowanie serwisów	Monitorowanie stanu naładowania akumulatora	Algorytm wyznaczania momentu ładowania	Optymalizacja kolejności i momentu ładowania
MiR Fleet Enterprise [77], [78]	1.1.4	-	✓	-	-	✓	-	✓	Wartość progowa	Wg. akt. stanu akum.
Kuka.AMR Fleet [79], [80]	2.11	-	✓	ograniczone (np. Python)	-	✓	-	✓	Wartość progowa	Wg. akt. stanu akum.
Omron Fleet Manager [81], [82]	FLOW 3.0	-	✓	ograniczone (proste algorytmy)	-	✓	-	✓	Wartość progowa	Wg. akt. stanu akum.
Agilox FMS [83], [84], [85]	3.2	-	✓	-	-	✓	-	✓	Wartość progowa	Wg. akt. stanu akum.
Orbit (Boston Dynamics) [86]	4..1.1	-	✓	-	-	✓	-	✓	-	-
Formant [87]	07.2025	✓	✓	ograniczone (np. Python)	-	Ograniczone (zależne od robota)	Samodzielne wdrożenie (np. Python)	✓	-	-
InOrbit [88], [89]	07.2025	✓	✓	ograniczone (np. Python)	-	Ograniczone (zależne od robota)	nie	✓	-	-
ANT Server (BlueBotics) [90]	07.2025	✓	✓	-	-	-	-	✓	Wartość progowa	Wg. akt. stanu akum.
Robotics Middleware Framework [91], [92]	ROS2 Jazzy Jalisco	✓	✓	Samodzielne wdrożenie (np. Python)	Samodzielne wdrożenie (np. Python)	Ograniczone (zależne od robota)	Samodzielne wdrożenie (np. Python)	✓	Samodzielne wdrożenie (np. Python)	Samodzielne wdrożenie (np. Python)

Analiza porównawcza systemów (Tabela 3) wykazała brak wdrożeń zaawansowanych mechanizmów decyzyjnych, takich jak ocena wykonalności misji w kolejce oraz optymalizacja kolejności i momentu ładowania. Zastosowane rozwiązania najczęściej opierają się na prostych progach stanu naładowania akumulatora. Integracja systemów ogranicza się głównie do podstawowej współpracy z ERP/MES/WMS, a obsługa flot heterogenicznych nie jest standardowo zapewniana. Warto jednak podkreślić, że porównywane systemy FMS monitorują aktualny poziom naładowania akumulatora w robotach AMR, a część systemów umożliwia rozszerzanie funkcjonalności poprzez dodatkowe moduły lub implementację własnych skryptów.

Wnioski te znajdują potwierdzenie w literaturze naukowej. Jak wskazują [69], [93], [94], większość komercyjnych platform flotowych koncentruje się na podstawowej koordynacji ruchu, marginalizując kwestie predykcji zużycia energii, utrzymania prewencyjnego czy adaptacyjnego sterowania opartego na sztucznej inteligencji. Zamiast wykorzystywać zaawansowane modele oparte na analizie dużych zbiorów danych (*ang. Big Data*), danych historycznych czy algorytmach uczenia maszynowego, dostępne systemy stosują najczęściej deterministyczne, uproszczone algorytmy oparte na prostych regułach progowych [12], [38], [73], [95]. Tymczasem zastosowanie bardziej zaawansowanych metod analitycznych umożliwiłoby istotny wzrost efektywności operacyjnej przedsiębiorstw, umożliwiając systemom wyższego poziomu (ERP, MES) dynamiczną rekonfigurację harmonogramów produkcyjnych oraz logistycznych, uwzględniając bieżący i przewidywany stan robotów, potencjalne przeszkody czy zmienne zapotrzebowanie energetyczne [12], [96].

Na podstawie przeprowadzonej analizy porównawczej systemów FMS ([78] - [92], Tabela 3)

oraz przeglądu literatury [12], [42], [69], [73], [74], [93] - [101] wyróżniono trzy główne obszary funkcjonalne, w których zidentyfikowane luki systemów FMS znacząco ograniczają możliwość pełnego wykorzystania potencjału robotów mobilnych:

- 1. Ograniczona otwartość i elastyczność funkcjonalna systemów FMS** - Analiza komercyjnych systemów zarządzania flotą robotów mobilnych [78] - [92] wskazuje, że obecne rozwiązania charakteryzują się ograniczoną interoperacyjnością w kontekście heterogenicznych flot robotów mobilnych oraz w większości przypadków ograniczoną możliwością wdrażania własnych, zaawansowanych funkcji zarządczych i predykcyjnych wykorzystujących techniki uczenia maszynowego (ML) lub sztucznej inteligencji (AI). W literaturze naukowej podkreśla się tymczasem, że metody uczenia maszynowego mają istotny potencjał, by znacząco zwiększyć efektywność zarządzania flotą robotów AMR, zapewniając dynamiczną adaptację i inteligentne podejmowanie decyzji [12], [69], [95]. Systemy dedykowane konkretnym producentom ([77], [78] - [86]) oferują pełną integrację jedynie w obrębie własnych urządzeń, co skutecznie uniemożliwia wdrożenie flot heterogenicznych. Z kolei platformy otwarte ([87] - [92]), umożliwiające obsługę robotów różnych producentów, najczęściej oferują jedynie podstawowe funkcje koordynacji i diagnostyki, ograniczone ze względu na technologiczne różnice pomiędzy poszczególnymi modelami robotów. Tylko nieliczne dostępne na rynku rozwiązania, bazujące na środowisku Robotics Middleware Framework (np. ROS), umożliwiają integrację autorskich algorytmów diagnostycznych i sterujących. Jednak wdrożenie takich rozwiązań wymaga od użytkownika zaawansowanych kompetencji programistycznych oraz eksperckiej wiedzy technicznej [71]. W konsekwencji przedsiębiorstwa tracą możliwość elastycznego dostosowania systemów flotowych do własnych specyficznych potrzeb operacyjnych, gdyż są ograniczone do stosowania wyłącznie predefiniowanych funkcji dostarczanych przez producentów. Brak możliwości implementacji własnych rozwiązań diagnostycznych, optymalizacyjnych i predykcyjnych powoduje, że przedsiębiorstwa nie mogą w pełni wykorzystać potencjału swoich flot robotów mobilnych, co istotnie ogranicza efektywność operacyjną i utrudnia realizację założeń Przemysłu 4.0 dotyczących elastyczności i skalowalności robotycznych [69].

- 2. Brak weryfikacji wykonalności zakolejkowanych misji** - Efektywne zarządzanie flotą robotów mobilnych wymaga nie tylko bieżącej alokacji zadań, lecz także ich uprzedniej oceny pod kątem wykonalności. Kluczowym ograniczeniem w tym zakresie jest czas działania robota na jednym ładowaniu, który jest warunkowany pojemnością akumulatora oraz zapotrzebowaniem energetycznym jednostki [95], [96], [97]. Ograniczenia wynikające z maksymalnej ładowności czy zastosowania dodatkowego wyposażenia (np. podnośników, przyczep transportowych lub robotów współpracujących) mogą dodatkowo skracać efektywny czas działania i zwiększać częstotliwość ładowania, co wymusza zwiększenie liczby robotów w systemie [98]. Obecnie stosowane systemy FMS nie posiadają mechanizmów predykcyjnych zdolnych do oceny, czy przypisany robot będzie w stanie zrealizować całą sekwencję zadań z uwzględnieniem jego aktualnego stanu energetycznego, długości trasy, masy ładunku i warunków środowiskowych [93], [95], [97], [99]. Zamiast tego, dominującym podejściem jest proste reagowanie na osiągnięcie progowego poziomu naładowania akumulatora (najczęściej 10-20%), po którym robot zostaje automatycznie przekierowany do ładowania, a jego zadania przeniesione na inne jednostki [78] - [92], [98].

Podstawowym wyzwaniem w eksploatacji AMR jest ograniczona pojemność akumulatora oraz czas potrzebny na jego uzupełnienie [14]. Przykładowo, w modelu KUKA KMP 1500 czas pracy na jednym ładowaniu wynosi około 4 godzin, przy czym uzupełnienie energii do 80% trwa ~1 godzinę, co przekłada się na stosunek ładowania do pracy rzędu 1:4 [100]. W warunkach produkcyjnych oznacza to, że robot realnie dostępny jest przez maksymalnie 80% czasu, nie licząc opóźnień związanych z kolejkami do ładowarek i przestojami technicznymi [42], [100], [101]. Na potrzeby niniejszej analizy opracowano zestawienie porównawcze (Tabela 4) czasu pracy i ładowania wybranych modeli AMR.

Tabela 4 Porównanie czasu pracy i ładowania dla różnych robotów AMR. Opracowanie własne

AMR	Czas pracy na pełnym naładowaniu	Czas ładowania 20-80%
MiR100 [78], [102]	~10 godzin	~2 godziny (0-80% nał.)
KUKA KMP 1500 [100]	~4 godziny	~1 godzina
OMRON MD-650 [103]	~8 godzin	~19,6 minuty
OMRON MD-900 [103]	~7,5 godziny	~19,6 minuty
AGILOX ONE [104]	~1 godzina	~3 minuty
Star-L Hansrobot [101]	~8 godzin	~2 godziny

Warto podkreślić, że większość obecnych systemów FMS całkowicie pomija czynniki wpływające na rzeczywiste zużycie energii, takie jak typ zadania, masa ładunku, degradacja ogniw i warunki środowiskowe (np. temperatura otoczenia). Takie uproszczone podejście choć łatwe do implementacji uniemożliwia zaawansowane harmonogramowanie zadań oraz integrację z nadrzędnymi systemami klasy ERP, MES czy WMS [73], [95].

W konsekwencji przedsiębiorstwa często podejmują decyzję o rozbudowie floty ponad rzeczywiste potrzeby, aby uniknąć przestojów wynikających z niespodziewanych przerw w dostępności robotów [9], [76]. Taka strategia prowadzi do wzrostu kosztów inwestycyjnych, obniżenia wskaźnika całkowitej efektywności wyposażenia (*ang. Overall Equipment Effectiveness*, OEE) oraz wydłużenia czasu zwrotu z inwestycji (*ang. Return on Investment*, ROI) [96], [98].

Wdrożenie adaptacyjnych strategii predykcyjnych, opartych na danych historycznych i aktualnych warunkach operacyjnych, umożliwiłoby dynamiczną ocenę wykonalności misji jeszcze przed jej przydzieleniem. Takie podejście pozwoliłoby ograniczyć liczbę jednostek w

systemie, zwiększyć ich dostępność oraz zintegrować planowanie z nadrzędnymi warstwami zarządzania produkcją i logistyką [12], [96]. W literaturze podkreśla się, że przewidywane zużycie energii, detekcja przeszkód oraz ocena stanu technicznego robotów mogłyby być wykorzystywane do bieżącej rekonfiguracji harmonogramów, co przełożyłoby się na zwiększenie efektywności operacyjnej całego przedsiębiorstwa [76].

- 3. Uproszczone podejście do zarządzania procesem ładowania** - Kolejną istotną luką funkcjonalną systemów FMS, ściśle powiązaną z brakiem predykcyjnej weryfikacji wykonalności misji, jest uproszczony sposób zarządzania ładowaniem robotów mobilnych. Pomimo postępującej automatyzacji i dynamicznego rozwoju branży AI, decyzje o ładowaniu wciąż podejmowane są w oparciu o statyczne progi naładowania, zazwyczaj ustawione na poziomie 10-20% [42]. W momencie ich osiągnięcia robot jest automatycznie wycofywany z realizacji zadań i kierowany do ładowania. Tradycyjne podejście nie uwzględnia rzeczywistego obciążenia systemu, harmonogramu produkcyjnego ani przewidywanego zapotrzebowania energetycznego. Decyzje o rozpoczęciu ładowania podejmowane są wyłącznie na podstawie bieżącego poziomu naładowania akumulatora, bez odniesienia do kontekstu operacyjnego i planowanych zadań [42]. W efekcie nie ma możliwości przewidzenia, ile robotów mobilnych będzie wymagało ładowania w jednym momencie. Utrudnia to zapewnienie ciągłości pracy systemu, szczególnie w środowiskach wielozmianowych lub o dużym zagęszczeniu zadań. W miejscach intensywnej współpracy wielu robotów (np. w strefach dokowania) prowadzi to do tzw. konfliktów dostępowych (*ang. dock grid conflict*), czyli sytuacji, w których kilka jednostek jednocześnie oczekuje na dostęp do ograniczonej liczby stanowisk ładowania [12], [74].

W konsekwencji, aby uniknąć zakłóceń i przestojów, przedsiębiorstwa są zmuszone do utrzymywania większej liczby robotów i / lub ładowarek, niż wynikałoby to z faktycznego zapotrzebowania. Ma to ponownie bezpośredni wpływ na zwiększenie kosztów inwestycyjnych oraz pogorszenie wskaźników efektywności systemu, takich jak OEE i ROI [76], [96], [98].

Na podstawie powyższej analizy można jednoznacznie stwierdzić, że istniejące systemy FMS, mimo swojej roli jako nadrzędnych koordynatorów floty robotów mobilnych, nie zapewniają wystarczającej funkcjonalności w zakresie predykcyjnego zarządzania zadaniami AMR [58], [73]. Autonomia pojedynczych robotów nie wystarcza w środowisku współdzielonym, skuteczne zarządzanie flotą i jej integracja z systemami produkcyjnymi wymaga zastosowania FMS, które integrują zarządzanie robotami z systemami wyższego poziomu (ERP, MES, WMS). W praktyce jednak komercyjne FMS bazują na uproszczonych algorytmach zarządzania zadaniami, co ogranicza możliwość planowania zadań z wyprzedzeniem, oceny wykonalności misji oraz optymalizacji procesu ładowania. Zidentyfikowane luki, takie jak brak weryfikacji zakolejkowanych misji, zarządzanie ładowaniem wyłącznie na podstawie progów naładowania oraz brak planowania momentu ładowania, przekładają się na spadek efektywności operacyjnej. W efekcie firmy zmuszone są do przewymiarowania flot i infrastruktury, co zwiększa koszty inwestycyjne.

Wdrożenie predykcyjnych modeli zużycia energii stanowi naturalną odpowiedź na zidentyfikowane ograniczenia systemów FMS. Modele tego typu, uwzględniające dane historyczne i parametry misji, umożliwiają oszacowanie zapotrzebowania energetycznego już na etapie planowania zadań. Integracja takich narzędzi z systemem zarządzania flotą pozwala na weryfikację wykonalności misji, optymalizację momentu ładowania oraz redukcję przestojów i liczby wymaganych jednostek. Pomimo potencjalnych korzyści, funkcjonalność predykcyjna pozostaje w komercyjnych systemach FMS marginalna lub całkowicie nieobecna. Obserwowana luka technologiczna uzasadnia konieczność przeprowadzenia analizy literaturowej w zakresie dostępnych modeli predykcyjnych, ich parametrów wejściowych oraz dokładności działania w różnych scenariuszach operacyjnych.

1.4 Źródła zasilania robotów mobilnych


Efektywne zarządzanie flotą robotów mobilnych wymaga nie tylko integracji systemów informatycznych, koordynacji zadań i planowania tras, ale również precyzyjnej kontroli nad stanem energetycznym poszczególnych jednostek. W tym kontekście istotną rolę odgrywa charakterystyka źródeł zasilania, które determinują zarówno zdolność robota do realizacji misji, jak i ogólną dostępność floty.

Parametry akumulatora oraz ich stan eksploatacyjny stanowią jeden z kluczowych czynników wpływających na wielkość floty oraz jej zdolność operacyjną. Szczególnie istotne są poziom naładowania (*ang. State of Charge - SoC*) oraz stopień zużycia ogniw (*ang. State of Health - SoH*), które wpływają na moment konieczności ładowania oraz planowanie rezerw jednostek. Utrzymywanie poziomu SoC w bezpiecznym zakresie, np. pomiędzy 20% a 80%, pozwala ograniczyć degradację akumulatorów i wydłużyć ich żywotność [76]. Niewłaściwe strategie ładowania, obejmujące zbyt częste lub zbyt szybkie ładowania, skutkują stopniowym spadkiem pojemności ogniw i wymuszają zwiększenie liczebności floty, aby zrekompensować czasowe przestoje jednostek [76], [96].

Charakterystyka źródeł zasilania robotów mobilnych AMR stanowi więc nieodłączny element kontekstu systemów FMS, wpływa bezpośrednio na dostępność robotów, możliwość realizacji zadań oraz koszty operacyjne. Z tego względu, ten podrozdział poświęcono szczegółowemu omówieniu technologii zasilania oraz parametrów eksploatacyjnych akumulatorów stosowanych w robotach mobilnych. W kolejnych rozdziałach (4, 5, 6) informacje te zostaną wykorzystane do identyfikacji zmiennych wpływających na zużycie energii oraz do budowy predykcyjnych modeli stanu energetycznego jednostek mobilnych.


Systemy zasilania autonomicznych robotów mobilnych opierają się głównie na akumulatorach litowo-jonowych, które oferują korzystny stosunek gęstości energii do masy oraz charakteryzują się wysoką trwałością cykliczną. Wybór odpowiedniego rodzaju ogniw, jak również sposób zarządzania zasobami energetycznymi, mają bezpośredni wpływ na zasięg operacyjny robota, czas jego pracy pomiędzy cyklami ładowania. Precyzyjne monitorowanie oraz kontrola kluczowych parametrów pracy akumulatora, w szczególności stanu naładowania (SOC), są istotne nie tylko z punktu widzenia niezawodności działania, lecz również dla optymalizacji zużycia energii i efektywnego planowania zadań [60]. Za szacowanie SOC odpowiada system zarządzania akumulatorem (*ang. Battery Control Module, BCM*), który może wykorzystywać różne metody estymacyjne, takie jak metoda coulombometryczna, pomiar napięcia spoczynkowego (*ang. Open Circuit Voltage, OCV*), estymatory stanu (np. filtry Kalmana), modele elektrochemiczne lub podejścia hybrydowe [105], [106], [107]. Każda z tych metod cechuje się określonymi ograniczeniami zarówno pod względem dokładności, jak i wrażliwości na temperaturę, starzenie ogniwa i warunki dynamiczne. W szczególności zależność pomiędzy napięciem obwodu otwartego OVC a SOC jest istotnym obszarem badań, który umożliwia budowę nienaruszającego struktury ogniwa modelu diagnostycznego.

W zakresie stanu naładowania (SOC) od około 20% do 80% zależność napięcia celi akumulatora litowo-jonowego od SOC ma w przybliżeniu liniowy przebieg (Rys. 11). Zakres ten jest powszechnie zalecany przez producentów jako optymalny dla codziennej eksploatacji, ze względu na korzystny kompromis między dostępnością energii a ograniczaniem procesów degradacyjnych [76].



Rys. 11 Zależność pomiędzy napięciem ogniwa (OCV) a stanem naładowania (SOC) akumulatora litowo-jonowego. Źródło: [108]

Dalsze ograniczenie zakresu pracy stanu naładowania (SOC) poniżej standardowo zalecanego przedziału 20-80% może dodatkowo przyczynić się do wydłużenia trwałości akumulatora. Takie podejście pozwala również spowolnić proces degradacji pojemności (Rys. 12), co zostało potwierdzone w badaniach, m.in. w pracy [107].



Rys. 12 Wpływ zakresu stanu naładowania (SOC) na degradację akumulatora litowo-jonowego w funkcji liczby cykli pracy. Źródło: [107]

Akumulatory litowo-jonowe stanowią szeroką klasę chemicznych źródeł energii, w której wspólną cechą jest wykorzystywanie litu jako nośnika ładunku elektrycznego. W ramach tej grupy wyróżnia się różne typy ogniw, różniące się przede wszystkim składem materiałów katodowych i anodowych. Do najczęściej stosowanych należą ogniwa:

- litowo-żelazowo-fosforanowe (LiFePO_4 , LFP),
- litowo-niklowo-manganowo-kobaltowe (LiNiMnCoO_2 , NMC),


- litowo-niklowo-kobaltowo-aluminiowe (LiNiCoAlO_2 , NCA),
- litowo-manganowe (LiMn_2O_4 , LMO),
- litowo-kobaltowe (LiCoO_2 , LCO).

Każdy z tych typów charakteryzuje się odmiennymi właściwościami użytkowymi, takimi jak gęstość energii, trwałość cykliczna, zakres temperatury pracy, stabilność termiczna i odporność na przeciążenia. W rezultacie, ich charakterystyki napięciowo-pojemnościowe (OCV-SOC) oraz podatność na degradację mogą istotnie się różnić [97], [109].

Mobilny robot autonomiczny MiR100 wykorzystywany w niniejszej pracy został wyposażony w zintegrowany system zasilania oparty na akumulatorze litowo-jonowym typu NMC. Zastosowana jednostka magazynująca energię charakteryzuje się napięciem nominalnym 24 V oraz pojemnością 39,6 Ah. Producent deklaruje wysoką trwałością cykliczną (ponad 1 000 cykli ładowania przy zachowaniu $\geq 80\%$ pojemności akumulatora) [102].


Akumulatory litowo-jonowe typu NMC łączą w sobie kluczowe zalety trzech pierwiastków: niklu (wysoka gęstość energii), manganu (stabilność strukturalna) oraz kobaltu (dobra przewodność elektronowa) [109]. W porównaniu do innych typów ogniw litowo-jonowych, takich jak LFP lub LCO akumulatory NMC oferują wyższy współczynnik gęstości energii (zarówno objętościowej, jak i masowej), co umożliwia konstruowanie lżejszych i bardziej kompaktowych układów zasilania przy zachowaniu porównywalnej pojemności energetycznej [97]. W porównaniu z LFP, ogniwa NMC zapewniają większy zasięg operacyjny (dłuższy czas pracy między cyklami ładowania) oraz mniejsze wymiary przy tej samej pojemności, co ma szczególne znaczenie w aplikacjach mobilnych, takich jak roboty autonomiczne [97].

W publikacjach oraz w dokumentacji technicznej producentów ogniw **litowo-jonowych typu NMC** (LiNiMnCoO_2) wykazano, że zależność napięcia otwartego obwodu (OCV) od stanu naładowania (SoC) charakteryzuje się nieliniowym przebiegiem. Krzywa ta ma łagodnie zakrzywiony kształt, przy czym szczególnie dynamiczne zmiany napięcia obserwuje się w początkowym (0-20% SoC) oraz końcowym (90-100% SoC) zakresie naładowania. W środkowym przedziale (20-90% SoC) krzywa staje się bardziej płaska, jednak nadal zachowuje nieliniowy charakter i jest aproksymowana w pracach [105], [106] za pomocą funkcji wielomianowych, wielomianowo-logarytmicznych i innych modeli matematycznych. Zastosowane przybliżenia prowadzą do błędu modelowania względem rzeczywistej charakterystyki pomiarowej - Rys. 13.



Rys. 13 Porównanie trzech modeli napięcia obwodu otwartego (OCV) dla ogniwa NMC względem stanu naładowania (SoC): (a) model wielomianowy, (b) wielomianowo-logarytmiczny, (c) wykładniczo-liniowy. Przedstawiono dopasowanie do danych eksperymentalnych oraz błędy aproksymacji. Źródło: [105]

Warto również podkreślić, że temperatura akumulatora zależna zarówno od warunków zewnętrznych, jak i od intensywności pracy systemu ma istotny wpływ na wartość SoC oraz na rzeczywiste zużycie energii. Charakterystyka napięciowa ogniwa, na podstawie której system zarządzania baterią (BMS) szacuje wartość SoC, ulega zmianie wraz z temperaturą roboczą akumulatora (Rys. 14), co może prowadzić do błędów estymacji poziomu naładowania, zwłaszcza w warunkach skrajnych. Ponadto temperatura wpływa na wewnętrzne parametry akumulatora, takie jak opór wewnętrzny i pojemność efektywna, co bezpośrednio przekłada się na zmienność zużycia energii w trakcie realizacji misji.



Rys. 14 Akumulator Litowy NMC- charakterystyka OCV - SoC w różnych temperaturach. Źródło: [110]

Nieliniowa zależność pomiędzy napięciem obwodu otwartego (OCV) a stanem naładowania akumulatora (SoC), szczególnie wyraźna w ogniwach typu NMC, stanowi wyzwanie dla systemów


zarządzania baterią (BCM), które wykorzystują funkcje aproksymujące OCV-SoC do estymacji poziomu energii. W efekcie, nawet przy identycznym zużyciu energii, robot mobilny może wykazywać różny spadek SoC w zależności od początkowego stanu naładowania lub warunków pracy [105], [106], [111]. Błędy wynikające z uproszczeń przyjętych w modelu estymacyjnym mogą prowadzić do zawyżonych lub zaniżonych wskazań zużycia, co wyklucza możliwość traktowania procentowego spadku SoC jako stałego i liniowego wskaźnika zużycia energii do predykcji wykonalności zakolejkowanych misji. Co istotne, użytkownik końcowy nie ma zazwyczaj dostępu do informacji o metodzie estymacji SOC zastosowanej przez producenta, ponieważ szczegóły algorytmu BMS pozostają niedostępne w dokumentacji technicznej. W takich warunkach konieczne staje się stosowanie bardziej zaawansowanych, modeli zużycia energii uwzględniających zarówno charakterystyki misji, jak i ograniczenia systemu estymacji. Tylko takie podejście umożliwia rzetelną predykcję zużycia energii i racjonalne planowanie zadań w środowisku zrobotyzowanym.

2 Predykcyjne metody szacowania zużycia energii w oparciu o parametry misji robota

Rozdział przedstawia przegląd metod predykcyjnych stosowanych do szacowania zużycia energii przez autonomiczne roboty mobilne. Uwzględniono zarówno podejścia oparte na jawnych zależnościach fizyczno-mechanicznych, jak i metody wykorzystujące dane operacyjne z zastosowaniem technik uczenia maszynowego oraz modele hybrydowe. Omówiono charakterystykę każdej grupy metod, ich wymagania obliczeniowe oraz warunki, w których osiągają najlepsze rezultaty. Rozdział kończy porównanie efektywności poszczególnych podejść w kontekście zastosowań przemysłowych.

Efektywne zarządzanie energią w robotach mobilnych staje się jednym z kluczowych wyzwań we współczesnej robotyce, zarówno z perspektywy technicznej, środowiskowej jak i optymalizacji zarządzania zasobami. Rosnące wymagania co do autonomii, niezawodności i optymalizacji operacyjnej powodują, że zagadnienia związane z metodami zasilania, strategią zużycia energii, momentu ładowania oraz zarządzania zadaniami dla całej floty AMR nabierają szczególnego znaczenia. W poprzednim rozdziale oraz w analizowanej w kolejnych podrozdziałach literaturze podkreślano, że zagadnienia związane z efektywnością energetyczną robotów mobilnych należą do obszarów intensywnie rozwijanych zarówno w środowisku akademickim, jak i przemysłowym. Ich aktualność wynika nie tylko z postępującej autonomizacji systemów robotycznych, lecz również z rosnącego nacisku na zrównoważony rozwój i efektywność energetyczną. Współczesne badania w tym obszarze znajdują się na styku nauki i praktyki inżynierskiej, co czyni tę dziedzinę szczególnie atrakcyjną i perspektywiczną dla przyszłych prac badawczo-rozwojowych.

W odpowiedzi na rosnące znaczenie efektywności energetycznej w zastosowaniach przemysłowych i naukowych, w pracy [60] przeprowadzono systematyczny przegląd literatury z ostatniej dekady (Rys. 15), obejmujący 244 artykuły naukowe dotyczące zagadnień związanych z optymalizacją energii, zarządzaniem naładowaniem akumulatora oraz modelowaniem zużycia energii przez autonomiczne roboty mobilne. Przegląd ten pozwolił na identyfikację aktualnych obszarów badawczych, a także na wskazanie luk w aktualnym stanie wiedzy.



Rys. 15 Analiza kierunków badań dotyczących zarządzania energią w systemach zasilania robotów mobilnych.
Źródło: [60].


Analiza statystyczna wykazała, że największe zainteresowanie badawcze koncentruje się na zagadnieniach optymalizacji energetycznej (63,3%) oraz systemach zarządzania poziomem naładowania akumulatora i technologiach ładowania (17,9%). **Zaledwie 10,8% badanych prac podejmuje temat bezpośredniego modelowania zużycia energii przez roboty mobilne, co wskazuje na istotną niszę badawczą w tym zakresie [60].**

1. Modele zużycia energii identyfikowane w literaturze zostały podzielone na trzy główne kategorie (Rys. 16): **Modele fizyczno-strukturalne (44%)** - bazują na zasadach fizyki (np. dynamice ruchu, stratach mocy), uwzględniające parametry mechaniczne robota oraz czynniki środowiskowe, takie jak masa, opory ruchu czy nachylenie terenu.
2. **Modele oparte na danych wykorzystujące uczenie maszynowe (40%)** - wykorzystujące algorytmy uczenia maszynowego (np. regresje, lasy losowe, sieci neuronowe), trenujące modele predykcyjne na danych telemetrycznych, sensorowych i operacyjnych.
3. **Modele hybrydowe (16%)** - łączące elementy podejść fizycznych i danych, np. poprzez wykorzystanie wielkości fizycznych jako cech wejściowych do modeli uczenia maszynowego lub korektę modeli fizycznych komponentami trenowanymi na danych.



Rys. 16 Udział podejść: fizycznych, opartych na danych oraz hybrydowych w modelowaniu zużycia energii.
Źródło: [60].

W niniejszej pracy rozwinęto tę klasyfikację o szczegółowy podział wewnętrzny, obejmujący konkretne podejścia modelowania spotykane w literaturze (Rys. 17). Tego rodzaju uszczegółowienie nie zostało dotąd przedstawione w istniejących publikacjach i stanowi autorską propozycję, opracowaną na podstawie analizy literatury omówionej w dalszej części rozdziału. Celem takiego podejścia jest uporządkowanie istniejących modeli predykcyjnych zużycia energii w sposób umożliwiający ich porównanie oraz ocenę potencjału wdrożeniowego w kontekście zastosowań przemysłowych.



Rys. 17 Klasyfikacja modeli predykcji zużycia energii w robotach mobilnych. Opracowanie własne
Zgodnie z analizą przedstawioną w pracy [60], predykcja zużycia energii w robotach mobilnych została jednoznacznie określona jako zadanie złożone, uwarunkowane wieloma czynnikami wpływającymi na

zużycie energii. W szczególności podkreślono znaczenie zarówno zmiennych wewnętrznych (takich jak masa, konfiguracja napędu, konstrukcja mechaniczna), jak i czynników zewnętrznych (np. warunki środowiskowe, rodzaj podłoża, obciążenie użytkowe, styl jazdy, a także zmienność misji). W efekcie, dokładność modeli predykcyjnych uzależniona jest nie tylko od jakości i zakresu dostępnych danych, ale także od kontekstu operacyjnego oraz charakterystyki scenariusza, w którym robot realizuje swoje zadania.

Autorzy pracy [93] zauważają, że większość dotychczasowych rozwiązań opiera się na fizycznych modelach analitycznych ściśle powiązanych z kinematyką konkretnego robota, co wymaga identyfikacji wielu parametrów i złożonej kalibracji. Wskazują oni jednak, że idealny algorytm predykcji energii powinien być zdolny do samo-adaptacji, dlatego preferują podejścia typu „czarna skrzynka” (black-box) oparte na uczeniu maszynowym zamiast czysto analitycznych modeli. Proponują również podejście hybrydowe, na przykład połączenie modelu wielomianowego (fizycznego) z automatycznym strojeniem parametrów, co pozwala wykorzystać zalety modeli fizycznych przy jednoczesnym zwiększeniu uniwersalności i ograniczeniu potrzeby manualnej kalibracji. Zwracają uwagę, że dotychczas niewiele prac związanych z AMR / AGV wykorzystywało metody AI/ML do predykcji zużycia energii, jednak dostępne wyniki pokazują duży potencjał adaptacyjności i wysokiej dokładności takich rozwiązań. W pracy wskazano również potrzebę opracowania zunifikowanego modelu predykcji zużycia energii dla różnych typów robotów [93].

W niniejszym rozdziale dokonano szczegółowego przeglądu istniejących podejść do predykcji zużycia energii w robotach mobilnych, skupiając się na trzech głównych grupach modeli: fizyczno-strukturalnych, opartych na danych i hybrydowych. Dodatkowo, w ramach tej pracy zestawiono i przeanalizowano wybrane publikacje pod kątem następujących kryteriów:

- **Rodzaj robota:** kołowy, gąsienicowy, z różnymi konfiguracjami napędu.
- **Warunki testowe:** laboratorium, środowisko rzeczywiste.
- **Zakres danych wejściowych:** prędkość, przyspieszenie, obciążenie, rodzaj podłoża, temperatura, nachylenie terenu itp.
- **Miary dokładności predykcji.**

Zestawienie wyników zostało przedstawione w formie tabelarycznej (Tabela 5 - Tabela 9), co pozwala na jednoznaczną identyfikację różnic pomiędzy podejściami oraz ich ograniczeń. Taka forma prezentacji ułatwia również dalsze odniesienie się do przedstawionych modeli w kolejnych podrozdziałach, gdzie szczegółowo omówione zostaną wybrane reprezentatywne modele dla każdej z trzech kategorii.

2.1 Modele zużycia energii oparte na opisie fizyczno-strukturalnym

Jednym z podejść do opisu zużycia energii przez roboty mobilne są **modele oparte na opisie fizyczno-strukturalnym** (*ang. Physics based*), określane często mianem modeli jawnych typu „biała skrzynka” (*ang. white-box models*) [60]. Ich wspólną cechą jest jawność struktury matematycznej oraz bezpośrednie oparcie na znanych i dobrze ugruntowanych zasadach fizyki, takich jak mechanika klasyczna, elektromechanika i zasady zachowania energii. W odróżnieniu od modeli uczonych na danych, modele oparte na opisie fizyczno-strukturalnym pozwalają na analityczne powiązanie parametrów konstrukcyjnych robota (np. masy, momentów bezwładności, charakterystyk silników) z przewidywanym zużyciem energii w określonych warunkach pracy.

Modele oparte na opisie fizyczno-strukturalnym mogą być formułowane na różne sposoby, w zależności od tego, które aspekty systemu robota mają zostać odwzorowane oraz jaki poziom uogólnienia jest akceptowalny w kontekście planowanej analizy. W zależności od przyjętego ujęcia, system może być modelowany jako lokalna dynamika komponentów, całosciowy bilans energetyczny, modularna struktura złożona z podukładów lub jako zbiór zmiennych stanu opisujących jego działanie w czasie. Poszczególne podejścia nie są rozłączne, mogą również występować równolegle w ramach jednego modelu lub są stosowane warstwowo. W praktyce oznacza to, że model może jednocześnie opisywać dynamikę ruchu, uwzględniać przepływy energii w całym układzie oraz rozdzielać analizę na poszczególne komponenty sprzętowe. Taka struktura umożliwia elastyczne dopasowanie modelu do specyfiki aplikacji oraz dostępnych danych i poziomu wiedzy domenowej.

Główną zaletą modeli fizyczno-strukturalnych jest ich interpretowalność, możliwe jest nie tylko przewidzenie wartości zużytej energii, ale również wskazanie konkretnych przyczyn strat: np. nadmiernego tarcia w układzie mechanicznym, nieefektywnej pracy silników lub obciążenia energetycznego elektroniki sterującej. Co więcej, w literaturze podkreśla się ponadto, że jawne modele oparte na opisie fizyczno-strukturalnym mogą być z powodzeniem implementowane w środowiskach symulacyjnych (np. Simulink, Simscape, Modelica, ROS Gazebo), a nawet stanowić podstawę do tworzenia tzw. cyfrowych bliźniaków (*ang. digital twins*, DT) robotów mobilnych [112], [113], [114], [115].

Poniżej opisano cztery podejścia spotykane w literaturze, stosowane w modelach zużycia energii dla robotów mobilnych, opartych na opisie fizyczno-strukturalnym, wraz z ich, zaletami i ograniczeniami.

Model dynamiczny zużycia energii oparty na równaniach ruchu

Modele dynamiczne stanowią jedno z klasycznych podejść do opisu zużycia energii w robotach mobilnych, w ramach grupy modeli opartych na opisie fizyczno-strukturalnym (*ang. physics-based*). Ich konstrukcja **opiera się na bezpośrednim wykorzystaniu równań ruchu wynikających z mechaniki klasycznej**, najczęściej formułowanych w postaci równań Newtona-Eulera lub metodą Lagrange’a [113], [116]. Zasadniczym celem tych modeli jest opis zależności między siłami i momentami działającymi na ciało robota a jego odpowiedzią dynamiczną, wyrażoną przez przyspieszenia liniowe i kątowe. W kontekście energetycznym oznacza to możliwość wyznaczenia mocy chwilowej i całkowitej energii zużytej do wykonania konkretnego manewru lub przemieszczenia. Podstawowym założeniem jest, że układ napędowy wykonuje pracę mechaniczną w celu pokonania sił bezwładności, oporów toczenia, tarcia i innych oddziaływań środowiskowych. Obliczona w ten sposób praca jest następnie przeliczana na moc dostarczaną z akumulatora, co pozwala na oszacowanie strat energetycznych w poszczególnych elementach układu [114]. Modele te mogą mieć postać relatywnie prostą ograniczoną do opisu translacyjnego ruchu masy po powierzchni (np. zależność między masą, prędkością i przebytą drogą) lub znacznie bardziej złożoną, uwzględniającą wszystkie główne źródła strat energii w robocie (w tym także efekty termiczne w silnikach oraz poślizg kół) [51], [112]

Zalety modeli dynamicznych:

- **Wysoka interpretowalność:** pozwalają na precyzyjną analizę źródeł strat energii i określenie udziału poszczególnych czynników, takich jak tarcie, bezwładność czy praca przeciwdziałająca siłom grawitacji [112].
- **Bezpośrednie powiązanie z parametrami konstrukcyjnymi:** modelowanie opiera się na rzeczywistych właściwościach robota, co ułatwia analizę przy zmianach projektowych [115].
- **Możliwość bilansowania energii:** uzyskane równania umożliwiają podział zużytej energii na część użyteczną i straty (mechaniczne, elektryczne, termiczne) [114], [115].
- **Zastosowanie w środowiskach symulacyjnych:** mogą być łatwo implementowane w narzędziach takich jak Simulink, Simscape, Modelica czy ROS Gazebo, a także stanowić podstawę dla cyfrowych bliźniaków [112], [115].

Model bilansowy zużycia energii

Modele bilansowe stanowią uproszczone, ale często bardzo użyteczne podejście do szacowania zużycia energii przez roboty mobilne. **Ich istotą jest zastosowanie zasad zachowania energii do oszacowania przepływów energetycznych w systemie.** W odróżnieniu od modeli dynamicznych, które skupiają się na szczegółowym odwzorowaniu sił i momentów działających na robota, modele bilansowe koncentrują się na całkowitych ilościach energii lub mocy, jakie są przekształcane i zużywane przez różne części układu w określonym czasie lub odcinku trasy [51], [117]. Podstawowym założeniem jest, że moc dostarczana do systemu (np. z akumulatora) jest dzielona na pracę użyteczną wykonywaną przez robota (np. pokonywanie oporów ruchu, podnoszenie ładunku, przyspieszanie), straty energii wynikające z nieidealności mechanicznych i elektrycznych (tarcie, opory w przekładniach, straty ciepłne w silnikach), pobór energii przez podsystemy pomocnicze (sterowanie, sensoryka, komunikacja) [118], [119]. Modele tego typu często korzystają z prostych zależności energetycznych, np. energii kinetycznej i potencjalnej, zsumowanej dla ruchu robota w zadanym czasie lub trasie. Całkowite zużycie energii szacuje się przez sumowanie nakładów energetycznych dla głównych zadań ruchowych oraz dla pracy podsystemów pokładowych [119].

Zalety modeli bilansowych:

- **Niska złożoność obliczeniowa:** dzięki wykorzystaniu uśrednionych wartości mocy lub energii, modele bilansowe są lekkie obliczeniowo i mogą być wykorzystywane w czasie rzeczywistym [118], [119].
- **Szybka implementacja:** wymagają relatywnie niewielkiej liczby parametrów wejściowych, często dostępnych z dokumentacji technicznej lub prostych pomiarów [51], [118].
- **Przejrzystość energetyczna:** pozwalają na oszacowanie całkowitej efektywności energetycznej robota oraz udziału różnych źródeł zużycia energii (ruch, obciążenie, elektronika, sterowanie) [117].

Model komponentowy (modularny) zużycia energii


Modele komponentowe stanowią podejście, w którym system robota mobilnego jest opisywany jako zbiór wzajemnie powiązanych podukładów, z których każdy odwzorowuje konkretne funkcje fizyczne, elektryczne lub obliczeniowe. W przeciwieństwie do modeli dynamicznych i bilansowych, które często traktują robota jako spójną całość, modele komponentowe **opierają się na dekompozycji funkcjonalnej, pozwalającej na niezależne modelowanie**, kalibrację i analizę poszczególnych części systemu [119].

Typowe komponenty wyodrębniane w takim modelu to:

- układ napędowy (silniki, przekładnie),

- układ przeniesienia napędu (koła, łożyska),
- układ sterowania i obliczeniowy (mikrokontrolery, komputery pokładowe),
- systemy sensoryczne (LIDAR, kamery, IMU),
- akcesoria i urządzenia wykonawcze (manipulatory, podnośniki),
- system zasilania (baterie, przetwornice).

Dla każdego z tych elementów dobierany jest odrębny model, może to być model fizyczny (np. dynamiczny dla silnika), statystyczny (np. regresja poboru mocy przez komputer), lub oparty na danych empirycznych (np. profil zużycia energii przez sensor w zależności od trybu pracy). Całościowy model zużycia energii powstaje przez agregację wyników cząstkowych, często z uwzględnieniem wzajemnych zależności między komponentami [113], [119]. Przykładowy fragment modelu komponentowego przedstawiono poniżej (Rys. 18).



Rys. 18 Model fragmentu robota mobilnego w formie grafu wiązań. Źródło: [113]

Takie podejście wspiera **modularność** i **skalowalność**, ponieważ pozwala łatwo dostosować strukturę modelu do konkretnego wariantu robota, aktualizować wybrane komponenty bez konieczności rekonstrukcji całego systemu, oraz identyfikować wpływ poszczególnych podukładów na ogólne zużycie energii [119].


Zalety modeli komponentowych:

- **Modularność i elastyczność:** możliwość łatwego dostosowania modelu do różnych konfiguracji sprzętowych oraz wymiany lub aktualizacji wybranych komponentów bez konieczności modyfikowania całej struktury [113].
- **Dopasowanie metod modelowania:** każdy komponent może być opisany za pomocą najbardziej adekwatnej metody - fizycznej, empirycznej lub analitycznej, co pozwala uwzględniać zarówno dokładne modele dynamiczne (np. silników), jak i uproszczone zależności energetyczne dla podsystemów cyfrowych [113], [120].
- **Łatwa rozbudowa i konserwacja modelu:** dodanie nowego komponentu (np. nowego czujnika) do modelu sprowadza się do uwzględnienia jego indywidualnego profilu energetycznego, bez konieczności przebudowy całego systemu [113], [121].

- **Praktyczność w kalibracji:** wiele komponentów można mierzyć i kalibrować niezależnie, co zwiększa efektywność procesu modelowania w warunkach rzeczywistych [113], [121].

Modele zużycia energii oparte na stanach (modele stanowe)

Modele oparte na stanach opisują system robota mobilnego jako zbiór zmiennych stanu, które reprezentują jego bieżące właściwości fizyczne, energetyczne lub funkcjonalne w czasie. Zmiennymi stanu mogą być zarówno klasyczne wielkości fizyczne, takie jak prędkość, przyspieszenie, pozycja, napięcie baterii, jak i wielkości logiczne lub dyskretne, np. tryb pracy systemu (jazda, postój, ładowanie, przetwarzanie danych). Kluczowym założeniem jest, że **zużycie energii zależy od bieżącego stanu robota i jego przejść pomiędzy stanami**, a nie tylko od ciągłych zmian parametrów fizycznych. Modelowanie tego typu opiera się na analizie dynamiki przejść między stanami oraz na przypisaniu zużycia energii do każdego ze stanów i/lub przejść. Na przykład, robot może mieć osobne profile poboru mocy w stanie jazdy po prostej, skrętu, bezruchu, przetwarzania sensorycznego czy transmisji danych. Stany mogą być definiowane na podstawie pomiarów, logiki operacyjnej lub schematów zadaniowych [122], [123]. Fragment modelu stanowego dla robota mobilnego przedstawiono poniżej (Rys. 19).



Rys. 19 Stanowy model zapotrzebowania energii w AGV. Źródło: [123]

Zalety modeli opartych na stanach:

- **Odwzorowanie rzeczywistego zachowania:** umożliwiają modelowanie typowych trybów pracy robota i ich wpływu na zużycie energii, z uwzględnieniem kontekstu operacyjnego [122], [123].
- **Redukcja złożoności:** reprezentacja systemu jako automatu stanów upraszcza analizę, pozwalając zachować istotne zależności bez rozbudowanych równań [123].
- **Skalowalność:** łatwa rozbudowa modelu o nowe stany lub dostosowanie do różnych konfiguracji robota i zadań [123], [124].
- **Integracja z danymi:** stany mogą być definiowane i kalibrowane na podstawie pomiarów, co eliminuje potrzebę stosowania szczegółowych modeli fizycznych [122], [123].
- **Przydatność w planowaniu:** dobrze sprawdzają się w estymacji czasu pracy, zarządzaniu energią i analizie efektywności strategii działania [122].

Analiza wybranych publikacji dotyczących fizyczno-strukturalnych modeli zużycia energii w robotach mobilnych

W ramach prezentowanej pracy dokonano przeglądu modeli predykcji zużycia energii, opartych na fizyczno-strukturalnym opisie procesu, obejmującego publikacje opublikowane po 2020 roku. Dla zilustrowania różnorodności podejść opracowano zestawienie w formie tabeli (Tabela 5), w którym porównano m.in. typ robota, rodzaj napędu, uwzględnione czynniki w bilansie energetycznym oraz deklarowaną skuteczność poszczególnych modeli publikowanych w literaturze. Następnie (Tabela 6) przedstawiono porównanie zalet i ograniczeń tych modeli.

Tabela 5 Przegląd literatury dotyczącej fizyczno-strukturalnych modeli predykcyjnych zużycia energii przez roboty mobilne. Opracowanie własne.

Literatura	Zastosowany model fizyczno-strukturalny	Rodzaj pojazdu	Rodzaj napędu	Symulacja	Weryfikacja	składniki wpływające na zużycie energii					Skuteczność [%]
						Napęd	Parametry terenu	Układ sterowania	Układ sensoryki	Akcesoria robota	
[51]	bilansowy	AGV	różnicowy	✓	-	$f(m)$	$f(d)$	-	-	-	90
[125]	dynamiczny	AGV	holonomiczny	-	✓	$f(m,v,a,I)$	$f(\mu_s, \mu_k, d)$	-	-	-	-
[122]	stanów	AGV	różnicowy	✓	✓	$f(m,v,I,SOC)$	$f(d)$	-	-	-	97
[116]	dynamiczny	AGV	różnicowy	✓	✓	$f(m,v,a,I)$	$f(d)$	✓	-	-	95
[123]	stanów	AGV / AMR	różnicowy	✓	✓	$f(m,v,a)$	$f(\mu_s, \mu_k, d)$	✓	✓	✓	98
[121]	komponentowy	Prototypowy robot mobilny	różnicowy	✓	✓	$f(m,v,a,I)$	$f(\theta, \mu_s, \mu_k, \kappa, \beta, d)$	✓	✓	-	98
[117]	bilansowy	Prototypowy robot mobilny	różnicowy	✓	✓	$f(m,v,a,I)$	$f(\mu_s, \mu_k, d)$	✓	✓	-	-
[124]	stanów	Prototypowy robot mobilny	poślizgowy	✓	✓	$f(m,v,a)$	$f(\theta, \mu_s, \mu_k, d)$	-	-	-	95
[119]	bilansowy	Prototypowy robot mobilny	holonomiczny	✓	✓	$f(m,v,a,\omega,I)$	$f(\theta, \mu_s, \mu_k, \kappa, d)$	✓	✓	-	95
[115]	dynamiczny	Prototypowy robot mobilny	różnicowy poślizgowy	-	✓	$f(m,v,a,I)$	$f(\theta, \mu_s, \mu_k, d)$	✓	-	-	97,5
[112]	dynamiczny	Prototypowy robot mobilny	różnicowy	✓	-	$f(m,v,a,\omega,I)$	$f(\mu_s, \mu_k, d)$	✓	✓	-	96
[120]	komponentowy	Prototypowy robot mobilny	różnicowy	✓	-	$f(v,a,I)$	$f(\mu_s, \mu_k, d)$	-	-	-	-
[126]	dynamiczny	Prototypowy robot mobilny	różnicowy	✓	✓	$f(m,v,a,I)$	$f(\mu_s, \mu_k, d)$	✓	✓	-	-
[114]	dynamiczny	Prototypowy robot mobilny	różnicowy	✓	-	$f(m,v,a,I)$	$f(d)$	-	-	-	-
[118]	bilansowy	Prototypowy robot mobilny	różnicowy	✓	✓	$f(m,v,a,P)$	$f(d)$	✓	✓	-	94
[113]	komponentowy	Miejski Pojazd Mobilny	poślizgowy przednią osią tylną osią dwuosiowe	✓	✓	$f(m,v,a,I,D)$	$f(\theta, \mu_s, \mu_k, \kappa, \beta)$	✓	-	-	81 91 89 92

Gdzie:

Napęd - uwzględnione parametry fizyczne

m- masa(robota i obciążenia)

v - prędkość pojazdu

a- przyspieszenie pojazdu

ω - prędkość kątowa pojazdu

I - moment bezwładności

D - siła oporu aerodynamicznego

SOC - poziom naładowania akumulatora

P- moc pobierana przez silniki

Parametry terenu - uwzględnione czynniki środowiskowe

θ - Nachylenie terenu (kąt)

μ_s - Tarcie statyczne

μ_k - Tarcie dynamiczne

κ - Poślizg wzdłużny kół,

β -Poślizg boczny

d - trasa misji

Tabela 6 Porównanie modeli zużycia energii w robotach mobilnych opartych na zależnościach fizyczno-strukturalnych - modele dynamiczne, bilansowe, komponentowe i stanowe. Opracowanie własne

Typ modelu	Zalety	Ograniczenia
Model dynamiczny zużycia energii oparty na równaniach ruchu [51], [112], [114], [115]	- wysoka interpretowalność - powiązanie z parametrami konstrukcyjnymi - możliwość bilansowania energii - zastosowanie w środowiskach symulacyjnych - możliwość przewidywania wpływu zmian projektowych bez potrzeby danych empirycznych	- wysoka liczba parametrów wejściowych - wrażliwość na zmiany środowiskowe - niska skalowalność <u>brak dostępu do danych producenta</u> <u>konieczność precyzyjnej kalibracji parametrów fizycznych robota</u> - wysoka wrażliwość na niedokładności w danych wejściowych <u>ograniczona uniwersalność</u> - wysoki koszt czasowy i techniczny opracowania modelu od podstaw
Model bilansowy zużycia energii [51], [117], [118], [119].	- niska złożoność obliczeniowa - szybka implementacja - przejrzystość energetyczna	- walidacja tylko w warunkach laboratoryjnych <u>trudność uzyskania danych producenta</u> - uproszczone założenia - brak odwzorowania dynamiki - ograniczona możliwość identyfikacji źródeł strat
Model komponentowy (modularny) zużycia energii [113], [120], [121].	- modularność i elastyczność - dopasowanie metod modelowania - łatwa rozbudowa i konserwacja - praktyczność w kalibracji	<u>wymagana znajomość szczegółowych parametrów</u> <u>pominięcie degradacji i zużycia</u> - konieczność dostrajania przy zmianach masy - czasochłonność konfiguracji - zróżnicowanie jakości modeli składowych komponentów
Modele zużycia energii oparte na stanach (modele stanowe) [122], [123], [124]	- odwzorowanie trybów pracy - redukcja złożoności - skalowalność - łatwa adaptacja do nowych scenariuszy	- uśrednianie mocy w stanach - niska dokładność przy zmiennych warunkach - brak uwzględnienia czynników środowiskowych - czasochłonność kalibracji (wymagane pomiary empiryczne) - ograniczona przenaszalność - brak fizycznego ugruntowania

Na podstawie przeprowadzonego przeglądu literatury (Tabela 5) oraz porównania cech wybranych podejść modelowania (Tabela 6) można zauważyć, że modele fizyczno-strukturalne, oparte na jawnych zależnościach fizycznych i matematycznych, są powszechnie stosowane głównie w kontekście robotów prototypowych przy niemal całkowitym braku wdrożeń w odniesieniu do rzeczywistych komercyjnych systemów AMR stosowanych w przemyśle. Zidentyfikowane modele uwzględniają zróżnicowaną liczbę parametrów fizycznych od podstawowych wielkości mechanicznych po bardziej szczegółowe ujęcia oporów ruchu i momentów bezwładności, jednak rzadko obejmują pełne zapotrzebowanie energetyczne wynikające z działania układów sterowania, sensoryki, systemów komunikacji i dodatkowych akcesoriów robota.

Modele fizyczno-strukturalne, oparte na jawnych zależnościach fizycznych i matematycznych, stanowią wartościowe narzędzie do predykcji zużycia energii, szczególnie w zastosowaniach wymagających wysokiej interpretowalności oraz w sytuacjach, gdzie dostępne są szczegółowe dane konstrukcyjne i środowiskowe. Ich największym atutem jest możliwość analizy przyczyn zużycia energii w oparciu o znane prawa fizyki, co pozwala nie tylko na prognozowanie zapotrzebowania energetycznego, ale również na identyfikację źródeł strat oraz ocenę efektywności komponentów. Uniwersalność modeli fizyczno-strukturalnych jest ograniczona, ponieważ ich dokładność w dużym stopniu zależy od precyzyjnych danych wejściowych oraz zgodności przyjętych założeń z rzeczywistym środowiskiem pracy robota. Nawet niewielkie różnice między warunkami modelowanymi a rzeczywistymi mogą prowadzić do istotnych błędów predykcji. [119], [121].

Modele fizyczno-strukturalne sprawdzają się przede wszystkim:

- w pracy z **robotami prototypowymi**, których parametry konstrukcyjne (masa, momenty bezwładności, charakterystyki silników, przekładnie) są znane lub łatwo mierzalne [116], [120], [121],
- w **zadaniach powtarzalnych i dobrze zdefiniowanych**, gdzie profil ruchu i środowisko (tarcie, nachylenia, obciążenie) są znane i stabilne [122],
- w **projektowaniu nowych konstrukcji**, gdzie model fizyczny wspiera analizę zmian projektowych [112], [122], [123],
- przy **analizie efektywności energetycznej**, umożliwiając bilansowanie energii i ocenę wpływu konkretnych parametrów technicznych [117], [119], [121],
- w integracji z narzędziami symulacyjnymi (Simulink, Modelica, ROS Gazebo), a także w zastosowaniach związanych z **cyfrowymi bliźniakami** [112], [121], [122].
- w **badaniach eksperymentalnych nad wpływem konkretnych czynników fizycznych** (np. rodzaju ogumienia, geometrii podwozia) na zużycie energii, gdzie model służy jako narzędzie do weryfikacji hipotez inżynierskich lub eksperymentalnych scenariuszy [118], [119], [121], [124].

Mimo wymienionych zalet, **stosowanie modeli fizyczno-strukturalnych wiąże się z istotnymi ograniczeniami**, które czynią je mniej użytecznymi w warunkach operacyjnych o wysokiej zmienności lub niskiej przejrzystości sprzętowej. Ich skuteczność znacząco spada, gdy:

- **brakuje dostępu do danych producenta** lub robot działa w **zamkniętym środowisku sprzętowo-programowym** [122],
- robot funkcjonuje w **dynamicznym i nieprzewidywalnym otoczeniu** (np. zmienne nawierzchnie, wilgoć, poślizgi, nachylenia), które trudno ująć w modelu [119], [127],
- konieczna jest częsta adaptacja modelu — **proces rozbudowy modelu i kalibracji parametrów jest czasochłonny**, wymaga szerokiej wiedzy domenowej i wielu pomiarów [118],
- robot posiada wiele aktywnych komponentów (sensory, kontrolery, systemy komunikacyjne), które w uproszczonym modelu nie są uwzględniane [119],

- wymagany jest **krótki czas wdrożenia**, a dostęp do wiedzy specjalistycznej (mechanika, system sterowania, elektronika) jest ograniczony.
- **modele często pomijają degradację komponentów w czasie** (np. spadek sprawności akumulatora, zużycie mechaniczne), co ogranicza ich trafność przy długoterminowej eksploatacji [113], [122].

W praktyce oznacza to, że modele fizyczno-strukturalne **nie są optymalnym wyborem** dla zastosowań w przemyśle, gdzie roboty działają w zróżnicowanych warunkach, zmieniają konfigurację lub są dostarczane jako zamknięte systemy. **W takich przypadkach lepsze rezultaty mogą zapewnić modele oparte na danych, które umożliwiają adaptację do zmiennych warunków bez konieczności jawnego opisu zjawisk fizycznych.**

2.2 Modele oparte na danych wykorzystujące uczenie maszynowe


Uczenie maszynowe (*ang. Machine Learning, ML*) stanowi jedną z fundamentalnych dziedzin sztucznej inteligencji, koncentrującą się na opracowywaniu algorytmów zdolnych do identyfikowania wzorców i uogólnień na podstawie danych empirycznych [128]. Głównym celem metod uczenia maszynowego jest skonstruowanie modelu, który ucząc się na zbiorze treningowym będzie potrafił dokonywać predykcji dla nowych, nieznanych wcześniej danych wejściowych [129]. W praktyce oznacza to, że złożone procesy, takie jak zużycie energii przez mobilnego robota, mogą być modelowane bez konieczności bezpośredniego definiowania zależności fizyczno-strukturalnych, a jedynie poprzez analizę danych z wykonanych zadań / tras [129], [130], [131]. Metody uczenia maszynowego są coraz częściej stosowane do modelowania zużycia energii w robotyce mobilnej ze względu na ich praktyczne zalety [101]. Przede wszystkim umożliwiają tworzenie modeli predykcyjnych bez konieczności szczegółowego odwzorowywania parametrów fizycznych układu, co upraszcza proces modelowania i wdrażania. Ponadto charakteryzują się dużą elastycznością, pozwalając na adaptację do różnych platform sprzętowych oraz zmiennych warunków pracy, takich jak typ nawierzchni, zmienna masa czy profil misji [60]. Dodatkowo, modele te mogą być skalowane do poziomu wielu jednostek, co umożliwia modelowanie na poziomie floty oraz identyfikację wzorców operacyjnych występujących w grupie robotów [132].

Warto podkreślić, że zastosowanie uczenia maszynowego wiąże się również z szeregiem wyzwań. Należą do nich m.in. potrzeba dostępu do dużych zbiorów danych [133], [134], ograniczona interpretowalność niektórych typów modeli [130], znaczne wymagania obliczeniowe [135] oraz podatność na przeuczenie [130]. W kontekście predykcji zużycia energii przez roboty mobilne, metody uczenia maszynowego bazują na danych empirycznych pozyskiwanych w trakcie rzeczywistej pracy systemu. Dane te mogą pochodzić zarówno z pomiarów wewnętrznych robota, jak i z czujników środowiskowych odzwierciedlających warunki operacyjne. Odpowiedni dobór cech wejściowych ma kluczowe znaczenie dla skuteczności modeli predykcyjnych.

W literaturze [60], [93], [134] wskazuje się podział modeli opartych na danych na:

- **modele statystyczne** (w pełni interpretowalne „białe skrzynki” - *ang. white-box*),
- **modele klasyczne uczenia maszynowego** (częściowo interpretowalne - *ang. grey-box*)
- **modele oparte na sztucznych sieciach neuronowych** („czarne skrzynki” - *ang. black-box*).

Schemat (Rys. 20) obrazuje ten podział, stanowiący punkt wyjścia do dalszego uporządkowanego opisu właściwości i zastosowań poszczególnych klas modeli.



Rys. 20 Klasy modeli predykcji zużycia energii opartych na danych wraz z przykładowymi metodami ich budowy, zestawionymi według stopnia interpretowalności i złożoności strukturalnej. Opracowanie własne na podstawie [60], [93], [134].

W kolejnych punktach przedstawiono wybrane metody uczenia maszynowego zastosowane do budowy modeli predykcji zużycia energii w robotyce mobilnej oraz w innych dziedzinach, z których modele te mogą być adaptowane. Analiza obejmuje m.in. rodzaj zastosowanej metody do budowy modelu, charakterystykę danych wejściowych oraz uzyskaną skuteczność predykcji. Dla zapewnienia lepszej przejrzystości i porównywalności poszczególnych modeli przygotowano również zestawienie tabelaryczne (Tabela 7), które porównuje kluczowe cechy powstałych modeli, stanowiąc punkt odniesienia dla dalszych analiz.

Modele statystyczne

Modele statystyczne stanowią jedną z podstawowych klas modeli predykcyjnych, tworzonych z wykorzystaniem metod uczenia maszynowego. Charakteryzują się prostą strukturą i wysoką interpretowalnością. Określane są jako „białe skrzynki” (*ang. white-box*), ponieważ umożliwiają bezpośrednią analizę zależności między zmiennymi wejściowymi a prognozowanym wynikiem, co jest istotne w kontekście transparentności modelowania technicznego, w tym predykcji zużycia energii. Modele statystyczne opierają się na dopasowaniu funkcji matematycznej (najczęściej liniowej lub jej uogólnionej postaci) do danych uczących. Proces uczenia polega na minimalizacji błędu predykcji przy założeniu pewnych warunków statystycznych, takich jak niezależność zmiennych, liniowość relacji czy rozkład normalny reszt.

W literaturze wykazano skuteczność różnych modeli statystycznych w predykcji zużycia energii, zarówno w odniesieniu do robotów mobilnych, jak i innych systemów technicznych (np. budynków i pojazdów). Do najczęściej stosowanych należą m.in.:

- model regresji liniowej [52],
- model regresji wielomianowej [136],
- model regresji wielorakiej [137], [138],
- model regresji złożonej z modułową strukturą regresji wielorakiej [139],
- uogólnione modele liniowe (GLM) [140].

Uogólnione modele liniowe (*ang. Generalized Linear Models, GLM*) stanowią uniwersalne rozszerzenie klasycznych modeli regresyjnych, umożliwiające modelowanie różnych typów zmiennych zależnych oraz relacji między zmienną objaśnianą a predyktorami. W skład GLM wchodzi m.in. regresja liniowa, regresja logistyczna, regresja Poissona czy Gamma. Modele te wykorzystują różne funkcje łączące i dopuszczają różne rozkłady zmiennej zależnej, np. normalny, Bernoulliego, Poissona. GLM stanowi podstawę matematyczną, w ramach której można stosować różne metody estymacyjne i selekcyjne, umożliwiające lepsze dopasowanie modelu do danych, szczególnie w przypadku dużej liczby predyktorów lub ich współliniowości. W kontekście budowy modeli predykcyjnych na bazie GLM istotnym etapem jest wybór odpowiednich predyktorów. W klasycznych podejściach regresyjnych powszechnie uwzględnia się wszystkie dostępne zmienne, co może prowadzić do nadmiernej złożoności modelu, przeuczenia i spadku interpretowalności. [141]. Aby temu zapobiec, stosuje się metody **selekcji zmiennych** (*ang. feature selection*) oraz **regularyzacji**, które pozwalają ograniczyć liczbę zmiennych oraz zmniejszyć ryzyko nadmiernego dopasowania.

Do najczęściej wykorzystywanych metod należą:

- **Forward Selection** - dodaje do modelu kolejne zmienne krok po kroku, wybierając te, które najbardziej poprawiają dopasowanie (np. według R^2) [142].
- **Stepwise Selection** - łączy dodawanie i usuwanie zmiennych na podstawie kryteriów statystycznych, umożliwiając dynamiczne dopasowanie struktury modelu [142].
- **LAR** (*ang. Least Angle Regression*) - zmienne są dobierane na podstawie ich korelacji z błędem prognozy, a współczynniki zmieniają się płynnie, co czyni tę metodę bliższą LASSO niż klasycznym technikom krokowym [143].

- **Ridge Regression** - stosuje regularyzację L2, zmniejszając wartości współczynników bez ich zerowania, co przeciwdziała współliniowości i przeuczeniu, ale nie eliminuje zmiennych [143].
- **LASSO** (*ang. Least Absolute Shrinkage and Selection Operator*) - Wprowadza regularyzację L1, która automatycznie zeruje część współczynników, pełniąc jednocześnie rolę selekcji zmiennych [138], [142], [143]. Ostateczna postać zadania optymalizacyjnego przyjmuje postać:

$$\hat{\beta} = \arg \min_{\beta} \left\{ \sum_{i=1}^n (y_i - x_i^T \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (1)$$

Gdzie: y_i - wartość rzeczywista dla próbki i , $x_i^T \beta$ - przewidywana wartość, n - liczba obserwacji,

λ - parametr regulacji, p - liczba cech, β_j - wartość j -tego współczynnika regresji

Kluczową właściwością regresji Lasso jest możliwość całkowitego wyzerowania niektórych współczynników β_j , co skutkuje automatycznym odrzuceniem zmiennych nieistotnych statystycznie. W efekcie otrzymywany jest model bardziej zwarty, mniej podatny na przeuczenie, a zarazem łatwiejszy do interpretacji. Jest to szczególnie przydatne w kontekstach wysokowymiarowych, gdy liczba potencjalnych predyktorów jest znaczna, a relacje pomiędzy nimi mogą być złożone lub współzależne [138]. LASSO stanowi zatem podejście estymacyjne stosowane w ramach modeli liniowych i uogólnionych modeli liniowych, umożliwiające jednoczesną redukcję wariancji estymatora, poprawę zdolności generalizacji oraz zwiększenie przejrzystości modelu przez eliminację zbędnych predyktorów [141].

Modele regresyjne, tworzone z wykorzystaniem statystycznych metod uczenia maszynowego, znajdują szerokie zastosowanie w analizie i predykcji zużycia energii w systemach technicznych i obliczeniowych. Ich główną zaletą jest niska złożoność obliczeniowa oraz łatwość implementacji, co pozwala na efektywne wykorzystanie nawet w warunkach ograniczonych zasobów obliczeniowych [134], [144], [145]. W kontekście modelowania zużycia energii, istotną korzyścią jest możliwość redukcji liczby zmiennych wejściowych, m.in. poprzez techniki selekcji cech lub regularyzację, co nie tylko upraszcza implementację modelu, ale także pozwala na lepsze zrozumienie wpływu poszczególnych parametrów na wynik końcowy [141]. Takie podejście zwiększa przejrzystość modeli i sprzyja ich wdrażaniu w środowiskach przemysłowych oraz w systemach o wysokich wymaganiach niezawodnościowych [136], [144], [146], [147].


Klasyczne modele uczenia maszynowego

Klasyczne modele uczenia maszynowego wykorzystują dane empiryczne do identyfikowania wzorców i odwzorowywania złożonych zależności między zmiennymi, bez konieczności formułowania uprzednich równań fizycznych [138]. Wśród nich wyróżnia się modele półparametryczne, określane mianem „szarych skrzynek” (*ang. grey-box models*). Stanowią one kompromis między pełną transparentnością modeli statystycznych (białe skrzynki) a elastycznością nieliniowych modeli o ograniczonej interpretowalności (czarne skrzynki) [148]. Struktura takich modeli zawiera zarówno część określoną z góry (np. liniową zależność od wybranych zmiennych), jak i komponenty dopasowywane do danych w sposób nieliniowy, bez wcześniejszego określenia ich formy. Przykładem takiego podejścia są uogólnione modele addytywne (*ang. Generalized Additive Model, GAM*), które estymują wpływ zmiennych wejściowych jako suma funkcji cząstkowych, dopasowywanych niezależnie dla każdej cechy [133].

$$y = \beta_0 + f_1(x_1) + f_2(x_2) + \dots + f_n(x_n) \quad (2)$$


Gdzie: $f_n(x_n)$ - to nieliniowe, lecz gładkie funkcje estymowane z danych empirycznych.

Podobnie, drzewa decyzyjne, choć nieparametryczne z definicji, często zaliczane są do tej kategorii ze względu na jawną strukturę reguł i możliwości śledzenia procesu decyzyjnego. Ich działanie opiera się na hierarchicznym podziale przestrzeni cech przy użyciu prostych reguł logicznych [147], [149]. Ilustrację tego mechanizmu przedstawia Rys. 21



Rys. 21 Przykład działania klasyfikacyjnego drzewa decyzyjnego: a) Podziały przestrzeni cech X_1 i X_2 na podstawie reguł decyzyjnych, b) Odpowiadające drzewo decyzyjne odwzorowujące zastosowane podziały. Opracowanie własne na podstawie [147], [149].

Aby zwiększyć niezawodność predykcji, pojedyncze drzewa decyzyjne można łączyć w większe struktury, tworząc tzw. **las losowe**. W tym podejściu wiele drzew budowanych jest niezależnie, z wykorzystaniem losowych podzbiorów danych i cech. Każde drzewo generuje własną prognozę, a wynik końcowy powstaje przez uśrednienie ich wyników [146], [150]. Ilustrację zasady działania przedstawiono na Rys. 22



Rys. 22 Schemat działania modelu zespołowego typu Random Forest - agregacja wyników wielu drzew decyzyjnych poprzez uśrednianie predykcji. Opracowanie własne na podstawie [146], [151]

W przedstawionych przypadkach uzyskuje się modele zdolne do odwzorowania nieliniowych relacji, budowanych na podstawie danych empirycznych przy jednoczesnym zachowaniu interpretowalnej struktury. Modele te cechują się stosunkowo niską złożonością obliczeniową i łatwością implementacji. W wielu przypadkach nie wymagają dużej liczby danych do osiągnięcia stabilnych wyników, a techniki regularyzacji oraz przycinania (w drzewach) umożliwiają ograniczenie przeuczenia. Co więcej, niektóre z tych modeli, jak drzewa decyzyjne czy lasy losowe, wykazują wewnętrzną zdolność selekcji istotnych cech, co ogranicza potrzebę ręcznej redukcji wymiarowości danych wejściowych [148], [151]. Dzięki tym właściwościom modele klasyczne znajdują szerokie zastosowanie w analizach inżynierskich i eksperymentalnych, gdzie konieczna jest równoczesna kontrola jakości predykcji oraz możliwość uzasadnienia uzyskanych wyników.


Modele oparte na sztucznych sieciach neuronowych

Sztuczne sieci neuronowe (*ang. Artificial Neural Networks, ANN*) stanowią klasę modeli matematycznych wykorzystywanych do odwzorowywania złożonych zależności pomiędzy zmiennymi wejściowymi a wyjściem systemu. Wyróżniają się zdolnością do aproksymacji nieliniowych funkcji oraz elastycznością w zastosowaniu do różnorodnych typów danych. Sieci neuronowe zaliczane są do grupy modeli typu **czarnej skrzynki** (*ang. black-box models*), ponieważ nie oferują możliwości bezpośredniego wglądu w reguły decyzyjne, które doprowadzają do wygenerowania konkretnego wyniku [136]. W przeciwieństwie do modeli opartych na zależnościach fizyczno-strukturalnych lub statystycznych (np. regresja liniowa), w których można jednoznacznie określić wpływ poszczególnych zmiennych na wynik końcowy, w sieciach neuronowych zależności te są zapisane w rozproszonej strukturze wag i aktywacji wielu warstw. Utrudnia to interpretację działania modelu i analizę przyczyn predykowanej wartości, szczególnie w przypadku głębokich architektur [136].

Podstawą każdej sieci neuronowej jest sztuczny neuron i funkcja aktywacji. W zależności od liczby warstw i ich organizacji wyróżnia się różne architektury [129], [136], [152]:

- **Sieć jednowarstwowa** (brak warstw ukrytych) - zdolna do modelowania jedynie relacji liniowych.
- **Sieć wielowarstwowa** (jedna lub więcej warstw ukrytych) - stosowana do klasycznych zadań regresji i klasyfikacji.
- **Sieć głęboka** (wiele warstw ukrytych) umożliwia analizę złożonych danych, np. czasowych, obrazów lub sekwencyjnych.

Każda z tych struktur znajduje zastosowanie w innych typach problemów, zależnie od ich złożoności i charakterystyki danych. Przykładowe architektury sieci neuronowych w zależności od liczby warstw ukrytych przedstawiono poniżej (Rys. 23).



Rys. 23 Przykłady architektur sztucznych sieci neuronowych: jednowarstwowej, wielowarstwowej i głębokiej, różniących się liczbą warstw ukrytych i zdolnością do modelowania złożonych zależności. Opracowanie własne na podstawie [128], [135], [148].

Pomimo ograniczonej przejrzystości, modeli opartych na sieciach neuronowych wykazują one wysoką skuteczność w modelowaniu procesów, których charakterystyka jest nieliniowa, dynamiczna lub trudna do opisanania analitycznie. Z tego względu znajdują szerokie zastosowanie w predykcji zużycia energii w systemach technicznych, w tym w robotyce mobilnej, pojazdach autonomicznych, instalacjach przemysłowych oraz systemach zarządzania budynkami. Do najczęściej wykorzystywanych modeli należą:

- Wielowarstwowy perceptron (*ang. Multilayer Perceptron, MLP*) [137],
- Konwolucyjne sieci neuronowe (*ang. Convolutional Neural Networks, CNN*) [130], [153], [154],
- Rekurencyjne sieci neuronowe (*ang. Recurrent Neural Networks, RNN*) [131], [135], [152],
- Głębokie sieci konwolucyjne z połączeniami rezydualnymi (*ang. Residual Neural Network*) [93].

Proces uczenia sieci neuronowej ma charakter iteracyjny i przebiega w ramach kolejnych epok, czyli pełnych przejść przez zbiór treningowy. W każdej epoce model przetwarza dane wejściowe, generuje prognozy, porównuje je z wartościami rzeczywistymi, a następnie aktualizuje swoje parametry (wagi) w celu minimalizacji funkcji straty, zazwyczaj z wykorzystaniem algorytmów optymalizacji gradientowej. Przed rozpoczęciem uczenia dane dzieli się na trzy rozłączne podzbiory: treningowy, walidacyjny i testowy [131], [136], [155]:

- **zbiór treningowy** (60-80%) - służy do estymacji wag i uczenia modelu,
- **zbiór walidacyjny** (10-20%) - pozwala monitorować jakość uczenia na bieżąco i wykrywać przeuczenie,
- **zbiór testowy** (10-20%) - wykorzystywany wyłącznie po zakończeniu uczenia, służy do niezależnej oceny zdolności modelu do generalizacji.

Ważnym hiperparametrem sterującym procesem uczenia jest liczba epok. Zbyt krótki trening może skutkować **niedouczeniem modelu** (*ang. underfitting*), czyli brakiem zdolności do uchwycenia istotnych wzorców w danych. Z kolei zbyt długa nauka może prowadzić do **przeuczenia** (*ang. overfitting*), w którym model zbyt dokładnie odwzorowuje dane treningowe, tracąc zdolność generalizacji i osiągając gorsze wyniki na nowych danych. Aby ograniczyć ryzyko przeuczenia, stosuje się strategię wczesnego zatrzymania (*early stopping*), która przerywa uczenie, gdy metryka walidacyjna nie poprawia się przez ustaloną liczbę epok.

Modele oparte na sieciach neuronowych znajdują coraz szersze zastosowanie w środowiskach przemysłowych, zwłaszcza tam, gdzie występuje potrzeba modelowania złożonych, nieliniowych procesów na podstawie dużych zbiorów danych. Ich elastyczność, wysoka skuteczność predykcji oraz zdolność do adaptacji czynią je użytecznymi w zadaniach takich jak prognozowanie zużycia energii, diagnostyka stanu technicznego czy optymalizacja procesów operacyjnych [134]. Z drugiej strony, w kontekście wymagań przemysłowych istotne są także ich ograniczenia: potrzeba znacznych zasobów obliczeniowych, wymóg dostępu do danych wysokiej jakości, a także ograniczona interpretowalność wyników, utrudniająca wdrożenia w środowiskach wymagających transparentności decyzyjnej [60], [136]. W praktyce przemysłowej skuteczne zastosowanie sieci neuronowych wymaga nie tylko odpowiednio dobranej architektury, ale również integracji z procesem monitorowania danych oraz narzędziami nadzorującymi jakość predykcji.

Modele tworzone z wykorzystaniem narzędzia AutoML

Automatyczne Uczenie Maszynowe (*ang. Automated Machine Learning, AutoML*) nie stanowi odrębnej klasy modeli predykcyjnych opartych na danych wykorzystujących uczenie maszynowe, lecz należy traktować go jako podejście metodologiczne / narzędzie. Jego głównym celem jest ograniczenie udziału człowieka w technicznych etapach tworzenia modeli uczenia maszynowego (ML), co sprzyja ukierunkowaniu procesu na rozwiązywany problem badawczy lub biznesowy. AutoML automatyzuje kolejne kroki procesu modelowania, obejmujące: wybór reprezentacji danych i cech (*feature engineering*), dobór architektury modelu (np. sieci neuronowych czy drzew decyzyjnych), strojenie hiperparametrów, walidację oraz ocenę jakości, a następnie selekcję najlepszego rozwiązania [156]

Podejście AutoML ta znajduje odzwierciedlenie w licznych narzędziach i platformach, które implementują powyższe założenia. Do najbardziej znanych należą: Google Cloud AutoML (Vertex AI AutoML) oraz Microsoft Azure AutoML (rozwiązania komercyjne), a także otwarte biblioteki, takie jak Auto-sklearn, TPOT czy AutoKeras. Ich wspólną cechą jest możliwość redukcji nakładu pracy specjalistycznej przy jednoczesnym zwiększeniu efektywności całego procesu modelowania [157].

W kontekście przemysłowym AutoML zyskuje rosnące znaczenie, ponieważ ułatwia wdrażanie metod uczenia maszynowego w organizacjach borykających się z niedoborem wysoko wykwalifikowanych ekspertów [156], [157]. Umożliwia szybsze prototypowanie rozwiązań, wspiera skalowalność modeli do dużych zbiorów danych oraz ułatwia ich integrację z istniejącą infrastrukturą, w tym z systemami chmurowymi i środowiskami IoT. Ponadto pozwala na cykliczne aktualizowanie i ponowne trenowanie modeli w procesie eksploatacji, co przeciwdziała degradacji jakości predykcji spowodowanej zmianami w charakterze danych (tzw. *data drift*). Z tego względu AutoML coraz częściej jest postrzegany jako technologia umożliwiająca efektywne wdrożenia rozwiązań opartych na sztucznej inteligencji w przemyśle, gdzie kluczowe znaczenie mają szybkość implementacji, niezawodność działania oraz redukcja kosztów operacyjnych [157], [158].

W literaturze poświęconej wykorzystaniu metod AutoML podkreśla się, że klasyczne podejścia do uczenia maszynowego wymagają znaczącego zaangażowania ekspertów, zwłaszcza w obszarze inżynierii cech, która odgrywa kluczową rolę w zadaniach predykcyjnych w tym również w kontekście zużycia energii. W odpowiedzi na te ograniczenia, coraz częściej proponowane są zautomatyzowane

metody ekstrakcji i selekcji cech, zintegrowane z AutoML, które umożliwiają pełne zautomatyzowanie procesu budowy modeli predykcyjnych, od przygotowania danych, przez wybór modelu, aż po jego strojenie [156], [158], [159].

W analizowanej literaturze AutoML jest wykorzystywany m.in. w predykcji zużycia energii na poziomie budynków, systemów miejskich i regionalnych [160], a także w estymacji zasięgu i poziomu naładowania pojazdów elektrycznych [159]. Przeprowadzona analiza literatury wskazuje jednak na wyraźny brak zastosowań AutoML w obszarze predykcji zużycia energii przez roboty mobilne. Mimo to, ze względu na znaczące podobieństwa w strukturze danych oraz charakterystyce problemu (np. dane czasowe, sensoryczne, zależność zużycia energii od scenariusza operacyjnego), techniki AutoML mogą stanowić perspektywiczną alternatywę również w tym obszarze.

Zastosowanie AutoML w robotyce mobilnej może istotnie obniżyć barierę wejścia dla przedsiębiorstw, które nie dysponują wyspecjalizowanymi zespołami ds. uczenia maszynowego lub w których utrzymanie i ciągła aktualizacja modeli predykcyjnych byłaby kosztowna. Dzięki automatyzacji procesów modelowania, możliwe jest szybsze wdrożenie systemów predykcyjnych opartych na rzeczywistych danych pomiarowych, bez konieczności głębokiej ekspertyzy w zakresie ML.

Analiza wybranych publikacji dotyczących modeli predykcji zużycia energii opartych na danych wykorzystujących uczenie maszynowe

W kolejnej części pracy przedstawiono wyniki przeglądu literatury dotyczącej metod predykcji zużycia energii opartych na danych, obejmującego prace opublikowane po 2020 roku. Na jego podstawie opracowano autorskie zestawienie (Tabela 7), które przedstawia, jakie modele wykorzystywane są w literaturze, jakie dane wejściowe służą do predykcji oraz jakie osiągane są wyniki. Następnie (Tabela 8) dokonano porównania trzech głównych grup tych modeli, statystycznych, klasycznych modeli uczenia maszynowego oraz sieci neuronowych z uwzględnieniem ich zalet i ograniczeń, w kontekście zastosowań przemysłowych.

Tabela 7 Przegląd wybranych metod (algorytmów uczenia maszynowego) stosowanych w predykcji zużycia energii pojazdów elektrycznych. Opracowanie własne.

Literatura	Metoda	Rodzaj pojazdu	Rodzaj napędu	Symulacja	Rzeczywiste środowisko	Zmienne niezależne					Czy wskazano wagi parametrów wejściowych	Skuteczność [%]
						Napęd	Parametry terenu i misji	Układ sterowania	Układ sensoryki	Akcesoria robota		
[52]	Regresja liniowa	AMR	różnicowy	-	✓	-	{t}	-	-	✓	-	99
[135]	RNN	AMR	różnicowy	-	✓	{m,v,ω,SoC}	{d}	✓	✓	✓	-	96
[155]	RNN	AGV	różnicowy	-	✓	{Ub}	-	-	-	-	-	93-99
[129]	ANN	Prototypowy robot mobilny	różnicowy	-	✓	-	{d}	-	-	-	-	98
[115]	ANN	Prototypowy robot mobilny	różnicowy poślizgowy	-	✓	{m,v,ω}	{μs, μk,d}	-	-	-	-	96 90
[130]	CNN	Prototypowy robot mobilny	różnicowy	✓	-	-	ortofoto mapy	-	-	-	-	50-90
[153]	CNN	Prototypowy robot mobilny	poślizgowy	-	✓	-	{θ,d}	-	-	-	-	88
[154]	CNN	Prototypowy robot mobilny	poślizgowy	-	✓	-	ortofoto mapy {θ, d}	-	-	-	-	87-91
[131]	RNN	Prototypowy robot mobilny	różnicowy	-	✓	{v,ω}	{d}	-	-	-	-	96
[137]	MLR MLP	Prototypowy robot mobilny	różnicowy	✓	✓	{v}	{d}	✓	✓	-	-	69 44
[139]	Regresja złożona	Prototypowy robot mobilny	akermana przednia os skrętna	-	✓	{v,a, ω}	{θ, μs, μk,d}	✓	✓	-	✓	98
[161]	ANN	Łazik planetarny	ślizgowy	✓	-	{v,a}	{θ, μs, μk,d,g}	-	-	-	-	95
[144]	ANN	samochód elektryczny	akermana przednia os skrętna	✓	✓	{m,v,D,SoC}	{θ, μs, μk,d,T}	-	-	-	✓	96
[162]	RNN+RF	samochód elektryczny	akermana przednia os skrętna	-	✓	{m,v,SoC}	{θ,d,T}	✓	-	-	-	85
[163]	RNN+RF	samochód elektryczny	akermana przednia os skrętna	-	✓	{m,v,a,SoC}	{θ,d,T}	-	-	-	-	95
[164]	Regresja liniowa / wykładnicza	samochód elektryczny	akermana przednia os skrętna	-	✓	{m,v,a,D}	{θ,d, μk,T}	-	-	-	-	98

Gdzie:

Metoda

ANN - sztuczne sieci neuronowe
 CNN- konwolucyjne sieci neuronowe
 RNN - rekurencyjne sieci neuronowe
 MLR - regresja wieloraka
 MLP - perceptron wielowarstwowy
 RF - drzewa losowe

Napęd - uwzględnione parametry fizyczne

m- masa(robota i obciążenia)
 v - prędkość pojazdu
 a- przyspieszenie pojazdu
 ω - prędkość kątowna pojazdu
 I - moment bezwładności
 D - siła oporu aerodynamicznego
 SOC - poziom naładowania akumulatora
 P- moc pobierana przez silniki
 Ub - napięcie ogniów akumulatora

Parametry terenu - uwzględnione czynniki środowiskowe

θ - Nachylenie terenu (kąt)
 μs - Tarcie statyczne
 μk - Tarcie dynamiczne
 κ - Poślizg wzdłużny kół,
 β -Poślizg boczny
 g - przyspieszenie grawitacyjne
 T- temperatura otoczenia
 d - trasa misji
 t- czas trwania misji

Tabela 8 Porównanie modeli w kontekście łatwości ich wdrożenia w warunkach przemysłowych na podstawie empirycznych pomiarów (zapisanych w formie tabelarycznej).

Opracowanie własne na podstawie [133], [135], [136], [137], [138], [141], [145], [147], [148], [149], [151], [152], [153], [154], [157], [158], [160],

Klasa modelu	Metoda budowy	Dane wejściowe: czy akceptuje dane tabelaryczne	Łatwość wdrożenia	Zapotrzebowanie na dane do uzyskania stabilnych wyników	Interpret.	Wskazywanie wag parametrów wejściowych	Główne zalety	Główne wady
Modele statystyczne	Regresja wieloraka (liniowa)	Tak	Wysoka	Małe / średnie	Wysoka	Tak, po standaryzacji	Niska latencja, wysoka stabilność, łatwa kalibracja prawdopodobieństw.	Brak modelowania nieliniowości i interakcji bez dodatkowych cech; wrażliwość na współliniowość.
	Regresja wielomianowa	Tak	Wysoka	Średnie	Średnia	Nie	Łatwa implementacja	Ograniczona przejrzystość.
	GLM	Tak	Wysoka	Małe / średnie	Wysoka	Tak	Łatwa interpretacja współczynników, prostota wdrożenia, kontrola złożoności, selekcja istotnych cech.	Wymaga poprawnej specyfikacji linku i rozkładu, ograniczona nieliniowość
Klasyczne modele uczenia maszynowego	GAM	Tak	Średnia	Średnie	Wysoka	Nie	Czytelne efekty częściowe, elastyczność bez utraty kontroli	Strojenie gładkości, słabsze dla silnych interakcji wysokiego rzędu
	Drzewo decyzyjne / las losowy	Tak	Wysoka	Małe / średnie	Wysoka na poziomie reguł	Nie wprost. Dostępne są ważności zmiennych oraz reguły.	Zrozumiałe reguły, naturalna obsługa nieliniowości i interakcji.	Niestabilność pojedynczego drzewa, ograniczona dokładność
Modele oparte na sztucznych sieciach neuronowych	CNN	Nie dla klasycznych tabel.	Niska / średnia	Duże; mniejsze przy zastosowaniu uczenia wstępnego.	Niska	Nie. Wagi nie odpowiadają bezpośrednio cechom wejściowym.	Uczenie reprezentacji z surowych sygnałów, dobra detekcja wzorców lokalnych	Wysokie koszty obliczeń; ograniczona przydatność dla statycznych tabel; niska przejrzystość.
	RNN/GRU	Warunkowo. Tak dla szeregów czasowych,	Niska / średnia	Duże	Niska	Nie. Brak bezpośrednich wag dla cech; możliwe analizy ważności sekwencyjnej.	Modelowanie zależności czasowych, przewaga przy długich sekwencjach	Trudny trening, ryzyko zanikającego gradientu, słaba interpretowalność
Modele tworzone z wykorzystaniem AutoML	automatyzacja wyboru, strojenia i walidacji modeli ML	Tak	Bardzo Wysoka	Średnie	Niska	Tak	Przyspieszenie procesu tworzenia modeli, Szybkie prototypowanie, łatwość wdrożenia bez szerokiej wiedzy ML	Ograniczona kontrola, koszt obliczeniowy

Na podstawie przeprowadzonego przeglądu (Tabela 7, Tabela 8) można stwierdzić, że modele oparte na danych wykorzystujące uczenie maszynowe są w literaturze budowane i testowane głównie na robotach prototypowych, przy ograniczonej liczbie prac odnoszących się do rzeczywistych, komercyjnych systemów AMR. Niewiele publikacji przedstawia modele predykcyjne zużycia energii dla AMR z potencjałem na wdrożenie w warunkach przemysłowych, a jeszcze rzadziej analizuje wpływ poszczególnych parametrów misji na wynik predykcji. W dominującej grupie znajdują się rozwiązania oparte na sztucznych sieciach neuronowych, osiągają one wysoką dokładność, lecz charakteryzują się wysokimi wymaganiami ilości i jakości danych uczących i niską interpretowalnością, co utrudnia identyfikację czynników wzrostu zużycia energii, a niska interpretowalność ogranicza przewidywalność reakcji modelu i bywa barierą wdrożeniową w systemach przemysłowych wymagających transparentności i bezpieczeństwa działania.

Modele bazujące na danych mają istotny potencjał wdrożeniowy w przemyśle [60]. Umożliwiają uczenie bez dostępu do szczegółowych modeli fizyczno-strukturalnych i parametrów producenta, dobrze adaptują się do zmiennych warunków pracy i konfiguracji, a także [60], [155]. W praktyce ułatwiają szybkie prototypowanie i aktualizację wraz z napływem nowych danych, co jest korzystne przy częstych zmianach profilu zadań i środowiska [60], [93]. **Sprawdzają się przede wszystkim:**

- gdy dostępne są obszerne zbiory telemetrii i logów misji, a pozyskanie pełnych modeli fizyczno-strukturalnych lub danych producenta jest trudne [147],
- w środowiskach o zmiennych warunkach pracy (różne parametry misji) i konfiguracjach, gdzie konieczna jest szybka adaptacja modeli do nowych danych [60], [155],
- w krótkoterminowej predykcji zużycia energii i stanu, z możliwością cyklicznej aktualizacji wraz z napływem nowych misji [131],
- w zadaniach na danych tabelarycznych i szeregach czasowych, z wykorzystaniem selekcji cech oraz redukcji wymiaru [134], [141],
- gdy istotny jest krótki czas przygotowania modelu i umiarkowane koszty obliczeń przy zachowaniu dobrej jakości predykcji wykorzystując klasyczne metody ML.

Mimo wymienionych zalet, **stosowanie modeli opartych na danych wiąże się z istotnymi ograniczeniami. Ich skuteczność znacząco spada, gdy:**

- dane są niereprezentatywne, zaszumione, niesynchronizowane lub zawierają luki, co prowadzi do błędów uczenia i wnioskowania [136],
- występuje dryf danych lub zmiany platformy/oprogramowania/obciążenia, a proces re-treningu i walidacji nie jest zautomatyzowany [134],
- wymagana jest wysoka interpretowalność decyzji; modele, zwłaszcza oparte na sieciach neuronowych, są trudne do wyjaśnienia i audytu [60],
- pojawia się nadmierne dopasowanie wynikające z ograniczonych danych treningowych lub niewłaściwej walidacji,
- brakuje spójnych metryk i protokołów porównawczych, co utrudnia ocenę użyteczności w warunkach produkcyjnych [60],
- ograniczone są zasoby na przygotowanie cech, etykietowanie lub zapewnienie jakości danych, przez co wdrożenie staje się nieefektywne [154].

Podsumowując, podejścia oparte na danych stanowią komplementarną alternatywę wobec modeli fizyczno-strukturalnych. W zastosowaniach przemysłowych sprawdzają się szczególnie wtedy, gdy dostępne są bogate zbiory telemetryczne, środowisko operacyjne jest zmienne, a celem jest szybkie uzyskanie przewidywań i ich bieżąca adaptacja. Wymagają jednak systematycznego nadzoru jakości danych i procesu uczenia oraz rozwiązań zwiększających interpretowalność modeli w krytycznych zastosowaniach energetycznych.

2.3 Modele Hybrydowe

W literaturze dotyczącej prognozowania zużycia energii w robotach mobilnych coraz większą uwagę poświęca się **modelom hybrydowym**, które łączą modele oparte na prawach fizyki z modelami budowanymi na podstawie danych pomiarowych [60]. Modele fizyczno-strukturalnych mogą przyjmować postać złożonych, wieloparametrycznych struktur, wymagających precyzyjnej znajomości domenowej [134]. Alternatywnie, mogą one być upraszczane kosztem dokładności odwzorowania rzeczywistego zużycia energii. Ich główną zaletą pozostaje jednak wysoki poziom interpretowalności [60]. Modele hybrydowe umożliwiają połączenie zalet modeli fizyczno-strukturalnych i bazujących na danych, kompensując jednocześnie ich ograniczenia - wrażliwość modeli fizyczno-strukturalnych na niedokładne lub zmienne parametry oraz niską odporność modeli bazujących na danych na warunki spoza zbioru uczącego.

Pojęcie modelu hybrydowego w kontekście predykcji zużycia energii ma charakter szeroki i niejednoznaczny. Odnosi się ono do różnorodnych strategii modelowania, metod przetwarzania danych wejściowych oraz technik integracji wyników cząstkowych. W praktyce termin ten obejmuje wiele konfiguracji łączących wiedzę domenową, na przykład modele fizyczno-strukturalnych opisujące dynamikę systemu, z algorytmami uczenia maszynowego. Poszczególne podejścia mogą różnić się zakresem zastosowania, strukturą modelu oraz celem integracji komponentów. W efekcie, pojęcie „modelu hybrydowego” nie odnosi się do jednej, ściśle zdefiniowanej architektury, lecz stanowi ramę analityczno-obliczeniową obejmującą zróżnicowane rozwiązania. Kluczową ideą jest wykorzystanie mocnych stron każdej z metod składowych w celu przezwyciężenia ograniczeń tradycyjnych podejść, takich jak trudność modelowania zmiennego i niezanego obciążenia robota. Zintegrowane podejścia hybrydowe umożliwiają tworzenie dokładniejszych i bardziej uniwersalnych estymacji zużycia energii, łącząc precyzję modeli fizyczno-strukturalnych z elastycznością i zdolnościami generalizacji modeli opartych na danych [134].

Przeprowadzona analiza literatury przedmiotu pozwala na wyróżnienie czterech głównych kategorii podejść hybrydowych, które różnią się zakresem integracji wiedzy eksperckiej z danymi empirycznymi:

- **Modele fizyczne z wbudowanymi elementami ML** (*ang. grey-box*) - Model opiera się na strukturze fizycznej, uzupełnianej komponentem ML, który kompensuje uproszczenia i nieuwzględnione zjawiska. Umożliwia to zachowanie interpretowalności przy jednoczesnym zwiększeniu dokładności predykcji w zmiennych warunkach pracy [137], [162],
- **Modele ML uwzględniające wiedzę fizyczną** (*ang. Physics-Informed Machine Learning, PIML*) - Uczenie maszynowe wzbogacone jest o zmienne pochodzące z równań fizycznych, co zawęży przestrzeń hipotez i zwiększa odporność modelu. Dzięki temu modele lepiej generalizują, nawet przy ograniczonej liczbie danych [163], [165],
- **Modele uczone na danych z symulacji fizycznych** (*ang. digital twin*) - Model trenowany jest na danych syntetycznych wygenerowanych w środowisku symulacyjnym z odwzorowaniem dynamiki i warunków rzeczywistych. Takie podejście pozwala na przenoszenie modeli do fizycznych systemów bez kosztownej rekonfiguracji [132], [164], [166], [167],
- **Wielomodelowe strategie predykcji** (*ang. Mixture of Experts, MoE*) - Predykcja opiera się na łączeniu wyników wielu modeli lub dynamicznym wyborze modelu -eksperta najlepiej dopasowanego do danego kontekstu. Zapewnia to elastyczność i wysoką dokładność w zmiennych warunkach operacyjnych [168], [169], [170].

Zalety i ograniczenia modeli hybrydowych

Zasadniczą zaletą modeli hybrydowych jest zdolność do równoczesnego wykorzystania atutów obu klas modeli: interpretowalności i zgodności z zasadami fizyki z jednej strony oraz adaptacyjności i elastyczności charakterystycznej dla modeli uczenia maszynowego z drugiej [164]. Dzięki tej integracji możliwe jest precyzyjniejsze odwzorowanie rzeczywistych zjawisk zachodzących w systemie, w tym takich, które trudno jednoznacznie opisać za pomocą klasycznego modelowania fizycznego jak dynamiczne zmiany obciążenia, nieliniowe straty energetyczne czy wpływ zmiennych warunków środowiskowych. Wprowadzenie wiedzy dziedzinowej w postaci zależności fizycznych pozwala również ograniczyć przestrzeń poszukiwań modelu ML, co przekłada się na zmniejszenie wymagań dotyczących liczby i jakości danych uczących oraz poprawę odporności modelu na zakłócenia pomiarowe [163]. Dodatkowo, modele hybrydowe charakteryzują się zazwyczaj wyższą zdolnością do generalizacji niż podejścia oparte wyłącznie na danych statystycznych, co ma kluczowe znaczenie w zastosowaniach realizowanych w środowiskach niestacjonarnych [134], [162]. Właściwie zaprojektowana architektura hybrydowa może również zwiększać przejrzystość modelu i wspierać jego wykorzystanie w zadaniach inżynierskich i regulacyjnych.

Z drugiej strony, opracowanie modeli hybrydowych wiąże się z licznymi wyzwaniami natury implementacyjnej. Przede wszystkim rośnie złożoność całego procesu projektowego, obejmującego zarówno konstrukcję, jak i weryfikację poszczególnych komponentów. Integracja wymaga kompetencji z zakresu modelowania fizycznego oraz zaawansowanych metod przetwarzania danych, co istotnie podnosi wymagania kompetencyjne dla osób projektujących tego rodzaju systemy w porównaniu do klasycznych rozwiązań jednorodnych [134]. Szczególnym problemem pozostaje przypisanie odpowiedzialności poszczególnym komponentom (fizycznemu i ML) w sposób zapewniający wzajemne uzupełnianie się funkcjonalności [162], [169], [170]. Warto także zaznaczyć, że modele hybrydowe mogą wiązać się z większym zapotrzebowaniem na zasoby obliczeniowe [60], [130].

Mimo że modele hybrydowe przedstawione w literaturze wykazują wysoką skuteczność predykcji, wyższą odporność na zakłócenia oraz lepszą uniwersalność, szczególnie w środowiskach zmiennych ich zastosowania dotyczą głównie platform badawczych, a nie komercyjnych robotów AMR stosowanych w środowiskach produkcyjnych. Wdrożenie takiego modelu wymaga zaawansowanej wiedzy zarówno z zakresu opisu fizyczno-strukturalnego systemu, jak i budowy modeli uczenia maszynowego, co przekłada się na wysokie koszty, długi czas implementacji oraz konieczność interdyscyplinarnego zespołu projektowego.

2.4 Porównanie modeli predykcyjnych zużycia energii przez roboty mobilne

Efektywna predykcja zużycia energii stanowi jedno z kluczowych wyzwań w zarządzaniu eksploatacją robotów mobilnych i innych pojazdów zasilanych poprzez akumulator, w szczególności autonomicznych jednostek AMR działających w środowiskach przemysłowych i magazynowych. Rzetelne prognozy zużycia energii mogą pozwolić na optymalizację planowania misji, ale także na minimalizację ryzyka nieoczekiwanego rozładowania akumulatorów, zwiększenie dostępności jednostek, ciągłości operacyjnej oraz poprawę efektywności wykorzystania floty. Niezależnie od typu platformy zdolność do wiarygodnego szacowania zapotrzebowania energetycznego jest warunkiem skutecznego planowania, zarządzania ładowaniem oraz ograniczania nieplanowanych przestojów.

W literaturze przedmiotu, jak również w poprzednich podrozdziałach pracy, tej rozprawy doktorskiej wyodrębniono trzy główne **klasy modeli predykcji zużycia energii**: oparte na opisie fizyczno-strukturalnym modele oparte na danych (z wykorzystaniem metod uczenia maszynowego) oraz modele hybrydowe, łączące elementy obu wcześniejszych klas. Każda z tych klas cechuje się odmienną strukturą modelu, wymaganiami wejściowymi oraz zakresem zastosowań. Poniższe porównanie ukazuje mocne i słabe strony każdego podejścia oraz wskazuje kontekst ich optymalnego wykorzystania. Z uwagi na różnorodność zastosowań i uwarunkowań technicznych, wybór odpowiedniego modelu do predykcji powinien być determinowany m.in. zakresem dostępnych danych, poziomem zmienności środowiska pracy oraz wymaganiami dotyczącymi interpretowalności wyników. Poniższa Tabela 9 zestawia modele zużycia energii oparte na opisie fizyczno-strukturalnym, modele oparte na danych wykorzystujące metod uczenia maszynowego i modele hybrydowe pod kątem wybranych kryteriów jakości predykcji i praktycznego zastosowania.

Tabela 9 Charakterystyka modeli predykcyjnych stosowanych w szacowaniu zużycia energii przez roboty mobilne.

Kryterium	Modele zużycia energii oparte na opisie fizyczno-strukturalnym	Modele oparte na danych wykorzystujące metody uczenia maszynowego	Modele hybrydowe
Zasada działania	Równania mechaniki, bilanse energetyczne	Uczenie wzorców z danych (ML: ANN, RNN, RT)	Połączenie cech fizycznych z ML / korekty modeli
Wymagana wiedza domenowa	Bardzo wysoka	Niska / umiarkowana	Umiarkowana do wysokiej
Wymagania danych wejściowych	Wiedza o systemie	Duży zbiór danych treningowych	Umiarkowane Dane fizyczne + empiryczne
Dokładność predykcji	Bardzo wysoka (w znanych warunkach)	Wysoka (w podobnych warunkach)	Potencjalnie najwyższa (adaptacyjność + wiedza)
Zdolność do adaptacji	Bardzo niska	Wysoka	Wysoka
Uniwersalność	Ograniczona (silna zależność od robota/terenu)	Wysoka (możliwość skalowania do floty)	Wysoka
Złożoność implementacji	Bardzo wysoka (modelowanie, kalibracja)	Średnia-wysoka (zbieranie danych, trenowanie)	Wysoka (łączenie modeli, walidacja)
Wymagania sprzętowe	Niskie (w symulacji), Średnie (czas rzeczywisty)	Wysokie (dla dużych modeli ML)	Wysokie
Czas wdrożenia	Długi - czasochłonne opracowanie modelu	Średni do długiego - potrzeba zebrania i przygotowania danych oraz trenowania modelu;	Najdłuższy - konieczne opracowanie modelu fizycznego i zebranie danych do komponentu ML
Interpretowalność	Wysoka	Średnia / niska	Średnia
Zastosowania	Stabilne środowiska znane profile misji	Zmienność, floty, szybkie wdrożenia	Środowiska częściowo znane, dynamiczne

Wybór metody predykcji zużycia energii powinien być ściśle uzależniony od warunków operacyjnych, dostępnych danych oraz celu wdrożenia. **W kontekście komercyjnych robotów AMR największy potencjał aplikacyjny wykazują modele oparte na danych, w szczególności klasyczne algorytmy uczenia maszynowego.** Cechuje je stosunkowo krótki czas wdrożenia, niewielkie wymagania obliczeniowe oraz brak konieczności znajomości wewnętrznej architektury robota, co umożliwia ich adaptację do zamkniętych systemów. Dodatkową zaletą jest możliwość skalowania ich na wiele platform oraz integracja z systemami zarządzania flotą. Modele te mogą być wdrażane zarówno poprzez ręczny dobór metody uczenia i strojenie parametrów, co zapewnia pełną kontrolę i większą przejrzystość działania, jak i z wykorzystaniem AutoML, które automatyzuje proces uczenia - ogranicza możliwość ingerencji w strukturę i parametry, lecz umożliwia szybkie wdrażanie rozwiązań opartych na danych z pomiarów empirycznych, nawet przy mniejszej wiedzy specjalistycznej, stanowiąc tym samym atrakcyjną alternatywę dla przemysłu.

Modele hybrydowe, choć oferują najwyższą precyzję i elastyczność, pozostają obecnie trudne do wdrożenia w warunkach przemysłowych ze względu na wysoką złożoność i wymagania interdyscyplinarne. Z kolei modele fizyczno-strukturalne, mimo dużej wartości poznawczej, są ograniczone do środowisk prototypowych, gdzie pełna znajomość konstrukcji robota jest dostępna.

Przeprowadzona w tym rozdziale analiza literatury pozwala zdefiniować następujące wnioski:

- Większość dotychczasowych prac dotyczy robotów badawczych (prototypowych) o znanych parametrach konstrukcyjnych i pełnym dostępie do metod sterowania lub do jednego typu misji.
- Zastosowania modeli predykcyjnych w odniesieniu do komercyjnych robotów AMR są marginalne, głównie z powodu ograniczonego dostępu do szczegółowej wiedzy o ich parametrach konstrukcyjnych oraz wewnętrznych mechanizmach działania.
- Niewiele publikacji podejmuje próbę systematycznej identyfikacji danych operacyjnych, które powinny być rejestrowane i wykorzystywane w modelach predykcyjnych. Modele rzadko integrują dane z różnych kategorii zmiennych (misji, środowiskowych, diagnostycznych).
- Rzadko analizowany jest wpływ zmiennych wejściowych na wynik predykcji, co utrudnia ich wykorzystanie do optymalizacji misji pod kątem zużycia energii.
- Dominują podejścia jednostkowe, skupione na jednym robocie, bez propozycji skalowalnych metod możliwych do zastosowania w różnych typach platform.
- nie są projektowane z myślą o bezpośrednim wykorzystaniu w systemach zarządzania flotą, np. w ocenie wykonalności zadań czy planowaniu strategii ładowania.

Wnioski z przeprowadzonej analizy literatury pozwoliły zidentyfikować luki badawcze, wskazujące na potrzebę opracowania podejścia umożliwiającego budowę adaptacyjnych, uniwersalnych modeli predykcyjnych, możliwych do zastosowania w komercyjnych robotach AMR. Modele te powinny wykorzystywać dane dostępne w typowych systemach przemysłowych, minimalizując zależność od wewnętrznej struktury robota. Kierunek ten stanowi zasadniczy obszar dalszych prac i wpisuje się w potrzeby rzeczywistego przemysłu, w którym predykcja zużycia energii może stać się elementem systemowego zarządzania flotą, planowania zadań i optymalizacji kosztów operacyjnych.

3 Cel pracy, zadania i przyjęta metodyka badawcza

Rozdział przedstawia założenia metodologiczne rozprawy, obejmujące identyfikację luki badawczej, sformułowanie celu głównego, zadań badawczych i utylitarnych. Omówiono także przyjęte podejścia metodologiczne oraz uzasadniono wybór metod badawczych w kontekście problematyki zużycia energii w robotach mobilnych. Rozdział porządkuje strukturę badań i wskazuje logiczną sekwencję etapów realizacji pracy.

3.1 Identyfikacja luki badawczej

Analiza przedstawiona w rozdziale 1 wykazała, że AMR stanowią kluczowy element rozwoju nowoczesnych systemów intralogistycznych, umożliwiając elastyczne, bezpieczne i efektywne realizowanie zadań transportowych w zmiennych warunkach operacyjnych. Jednocześnie zidentyfikowano szereg barier ograniczających pełne wykorzystanie ich potencjału, w tym:

- brak zaawansowanych metod planowania zadań uwzględniających aktualny stan energetyczny robotów w systemach FMS,
- niedostosowanie harmonogramów ładowania do bieżących potrzeb, stanu floty i obciążenia infrastruktury,
- brak mechanizmów weryfikacji wykonalności zakolejkowanych misji z uwzględnieniem zmiennych środowiskowych i diagnostycznych.

Rozdział 2, poświęcony metodom predykcji zużycia energii w AMR, wskazał, że w literaturze istnieją różne podejścia od modeli fizyczno-strukturalnych, przez metody oparte na uczeniu maszynowym, po modele hybrydowe. Przeprowadzona analiza literatury wykazała, że:

- większość dotychczasowych prac dotyczy robotów badawczych (prototypowych) o znanych parametrach konstrukcyjnych i pełnym dostępie do metod sterowania lub do jednego typu misji,
- zastosowania modeli predykcyjnych w odniesieniu do komercyjnych robotów AMR są marginalne, głównie z powodu ograniczonego dostępu do szczegółowej wiedzy o ich parametrach konstrukcyjnych oraz wewnętrznych mechanizmach działania,
- niewiele publikacji podejmuje próbę systematycznej identyfikacji danych operacyjnych, które powinny być rejestrowane i wykorzystywane w modelach predykcyjnych. Modele rzadko integrują dane z różnych kategorii zmiennych (misji, środowiskowych, diagnostycznych),
- rzadko analizowany jest wpływ zmiennych wejściowych na wynik predykcji, co utrudnia ich wykorzystanie do optymalizacji misji pod kątem zużycia energii,
- dominują podejścia jednostkowe, skupione na jednym robocie, bez propozycji skalowalnych metod możliwych do zastosowania w różnych typach platform,
- nie są projektowane z myślą o bezpośrednim wykorzystaniu w systemach zarządzania flotą, np. w ocenie wykonalności zadań czy planowaniu strategii ładowania.

Zidentyfikowane ograniczenia wskazują na brak uniwersalnych modeli predykcji zużycia energii dedykowanych komercyjnym robotom AMR, możliwych do integracji w systemach flotowych i wspierających inteligentne zarządzanie robotami mobilnymi w dynamicznych środowiskach przemysłowych. Na tej podstawie sformułowano następującą lukę badawczą:

Brak uniwersalnego, wieloparametrycznego modelu predykcji zużycia energii dla komercyjnych autonomicznych robotów mobilnych pracujących w środowisku intralogistycznym, który łączyłby zmienne opisujące misję, uwarunkowania środowiskowe i parametry diagnostyczne robota oraz integrował wyniki predykcji z procesami oceny wykonalności zadań.

3.2 Cel główny

Wypełnienie luki badawczej zdefiniowanej w rozdziale 3.1 jest kluczowe zarówno z perspektywy rozwoju teorii w zakresie modelowania zużycia energii przez AMR, jak i w kontekście praktycznych potrzeb przemysłu. Mając to na uwadze, sformułowano następujący główny cel pracy:

Celem pracy jest opracowanie i weryfikacja modelu predycyjnego zużycia energii dla komercyjnych autonomicznych robotów mobilnych (AMR). Opracowany model pozwoli na szacowanie zapotrzebowania energetycznego misji i wsparcie decyzji dotyczących zarządzania flotą w intralogistyce, zwiększając autonomię robota poprzez ocenę wykonalności zakolejkowanych zadań oraz wczesne wykrywanie zakłóceń.

Realizacja celu głównego pracy będzie przebiegać w ramach wieloetapowego procesu, obejmującego konstruowanie i ocenę kilku wariantów modeli predycyjnych. W pierwszej kolejności rozważone zostaną proste modele regresyjne (np. wielomianowe), następnie modele statystyczne oparte na metodach uczenia maszynowego o charakterze jawnym (*ang. white-box*), umożliwiające interpretację zależności pomiędzy zmiennymi. Kolejnym etapem będzie zastosowanie podejść zautomatyzowanych (AutoML), prowadzących do budowy modeli niejawnych (*ang. black-box*), których główną zaletą jest potencjalnie wyższa dokładność predykcji, przy ograniczonej interpretowalności. Modele te stanowią etapy pośrednie, umożliwiające systematyczną ocenę przydatności danych wejściowych, dokładności predykcji oraz poziomu interpretowalności uzyskanych wyników. Na tej podstawie wytypowany zostanie model docelowy, który spełni zarówno wymagania naukowe, jak i praktyczne.

Opracowanie modelu predycyjnego zużycia energii dla komercyjnych autonomicznych robotów mobilnych (AMR) stanowi rozwinięcie dotychczasowych podejść, które w większości koncentrowały się na robotach prototypowych oraz jednostkowych scenariuszach misji, pozbawionych możliwości skalowania i integracji w systemach flotowych. Realizacja tego celu obejmuje aspekt naukowy, polegający na opracowaniu i ocenie modeli predycyjnych opartych na różnych podejściach (model regresyjny, model statystyczny oparty na metodach uczenia maszynowego, AutoML), z uwzględnieniem danych dotyczących przebiegu misji, parametrów środowiskowych oraz informacji diagnostycznych AMR. Z drugiej strony, cel pracy posiada także wymiar **praktyczny**, związany z zastosowaniem opracowanego modelu do wspierania procesów zarządzania flotą w intralogistyce, w tym:

- szacowania zapotrzebowania energetycznego misji,
- oceny wykonalności zakolejkowanych zadań,
- wczesnego wykrywania anomalii operacyjnych.

W ten sposób opracowany model predycyjnego zużycia energii dla komercyjnych autonomicznych robotów mobilnych (AMR) pozwoli zwiększać autonomię robotów oraz wspierać inteligentne zarządzanie systemami intralogistycznymi, przyczyniając się zarówno do rozwoju teorii w obszarze predykcji energetycznej, jak i do poprawy efektywności praktycznych wdrożeń w przemyśle.

3.3 Zadania szczegółowe

W ramach realizacji celu głównego pracy dokonano identyfikacji zestawu istotnych parametrów wpływających na zużycie energii w kontekście operacyjnym AMR, uwzględniając zarówno charakterystykę misji (dystans, typ zadania, środowisko), parametry robota jak i otoczenia. Na podstawie przeglądu literatury i analizy istniejących podejść opracowano kilka wariantów modelu predycyjnego opartego na uczeniu maszynowym. Porównano je pod względem dokładności, możliwości interpretacji oraz potencjału wdrożeniowego dla komercyjnych robotów AMR. Wytypowano także podzbiór parametrów wejściowych o największym wpływie na wynik predykcji. Jako zadania szczegółowe, stanowiące pewien rodzaj etapów niezbędnych do realizacji celu głównego pracy, określono następujące szczegółowe **zadania badawcze (B) i uylitarne (U)**, które zestawiono poniżej (Tabela 10, Tabela 11).

Tabela 10 Szczegółowe zadania badawcze wynikające z celu głównego rozprawy oraz wskazanie miejsc ich realizacji w pracy.

Nr zad.	Zadania badawcze	Realizacja w rozprawie
1B	Porównanie i ocena wybranych cech systemów AGV i AMR w kontekście ich zastosowania w różnych środowiskach produkcyjnych, umożliwiające określenie, które rozwiązanie lepiej odpowiada specyfice danego zakładu oraz ułatwiające dobór technologii adekwatnej do wymagań operacyjnych	Rozdział 1.2 Tabela 2
2B	Porównanie funkcjonalności wybranych komercyjnych systemów zarządzania flotą robotów mobilnych w kontekście stosowanych metod monitorowania i zarządzania energią	Rozdział 1.3 Tabela 3
3B	Analiza i klasyfikacja istniejących metod predykcji zużycia energii w robotach mobilnych oraz identyfikacja ich ograniczeń istotnych z punktu widzenia zastosowań przemysłowych	Rozdział 2.2 Tabela 8 Tabela 9
4B	Rozwinięcie i uzupełnienie klasyfikacji modeli predykcji zużycia energii w robotach mobilnych o szczegółowy podział wewnętrzny	Rozdział 2 Rys. 17
5B	Identyfikacja i systematyzacja zmiennych wejściowych istotnych dla predykcji zużycia energii w AMR, z uwzględnieniem parametrów misji, środowiska oraz stanu robota	Rozdział 4.3 Rys. 29
6B	Opracowanie planu eksperymentów rejestrujących dane operacyjne i energetyczne z misji AMR	Rozdział 5.1 Tabela 14 Tabela 17 Rys. 33
7B	Opracowanie jednoparametrycznego modelu predykcyjnego (M1) zużycia energii AMR, opartego na regresji (np. wielomianowej), dla pojedynczej misji, w celu ustanowienia punktu odniesienia dla dalszych analiz	Rozdział 6.1 Równanie 10
8B	Opracowanie dwóch wariantów wieloparametrycznych modeli predykcyjnych zużycia energii AMR: modelu statystycznego opartego na metodach uczenia maszynowego o charakterze jawnym (M2) oraz modelu w podejściu AutoML(M3).	Rozdział 6.2, Równanie 11 Rozdział 6.3
9B	Analiza i ocena wpływu poszczególnych zmiennych wejściowych na dokładność predykcji modeli (ocena ważności cech)	Rozdział 6.5 Tabela 43 Tabela 44
10B	Porównanie modelu statystycznego (M2) oraz modelu w podejściu AutoML (M3) pod kątem jakości predykcji, interpretowalności wyników, złożoności strukturalnej oraz potencjału wdrożeniowego.	Rozdział 6.4 Tabela 42

Tabela 11 Szczegółowe zadania utylitarne wynikające z celu głównego rozprawy oraz wskazanie miejsc ich realizacji w pracy.

Nr zad.	Zadania utylitarne	Realizacja w rozprawie
1U	Budowa i uruchomienie stanowiska pomiarowego do rejestracji danych AMR, obejmującego dobór protokołów komunikacyjnych, elementów sprzętowych i architektury systemu akwizycji.	Rozdział 5.2 Tabela 20 Tabela 23 Rys. 41
2U	Opracowanie i implementacja prototypowego systemu do oceny wykonalności zakolejkowanych misji AMR, integrującego modele predykcyjne zużycia energii z systemem nadzorczym w Node-RED	Rozdział 6.1 Rys. 50
3U	Opracowanie i implementacja prototypowego systemu wykrywania anomalii na drodze transportowej podczas realizacji misji AMR, integrującego modele predykcyjne zużycia energii z systemem nadzorczym w Node-RED	Rozdział 6.1 Rys. 47
4U	Ocena modelu statystycznego opartego na metodach uczenia maszynowego (M2) i AutoML(M3) pod kątem łatwości wdrożenia w systemach zarządzania flotą.	Rozdział 6.4 Tabela 42
5U	Określenie potencjału rozszerzenia modeli o dodatkowe funkcje	Rozdział 7.5

3.4 Zastosowane metodyki i metody badawcze


Do realizacji celu głównego pracy zastosowano podejścia badawcze oparte na kilku uzupełniających się metodykach oraz odpowiednio dobranych metodach badawczych, dostosowanych do charakteru prowadzonych badań. Ich systematyczne zestawienie przedstawiono poniżej (Tabela 12) [171], [172], [173], [174], [175], [176].

Tabela 12 Struktura procesu badawczego: etapy, cele, zastosowane metody i oczekiwane produkty

Zadanie	Etap badawczy	Cel zastosowania	Metodyka badawcza	Metoda badawcza	Produkt etapu
1B 2B 3B 4B	1. Analiza literatury	Identyfikacja luk badawczych i ograniczeń istniejących metod predykcji zużycia energii	Analiza literaturowa	Przegląd systematyczny i porównawczy literatury	Raport z przeglądu, macierz publikacje–cechy, lista luk.
5B	2. Identyfikacja zmiennych wejściowych modelu predykcyjnego zużycia energii przez AMR	Określenie zestawu zmiennych wejściowych wpływających na zużycie energii AMR	Eksploracyjna (analiza ekspercka)	Diagram Ishikawy, analiza przyczynowo skutkowa.	Tabela zestawu zmiennych wejściowych modelu, diagram Ishikawy.
6B	3. Planowanie eksperymentu	Opracowanie scenariuszy eksperymentów umożliwiających rejestrację danych	Empiryczna (z elementami DoE - Design of Experiments)	Projekt scenariuszy pomiarowych (liczba powtórzeń, poziomy czynników), arkusz planu pomiarów	Plan eksperymentu: zestaw scenariuszy i liczby cykli, arkusz planu pomiarów
	4. Gromadzenie danych z misji AMR	Zebrań danych operacyjnych i energetycznych w warunkach kontrolowanych i rzeczywistych	Empiryczna	Rejestracja danych z misji AMR MiR100	Surowy zbiór danych / logi z misji.
7B	6. Modelowanie M1	Weryfikacja poprawności systemu pomiarowego i jakości danych. Opracowanie modelu referencyjnego dla pojedynczej misji AMR	Modelowanie predykcyjne	Regresja	Model regresyjny (np. wielomianowy) (M1) , służący jako punkt odniesienia do dalszych analiz
	7. Analiza wyników modelu M1	Ocena jakości prostego modelu M1, identyfikacja ograniczeń i wniosków do dalszego modelowania	Analiza ilościowa	Ocena metryk (R^2)	Wnioski i rekomendacje do budowy kolejnych modeli (M2, M3)
	8. Gromadzenie danych wieloparametrycznych z misji AMR	Rozszerzenie bazy danych o większą liczbę misji, obejmujących różnorodne parametry wejściowe	Empiryczna	Rejestracja danych z misji AMR MiR100	Surowy zbiór danych wieloparametrycznych (logi)
8B 9B	9. Modelowanie statystyczne oparte na ML (M2)	Wybór kluczowych zmiennych istotnych dla dokładności predykcji	Eksploracyjna	np. Regresja krokowa (<i>stepwise regression</i> / <i>LASSO</i>)	Model statystyczny oparty na ML o charakterze jawnym (M2) - Ważność cech dla modelu, lista wybranych predyktorów.
		Opracowanie modelu dla predykcji zużycia energii (white box) - M2	Modelowanie predykcyjne	np. Regresja liniowa uogólniona	Parametry modelu, metryki, wykresy diagnostyczne
8B 9B	10. Modelowanie oparte na AutoML (M3)	Opracowanie modelu dla predykcji zużycia energii (black-box) - M3	Modelowanie predykcyjne	Zautomatyzowane uczenie maszynowe (AutoML)	Model AutoML o charakterze niejawnym (M3) , metryki
		Określenie wpływu cech wejściowych na wynik modelu, porównanie z wynikami regresji	Eksploracyjna / Ilościowa	Wartości Shapleya	Profile ważności cech, raport interpretacji.
10B	11. Walidacja modeli	Ocena dokładności predykcji, generalizacja modelu	Ilościowa	Krosvalidacja, metryki MAPE, R^2 , AR-S	Tabela metryk i wnioski o generalizacji

Mapa rozdziałów (Rys. 24) obrazuje logiczny układ treści pracy, w którym kolejne etapy badań zostały uporządkowane w sposób chronologiczny. Zawiera ona zarówno zadania badawcze, jak i uptytarne, a także odniesienia do miejsc w rozprawie, gdzie przedstawiono uzyskane odpowiedzi i wyniki. Dzięki temu schemat pełni funkcję przewodnika, porządkującego przebieg procesu badawczego oraz lokalizującego rezultaty poszczególnych etapów.

3.5 Mapa rozdziałów rozprawy doktorskiej oraz zrealizowanych zadań badawczych i utylitarnych




Rys. 24 Mapa rozdziałów rozprawy doktorskiej oraz zrealizowanych szczegółowych zadań badawczych i utylitarnych

4 Identyfikacja zmiennych wejściowych modelu predykcyjnego zużycia energii przez AMR

Celem rozdziału jest wyznaczenie zestawu zmiennych wejściowych (predyktorów), które będą stanowić podstawę dla budowy modelu predykcyjnego zużycia energii AMR. Rozdział prezentuje autorskie podejście do identyfikacji czynników wpływających na zużycie energii przez autonomiczne roboty mobilne. W pierwszej części rozdziału przeanalizowano czynniki wpływające na zużycie energii na podstawie analizy literatury, a następnie skonfrontowano je z ujęciem teoretycznym obejmującym mechanizmy bilansu energetycznego oraz sprawności podsystemów robota. Pozwoliło to zweryfikować kompletność zestawu oraz wskazać dodatkowe aspekty nieuwzględnione w dotychczasowych badaniach. Kolejnym krokiem była redukcja czynników do zbioru najbardziej informatywnych i możliwych do pomiaru, co wsparte zostało analizą przyczynowo skutkową w postaci diagramu Ishikawy.

Efektywna predykcja zużycia energii w robotach mobilnych wymaga nie tylko doboru odpowiednich metod, lecz przede wszystkim precyzyjnego określenia czynników wpływających na zużycie energii w robotach mobilnych podczas realizacji misji. W rozdziale 3.1 wskazano istotne luki badawcze w tym obszarze: brak systematycznej identyfikacji danych operacyjnych, ograniczoną analizę wpływu zmiennych wejściowych na wynik predykcji oraz dominację podejść jednostkowych, skupionych na pojedynczych platformach. **Dlatego w niniejszym rozdziale skoncentrowano się na identyfikacji czynników wpływających na zużycie energii przez roboty AMR, które będą pełnić rolę zmiennych wejściowych (predyktorów) w modelu predykcji energii.** Logikę tego etapu badań od identyfikacji czynników wpływających na zużycie energii, przez ich formalizację jako predyktorów, aż do wykorzystania w modelu predykcyjnym zilustrowano poniżej (Rys. 25).



Rys. 25 Schemat przejścia od identyfikacji czynników wpływających na zużycie energii (diagram Ishikawy), poprzez ich wykorzystanie jako zmienne wejściowe (predyktory), do modelu predykcyjnego zużycia energii AMR.

Skuteczność modeli predykcyjnych w kontekście szacowania zużycia energii przez autonomiczne roboty mobilne zależy w dużej mierze od prawidłowego doboru **predyktorów**. Nadmiar predyktorów, zwłaszcza redundantnych, silnie skorelowanych lub niemających istotnego związku z mechanizmem generowania odpowiedzi, może prowadzić do przetrenowania modelu, zwiększonej złożoności obliczeniowej oraz obniżenia zdolności generalizacji. Z tego względu istotne jest ograniczenie przestrzeni wejściowej do podzbioru najbardziej informacyjnych predyktorów, które pozwalają na zachowanie równowagi między złożonością modelu a jego zdolnością do uogólniania wiedzy na nowe przypadki

W niniejszej pracy zaproponowano **trójetapowe hybrydowe podejście** do identyfikacji i oceny ważności zmiennych wejściowych (predyktorów) modelu predykcji zużycia energii AMR - Rys. 26.

- **Etap 1 (rozdział 4)** obejmuje identyfikację teoretyczno-literaturową: przegląd literatury zestawiony z klasycznymi równaniami mechaniki ruchu (bilans sił / mocy) oraz warstwą sprawnościową układu (mechaniczną i elektryczną), a także modelem komponentowym poboru energii. Na tej podstawie wyznaczane są kategorie potencjalnych predyktorów.

- **Etap 2 (rozdział 4)** stanowi systematyzację jakościową z wykorzystaniem analizy przyczynowo skutkowej (diagramu Ishikawy), której celem jest wyłonienie pełnego zestawu predyktorów możliwych do pozyskania i wykorzystania w modelu predykcyjnym. Etap ten stanowi pomost między analizą teoretyczną a empiryczną, definiując zmienne wejściowe przyjęte do dalszego modelowania.
- **Etap 3 (rozdział 6)** ma charakter ilościowy i obejmuje ocenę istotności oraz wpływu poszczególnych predyktorów na wynik predykcji po zbudowaniu modeli. Wykorzystano w nim metody selekcji i oceny ważności zmiennych (np. LASSO, wartości Shapleya, regresję krokową), umożliwiające identyfikację zestawu predyktorów o największym znaczeniu dla dokładności prognozy zużycia energii.



Rys. 26 Trójetapowe hybrydowe podejście do identyfikacji i selekcji predyktorów zużycia energii AMR.

Takie połączenie podejścia heurystycznego i analitycznego umożliwi skuteczną redukcję predyktorów przy jednoczesnym zachowaniu najistotniejszych informacji dla modelu.

4.1 Klasyfikacja czynników wpływających na zużycie energii

W rozdziale 2 wykazano, że zużycie energii przez robota mobilnego nie ogranicza się wyłącznie do zasilania układu lokomocyjnego. Jak pokazano w analizie eksperymentalnej zawartej w publikacji [60], w przypadku konkretnego robota mobilnego ponad 50% całkowitej mocy pobieranej przypadło na lokomocję, natomiast obliczenia i sensoryka stanowiły odpowiednio 33% oraz 11% zapotrzebowania energetycznego. Wynik ten wskazuje jednoznacznie, że model opisujący zużycie energii powinien uwzględniać nie tylko parametry związane z ruchem, masą i środowiskiem, ale również architekturę systemów pokładowych, charakterystykę algorytmów sterowania, aktywność sensoryki oraz profil zadaniowy. W związku z powyższym, poniżej przedstawiono wstępny przegląd czynników mających wpływ na całkowite zużycie energii przez roboty mobilne. Przegląd ten ma charakter ogólny i służy jako punkt wyjścia do dalszego zawężenia zbioru czynników wpływających na zużycie energii w odniesieniu do konkretnej platformy mobilnej, środowiska operacyjnego oraz typu wykonywanej misji.

Przedstawiona klasyfikacja ma charakter autorski na podstawie analizy strukturalnej systemów mobilnych robotów autonomicznych oraz identyfikacji potencjalnych źródeł zużycia energii. W ramach przeglądu literatury przeanalizowano istniejące modele predykcyjne, ze szczególnym uwzględnieniem stosowanych w nich predyktorów. Na tej podstawie dokonano autorskiej systematyzacji czynników w sześć podgrup, odzwierciedlających główne źródła zużycia energii w robotach mobilnych. Tabela 13 przedstawia aktualny stan wiedzy w tym zakresie, wraz z przykładami prac, w których poszczególne czynniki zostały wykorzystane jako zmienne wejściowe w modelach predykcyjnych.

Tabela 13 Grupy czynników mających wpływ na zużycie energii w robotach mobilnych - zestawienie źródeł literaturowych.

Grupa czynników	Wybrana cecha (predyktor)	Przykładowe źródła literaturowe
Czynniki konstrukcyjne i mechaniczne	masa robota	[60], [152]
	rozkład masy (moment bezwładności)	[60], [93]
	liczba kół (napędzanych i biernych)	[60]
	liczba silników i ich konfiguracja	[60]
	powierzchnia czołowa	[128]
	parametry silników (moment, sprawność)	[118],
	rodzaj napędu kinematycznego (skid, dyferencjalny, mecanum)	[60], [93]
	typ napędu (koła, gąsienice)	[113]
	akcesoria robota	[52]
Czynniki układu zasilania	typ źródła zasilania	[60], [93]
	SoC akumulatora	[116], [128]
	aktualne napięcie pod obciążeniem	[155]
	temperatura akumulatora	[110], [128]
	odzysk energii (rekuperacja)	[60]
	pojemność akumulatora	[60], [128]
	czas używania akumulatora (degradacja) - SoH	[128], [144]
Czynniki systemów sterowania i sensoryki pokładowej	tryb pracy robota (czuwanie (IDLE), jazda, manewrowanie, bezczynność)	[93], [117]
	liczba aktywnych sensorów	[60], [93]
	zużycie energii przez sensory	[60], [139]
	częstotliwość odczytu z sensorów	[60], [93]
	ilość danych do przetworzenia (nawigacja)	[60]
	zużycie energii przez systemy sterowania - tryb pracy	[60], [93], [117]
Czynniki kinematyczno-dynamiczny ruchu	średnia prędkość liniowa	[60], [93], [177]
	średnia prędkość kątowna	[52], [60], [93]
	przyspieszenie liniowe i kątowe	[60], [93]
	siły/momenty działające na układ napędowy	[134]
	typ ruchu (jazda do przodu, skręcanie, cofanie, zatrzymywanie się)	[52], [93]
	rodzaj algorytmu sterowania napędami	[60]
Czynniki zadaniowe (misji)	metoda planowania trasy	[60], [130]
	obciążenie robota (ładunek, jego rozkład)	[60], [93]
	długość trasy	[93], [154]
	liczba zakrętów	[93], [134]

Czynniki środowiskowe	uksztaltowanie otoczenia (np. wąskie przejścia)	[38], [60], [153]
	krzywizna trajektorii	[38], [52], [60]
	typ nawierzchni (parametryzowany jako współczynnik tarcia)	[60], [93]
	nachylenie terenu (wzdłuż i poprzecznie do kierunku jazdy)	[60], [93]
	temperatura otoczenia	[128], [164]
	opory aerodynamiczne	[93], [134]
	opory toczenia	[60], [130]
	opory trakcyjne	[60], [165]

Należy podkreślić, że zaprezentowany przegląd literatury, mimo że obejmuje szerokie spektrum czynników wykorzystywanych w istniejących modelach predykcyjnych, nie wyczerpuje w pełni możliwych źródeł zmienności energetycznej. Modele opisywane w przytoczonych publikacjach są z reguły dostosowane do specyfiki pojedynczych platform lub środowisk działania, co może prowadzić do pominięcia istotnych aspektów. Dlatego w kolejnym etapie analizę literaturową uzupełniono o podejście teoretyczne, obejmujące formalny opis procesów energetycznych w robotach mobilnych. Wykorzystano tu zarówno klasyczne równania bilansu sił i mocy, jak i modele sprawności mechanicznej oraz elektrycznej, a także ujęcia komponentowe opisujące zużycie energii przez sensorykę, systemy sterowania i podzespoły elektroniczne. Takie wielowarstwowe podejście pozwala zweryfikować kompletność zestawu czynników wpływających na zużycie energii robotów mobilnych zidentyfikowanych w literaturze oraz wskazać dodatkowe parametry, które potencjalnie mogą mieć istotny wpływ na całkowite zużycie energii przez robota mobilnego.

Jednym z najbardziej intuicyjnych i jednocześnie fizycznie uzasadnionych podejść określających podstawowe parametry mające wpływ na zużycie energii jest bilans sił działających na robota w czasie przemieszczania się. Pozwala on zidentyfikować kluczowe składniki wymagające pokonania przez układ napędowy oraz oszacować moc mechaniczną niezbędną do wykonania zadanej trajektorii [178]. W analizie przyjęto uproszczony przypadek robota poruszającego się pod górę z ustaloną prędkością v , po nachylonej powierzchni o kącie θ , przy znanej masie całkowitej układu m . Uproszczenie to pozwala wyodrębnić podstawowe siły oporów oraz składniki dynamiczne, bez konieczności uwzględniania złożonej geometrii trajektorii i zmienności obciążenia.

Bilans sił wzdłuż kierunku ruchu przyjmuje postać [178] :

$$F_{napęd} = F_g + F_{tocz} + F_{aero} + F_a + F_{skr} + F_{pos} + F_{start} + F_{dod} \quad (3)$$

Gdzie:

- F_g - Siła grawitacji na pochyłości,
- F_{tocz} - Opór toczenia,
- F_{aero} - Opór aerodynamiczny,
- F_a - Siła bezwładności (przyspieszenia),
- F_{skr} - Opory przy skręcie (szczególnie w skid-steer),
- F_{pos} - Poślizg kół / gąsienic,
- F_{start} - Siła przewyżczająca opory początkowe,
- F_{dod} - Inne nieujęte siły

Rozpisanie poszczególnych składowych bilansu sił w oparciu o parametry konstrukcyjne i środowiskowe prowadzi do następującej postaci równania:

$$F_{napęd} = m \cdot g \cdot \sin\theta + \mu_t \cdot m \cdot g \cdot \cos\theta + \frac{1}{2} \cdot \rho \cdot C_d \cdot A \cdot v^2 + m \cdot a + \alpha_{skr} \cdot m \cdot g + F_{pos} + \mu_{start} \cdot m \cdot g + F_{dod} \quad (4)$$

Gdzie:

- m** - masa robota,
- g** - przyspieszenie grawitacyjne,
- θ** - nachylenie terenu,
- μ_t** - współczynnik dynamiczny oporu toczenia (zależny od podłoża),
- ρ** - gęstość powietrza,
- C_d** - współczynnik oporu aerodynamicznego,
- A** - powierzchnia czołowa robota,
- V** - prędkość robota,
- a** - przyspieszenie liniowe robota,
- α_{skr}** - współczynnik empiryczny zależny od sposobu skrętu, rodzaju podłoża i rozstawu kół,
- F_{pos}** - Poślizg kół / gąsienic (modelowane empirycznie),
- μ_{start}** - współczynnik statyczny oporu toczenia (zależny od podłoża).

Wyznaczenie tej siły umożliwia następnie oszacowanie energii w czasie t jaka musi zostać wykorzystana przez układ napędowy:

$$E_c = F_{napęd} \cdot v \cdot t \quad (5)$$

Zastosowanie klasycznego bilansu sił jako podstawy modelowania energetycznego robota mobilnego umożliwia identyfikację i ilościowe opisanie podstawowych parametrów wpływających na zużycie energii w trakcie ruchu. Model ten uwzględnia fizyczne składniki oporów takich jak siła grawitacji na pochyłości, opór toczenia, opór aerodynamiczny i siły bezwładnościowe co zapewnia wysoką interpretowalność oraz intuicyjne powiązanie parametrów konstrukcyjnych i środowiskowych z wymaganym wysiłkiem napędowym. Podejście to pozwala nie tylko oszacować minimalną moc mechaniczną niezbędną do pokonania oporów ruchu, ale również przeprowadzić analizę wrażliwości poszczególnych parametrów, takich jak masa robota, kąt nachylenia terenu czy typ nawierzchni.

Należy jednak podkreślić, że model bilansu sił choć użyteczny w pierwszym etapie analizy nie uwzględnia wewnętrznych strat wynikających z ograniczonej sprawności mechanicznej podzespołów, takich jak silniki, przekładnie czy mechanizmy przeniesienia napędu. Dlatego w dalszej części analizy konieczne jest uzupełnienie modelu o warstwę sprawnościową, która pozwoli na realistyczne odwzorowanie zapotrzebowania na energię z punktu widzenia rzeczywistego obciążenia mechanicznego układu napędowego [178], [179].

$$\eta_{mechaniczna} = \eta_{silnika} \cdot \eta_{przekładni} \cdot \eta_{sprzęgieł} \cdot \eta_{łożysk} \cdot \dots \quad (6)$$

Wartość $\eta_{mechaniczna}$ umożliwia przeliczenie teoretycznej energii, wyznaczonej na podstawie bilansu sił, na rzeczywistą energię, jaka musi być dostarczona do układu napędowego, aby pokryć straty wynikające z nieidealnej transmisji energii w systemie mechanicznym.

Rozszerzając analizę poza układ mechaniczny, należy uwzględnić również straty wynikające z ograniczonej sprawności komponentów elektronicznych odpowiedzialnych za konwersję, dystrybucję i kontrolę przepływu energii w systemie. Dotyczy to w szczególności źródeł zasilania (np. akumulatorów), przetwornic, sterowników napędów oraz układów zabezpieczeń energetycznych. W tym celu wprowadza się model sprawności układu zasilania, wyrażony jako iloczyn sprawności poszczególnych elementów toru energetycznego [178].

$$\eta_{elektryczna} = \eta_{baterii} \cdot \eta_{przetwornic} \cdot \eta_{sterowników} \cdot \dots \quad (7)$$

Zastosowanie tego modelu umożliwia oszacowanie rzeczywistej ilości energii, jaka musi zostać pobrana ze źródła zasilania w celu pokrycia zapotrzebowania energetycznego wynikającego z bilansu sił, strat mechanicznych i elektrycznych.

W kontekście rzeczywistych zastosowań należy dodatkowo uwzględnić wpływ takich czynników jak: temperatura otoczenia i komponentów (oddziałująca na sprawność), procesy degradacji źródeł zasilania (np. starzenie ogniw litowo-jonowych), a także charakterystyka przyjętych metod sterowania (mająca wpływ na profil obciążeniowy układów napędowych). Czynniki te, choć często pomijane w uproszczonych analizach, mogą stanowić istotny składnik końcowego zużycia energii przez robota mobilnego.

Zgodnie z wynikami prezentowanymi w literaturze [60], zużycie energii przez komponenty mechaniczne i układ napędowy nie stanowią jedyne istotnego składnika bilansu energetycznego robota mobilnego. W praktyce znaczący udział w całkowitym zużyciu energii mają także komponenty sterujące i komunikacyjne, takie jak główny komputer sterujący, sterowniki napędów, moduły komunikacji bezprzewodowej, systemy bezpieczeństwa, a także sensoryka pokładowa, obejmująca m.in. skanery, czujniki odległości, systemy lokalizacji i inercyjne jednostki pomiarowe. Pobór mocy przez wymienione elementy nie jest wartością stałą, lecz zależy od aktualnego stanu operacyjnego robota oraz realizowanego fragmentu misji. Dlatego w celu realistycznej estymacji energii zużywanej przez te komponenty, należy najpierw zidentyfikować typowe stany funkcjonalne robota (np. oczekiwanie, ruch, ładowanie), a następnie przypisać do każdego z nich wartości poboru mocy uzyskane z dokumentacji technicznej lub określone na podstawie pomiarów eksperymentalnych.

Dla każdego komponentu i jego energia zużyta w danym stanie j może być opisana ogólnym równaniem:

$$E_{i,j} = P_{i,j} \cdot t_j \quad (8)$$

Gdzie:


- $E_{i,j}$ - energia zużyta przez komponent i w stanie robota j
- $P_{i,j}$ - średni pobór mocy przez komponent i w stanie j
- t_j - czas trwania stanu j .

Całkowite zużycie energii przez daną grupę komponentów (np. sensorykę lub sterowanie) można następnie wyrazić jako sumę energii pobranej przez wszystkie komponenty we wszystkich stanach aktywności:

$$E_{ukl_ster} = \sum_j \sum_i P_{i,j} \cdot t_j \quad (9)$$

Takie podejście umożliwia nie tylko zwiększenie precyzji modelu zużycia energii, ale także uwzględnienie wpływu profilu misji oraz dynamiki działania robota na poziom obciążenia jego podsystemów elektronicznych.

Na podstawie analizy czynników przedstawionych w literaturze (Tabela 13), a następnie ich porównania z ujęciem teoretycznym opartym na równaniach (3 - 9), obejmujących bilans sił napędowych, modele sprawności energetycznej oraz zużycia energii przez podsystemy elektroniczne, przeprowadzono autorską systematyczną klasyfikację czynników wpływających na całkowite zapotrzebowanie energetyczne robota mobilnego. Zaproponowany podział obejmuje sześć głównych grup, które oddają kluczowe czynniki wpływające na zużycie energii niezależnie od typu i przeznaczenia robota mobilnego. Klasyfikacja ta stanowi punkt wyjścia do dalszej selekcji parametrów istotnych z perspektywy modelowania predykcyjnego oraz projektowania eksperymentów badawczych. W celu czytelnego przedstawienia relacji między poszczególnymi grupami czynników opracowano diagram przyczynowo skutkowy Ishikawy (Rys. 27). Diagram ten syntetycznie obrazuje wieloczynnikowy charakter zużycia energii w robotach mobilnych. Poszczególne odgałęzienia diagramu odpowiadają wyróżnionym kategoriom czynników, a ich rozwinięcia przedstawiają konkretne parametry, które zgodnie z przeprowadzoną analizą mogą w istotny sposób kształtować całkowite zapotrzebowanie energetyczne.



Rys. 27 Diagram Ishikawy przedstawiający klasyfikację czynników wpływających na zużycie energii przez roboty mobilne w ujęciu systemowym. Opracowanie własne

4.2 Identyfikacja czynników zmiennych i mierzalnych

W celu zwiększenia trafności predykcji zużycia energii przez mobilnego robota autonomicznego AMR wykonującego zadania intralogistyczne, przeprowadzono proces selekcji istotnych czynników wpływających na zużycie energii. Redukcja liczby czynników opiera się na zasadzie uwzględniania w modelu wyłącznie tych czynników, które są informatywne, zmienne oraz możliwe do pomiaru lub estymacji w czasie rzeczywistym. Celem było zbudowanie modelu wykorzystującego tylko te czynniki, które mają rzeczywisty i mierzalny wpływ na zużycie energii, a jednocześnie są dostępne na etapie predykcji, tj. przed realizacją zadania przez robota. Kluczowe założenia redukcji czynników to:

Do modelu należy wprowadzać jedynie te czynniki, które:

- mają bezpośredni wpływ na zmienną objaśnianą, tj. zużycie energii,
- są zmienne w czasie lub różnicują scenariusze,
- są mierzalne lub możliwe do oszacowania online,
- są przyczynami, a nie skutkami działania systemu,
- wykazują korelację z poziomem zużycia energii,
- mogą być jednoznacznie określone przed rozpoczęciem realizacji zadania (np. dystans misji, masa ładunku, początkowy stan naładowania akumulatora), tak aby model predykcyjny mógł wykorzystać je w procesie estymacji.

W kontekście niniejszej rozprawy doktorskiej, a w szczególności opracowywanego w jej ramach modelu predykcyjnego, przyjęto założenie, że dotyczy on komercyjnego robota mobilnego realizującego zadania intralogistyczne wewnątrz hali przemysłowej. Taki scenariusz operacyjny charakteryzuje się wysokim poziomem powtarzalności warunków środowiskowych oraz ograniczoną możliwością ingerencji w konfigurację sprzętową robota. W związku z tym:


Z modelu wykluczono następujące czynniki:

- **czynniki środowiskowe**, takie jak rodzaj nawierzchni oraz topografia terenu - założono ich niezmienność, brak nachyleń oraz jednolitą strukturę podłoża
- **opór aerodynamiczny** - ze względu na niskie prędkości poruszania się robota jego wpływ uznano za pomijalny,
- **czynniki konstrukcyjne i sterujące robota**, w tym: pojemność akumulatora, typ napędu, właściwości układu sterowania i sensoryki, są one niezmiennie w obrębie analizowanego przypadku i niedostępne do modyfikacji z poziomu programistycznego - zostały potraktowane jako elementy składowe stałej zużycia energii przez robota, zależnej wyłącznie od czasu trwania zadania, i jako takie nie są uwzględniane jako predyktory w modelu zużycia energii. Jednak w celu umożliwienia uogólnienia modelu predykcyjnego oraz jego zastosowania dla różnych typów platform AMR, czynniki te mogą być pośrednio reprezentowane jako komponent tzw. modelu robota (konkretny model robota dostępny komercyjnie), różnicującego dane wejściowe w przypadku analizy wielu jednostek jednocześnie,
- **czynniki będące skutkiem działania systemu**, np. chwilowe zużycie energii przez komponenty elektroniczne - nie pełnią funkcji przyczynowych i nie są znane na etapie planowania misji.

Na podstawie powyższych założeń dokonano eliminacji czynników nieinformatywnych oraz czynników stałych, co umożliwiło opracowanie uproszczonego i bardziej uogólnionego zestawu potencjalnych predyktorów. Redukcja liczby predyktorów korzystnie wpływa na jakość modelu ograniczając ryzyko

przeuczenia, zmniejsza złożoność obliczeniową oraz poprawia przejrzystość i interpretowalność wyników. Dodatkowo, eliminacja predyktorów niezmiennych i nadmiarowych pozwala ograniczyć wpływ szumu informacyjnego i potencjalnych zakłóceń na etapie uczenia i działania modelu, co ma szczególne znaczenie w kontekście implementacji rozwiązania w środowisku przemysłowym.

Na poniższym rysunku (Rys. 28) przedstawiono wersję diagramu Ishikawy zredukowaną o czynniki nieinformatywne i stałe



Rys. 28 Zredukowany diagram Ishikawy o czynniki nieinformatywne i stałe

W wyniku opisanej redukcji uzyskano ograniczony, lecz informacyjnie bogaty zestaw czynników, które mogą stanowić podstawę do konstrukcji predykcyjnego modelu zużycia energii. Czynniki te spełniają przyjęte kryteria mierzalności, zmienności oraz przyczynowego związku z wartością prognozowanej wielkości. Co istotne, są one również możliwe do określenia przed rozpoczęciem zadania, co pozwala na ich rzeczywiste wykorzystanie w kontekście predykcji. Należy jednak zauważyć, że trafność i skuteczność modelu predykcyjnego zależy nie tylko od jakości wybranych predyktorów, lecz także od ich dostępności w konkretnych warunkach wdrożeniowych. W szczególności w środowiskach przemysłowych, gdzie powszechnie wykorzystywane są komercyjne platformy AMR, istnieje szereg ograniczeń związanych z integracją dodatkowych komponentów pomiarowych i modyfikacją sprzętu. Z tego względu dalsza selekcja czynników powinna uwzględniać nie tylko ich wartość informacyjną, lecz również praktyczną dostępność w ramach istniejącej infrastruktury systemowej robota.

4.3 Selekcja czynników możliwych do obserwacji w systemie MiR

W kolejnym etapie pracy przeprowadzono dalszą selekcję czynników zidentyfikowanych wcześniej jako potencjalnie istotne dla modelowania zużycia energii. Tym razem punktem odniesienia stały się praktyczne uwarunkowania wdrażania systemów predykcyjnych w rzeczywistych środowiskach przemysłowych. Choć celem pracy pozostaje opracowanie modelu możliwie uniwersalnego, zdolnego do zastosowania w różnych platformach robotycznych, jego konstrukcja została oparta na danych dostępnych dla konkretnego systemu komercyjnego, jakim jest robot mobilny MiR100.

Z perspektywy zastosowań przemysłowych kluczowe jest, aby wdrożenie modelu predykcyjnego zużycia energii nie wymagało ingerencji w sprzęt robota. Instalacja dodatkowych czujników, choć potencjalnie zwiększałaby liczbę dostępnych danych, mogłaby prowadzić do utraty gwarancji producenta i zwiększenia kosztów. Dlatego przyjęto założenie projektowe, zgodnie z którym model powinien wykorzystywać wyłącznie dane możliwe do określenia przed rozpoczęciem zadania (np. parametry misji) oraz te, które są standardowo dostępne poprzez interfejs API robota.

W związku z tym przyjętym założeniem, kolejnym krokiem była analiza struktury odpowiedzi udzielanej przez robota MiR100 na zapytanie o jego bieżący stan poprzez interfejs REST (*ang. Representational State Transfer*) API. Dane te stanowią punkt wyjścia do dalszej redukcji czynników, tym razem ograniczonej do rzeczywiście dostępnych zmiennych, które mogą być pozyskiwane w sposób automatyczny poprzez API. Poniżej przedstawiono przykładową odpowiedź na zapytanie w formacie JSON, będącą podstawą dalszej analizy:

```
{
  "allowed_methods": null,
  "battery_percentage": 100.0,
  "battery_time_remaining": 47999,
  "distance_to_next_target": 0.0,
  "errors": [],
  "footprint": "[[0.506,-0.32],[0.506,0.32],[-0.454,0.32],[-0.454,-0.32]]",
  "joystick_low_speed_mode_enabled": false,
  "joystick_web_session_id": "",
  "map_id": "e56ac9d1-a3f7-11ea-b705-94c6911e79e1",
  "mission_queue_id": null,
  "mission_queue_url": null,
  "mission_text": "Starting...",
  "mode_id": 7,
  "mode_key_state": "idle",
  "mode_text": "Mission",
  "moved": 1124063.19,
  "position": {
    "orientation": 61.76313018798828,
    "x": 23.316701889038086,
    "y": 22.89132308959961
  },
  "robot_model": "MiR100",
  "robot_name": "MiUR10",
  "safety_system_muted": false,
  "serial_number": "18010xxx2100880",
  "session_id": "200f551a-d37c-11e8-b79c-94c6911e79e1",
  "state_id": 4,
  "state_text": "Pause",
  "unloaded_map_changes": false,
  "uptime": 1297,
  "user_prompt": null,
  "velocity": {
    "angular": 0.0,
    "linear": 0.0
  }
}
```

Na podstawie przedstawionej klasyfikacji (Rys. 28) oraz z uwzględnieniem ograniczeń wynikających z charakterystyki środowiska przemysłowego i architektury systemu robota, przeprowadzono ukierunkowaną selekcję czynników istotnych z perspektywy modelowania predykcyjnego zużycia energii. Celem tego etapu było wyodrębnienie czynników, które przy zachowaniu przyczynowego związku z prognozowaną wielkością mogą być pozyskane w sposób bezinwazyjny, bez konieczności modyfikacji sprzętowej. Kryteria selekcji oparto na analizie danych dostępnych za pośrednictwem interfejsu API platformy MiR100 oraz na wymaganiach dotyczących możliwości zastosowania modelu w rzeczywistym scenariuszu intralogistycznym. W dalszej części rozdziału przedstawiono finalny

zestaw czynników wejściowych, przyporządkowanych do odpowiednich kategorii, wraz z uzasadnieniem ich uwzględnienia w modelu predykcyjnym.

Czynniki konstrukcyjne i mechaniczne

Czynniki konstrukcyjne i mechaniczne, takie jak masa robota, typ napędu czy charakterystyka przekładni, pozostają stałe w trakcie jednej misji. Ich wpływ na zużycie energii ma charakter pośredni i może być reprezentowany jedynie jako stały składnik zależny od czasu trwania zadania. Z tego względu nie są one traktowane jako zmienne dynamiczne w modelu predykcyjnym. Aby umożliwić uogólnienie modelu na różne platformy, do zbioru danych wprowadzono identyfikatory AMR: markę, model oraz numer seryjny. Pozwala to różnicować obserwacje według konkretnej platformy oraz śledzić zmiany wynikające np. z eksploatacji, starzenia komponentów i degradacji układu zasilania. Taka struktura danych umożliwia nie tylko dokładniejszą predykcję zużycia energii przez robota podczas misji, ale także potencjalne przyszłe rozszerzenie modelu o funkcje związane z utrzymaniem predykcyjnym. Dodatkowo, uwzględniono obecność akcesoriów - takich jak haki, windy i roboty współpracujące wraz z informacją o ich typie i sposobie użytkowania. Wybrane czynniki pozwalają różnicować scenariusze zużycia nawet w obrębie tej samej platformy sprzętowej.

Czynniki układu zasilania

W kontekście modelowania zużycia energii jednym z nielicznych parametrów możliwych do pozyskania na etapie planowania misji, bezpośrednio z poziomu API robota MiR100, jest początkowy poziom naładowania akumulatora (SoC). Parametr ten, wyrażany jest w procentach i informuje o szacunkowej ilości dostępnej energii w akumulatorze. Jak wskazują wyniki badań [116], [128] aktualna wartość SoC może mieć znaczący wpływ na rzeczywiste zużycie energii w trakcie realizacji zadania, a także na liczbę możliwych do wykonania misji w ramach pojedynczego cyklu ładowania. Uwzględnienie tej zmiennej w modelu predykcyjnym jest zatem uzasadnione z punktu widzenia zarówno energetycznego, jak i operacyjnego.

Ze względu na wymogi gwarancyjne producenta komercyjnych robotów AMR, w pracy nie przewidywano ingerencji w strukturę układu zasilania. Nie są zatem realizowane bezpośrednie pomiary napięcia ani prądu na ogniwach akumulatora - model bazuje wyłącznie na danych dostępnych poprzez oficjalne, nieinwazyjne interfejsy systemowe. W trakcie każdej misji zapisywana jest metka czasowa, co umożliwia estymację czasu pracy akumulatora oraz analizę profilu zużycia energii. Dodatkowo, jeśli system zostanie rozbudowany o dane dotyczące cykli ładowania (np. z pamięci BMS lub zintegrowanego systemu ładowania), możliwe będzie ich wykorzystanie do identyfikacji długoterminowych trendów zużycia, co może stanowić podstawę dla rozszerzenia modelu o komponent predykcyjnego utrzymania technicznego.

Jedynym sygnałem pochodzącym z układu zasilania, którego rejestracja została dodatkowo rozszerzona, jest temperatura akumulatora. Czynnikiem ten może wpływać na sprawność systemu energetycznego, a jednocześnie może pełnić funkcję kontrolną w ramach mechanizmów bezpieczeństwa umożliwiając monitorowanie ryzyka, ostrzeganie i odpowiednie reagowanie w sytuacjach niepożądanych.

Czynniki systemów sterowania i sensoryki pokładowej

Czynniki związane z systemami sterowania oraz sensoryką pokładową zostały poddane analizie, jednak ostatecznie nie zostały zakwalifikowane do zbioru predyktorów dla modelu predykcyjnego zużycia energii. W przypadku komercyjnych platform robotycznych użytkownik nie ma możliwości ingerencji ani z poziomu interfejsu API, ani poprzez dostępne oprogramowanie w konfigurację i parametry pracy sensorów w sposób, który mógłby wpłynąć na profil energetyczny systemu. W związku z tym, ich wpływ uznano za niemodyfikowalny i stały w ramach pojedynczej misji, zależny jedynie od czasu jej trwania oraz przebytego dystansu. Decyzja ta została podyktowana ograniczeniami wynikającymi z zamkniętej architektury systemów komercyjnych robotów mobilnych, które nie pozwalają zmianę zachowania podsystemów niskiego poziomu.

Czynniki kinematyczno-dynamiczne ruchu

Środowisko programistyczne robota MiR100 umożliwia definiowanie ograniczeń maksymalnej prędkości oraz przyspieszeń zarówno liniowych, jak i kątowych na etapie planowania misji. W związku z tym, parametry te zostały uwzględnione jako istotne czynniki w modelu predykcyjnym zużycia energii. Należy jednak zaznaczyć, że rzeczywiste wartości prędkości osiągane podczas ruchu zależą również od charakterystyki środowiska w warunkach ograniczonej przestrzeni lub dużego zagęszczenia przeszkód robot automatycznie dostosowuje swoją trajektorię i prędkość, poruszając się wolniej w celu zapewnienia bezpiecznej nawigacji.

Czynniki zadaniowe (misji)


Do grupy czynników potencjalnie wpływających na zużycie energii przez AMR zaliczyć należy również zmienne związane z charakterystyką realizowanej misji. Są to dane definiowane na etapie planowania zadania, które nie pochodzą bezpośrednio z pomiarów pokładowych, lecz stanowią element wejściowy planu operacyjnego. Jednym z podstawowych czynników w tej kategorii jest planowany dystans przejazdu. Należy jednak podkreślić, że w trakcie rzeczywistego wykonywania misji robot może dynamicznie zmieniać trasę np. w odpowiedzi na wykryte przeszkody, co wpływa na ostateczny przebieg i długość ścieżki. Kolejnym istotnym czynnikiem jest obciążenie robocze (masa przewożonego towaru), które zwiększa zarówno całkowitą masę układu, jak i jego moment bezwładności. Ma to szczególne znaczenie podczas manewrów skrętnych, gdzie większe obciążenie przekłada się na zwiększone zapotrzebowanie energetyczne. Ponadto, na zużycie energii mogą wpływać: planowany tor jazdy, liczba zakrętów oraz topologia środowiska pracy, które warunkują sposób działania algorytmów nawigacyjnych. W efekcie, robot może dostosowywać prędkość i trajektorię w zależności od układu otoczenia. Im bardziej złożone i ciasne środowisko, tym częściej wymagane są manewry korekcyjne i redukcja prędkości, co wpływa na ogólne zużycie energii.

Do zbioru danych pomiarowych planowane jest również włączenie identyfikatora misji (nazwa misji), który będzie pełnił funkcję informacyjną. Nazwa misji może nieść ze sobą dodatkowy kontekst operacyjny - np. odniesienie do konkretnego typu zlecenia, lokalizacji początkowej i końcowej, rodzaju transportowanego ładunku czy nawet priorytetu zadania. Tego rodzaju informacje, mimo że nie są bezpośrednimi wielkościami fizycznymi, mogą odzwierciedlać pewne wzorce energetyczne charakterystyczne dla danej klasy zadań. Uwzględnienie ich w modelu predykcyjnym może umożliwić lepsze odwzorowanie zależności nieliniowych i zwiększyć trafność predykcji w kontekście danych historycznych.

Czynniki środowiskowe

W kontekście analizowanego przypadku przyjęto, że roboty poruszają się w obrębie tej samej, jednorodnej przestrzeni hali produkcyjnej w której warunki środowiskowe pozostają względnie niezmiennie. Współczynnik tarcia podłoża, typ nawierzchni oraz inne parametry fizyczne otoczenia zostały uznane za stałe i identyczne dla wszystkich robotów operujących w danym obszarze. W związku z tym ich wpływ na zużycie energii traktowany jest jako stała funkcja czasu trwania misji oraz przebytego dystansu. Spośród czynników środowiskowych jedynie temperatura otoczenia została uwzględniona jako zmienna mogąca wpływać na efektywność energetyczną. Zmiany temperatury mogą oddziaływać na sprawność komponentów elektronicznych, charakterystykę pracy akumulatora oraz opory wewnętrzne układów napędowych, a tym samym powodować zauważalne różnice w zużyciu energii w identycznych scenariuszach operacyjnych.

Po przeprowadzeniu redukcji czynników potencjalnie wpływających na zużycie energii, zachowano wyłącznie te zmienne, które są zmienne w czasie lub różnicują scenariusze misji, mają charakter informatywny w kontekście modelowania oraz mogą być określone na etapie inicjalizacji zadania w przypadku wykorzystania robota MiR100. **Wszystkie zidentyfikowane w ten sposób czynniki, potencjalnie pełniące rolę predyktorów w funkcji predykcyjnej zużycia energii**, przedstawiono na poniższym diagramie Ishikawy (Rys. 29).



Rys. 29 Diagram Ishikawy przedstawiający czynniki potencjalnie wpływające na zużycie energii robota MiR100, wybrane po dwuetapowej redukcji według kryteriów zmienności, informatywności i dostępności na etapie planowania misji.

Celem prac opisanych w rozdziale była redukcja zbędnych danych i pozostawienie wyłącznie parametrów potencjalnie istotnych z punktu widzenia modelowania. W kolejnym rozdziale, podczas budowy modeli predykcyjnych, zostanie przeprowadzona analiza ilościowa, mająca na celu określenie wpływu poszczególnych zmiennych na dokładność predykcji zużycia energii.

5 Projekt eksperymentów i stanowisko badawcze

Rozdział piąty koncentruje się na opracowaniu planu eksperymentów oraz budowie stanowiska badawczego, stanowiących kluczowe elementy realizacji celu głównego rozprawy. W pierwszej części przedstawiono założenia metodologiczne dotyczące projektowania eksperymentów w podejściu sekwencyjnym, obejmującym etap wstępny oraz etap właściwy w formie eksperymentu wieloczynnikowego. Szczegółowo opisano przyjęte cele poszczególnych etapów, strukturę planu badań oraz zasady rejestracji danych operacyjnych i energetycznych z misji robota AMR. W drugiej części rozdziału zaprezentowano stanowisko badawcze, obejmujące architekturę systemu pomiarowego, dobór czujników i komponentów komunikacyjnych oraz środowisko testowe, w którym realizowano misje. Opisano zarówno aspekt sprzętowy, jak i programowy systemu, ze szczególnym uwzględnieniem mechanizmów automatyzacji procesu akwizycji danych.

5.1 Projekt eksperymentów

Projektowanie eksperymentów jest jednym z kluczowych elementów badań naukowych, umożliwiającym nie tylko zebranie danych, lecz także zapewnienie ich jakości, powtarzalności i przydatności do dalszej analizy. W literaturze metodologicznej pojęcie „planowanie eksperymentu” (Design of Experiments, DoE) bywa ujmowane szeroko od prostych eksperymentów jednoczynnikowych OFAT (One-Factor-at-a-Time) do planów wieloczynnikowych (pełnych i ułamkowych) oraz metod powierzchni odpowiedzi. W niniejszej pracy podejście DoE zostało zastosowane w ujęciu sekwencyjnym, co oznacza, że badania zostały podzielone na dwa etapy, z których każdy miał własny cel metodologiczny, a jednocześnie stanowił logiczną podstawę dla kolejnego [180].

Przyjęcie strategii sekwencyjnej wynikało z charakteru problemu badawczego. W rozdziale 2 wskazano, że możliwe jest konstruowanie modeli predykcyjnych zużycia energii robotów mobilnych, jednak w literaturze dostępnych jest stosunkowo niewiele opracowań potwierdzających możliwość skutecznego zastosowania tego podejścia w praktyce operacyjnej AMR. Równocześnie dostępne komercyjne systemy FMS oferują ograniczoną funkcjonalność w tym zakresie. Dodatkowo, podczas wstępnych testów, zauważono nieoczekiwaną zmienność zużycia energii (wyrażoną jako spadek SoC akumulatora) nawet w ramach realizacji tej samej misji. Z tego powodu zdecydowano się na dwustopniowy plan eksperymentów:

- **W pierwszym etapie** przeprowadzono eksperyment wstępny, którego celem było zweryfikowanie i opisanie wspomnianej zależności, budowa pierwszego jednowymiarowego modelu referencyjnego - **M1** (np. wielomianowego) zależność zużycia energii podczas misji w zależności od początkowego stanu SoC akumulatora, oraz przygotowanie i przetestowanie układu pomiarowego.
- **W drugim etapie** zrealizowano eksperyment wieloczynnikowy, obejmujący dodatkowe czynniki wpływające na zużycie energii (m.in. długość trasy, obciążenie, temperatura akumulatora), co umożliwiło budowę dwóch modeli wieloparametrycznych - **M2** (Statystyczny oparty na ML) i **M3** (AutoML) oraz ich porównanie pod względem dokładności, użyteczności i łatwości wdrożenia w warunkach przemysłowych.

Zebrane w ten sposób dane stanowią podstawę opracowania trzech modeli predykcyjnych:

- **M1** - jednoparametryczny model regresyjny o charakterze bazowym,
- **M2** - wieloparametryczny model statystyczny oparty na metodach uczenia maszynowego, jawny (white-box),
- **M3** - wieloparametryczny model konstruowany w podejściu zautomatyzowanym (AutoML), niejawny (black-box).

opisanych w rozdziale 6.

Etap 1 - Eksperyment wstępny (OFAT)

W przypadku prostych modeli predykcyjnych, opracowywanych dla konkretnych misji realizowanych przez roboty mobilne, które zasilane są akumulatorami litowo-jonowymi, możliwe jest zastosowanie uproszczonego podejścia do szacowania zużycia energii. Zakłada się przy tym, że w niezmiennych warunkach operacyjnych każde wykonanie tej samej misji wiąże się z porównywalnym zużyciem energii.

Podczas realizacji zadań transportowych oraz wstępnych testów zaobserwowano, że mobilny robot MiR100, wykonując wielokrotnie identyczne zadania transportowe w niezmiennych warunkach operacyjnych, wykazuje rozbieżności w poziomie zużycia energii z akumulatora. Z perspektywy bilansu energetycznego układu zjawisko to jest nieoczekiwane i nie powinno występować w przypadku powtarzalnych cykli pracy. Jednakże, biorąc pod uwagę nieliniowy charakter zależności pomiędzy stanem naładowania a napięciem ogniw w akumulatorach typu litowo-NMC, a także fakt, iż system BMS oblicza SoC na podstawie charakterystyki napięcia (co przedstawiono w rozdziale 1.4) możliwe są odchylenia w raportowanym zużyciu energii. W niniejszym etapie pracy zdecydowano się na budowę modelu zużycia energii dla konkretnej misji robota AMR MiR100. Model opisuje procentowy spadek poziomu naładowania akumulatora (SoC) i umożliwia zarówno predykcję wykonalności zakolejkowanych misji, jak i detekcję potencjalnych anomalii na trasie transportowej. Zrezygnowano przy tym z bezpośredniego pomiaru napięcia na ogniwach akumulatora, ponieważ ingerencja w układ elektryczny robota mogłaby skutkować utratą gwarancji. Zamiast tego, system wykorzystuje dane o stanie naładowania akumulatora (SoC) udostępniane przez oficjalne API robota MiR100. Takie podejście pozwala na zachowanie pełnej kompatybilności z urządzeniem oraz zwiększa możliwość adaptacji opracowanego rozwiązania do innych platform robotycznych.

Cel główny etapu 1

Celem Etapu 1 jest opracowanie i wstępna weryfikacja prostego modelu predykcji zużycia energii dla autonomicznego robota mobilnego (AMR), opartego wyłącznie na początkowym stanie naładowania akumulatora (SoC_start). Model pełni rolę punktu odniesienia oraz umożliwia ocenę przydatności podejścia jednowymiarowego do prognozowania zużycia energii.

Cele szczegółowe Etapu 1

W ramach realizacji celu głównego Etapu 1, zaplanowano następujące cele szczegółowe:

1. **Weryfikacja układu pomiarowego** - ocena poprawności działania architektury akwizycji danych i jej przydatności do dalszych etapów badań.
2. **Określenie charakterystyki zużycia energii w misji referencyjnej** - wykonanie serii powtarzalnych przejazdów tej samej misji w celu przedstawienia profilu zużycia energii i potwierdzenia obserwacji, że ta sama misja może prowadzić do różnych wartości ΔSoC .
3. **Rejestracja wariantów misji (zakłóceńowych i skróconych)** - przeprowadzenie dodatkowych przejazdów w zmodyfikowanych warunkach (np. z przeszkodą, że skróconą trasą) w celu ukazania, jak zmienia się charakterystyka zużycia energii.
4. **Opracowanie jednowymiarowego modelu predykcji (M1)** - opracowanie jednowymiarowego modelu predykcyjnego $\Delta\text{SoC}=f(\text{SoC_start})$, bazującego na wynikach pomiarów.
5. **Implementacja i weryfikacja modelu M1** - weryfikacja modelu predykcyjnego oraz jego integracja w systemie sterującym (Node-RED), a następnie przetestowanie w czterech scenariuszach eksperymentalnych.
6. **Opracowanie wniosków rozwojowych** - identyfikacja ograniczeń modelu M1 i sformułowanie wskazówek do budowy bardziej uniwersalnych modeli (M2, M3) oraz rozbudowy stanowiska pomiarowego.

Przyjęta metodologia eksperymentu

- W Etapie 1 stosowane jest podejście typu DoE OFAT (*ang. One-Factor-at-a-Time*). Jedynym czynnikiem eksperymentalnym zmienianym w badaniach jest początkowy stan naładowania akumulatora (SoC_start), natomiast wszystkie pozostałe warunki misji pozostają stałe (długość i konfiguracja trasy, obciążenie, prędkość robota). Taki wybór opiera się na dwóch przesłankach:
- **Charakter modelu M1** - zakłada się opracowanie możliwie prostego, jednowymiarowego modelu odniesienia, umożliwiającego ocenę wykonalności misji i wczesną detekcję anomalii. W takim ujęciu nie zachodzi potrzeba wprowadzania wielu zmiennych.
- **Etapowość badań** - przyjęcie podejścia OFAT pozwala w sposób kontrolowany zarejestrować charakterystykę zużycia energii w funkcji pojedynczego parametru, a następnie sprawdzić stabilność modelu. Rozwiązanie to stanowi punkt wyjścia do kolejnych etapów badań, w których metodologia zostanie rozszerzona na wieloczynnikowe modele statystyczne (M2, M3).

Podstawowe założenia eksperymentu

W Etapie 1 jednostkę eksperymentalną stanowi pojedynczy przejazd robota AMR MiR100 realizującego tę samą misję w stałych warunkach (zdefiniowana trasa, stałe obciążenie, zadana prędkość). Zmiennym czynnikiem eksperymentalnym, zgodnie z przyjętą metodologią OFAT, jest wyłącznie początkowy stan naładowania akumulatora (SoC_start) w zakresie 100-10%. Odpowiedzią badaną w eksperymencie jest wartość zużycia energii, wyrażona jako spadek SoC ($\Delta\text{SoC} [\%]$) w trakcie pojedynczej misji.


Plan prób i scenariusze eksperymentalne

W tym etapie przygotowywane są scenariusze eksperymentalne, w których jedynym zmiennym czynnikiem eksperymentalnym jest początkowy stan naładowania akumulatora (SoC_start). Eksperymenty przewidują realizację trzech wariantów misji:

1. Misja referencyjna (kalibracyjna ~140 m)

Przewidziane są trzy pełne cykle rozładowania akumulatora w zakresie 100% $\rightarrow$ 10% SoC, realizowane każdorazowo na tej samej trasie (B1 $\rightarrow$ B2 $\rightarrow$ B3 $\rightarrow$ B4 $\rightarrow$ B2 $\rightarrow$ B1). Celem jest zebranie danych dla **jednowymiarowego modelu M1: $\Delta\text{SoC} = f(\text{SoC_start})$** . Trzy pełne cykle rozładowania akumulatora mają umożliwić uzyskanie stabilnej charakterystyki odniesienia oraz ograniczenie wpływu losowych odchyleń. Rys. 30a przedstawia konfigurację środowiska z


punktami B1-B4, Rys. 30b algorytm automatycznego cyklu pomiarowego wraz z kolejnością zadanych punktów.



Rys. 30 Konfiguracja środowiska testowego oraz schemat automatycznego cyklu pomiarowego:

2. Misja z objazdem (wydłużona do ~220 m)

Przewiduje się dwa pełne cykle rozładowania akumulatora w zakresie 100% → 10% SoC w warunkach wymuszonej przeszkody na trasie. W przypadku wykrycia przeszkody robot samodzielnie planuje trasę alternatywną, co skutkuje wydłużeniem misji z ok. 140 m do ok. 220 m. Celem tego wariantu jest sprawdzenie, w jaki sposób wydłużenie trasy wpływa na charakterystykę zużycia energii. Analizowane jest, czy różnica w długości misji będzie widoczna wyłącznie jako stałe przesunięcie (offset) względem misji referencyjnej, czy też ujawni się dodatkowa zależność (np. bardziej liniowy wzrost zużycia w funkcji SoC_start). **Przyjęta zasada zakłada, że w przypadku istotnych rozbieżności między cyklami, rozumianych jako różnica zużycia energii Δ SoC większa niż 10% w tych samych punktach początkowych SoC, należy wykonać pełen trzeci cykl rozładowania 100-10% SoC.** Rys. 31a-b przedstawia automatyczny sposób wyznaczania objazdu przez AMR w mapie środowiska, a Rys. 31c-d przedstawia warunki rzeczywiste - przejazd niezakłócony oraz przejazd z przeszkodą.



Rys. 31 Planowanie dynamicznego objazdu po wykryciu przeszkody: a) mapa przed wyznaczeniem objazdu, b) planowany objazd po detekcji przeszkody, c) niezakłócona trasa przejazdu, d) trasa z przeszkodą. Źródło opracowanie własne

3. Misja porównawcza (100m)

Przewiduje się jeden cykl rozładowania na trasie krótszej niż referencyjna na trasie (B1 → B2 → B3 → B2 → B1). Wariant ten ma charakter pomocniczy i służy do jakościowego porównania charakterystyki rozładowania dla różnych długości misji. Nie jest wykorzystywany ani do budowy modelu, ani do jego formalnej walidacji, lecz dostarcza materiału do wniosków dotyczących ograniczeń podejścia jednowymiarowego oraz stanowi podstawę do rozszerzenia metodologii w Etapie 2.

Procedura i akwizycja danych

Każda misja testowa jest rejestrowana w sposób zautomatyzowany przy wykorzystaniu środowiska Node-RED komunikującego się z AMR poprzez API. Dla każdej jednostki eksperymentalnej (pojedynczego przejazdu) zapisywane są następujące dane:

- **ID pomiaru** - numer identyfikacyjny każdej próby w systemie,
- **Numer pomiaru w serii** - pozycja w danym cyklu rozładowania (np. pierwszy, drugi przejazd itd.),
- **Nazwa misji** - określenie wariantu (np. Mir_bat_140 – misja referencyjna 140 m),
- **Zużycie energii** - wyrażone jako spadek SoC (ΔSoC [%]) dla pojedynczej misji,
- **Data i czas** - znacznik czasowy rozpoczęcia pomiaru,
- **Temperatura akumulatora [°C]** - wartość monitorowana w celu kontroli warunków pracy,

- **Początkowy SoC [%]** - jedyny czynnik eksperymentalny, zmieniany pomiędzy próbami,
- **Obciążenie robota [kg]** - utrzymywane na stałym poziomie (100 kg) we wszystkich pomiarach.

Wszystkie pozostałe parametry misji, takie jak trasa, kolejność punktów nawigacyjnych, prędkość przejazdu i obciążenie, są utrzymywane jako stałe. Dzięki temu zmienną wejściową (czynnikiem eksperymentalnym) pozostaje wyłącznie SoC_start, natomiast zmienną odpowiedzi badaną w eksperymencie jest zużycie energii $\Delta\text{SoC} [\%]$.

Analiza danych i kryteria oceny modelu

Dane zebrane podczas misji referencyjnej są wykorzystywane do opracowania modelu zależności zużycia energii od początkowego stanu naładowania akumulatora. Dopasowanie nie jest z góry ograniczone do jednej postaci funkcji, lecz obejmuje analizę kilku prostych grup modeli (m.in. liniowych, potęgowych, wykładniczych, wielomianowych). Ostateczny wybór formy modelu zostaje przeprowadzony w rozdziale 6 na podstawie jakości dopasowania oraz zasady możliwie najprostszej postaci funkcji spełniającej wymagania. Jakość dopasowania jest oceniana przy użyciu współczynnika determinacji R^2 , z przyjętym progiem na poziomie $R^2 \geq 0,90$.

Scenariusze testowe

W celu praktycznej oceny użyteczności modelu M1 przewiduje się jego weryfikację w czterech scenariuszach testowych, odzwierciedlających zarówno warunki referencyjne, jak i sytuacje zakłócenieniowe oraz aplikacyjne związane z planowaniem misji.

- **Scenariusz 1 - weryfikacja modelu zużycia energii** - Model M1 jest sprawdzany na danych z misji referencyjnych w celu oceny jego przydatności do przewidywania zużycia energii w warunkach bazowych oraz potwierdzenia poprawności dopasowania.
- **Scenariusz 2 - wykrycie przeszkody na trasie** - Analizowane jest, czy model M1 pozwala wykryć przekroczenie przewidywanego zużycia energii, co może wskazywać na wydłużenie trasy robota (np. z powodu omijania przeszkody).
- **Scenariusz 3 - system wczesnego powiadamiania o odchyleniach** - Model M1 jest wykorzystywany do detekcji istotnych różnic między przewidywanym a rzeczywistym zużyciem energii. Celem jest sprawdzenie, czy może on pełnić funkcję narzędzia ostrzegającego o nieprawidłowościach na trasie robota, wspierającego zarządzanie flotą AMR.
- **Scenariusz 4 - system weryfikacji wykonalności zakolejkowanych misji** - Na podstawie przewidywanego zużycia energii oceniana jest możliwość realizacji zakolejkowanych zadań bez konieczności doładowania akumulatora. Analizowane jest, czy model może wspierać decyzje dotyczące planowania pracy w środowisku przemysłowym.

Wnioski rozwojowe

Na zakończenie Etapu 1 przewiduje się opracowanie wniosków rozwojowych, które pozwolą ocenić przydatność podejścia jednowymiarowego oraz określić jego ograniczenia. Analiza ma umożliwić wskazanie czynników nieuwzględnionych w modelu M1, a istotnych dla charakterystyki zużycia energii (np. długość misji, obciążenie, prędkość jazdy, temperatura akumulatora). Rezultatem będzie zestaw rekomendacji dotyczących konstrukcji bardziej zaawansowanych modeli wieloczynnikowych

Planowane jest, aby wnioski rozwojowe przyjęły formę tabeli, w której każda obserwacja z Etapu 1 będzie powiązana z:

- zidentyfikowanym ograniczeniem modelu jednowymiarowego,
- wstępną rekomendacją metodologiczną,
- kierunkiem rozwoju w kolejnych etapach badań.

Posumowanie

W celu uporządkowania kluczowych założeń Etapu 1 opracowano zestawienie obejmujące wszystkie elementy planu eksperymentu zgodnego z podejściem DoE typu OFAT. Ujęto w nim m.in. cel etapu, jednostkę eksperymentalną, czynniki zmienne i kontrolowane, zakres i poziomy analizowanego parametru, a także liczbę replikacji, procedurę rejestracji danych oraz planowaną metodę analizy. Podsumowanie przedstawiono poniżej (Tabela 14).

Tabela 14 Założenia planu eksperymentu dla Etapu 1 (podejście DoE typu OFAT)

Element planu eksperymentu	Założenie (Etap 1 - DoE OFAT)
Cel etapu	Opracowanie i wstępna weryfikacja prostego, jednowymiarowego modelu predykcji zużycia energii (M1), opartego na SoC_start
Jednostka eksperymentalna	Pojedynczy przejazd robota AMR MiR100 realizującego zdefiniowaną misję w stałych warunkach
Czynnik eksperymentalny	Początkowy stan naładowania akumulatora (SoC_start)
Zakres i poziomy czynnika	100% → 10% SoC (ciągłe obniżanie w kolejnych przejazdach)
Zmienne odpowiedzi	Zużycie energii wyrażone jako ΔSoC [%] akumulatora
Warunki kontrolowane (stałe)	Trasa przejazdu (B1→B2→B3→B4→B2→B1), konfiguracja punktów, obciążenie 100 kg, środowisko testowe
Scenariusze eksperymentalne	1) Misja referencyjna (trasa ok. 140 m, 3 pełne cykle) 2) Misja z przeszkodą (trasa ok. 220 m, 2 pełne cykle) 3) Misja skrócona - cel pomocniczy (1 cykl)
Replikacje	Misja referencyjna: 3 pełne cykle Misja z przeszkodą: 2-3 cykle Misja skrócona: 1 cykl
Procedura rejestracji danych	Automatyczna akwizycja w Node-RED (ID pomiaru, SoC_start, ΔSoC , czas, temperatura, obciążenie)
Plan analizy	Dopasowanie prostych modeli (liniowe, wielomianowe, potęgowe, wykładnicze), wybór funkcji spełniającej $R^2 \geq 0,90$

Etap 2 - Eksperyment wieloczynnikowy

Etap 2 stanowi rozwinięcie podejścia przyjętego w Etapie 1. Jednowymiarowy model odniesienia (M1) zapewnia prostą, referencyjną charakterystykę zużycia energii, jednak nie uwzględnia innych czynników wpływających na zużycie energii (operacyjnych, konstrukcyjnych i środowiskowych). Zgodnie z wnioskami z etapu pierwszego (rozdział 5.1 - Etap 1) oraz na podstawie przeglądu modeli predykcyjnych (rozdział 2) i identyfikacji czynników istotnych dla zużycia energii w AMR (rozdział 4), projektuje się **eksperyment wieloczynnikowy**. W niniejszym etapie planuje się eksperyment wieloczynnikowy, którego celem jest określenie efektów głównych (w jakim stopniu poszczególne czynniki - np. długość trasy, masa ładunku, prędkość robota, wpływają na zużycie energii) oraz czy ich oddziaływanie zmienia się w zależności od kombinacji czynników (interakcje między czynnikami).

Dlatego celem Etapu 2 jest budowa dwóch typów modeli predykcji zużycia energii, realizowanych równolegle na tym samym zbiorze danych. Taki zabieg pozwala na obiektywne porównanie jakości predykcji, interpretowalności i przydatności praktycznej obu podejść, przy identycznych warunkach eksperymentalnych oraz pozwala określić które czynniki (predyktory) mają największy wpływ na zużycie energii w obu przypadkach. Dzięki temu możliwe będzie wyciągnięcie wniosków nie tylko o skuteczności metod, lecz także o ich dopasowaniu do potrzeb przemysłowych systemów intralogistycznych. Na podstawie zadań badawczych **8B-9B** przewidziano budowę i porównanie dwóch modeli:

- **Model M2 - statystyczny** - Model ten budowany jest metodami klasycznymi, co pozwala uzyskać **jawny wzór matematyczny** (ang. *white-box*) opisujący relację między zużyciem energii a wybranymi czynnikami. Umożliwia to testowanie istotności zmiennych, interpretację kierunku i wielkości ich wpływu oraz prostą implementację w systemach nadrzędnych. Model M2 zapewnia więc przejrzystość i walor poznawczy, lecz wymaga specjalistycznej wiedzy w zakresie projektowania i estymacji modeli.
- **Model M3 - automatyczny** - Model ten opiera się na podejściu AutoML, w którym dobór algorytmów i strojenie hiperparametrów odbywa się w sposób zautomatyzowany przez system. Jest to model **niejawny (black-box)**, trudniejszy do interpretacji, ale potencjalnie dokładniejszy w predykcji. Zaletą modelu M3 jest prostota budowy oraz wdrożenia, możliwe jest jego praktyczne wykorzystanie także przez użytkowników nieposiadających zaawansowanej wiedzy w zakresie statystyki czy uczenia maszynowego.

Równoległa realizacja modeli M2 i M3 umożliwi wykonanie zadania badawczego **10B** oraz zadania utylitarnego **4U**, a także porównanie obu podejść pod względem interpretowalności, dokładności predykcji, łatwości wdrożenia w systemach komercyjnych i przemysłowych oraz potencjału dalszej rozbudowy.

Cel główny Etapu 2

Celem Etapu 2 jest opracowanie i porównanie dwóch modeli predykcji zużycia energii AMR - modelu statystycznego typu white-box (M2) oraz modelu automatycznego typu black-box (M3), w celu oceny jakości predykcji, istotności czynników oraz zestawienia zalet i ograniczeń metod budowy modeli predykcyjnych zużycia energii AMR pod kątem interpretowalności i wdrożenia w systemach intralogistycznych.”

Cele szczegółowe Etapu 2

W ramach realizacji celu głównego etapu 2, zaplanowano następujące cele szczegółowe:

1. **Określenie zestawu czynników eksperymentalnych i poziomów** - wyznaczenie kluczowych zmiennych operacyjnych, konstrukcyjnych i środowiskowych oraz zaprojektowanie planu eksperymentu wieloczynnikowego (DoE).
2. **Realizacja pomiarów i akwizycja danych** - przeprowadzenie eksperymentów zgodnie z planem DoE w celu pozyskania danych umożliwiających estymację efektów głównych i interakcji między czynnikami.
3. **Opracowanie modelu statystycznego (M2)** - opracowanie modelu typu white-box, obejmującego estymację parametrów, testy istotności i interpretację wpływu czynników na zużycie energii.
4. **Opracowanie modelu automatycznego (M3)** - opracowanie modelu typu black-box z wykorzystaniem AutoML, obejmującego automatyczny dobór algorytmów i strojenie hiperparametrów.
5. **Porównanie jakości predykcji modeli M2 i M3** - analiza dokładności predykcji na wspólnym zbiorze danych przy zastosowaniu jednolitych metryk walidacyjnych (AR-S).
6. **Ocena wpływu predyktorów modelu**- analiza i ocena wpływu poszczególnych zmiennych wejściowych na dokładność predykcji modeli (ocena ważności cech).
7. **Sprawdzenie przydatności modeli w zastosowaniach operacyjnych** - ocena możliwości wykorzystania M2 i M3 do prognozowania wykonalności zakolejkowanych misji oraz wsparcia decyzji w systemach zarządzania flotą AMR.
8. **Opracowanie wniosków rozwojowych** - sformułowanie zaleceń dotyczących dalszego kierunku badań, w tym budowy modeli adaptacyjnych (online) oraz rozszerzeń na inne typy robotów mobilnych.

Przyjęta metodologia eksperymentu

W Etapie 2 przyjęto podejście typu **DoE** - **eksperyment wieloczynnikowy** (*ang. factorial design*), w którym jednocześnie zmieniane są wybrane parametry misji i warunków pracy robota. Takie ujęcie umożliwia rejestrację efektów głównych (wpływu pojedynczych czynników, np. długości trasy, obciążenia robota czy typu akumulatora). Przyjęcie tego podejścia wynika z trzech przesłanek:

- **Rozwój metodologiczny** - Etap 1 pozwolił na weryfikację prostego modelu jednowymiarowego i układu pomiarowego. W Etapie 2 konieczne jest uwzględnienie wielu czynników istotnych dla realnych warunków pracy AMR, zidentyfikowanych w rozdziale 4.
- **Cel badawczy** - dążenie do uchwycenia pełniejszego obrazu zależności energetycznych oraz ocena, które czynniki (i ich kombinacje) mają kluczowy wpływ na dokładność predykcji.
- **Praktyczne zastosowanie** - tylko model wieloparametryczny może stanowić podstawę dla systemów planowania misji i prognozowania wykonalności zadań w warunkach przemysłowych.

Podstawowe założenia eksperymentu

Jednostkę eksperymentalną stanowi pojedynczy przejazd robota AMR MiR100 realizującego tę samą misję w stałych warunkach (zdefiniowana trasa, robota, powtarzalne środowisko testowe, zadana prędkość). Przyjęte czynniki eksperymentalne:

- początkowy stan naładowania akumulatora (SoC_start) w zakresie 100-10%,
- **stan akumulatora - 2 poziomy** (akumulator eksploatowany ~2 lata, akumulator nowy),
- **obciążenie robota - 3 poziomy** (0%, 50%, 100%),
- **długość trasy – 3 poziomy** (30 m, 140 m, 350 m).

W planie eksperymentu przyjęto **18 kombinacji eksperymentalnych** wynikających z układu czynników i ich poziomów ($2 \times 3 \times 3$). **Zmienną odpowiedzi** w każdym przypadku stanowi zużycie energii, wyrażone jako spadek SoC [%] podczas pojedynczej misji transportowej robota AMR. Dla każdej kombinacji czynników przewidziano realizację **pełnych serii rozładowania akumulatora w zakresie 100→10% SoC** (Tabela 15), przy czym **liczbę powtórzeń ustalono na co najmniej trzy (≥ 3)** zgodnie z zaleceniami literaturowymi dotyczącymi projektowania eksperymentów, które wskazują, że taka liczba replikacji stanowi minimum umożliwiające wiarygodną ocenę zmienności wyników i rozróżnienie efektów istotnych od przypadkowych [180], [181], [182]. Pojedyncza seria dostarcza znaczną liczbę jednostek eksperymentalnych (pojedynczych misji), jednak jej powtórzenie jest niezbędne dla potwierdzenia powtarzalności wyników i ograniczenia wpływu pojedynczego przebiegu. Dzięki temu możliwe jest odróżnienie efektów rzeczywistych od czynników trudnych do pełnej kontroli, takich jak zmienność warunków otoczenia, co zwiększa wiarygodność uzyskanych rezultatów.

Tabela 15 Liczba zaplanowanych replikacji (pełnych serii rozładowania akumulatora 100→10% SoC podczas realizacji misji AMR) dla poszczególnych kombinacji obciążenia, trasy i stanu akumulatora.

Obciążenie	Akumulator 1 (2 lata działania)			Akumulator 2 (nowy)		
	30m	140m	350m	30m	140m	350m
0 kg	3	3	3	3	3	3
50 kg	3	3	3	3	3	3
100 kg	3	3	3	3	3	3

Plan prób i scenariusze eksperymentalne

W literaturze naukowej nie zidentyfikowano opracowań systematycznie zestawiających typowe długości misji (pętli) realizowanych przez roboty AMR. Wynika to z faktu, że dystanse pokonywane przez tego typu roboty są w dużym stopniu uzależnione od charakterystyki przedsiębiorstwa, specyfiki procesu intralogistycznego oraz layoutu hali produkcyjnej i magazynowej. Długość tras stanowi zatem cechę indywidualną danego zakładu i trudno jest wskazać wartości uogólnione. Z tego względu w

badaniach przyjęto trzy reprezentatywne długości tras, odpowiadające możliwościom dostępnej hali testowej oraz założonym scenariuszom intralogistycznym:

- **30 m** - krótki dystans odpowiadający transportowi intrakomórkowemu lub między sąsiednimi stanowiskami ($B1 \rightarrow B2 \rightarrow B1$),
- **140 m** - dystans pośredni, odzwierciedlający typowe trasy dostaw komponentów między obszarami produkcji ($B1 \rightarrow B2 \rightarrow B3 \rightarrow B4 \rightarrow B2 \rightarrow B1$),
- **350 m** - dłuższa trasa odpowiadająca transferowi między strefami hali, np. transport z magazynu do linii produkcyjnej
($B1 \rightarrow B2 \rightarrow B4 \rightarrow B3 \rightarrow B1 \rightarrow B2 \rightarrow B4 \rightarrow B3 \rightarrow B1 \rightarrow B2 \rightarrow B4 \rightarrow B3 \rightarrow B1 \rightarrow B2 \rightarrow B3 \rightarrow B2 \rightarrow B1$)



Rys. 32 Mapa obszaru z zaznaczonymi punktami pośrednimi (B1-B4) i stacją ładującą (a) oraz schemat algorytmu automatycznej realizacji pomiarów (b).

Procedura i akwizycja danych

Każda misja testowa będzie rejestrowana w sposób zautomatyzowany przy wykorzystaniu środowiska Node-RED, komunikującego się z robotem AMR poprzez API. W trakcie realizacji eksperymentu, zbieranie danych będzie realizowane w różnych częstotliwościach, zależnie od charakterystyki parametru. Należy zaznaczyć, że nie wszystkie dane będą zbierane ciągle w czasie rzeczywistym, niektóre parametry, takie jak „planowana trasa” czy „obciążenie”, będą zapisywane jednorazowo na początku misji, a inne, jak prędkość, przyspieszenie, czy orientacja, będą zbierane w trakcie misji, z częstotliwością 1Hz. Zestawienie zbieranych danych, faz misji oraz częstotliwości pomiarów przedstawiono poniżej (Tabela 16).

Tabela 16 Zestawienie parametrów pomiarowych zbieranych dla systemu predykcji zużycia energii robota mobilnego, wraz z fazą pozyskiwania danych, źródłem informacji oraz częstotliwością pomiaru.

Parametr	Faza misji	Źródło danych	Częstotliwość
Nazwa misji	start	FMS	1x
Planowana trasa (dystans)	start	FMS	1x
Obciążenie (ładunek)	start	FMS	1x
Zainstalowane akcesoria	start	MiR100	1x
Model robota	start	MiR100	1x
Numer seryjny	start	MiR100	1x
Początkowy SoC	start	MiR100	1x
Metka czasowa rozpoczęcia pomiaru	start	MiR100	1x
Prędkość liniowa	w trakcie misji	MiR100	1Hz
Prędkość kątowna	w trakcie misji	MiR100	1Hz
Przyspieszenie liniowe	w trakcie misji	MiR100	1Hz
Przyspieszenie kątowe	w trakcie misji	MiR100	1Hz
Orientacja (ilość zakrętów)	w trakcie misji	MiR100	1Hz
Temperatura akumulatora	w trakcie misji	Czujnik temp. bat.	1Hz
Temperatura otoczenia	w trakcie misji	Czujnik temp. ot.	1Hz
Przebyta odległość	koniec	MiR100	1x
Końcowy SoC	koniec	MiR100	1x

W eksperymencie zmieniane będą czynniki eksperymentalne przedstawione w Tabeli 15. Pozostałe parametry, takie jak temperatura akumulatora, temperatura otoczenia, model robota czy zainstalowane akcesoria, będą mierzone i rejestrowane, ponieważ mogą mieć wpływ na wyniki eksperymentu. Choć nie są to parametry zmieniane w trakcie eksperymentu, ich pomiar pozwoli na uwzględnienie ich ewentualnego wpływu na zużycie energii. Zbieranie tych danych przygotowane jest również z myślą o opracowaniu bardziej ogólnych modeli predykcyjnych, które będą mogły być zastosowane do różnych modeli robotów AMR w przyszłości. Dzięki temu zmiennymi wejściowymi (czynniki eksperymentalnymi) pozostaną wyłącznie wymienione parametry, a zmienną odpowiedzi badaną w eksperymencie będzie zużycie energii, wyrażone jako spadek SoC ($\Delta\text{SoC} [\%]$).

Analiza danych i kryteria oceny modelu

Zebrane dane w Etapie 2 eksperymentu zostaną wykorzystane do zbudowania dwóch modeli predykcyjnych zużycia energii, w celu porównania dwóch podejść do budowy modelu, uwzględniając, wymaganą wiedzę, czas potrzebny na wdrożenie oraz dokładność i interpretowalność modelu:

- **Model M2 (statystyczny, white-box):** Będzie wymagał głębszej analizy i specjalistycznej wiedzy z zakresu statystyki i regresji, pozwalając na uzyskanie jawnego wzoru matematycznego, który umożliwia pełną interpretację czynników wpływających na zużycie energii.
- **Model M3 (automatyczny, black-box):** Będzie wykorzystywał podejście AutoML, które automatycznie dobierze metodę budowy modelu i przeprowadzi strojenie hiperparametrów, co

pozwole na szybsze opracowanie modelu bez konieczności zaawansowanej wiedzy w zakresie uczenia maszynowego.

Zgodnie z analizą literatury (Tabela 7), modele predykcyjne budowane z wykorzystaniem ML osiągają **skuteczność na poziomie >90%, co stanowi cel eksperymentalny**. Do oceny skuteczności modeli planowane jest zastosowanie skorygowanego współczynnika determinacji (*ang. Adjusted R-Squared*, AR-S), który uwzględnia korektę dopasowania modelu do liczby próbek oraz zmienności danych. AR-S jest odpowiednią miarą, ponieważ oprócz oceny dokładności predykcji, bierze również pod uwagę złożoność modelu, co jest szczególnie istotne przy porównywaniu modeli white-box (statystycznych) i black-box (automatycznych). Dzięki temu AR-S pozwala na obiektywne porównanie obu podejść, eliminując wpływ nadmiernego dopasowania w bardziej złożonych modelach.

Posumowanie


W celu uporządkowania kluczowych założeń Etapu 2 opracowano zestawienie obejmujące wszystkie elementy planu eksperymentu zgodnego z podejściem DoE - eksperyment wieloczynnikowy. Poniżej (Tabela 17) przedstawiono podsumowanie najważniejszych założeń, działań oraz wyników przeprowadzonych eksperymentów

Tabela 17 Założenia planu eksperymentu dla Etapu 2 (podejście DoE - Eksperyment wieloczynnikowy)

Element planu eksperymentu	Założenie (Etap 2 - DoE Eksperyment wieloczynnikowy)						
Cel etapu	opracowanie dwóch modeli predykcyjnych zużycia energii AMR (M2 i M3) oraz ich porównanie pod względem trudności budowy, wymaganej wiedzy i czasu wdrożenia, dokładności predykcji						
Jednostka eksperymentalna	pojedynczy przejazd robota AMR MiR100 realizującego zdefiniowaną misję w stałych warunkach						
Czynnik eksperymentalny	początkowy stan naładowania akumulatora (SoC_start), stan akumulatora, obciążenie robota, dystans misji						
Zakres i poziomy czynnika	• SoC - 100% → 10% SoC (ciągłe obniżanie w kolejnych przejazdach) • stan akumulatora (używany ~2 lata / nowy), • obciążenie robota (0kg - 0%, 50kg - 50%, 100kg - 100%), • dystans misji (trasa 30m, 140m, 350m).						
Zmienne odpowiedzi	zużycie energii wyrażone jako ΔSoC [%] akumulatora						
Warunki kontrolowane (stałe)	konfiguracja punktów, środowisko testowe						
Scenariusze eksperymentalne, Replikacje		Akumulator 1 (2 lata działania)			Akumulator 2 (nowy)		
	Obciążenie	30m	140m	350m	30m	140m	350m
	0 kg	3	3	3	3	3	3
	50 kg	3	3	3	3	3	3
	100 kg	3	3	3	3	3	3
Procedura rejestracji danych	automatyczna akwizycja w Node-RED - Tabela 16						
Plan analizy	Porównanie modeli predykcyjnych: M2 - model statystyczny (white-box) oraz M3 - model bazujący na AutoML (black-box). Oczekiwana skuteczność modeli >90% . Skuteczność modeli zostanie oceniona za pomocą metody AR-S (Adjusted R-Squared), która pozwoli uwzględnić zmienność danych i liczebność próbek, a także porównać dopasowanie modeli z różną złożonością (white-box vs black-box).						

Struktura eksperymentu i kolejność działań

Na poniższym schemacie (Rys. 33) przedstawiono kolejność działań w Etapie 1 (Eksperyment wstępny OFAT) oraz Etapie 2 (Eksperyment wieloczynnikowy) eksperymentu, uwzględniając zadania prowadzące do realizacji określonych celów badawczych pracy. Schemat ten stanowi rozwinięcie mapy rozdziałów pracy doktorskiej (Rys. 24), szczegółowo przedstawiającej strukturę pracy. Umieszczanie planu eksperymentu w głównym tekście rozdziału mogłoby wprowadzać niepotrzebną złożoność w jego odbiorze, dlatego zaprezentowano go na osobnym, szczegółowym schemacie.



Rys. 33 Schemat przedstawiający kolejność działań w Etapie 1 oraz Etapie 2 eksperymentu, z uwzględnieniem celów poszczególnych etapów badawczych.

5.2 Stanowisko badawcze

Z uwagi na ograniczony dostęp do szczegółowych informacji dotyczących konstrukcji wewnętrznej, parametrów podzespołów oraz metod sterowania stosowanych w komercyjnych robotach AMR, opracowanie dokładnych, jawnych modeli opartych na klasycznych równaniach fizyczno-strukturalnych jest niemożliwe. W takich przypadkach najbardziej efektywnym podejściem są modele uczenia maszynowego, które wymagają jednak wcześniejszego zebrania odpowiednich danych wejściowych wykorzystywanych do nauki modelu. Czynniki te zostały określone w Rozdziale 4 - (Rys. 29). Aby zebrać dane, zaprojektowano stanowisko badawcze realizując **zadanie uylitarne 4U**, które umożliwia akwizycję i rejestrację zmiennych wejściowych do modelu predykcyjnego, dotyczących czynników wpływających na zużycie energii robota AMR MiR100 podczas realizacji misji. Projekt systemu pomiarowego jest zgodny z założeniami dwuetapowego planu eksperymentu (Tabela 14, Tabela 17, Rys. 33), które precyzyjnie określają zmienne do pomiaru oraz częstotliwość ich rejestracji. Celem budowy stanowiska badawczego jest zapewnienie infrastruktury pomiarowej umożliwiającej efektywne zbieranie danych niezbędnych do modelowania zużycia energii, zgodnie z wymaganiami eksperymentalnymi.

Realizacja procesu pomiarowego wymagała zaprojektowania spójnej architektury komunikacyjnej, obejmującej dobór odpowiednich czujników, komponentów systemowych oraz protokołów transmisji danych zgodnych ze standardami przemysłowymi. Wybór tych elementów zależał od specyfiki środowiska przemysłowego, w którym robot realizuje swoje zadania. W dalszej części rozdziału przedstawiono szczegółowy opis otoczenia testowego, analizę doboru protokołów komunikacyjnych, selekcję sensorów oraz komponentów, a także strukturę architektury systemu umożliwiającego efektywne zbieranie danych na potrzeby modelowania predykcyjnego.


Opis środowiska fizycznego - hala testowa

Środowisko testowe wykorzystywane podczas zbierania danych stanowiła hala przemysłowa (Rys. 34) o wymiarach 20×40 metrów, w której wyznaczono zorganizowane ciągi transportowe oraz stanowiska współpracujące z mobilnym robotem autonomicznym (AMR MiR100). Przestrzeń hali została pokryta jednolitą nawierzchnią z betonu przemysłowego, zabezpieczoną powłoką epoksydową, typową dla obiektów o podwyższonych wymaganiach eksploatacyjnych, takich jak zakłady produkcyjne i centra logistyczne. Posadzka jest jednorodna pod względem wysokości, co eliminuje wpływ nierówności na parametry ruchu robota.



Rys. 34 Przestrzeń testowa wykorzystywana w eksperymentach:

Hala testowa została przygotowana w taki sposób, aby możliwie wiernie odwzorować warunki realizacji zadań intralogistycznych. Na rysunku Rys. 36 przedstawiono uproszczony rzut hali wraz z wyznaczonymi dwukierunkowymi ścieżkami transportowymi, stanowiącymi podstawę do planowania trajektorii ruchu robota. Wyznaczone stanowiska, oznaczone na rzucie hali literą **M**, reprezentują punkty pośrednie misji robota, pomiędzy którymi robot realizuje autonomiczne misje transportowe. Przed rozpoczęciem procesu pomiarowego hala była wyposażona w infrastrukturę bezprzewodowej transmisji danych w technologii **Wi-Fi**, zapewniającą pokrycie sygnałem na całej powierzchni użytkowej. Punkty dostępne (*ang. access point*), których lokalizacje również zaznaczono na rzucie hali, zostały zamontowane pod sufitem, na wysokości 8 metrów, co pozwala na zmniejszenie efektu zasłonięcia i poprawę propagacji sygnału w poziomie.



Rys. 35 Rzut hali testowej z wyznaczonymi ścieżkami transportowymi (na niebiesko), punktami współpracy robota (B), stacją ładowania (C) oraz lokalizacjami punktów dostępowych Wi-Fi.

Po zakończeniu każdej misji system zarządzający przebiegiem eksperymentu i akwizycją danych monitoruje stan akumulatora robota i w przypadku spadku poziomu naładowania poniżej określonego progu inicjuje zakończenie cyklu pomiarów (100-10% SoC) i jego powrót do automatycznej stacji ładowania (Rys. 36), oznaczonej literą **C** na Rys. 36.



Rys. 36 Stacja ładowania robota mobilnego MiR100.

Przedstawione środowisko testowe stanowiło punkt wyjścia dla dalszych etapów prac badawczo-projektowych realizowanych w ramach niniejszej pracy. Jego konfiguracja, obejmująca układ przestrzenny hali, rozmieszczenie stanowisk roboczych oraz dostępność infrastruktury sieciowej - została przyjęta jako stały kontekst, w którym projektowano system akwizycji danych. Parametry tego środowiska bezpośrednio wpływały na dobór metod komunikacji, lokalizację czujników oraz sposób integracji poszczególnych komponentów systemu, a tym samym determinowały techniczne możliwości realizacji pomiarów niezbędnych do budowy modelu predykcyjnego zużycia energii.

Wymagania funkcjonalne i komunikacyjne

W procesie budowy modelu predykcyjnego zużycia energii, zmienne wejściowe dzielą się na trzy grupy: zmienne, dostępne przed rozpoczęciem misji oraz które należy zmierzyć w trakcie jej realizacji i po zakończeniu zadania. Zmienne dostępne przed misją obejmują takie czynniki jak planowany dystans, ładunek robota (obciążenie), początkowy poziom naładowania akumulatora i są ustalane przed rozpoczęciem misji. W trakcie realizacji misji rejestrowane są zmienne takie jak prędkość robota (kątowna i liniowa), pozycja, temperatura akumulatora oraz informacje o liczbie zakrętów i liczbie przeszkód. Po zakończeniu misji rejestrowane są dane dotyczące całkowitego zużycia energii, czasu trwania zadania oraz faktycznie pokonanej odległości. W celu efektywnego zebrania tych danych, konieczne jest skonfrontowanie zmiennych wymaganych do pomiaru, określonych w Tabeli 16, z możliwościami pozyskania tych parametrów z systemu robota MiR100 (API). W przypadku parametrów nieuwzględnionych w interfejsie systemowym robota (np. temperatura otoczenia) konieczne jest zastosowanie **zewnętrznych czujników IoT**, zintegrowanych z architekturą komunikacyjną stanowiska pomiarowego. Ostateczny zestaw zmiennych, wraz z informacją o ich dostępności i wymaganej częstotliwości próbkowania, stanowi podstawę do zaprojektowania procedury zbierania danych oraz budowy spójnego zbioru treningowego dla modelu predykcyjnego.

Większość zmiennych niezbędnych do budowy modelu predykcji zużycia energii przez robota mobilnego może być pozyskana bezpośrednio z jego interfejsu API, co wymaga implementacji dwukierunkowej komunikacji pomiędzy budowanym systemem nadzorująco-pomiarowym (Node-Red) a platformą mobilną MiR100. Dane te obejmują m.in. pozycję, prędkość, plan misji, stan naładowania akumulatora i parametry dynamiczne ruchu (rozdział 4.3). Jednakże robot nie udostępnia informacji o temperaturze akumulatora ani temperaturze otoczenia. W związku z tym konieczne jest zastosowanie dodatkowych czujników IoT.

Temperatura akumulatora może być rejestrowana za pomocą czujnika z jednokierunkową transmisją danych do systemu pomiarowego, z częstotliwością 1Hz, co jest wystarczające do monitorowania bezpieczeństwa kontroli temperatury akumulatora oraz wpływu temperatury na parametry pracy akumulatora. W tym przypadku szczególną uwagę należy zwrócić na sposób zasilania czujnika. Aby

uniknąć jakiegokolwiek wpływu poboru prądu przez urządzenie pomiarowe na bilans energetyczny robota, czujnik temperatury akumulatora powinien być wyposażony we własne, niezależne źródło zasilania. Zalecane jest zastosowanie rozwiązań energooszczędnych, charakteryzujących się niskim poborem prądu oraz wysoką odpornością na zakłócenia elektromagnetyczne i propagacyjne, typowe dla środowisk przemysłowych, w których obecność dużych maszyn, konstrukcji stalowych i innych źródeł interferencji może prowadzić do tłumienia lub blokowania sygnału transmisyjnego.

Temperatura otoczenia powinna być mierzona w kilku reprezentatywnych punktach hali. Ze względu na powolny charakter zmian temperatury oraz ograniczoną długość misji robota, wystarczające jest jednokrotne pobranie danych na początku jednostki eksperymentalnej (misji). Również w tym przypadku rekomenduje się wykorzystanie czujników z własnym zasilaniem baterijnym, długim czasem pracy bez wymiany baterii oraz jednokierunkową transmisją danych, co pozwala ograniczyć konieczność stosowania zasilania stałego i minimalizuje potrzebę interwencji serwisowych.

Dobór protokołów komunikacyjnych

Na podstawie zestawienia parametrów (Tabela 16), które należy rejestrować przed misją, w jej trakcie oraz po jej zakończeniu, określono konieczność pozyskiwania danych z czterech kluczowych źródeł:

- systemu zarządzania flotą (FMS),
- robota mobilnego MiR100,
- czujnika temperatury akumulatora,
- zestawu czujników mierzących temperaturę otoczenia.

Każde z wymienionych urządzeń i systemów charakteryzuje się odmiennymi wymaganiami w zakresie transmisji danych, takimi jak częstotliwość próbkowania, tolerancja na opóźnienia, odporność na zakłócenia i rozmiar przesyłanych pakietów. Czynniki te determinują konieczność zastosowania odpowiednio dobranych metod akwizycji i wymiany danych. W dalszej części rozdziału przedstawiono proces selekcji technologii komunikacyjnych dla wszystkich źródeł. Prace [5], [6], [34], [183] wskazują, że ograniczona interoperacyjność to jedno z głównych wyzwań we wdrażaniu zintegrowanych rozwiązań intralogistycznych. Wybór otwartych i powszechnie wspieranych metod komunikacyjnych, zapewniających bezpieczeństwo transmisji, choć niekoniecznie będących formalnymi standardami przemysłowymi zwiększa potencjał adaptacyjny projektowanego systemu, umożliwiając jego integrację z rozwiązaniami różnych producentów oraz zastosowanie w zróżnicowanych środowiskach operacyjnych.

Systemy zarządzania pomiarami

W ramach realizowanego zadania zaprojektowano i zrealizowano autorski system zarządzania AMR, odpowiedzialny za nadzorowanie realizacji misji, kolejkovanie zadań oraz monitorowanie stanu robotów. System ten został zintegrowany z opracowanym równolegle modułem akwizycji danych, niezbędnych do budowy modelu predykcyjnego zużycia energii. Oba komponenty funkcjonowały w ramach jednej, spójnej platformy programowej.

Zgodnie z rozwiązaniami powszechnie stosowanymi w systemach typu FMS, integrujących warstwy IT i OT, do komunikacji można wykorzystać uznane mechanizmy wymiany danych, takie jak REST API, protokół MQTT oraz standard OPC-UA. Wszystkie te technologie mogą być wdrażane z wykorzystaniem lokalnej infrastruktury sieciowej opartej na LAN/WLAN, która była dostępna w hali testowej, gdzie przeprowadzono eksperymenty z udziałem robota mobilnego. W przypadku konieczności integracji z zewnętrznym systemem zarządzania flotą, zapewniono możliwość rozszerzenia komunikacji poprzez istniejącą sieć lokalną, co umożliwia elastyczną wymianę danych oraz zwiększa interoperacyjność i adaptacyjność opracowanego systemu pomiarowego.

Robot mobilny MiR100

Kolejnym urządzeniem, o kluczowym znaczeniu z perspektywy ilości generowanych danych, jest robot mobilny, który komunikuje się wyłącznie za pośrednictwem interfejsu REST API, działającego w oparciu o protokół HTTP. Takie rozwiązanie ogranicza możliwe sposoby integracji, jednak opiera się na lokalnej sieci WLAN, która została wdrożona w przestrzeni hali testowej. Architektura ta jest powszechnie stosowana, stabilna i uniwersalna, co umożliwia jej skuteczne wykorzystanie jako podstawy komunikacji pomiędzy jednostką centralną systemu a urządzeniami i podsystemami.

W celu zapewnienia interoperacyjności tworzonego systemu z robotami mobilnymi, które wykorzystują inne metody komunikacji, przewidziano możliwość zastosowania zewnętrznego mikrokomputera (np. Raspberry Pi), pełniącego funkcję pośredniego węzła komunikacyjnego. Urządzenie to może realizować połączenie z jednostką centralną przy użyciu interfejsu REST API, natomiast z robotem może komunikować się zgodnie z jego natywnym protokołem transmisji. Takie rozwiązanie umożliwia integrację systemu pomiarowego z różnorodnymi platformami bez konieczności ingerencji w oryginalną strukturę sprzętową robota AMR, co pozwala zachować zgodność z wymaganiami producenta oraz ułatwia rozszerzanie systemu / pomiarów o kolejne urządzenia.

Czujnik temperatury akumulatora robota mobilnego

W kontekście projektowania systemu akwizycji danych na potrzeby modelowania predykcyjnego zużycia energii przez robota mobilnego, określono wymagania funkcjonalne dla czujnika odpowiedzialnego za pomiar temperatury akumulatora. W celu wyeliminowania wpływu poboru energii przez czujnik na bilans energetyczny robota podczas fazy pomiarowej, przyjęto jego niezależne zasilanie z modułu baterijnego. Zasadniczym kryterium doboru technologii komunikacyjnej jest zapewnienie ciągłości i niezawodności transmisji danych w środowisku przemysłowym, w którym obecność konstrukcji metalowych i zakłóceń elektromagnetycznych może znacząco wpływać na stabilność połączenia. Ze względu na mobilny charakter robota, czujnik musi utrzymywać łączność z systemem nadrzędnym w całym obszarze realizacji misji. Ponadto, z uwagi na bezpieczeństwo eksploatacji oraz konieczność wczesnego wykrywania potencjalnych stanów niepożądanych, założono odczyt temperatury z częstotliwością 1Hz. Preferowane są rozwiązania komunikacyjne umożliwiające wykorzystanie istniejącej infrastruktury sieciowej (LAN/WLAN) oraz zapewniające skalowalność systemu w kontekście przyszłej rozbudowy.

W celu wyznaczenia najbardziej odpowiedniej technologii komunikacyjnej, spełniającej zdefiniowane wymagania funkcjonalne i środowiskowe, przeprowadzono ocenę metod komunikacji z wykorzystaniem macierzy oceny wielokryterialnej. Proces oceny został podzielony na trzy etapy:

- **Etap 1 wyznaczenia technologii komunikacyjnej - określenie istotności kryteriów** - Na podstawie analizy literatury przedmiotu, dokumentacji technicznej oraz aktualnej wiedzy inżynierskiej określono istotność (wagę) poszczególnych kryteriów oceny (Tabela 18). Ocena ta pozwalała ustalić, które z kryteriów mają kluczowe znaczenie dla poprawnej realizacji pomiarów oraz niezawodności całego systemu akwizycji danych. Wykorzystano pięciostopniową skalę istotności (Rys. 37), w której:



Rys. 37 Pięciostopniowa skala istotności kryteriów oceny technologii komunikacyjnych

- 1- Niska istotność** - kryterium ma marginalny wpływ na poprawną realizację pomiarów.
- 2- Ograniczona istotność** - kryterium wpływa na system, lecz jego znaczenie jest drugorzędne.
- 3- Średnia istotność** - kryterium istotne, ale możliwe są kompromisy w jego spełnieniu.
- 4- Wysoka istotność** - kryterium znacząco warunkuje niezawodność i jakość pomiarów.
- 5- Bardzo wysoka istotność** - kryterium kluczowe, niezbędne do prawidłowego działania systemu.

Tabela 18 Kryteria oceny technologii komunikacyjnych dla czujnika temperatury akumulatora robota MiR10 wraz z przypisanymi wagami i uzasadnieniem.

Kryterium	Waga	Uzasadnienie
1 Energooszczędność technologii transmisyjnej	3	Planowane bateryjne zasilanie czujnika podczas pomiarów, brak wpływu na bilans energetyczny robota. Jednak ze względu na niewielki pobór mocy przez czujnik, w rozwiązaniu docelowym dopuszcza się jego zasilanie z robota,
2 Zasięg operacyjny transmisji	5	Wyjazd robota poza obszar zasięgu skutkuje utratą łączności i przerwaniem akwizycji danych, co bezpośrednio wpływa na jakość i ciągłość pomiarów.
3 Odporność protokołu na zakłócenia fizyczne i elektromagnetyczne	4	Zakłócenia i utraty sygnału mogą powodować braki w danych, co będzie wpływało na brak pełnej wiedzy o procesie
4 Zdolność do transmisji z krótkim interwałem czasowym (~1 sek.)	4	Wymagany odczyt co 1s
5 Złożoność techniczna implementacji komunikacji	1	Złożoność implementacji ma znaczenie na etapie budowy stanowiska, jednak kluczowe pozostaje zapewnienie skutecznej akwizycji danych.
6 Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	3	Wykorzystanie istniejącej infrastruktury LAN/WLAN upraszcza system i redukuje koszty, jednak priorytetem pozostaje zapewnienie stabilnej i niezawodnej transmisji danych.
7 Skalowalność systemowa i sieciowa	2	Istotna z perspektywy przyszłej rozbudowy systemu, zarówno w kontekście zwiększenia liczby robotów, jak i rozszerzenia obszaru ich działania.
8 Koszt wdrożenia	3	Koszt wdrożenia obejmuje zarówno nakłady początkowe, jak i koszty stałe związane z utrzymaniem wybranej technologii komunikacyjnej.

- **Etap 2 wyznaczenia technologii komunikacyjnej - ocena technologii względem kryteriów**
- W drugim etapie, ponownie w oparciu o analizę literatury, dokumentację techniczną i wiedzę inżynierską, dokonano oceny stopnia spełnienia poszczególnych kryteriów przez wybrane technologie komunikacyjne (Tabela 19). W tym etapie również zastosowano pięciostopniową skalę (Rys. 38), w której:



Rys. 38 Skala spełnienia kryteriów przez analizowane technologie

- 1- **Brak spełnienia** - technologia nie realizuje danego kryterium w praktyce.
- 2- **Niskie spełnienie** - technologia spełnia kryterium w ograniczonym zakresie, z poważnymi kompromisami.
- 3- **Umiarkowane spełnienie** - technologia zapewnia akceptowalny poziom zgodności, choć z wyraźnymi ograniczeniami.
- 4- **Wysokie spełnienie** - technologia w dużym stopniu realizuje kryterium, a ograniczenia są drugorzędne.
- 5- **Pełne spełnienie** - technologia całkowicie i bez istotnych zastrzeżeń odpowiada danemu kryterium.

Tabela 19 Punktowa ocena wybranych technologii komunikacyjnych względem kryteriów istotnych dla zastosowania w czujniku temperatury akumulatora robota mobilnego.

Kryterium	MQTT	REST API	OPC-UA	Bluetooth	ZigBee	LoRa	GSM
Energooszczędność technologii transmisyjnej	3	3	3	4	4	5	4
Zasięg operacyjny transmisji	3	3	3	2	2	5	5
Odporność transmisji na zakłócenia fizyczne i elektromagnetyczne	3	3	3	3	3	5	2
Zdolność do transmisji z krótkim interwałem czasowym (~1 sek.)	5	5	4	4	4	1	4
Złożoność techniczna implementacji komunikacji	4	5	4	3	3	4	3
Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	5	5	5	1	1	2	2
Skalowalność systemowa i sieciowa	4	4	4	1	4	5	5
Koszt wdrożenia	5	5	5	3	2	2	1

- **Etap 3 wyznaczenia technologii komunikacyjnej - integracja wyników i wybór technologii**
- Na podstawie wcześniej przypisanych ocen cząstkowych (Tabela 18) oraz zdefiniowanych wag poszczególnych kryteriów (Tabela 19) przeprowadzono ocenę końcową z wykorzystaniem macierzy oceny wielokryterialnej, w której każda wartość została pomnożona przez wagę odpowiadającego jej kryterium. Uzyskane w ten sposób wyniki odzwierciedlają łączną zgodność danej technologii komunikacyjnej z wymaganiami funkcjonalnymi i środowiskowymi stawianymi systemowi pomiarowemu. Porównanie wartości końcowych umożliwiło wskazanie technologii, która najlepiej spełnia postawione założenia projektowe - Tabela 20.

Tabela 20 Macierzy oceny wielokryterialnej technologii komunikacyjnych po uwzględnieniu wag kryteriów, odzwierciedlająca stopień zgodności z wymaganiami funkcjonalnymi i środowiskowymi dla czujnika temperatury akumulatora robota mobilnego MiR100.

Kryterium	MQTT	REST API	OPC-UA	Bluetooth	ZigBee	LoRa	GSM
Energooszczędność technologii transmisyjnej	9	9	9	12	12	15	12
Zasięg operacyjny transmisji	15	15	15	10	10	25	25
Odporność protokołu na zakłócenia fizyczne i elektromagnetyczne	12	12	12	12	12	20	8
Zdolność do transmisji z krótkim interwałem czasowym (~1 sek.)	20	20	16	16	16	4	16
Złożoność techniczna implementacji komunikacji	4	5	4	3	3	4	3
Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	15	15	15	3	3	6	6
Skalowalność systemowa i sieciowa	8	8	8	2	8	10	10
Koszt wdrożenia	15	15	15	9	6	6	3
SUMA:	98	99	94	67	70	90	83

Przeprowadzona ocena metod komunikacji z wykorzystaniem macierzy oceny wielokryterialnej wykazała, że najbardziej dopasowaną technologią do zastosowania w czujniku temperatury akumulatora robota mobilnego MiR100 jest REST API. Trzy technologie (REST API, MQTT, OPC-UA) uzyskały jednak zbliżoną punktację i wszystkie spełniają wymagania funkcjonalne i środowiskowe systemu. Ostateczny wybór REST API wynikał z kryterium złożoności implementacyjnej. Protokół ten umożliwia bezpośrednią komunikację z urządzeniem końcowym, bez konieczności stosowania elementów / urządzeń pośredniczących, takich jak broker (w przypadku MQTT) lub serwer (OPC-UA). Należy podkreślić, że każda z tych technologii może być skutecznie zastosowana w projektowanym systemie, przy odpowiednim dostosowaniu architektury komunikacyjnej.

Czujniki temperatury otoczenia

Czujniki temperatury otoczenia zaplanowano rozmieścić w wybranych punktach hali testowej, w celu umożliwienia późniejszego wyznaczenia uśrednionego profilu temperaturowego podczas realizacji misji robota mobilnego. Z uwagi na rozmieszczenie rozproszone oraz konieczność ograniczenia częstotliwości serwisowania, kluczowym wymaganiem wobec tych urządzeń jest ich energooszczędność - możliwość długotrwałej pracy w trybie zasilania bateryjnego. Drugim istotnym czynnikiem jest zasięg transmisji danych w warunkach przemysłowych, ograniczenia w zasięgu mogą wymuszać zastosowanie dodatkowych punktów pośredniczących, co zwiększa złożoność systemu. Ze względu na stacjonarny charakter montażu, szczególnie ważna jest odporność na zakłócenia elektromagnetyczne oraz przeszkody fizyczne, takie jak metalowe elementy wyposażenia hali (np. maszyny, szafy, systemy wentylacyjne), które mogą prowadzić do utraty łączności. Preferowane są technologie komunikacyjne umożliwiające integrację z istniejącą infrastrukturą sieciową (LAN/WLAN) oraz zapewniające skalowalność rozwiązania w kontekście przyszłej rozbudowy systemu.

Dobór odpowiedniej technologii komunikacyjnej dla czujników temperatury otoczenia ponownie przeprowadzono z wykorzystaniem macierzy oceny wielokryterialnej w trzy etapowym procesie. Zastosowano zestaw kryteriów zbliżony do tego, który wykorzystano przy wcześniejszej analizie, jednak ze względu na odmienny charakter akwizycji danych oraz sposób instalacji czujników, dostosowano wagi poszczególnych kryteriów. Na podstawie analizy literatury przedmiotu,

dokumentacji technicznej oraz aktualnej wiedzy inżynierskiej określono istotność (wagę) poszczególnych kryteriów (Tabela 21) wykorzystując pięciostopniową skalę istotności (Rys. 37).

Tabela 21 Kryteria oceny technologii komunikacyjnych dla czujników temperatury otoczenia robota mobilnego wraz z przypisanymi wagami i uzasadnieniem.

Kryterium	Waga	Uzasadnienie
1 Energooszczędność technologii transmisyjnej	5	Kluczowe przy długotrwałym zasilaniu wyłącznie baterijnym
2 Zasięg operacyjny transmisji	4	Wyjazd robota poza obszar zasięgu skutkuje utratą łączności i przerwaniem akwizycji danych, co bezpośrednio wpływa na jakość i ciągłość pomiarów.
3 Odporność protokołu na zakłócenia fizyczne i elektromagnetyczne	5	W przypadku czujnika stacjonarnego zakłócenia lub zasłonięcie mogą całkowicie zablokować transmisję, prowadząc do braków danych i utraty informacji o przebiegu procesu.
4 Zdolność do transmisji z średnim interwałem czasowym (~1min)	4	Wymagany odczyt tylko na starcie misji
5 Złożoność techniczna implementacji komunikacji	1	Złożoność implementacji ma znaczenie na etapie budowy stanowiska, jednak kluczowe pozostaje zapewnienie skutecznej akwizycji danych.
6 Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	3	Wykorzystanie istniejącej infrastruktury LAN/WLAN upraszcza system i redukuje koszty, jednak priorytetem pozostaje zapewnienie stabilnej i niezawodnej transmisji danych.
7 Skalowalność systemowa i sieciowa	2	Istotna z perspektywy przyszłej rozbudowy systemu, zarówno w kontekście zwiększenia liczby robotów, jak i rozszerzenia obszaru ich działania.
8 Koszt wdrożenia	3	Koszt wdrożenia obejmuje zarówno nakłady początkowe, jak i koszty stałe związane z utrzymaniem wybranej technologii komunikacyjnej.

Następnie, wykorzystując wiedzę ekspercką, dokonano oceny wybranych technologii komunikacyjnych pod względem ich zgodności z przyjętymi kryteriami (Tabela 22). Każdej technologii ponownie przypisano ocenę w pięciostopniowej skali (Rys. 38).

Tabela 22 Punktowa ocena wybranych technologii komunikacyjnych względem kryteriów istotnych dla zastosowania w czujnikach temperatury otoczenia.

Kryterium	MQTT	REST API	OPC-UA	Bluetooth	ZigBee	LoRa	GSM
Energooszczędność technologii transmisyjnej	3	3	3	4	4	5	4
Zasięg operacyjny transmisji	3	3	3	2	2	5	5
Odporność transmisji na zakłócenia fizyczne i elektromagnetyczne	3	3	3	3	3	5	2
Zdolność do transmisji z średnim interwałem czasowym (~1 min)	5	5	5	5	5	5	5
Złożoność techniczna implementacji komunikacji	4	5	4	3	3	4	3
Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	5	5	5	1	1	2	2
Skalowalność systemowa i sieciowa	4	4	4	1	4	5	5
Koszt wdrożenia	5	5	5	3	2	2	1

Na podstawie przypisanych ocen cząstkowych (Tabela 22) oraz zdefiniowanych wag kryteriów (Tabela 21), wykorzystując macierzy oceny wielokryterialnej obliczono ocenę końcową dla każdej z analizowanych technologii komunikacyjnych. Uzyskane wyniki odzwierciedlają stopień zgodności poszczególnych technologii z wymaganiami funkcjonalnymi i środowiskowymi stawianymi systemowi pomiarowemu. Analiza wyników pozwoliła na wskazanie rozwiązania najlepiej odpowiadającego

założeniom projektowym w zakresie akwizycji temperatury otoczenia na początku misji. Zestawienie wyników przedstawiono poniżej (Tabela 23).

Tabela 23 Macierzy oceny wielokryterialne technologii komunikacyjnych po uwzględnieniu wag kryteriów, odzwierciedlająca stopień zgodności z wymaganiami funkcjonalnymi i środowiskowymi dla czujników temperatury otoczenia.

Kryterium	MQTT	REST	OPC-UA	Bluetooth	ZigBee	LoRa	GSM
Energooszczędność technologii transmisyjnej	15	15	15	20	20	25	20
Zasięg operacyjny transmisji	12	12	12	8	8	20	20
Odporność protokołu na zakłócenia fizyczne i elektromagnetyczne	15	15	15	15	15	25	10
Zdolność do transmisji z średnim interwałem czasowym (~1 min)	20	20	20	20	20	20	20
Złożoność techniczna implementacji komunikacji	4	5	4	3	3	4	3
Zgodność z istniejącą infrastrukturą sieciową (LAN/WLAN)	15	15	15	3	3	6	6
Skalowalność systemowa i sieciowa	8	8	8	2	8	10	10
Koszt wdrożenia	15	15	15	9	6	6	3
SUMA:	104	105	104	80	83	116	92

Przeprowadzona ocena metod komunikacji z wykorzystaniem macierzy oceny wielokryterialnej wykazała, że technologią najlepiej spełniającą wymagania systemu akwizycji temperatury otoczenia jest LoRa. O wysokiej ocenie tej technologii zadecydowały przede wszystkim jej energooszczędność, umożliwiającą długotrwałą pracę czujników na zasilaniu bateryjnym bez konieczności częstej konserwacji. LoRa została opracowana z myślą o zastosowaniach IoT, w których kluczowe jest niezawodne przesyłanie małych pakietów danych w dużych odstępach czasu i na znaczne odległości. Protokół wykorzystuje pasmo 868 MHz, co w porównaniu do technologii działających w paśmie 2,4 GHz (takich jak MQTT, REST API, OPC-UA czy Bluetooth) zapewnia lepszą propagację sygnału i większą odporność na zakłócenia oraz przeszkody fizyczne, typowe dla środowisk przemysłowych. Pomimo konieczności zastosowania dodatkowego sprzętu pośredniczącego (bramki LoRa - *ang. gateway*), dane odebrane z czujników są automatycznie przesyłane na serwer, z którego mogą być następnie udostępniane do systemu nadrzędnego za pośrednictwem protokołu MQTT. Umożliwia to spójną integrację z istniejącą infrastrukturą komunikacyjną. Tym samym technologia LoRa, pomimo nieco większej złożoności wdrożeniowej, najlepiej spełniła zdefiniowane wymagania techniczne i środowiskowe.

Dobór komponentów systemu

Na podstawie wymagań funkcjonalnych i parametrów technicznych określonych w poprzednich rozdziałach, a także w oparciu o analizę dostępnych rozwiązań komunikacyjnych, dokonano doboru komponentów systemu. Wybór ten został przeprowadzony z uwzględnieniem wyników analizy porównawczej protokołów komunikacyjnych, opracowanej w formie macierzy wielokryterialnej. W niniejszej części przedstawiono opis wybranych elementów oraz uzasadnienie ich zastosowania w kontekście projektowanego układu. W dalszej kolejności zaprezentowano zbudowany układ pomiarowy, uwzględniający omawiane komponenty.

Cały obszar hali produkcyjnej objęty jest jednolitą infrastrukturą bezprzewodową, opartą na punktach dostępowych pracujących w paśmie 2,4 GHz. Zapewnia ona ciągłość zasięgu oraz stabilną transmisję danych na potrzeby systemów operujących w czasie rzeczywistym. W oparciu o tę sieć realizowana będzie komunikacja między centralną jednostką sterującą, odpowiedzialną za akwizycję danych pomiarowych i nadzorowanie przebiegu pomiarów, a pozostałymi elementami systemu. Jednostka ta pełni również funkcję systemu zarządzania flotą robotów mobilnych (FMS), integrując nadzór nad środowiskiem z koordynacją pracy autonomicznych robotów.

Bezprzewodowy czujnik temperatury BleBox tempSensor v2 - pomiar temperatury akumulatora

Urządzenie zostało wyposażone w wodoodporną, przewodową sondę temperatury, umożliwiającą prowadzenie pomiarów w zakresie od -55°C do 125°C. Dzięki kompaktowej konstrukcji oraz zasilaniu poprzez złącze USB typu C (5 V, maks. 1 W), możliwy jest jego bezinwazyjny montaż na obudowie akumulatora robota, bez ingerencji w strukturę mechaniczną urządzenia, co eliminuje ryzyko utraty gwarancji producenta. Czujnik charakteryzuje się rozdzielczością 0,125°C oraz dokładnością pomiaru $\pm 0,5^\circ\text{C}$ w zakresie temperatur od -10°C do 85°C, co zapewnia wystarczającą wiarygodność danych w typowych warunkach eksploatacyjnych. Komunikacja z systemem nadrzędnym realizowana jest bezprzewodowo w standardzie Wi-Fi (802.11g), przy czym otwarte API umożliwia integrację poprzez zapytania HTTP (GET). W warunkach mobilnych urządzenie może być zasilane zewnętrnie, na przykład z użyciem powerbanku o pojemności 20 000mAh, przy założonym maksymalnym poborze mocy 1 W (ok. 200mA) pozwala to na około 100 godzin autonomicznej pracy. Alternatywnie, możliwe jest zasilanie czujnika bezpośrednio z portu USB komputera pokładowego robota lub z dedykowanej przetwornicy napięcia 5 V.

Bezprzewodowy czujnik temperatury i wilgoci Dragino LHT65N - pomiar temperatury otoczenia

bezprzewodowy czujnik środowiskowy wykorzystujący technologię LoRaWAN klasy A, umożliwiający transmisję danych na duże odległości przy niskim poborze energii. Urządzenie posiada wbudowaną baterię 2400mAh, zapewniającą do 10 lat pracy. Czujnik mierzy temperaturę w zakresie -40°C do +85°C z rozdzielczością 0,01°C i dokładnością $\pm 0,3^\circ\text{C}$ oraz wilgotność (0-96% RH) z rozdzielczością 0,04% i dokładnością $\pm 3\%$. Dane przesyłane są siecią LoRa (868 MHz) do serwera TTN, skąd mogą być pobierane do własnych systemów poprzez protokół MQTT.

Bramka dostępowa LoRa (*ang. Gateway*)

MikroTik wAP LR8 to odporna na warunki atmosferyczne bramka LoRaWAN działająca w paśmie EU868, przeznaczona do zastosowań zewnętrznych. Umożliwia transmisję pakietów UDP do publicznych i prywatnych serwerów, w tym TTN. Urządzenie wyposażono w interfejs Wi-Fi 2,4 GHz oraz port Ethernet (10/100 Mb/s), co zapewnia elastyczność integracji. Wbudowana antena 2 dBi pozwala na zasięg do kilkuset metrów w terenie otwartym; zastosowanie anteny zewnętrznej (np. 6,5 dBi) może zwiększyć zasięg do kilku kilometrów

Jednostka centralna ADVANTECH UNO-247-J1N1AE


Jednostka centralna nie wymaga znacznych zasobów obliczeniowych, jednak z uwagi na konieczność zapewnienia wysokiej niezawodności, stabilności działania oraz odporności na czynniki środowiskowe, zdecydowano się na zastosowanie komputera klasy przemysłowej. W projekcie wykorzystano model UNO-247-J1N1AE firmy Advantech, charakteryzujący się kompaktową, bez wentylatorową konstrukcją, odpornością na wstrząsy i wibracje oraz możliwością pracy w szerokim zakresie temperatur. Urządzenie oferuje stabilną komunikację przewodową z siecią lokalną, co jest istotne z perspektywy niezawodnej transmisji danych pomiarowych oraz sterowania systemem zarządzania flotą robotów mobilnych. Platforma obsługuje zarówno system operacyjny Windows, jak i Linux, co zapewnia elastyczność w doborze środowiska programistycznego i integracyjnego.

Architektura stanowiska badawczego

Jednostkę centralną stanowi komputer przemysłowy ADVANTECH UNO-247-J1N1AE z zainstalowanym systemem operacyjnym Linux, na którym uruchomiono środowisko Node-RED. Jest to platforma graficznego programowania blokowego (narzędzie typu low-code / no-code) przeznaczona do szybkiego prototypowania logiki systemowej i integracji urządzeń w ramach IoT, umożliwiające budowę rozproszonych aplikacji za pomocą graficznego edytora przepływów (*ang. flow-based programming*). Dzięki swojej modularnej strukturze, Node-RED wspiera także integrację z własnymi skryptami w języku Python i JS, co umożliwia realizację bardziej zaawansowanych zadań analitycznych lub kontrolnych.


W jednostce centralnej zainstalowano również system bazodanowy MySQL, służący do archiwizacji danych pomiarowych. Node-RED pełni rolę środowiska pomiarowego odpowiedzialnego za zbieranie danych przed, w trakcie oraz po zakończeniu misji robota mobilnego. Dane te są systematycznie zapisywane w bazie danych, umożliwiając ich dalszą analizę oraz wizualizację.

Co istotne, środowisko **Node-RED** nie ogranicza się wyłącznie do funkcji pomiarowych - pełni ono również rolę autorskiego systemu zarządzania flotą (**FMS**), umożliwiającego m.in. kolejkovanie misji, automatyczne odsyłanie robota do stacji ładowania po osiągnięciu progowego poziomu energii, a także integrację i testowanie autorskich algorytmów predykcyjnych zużycia energii oraz mechanizmów wczesnego reagowania na zakłócenia podczas realizacji zadań. Node-RED umożliwia nie tylko budowę środowiska pomiarowego, ale również opracowanie systemu sterującego przebiegiem misji / pomiarów automatyzującego akwizycję danych (Rys. 39). Z uwagi na czasochłonny charakter eksperymentów związanych z rozładowywaniem akumulatora podczas pracy robota, system pomiarowy musiał zostać w pełni zautomatyzowany.




Rys. 39 Schemat działania autorskiego systemu pomiarowo-zarządzającego misjami robota mobilnego MiR100 zrealizowanego w środowisku Node-RED

Dzięki otwartej architekturze i wsparciu licznych protokołów przemysłowych, środowisko Node-RED może być również zintegrowane z innymi systemami przedsiębiorstwa, takimi jak WMS, ERP czy MES, co czyni go elastycznym komponentem w strukturze Przemysłu 4.0. Schemat komunikacji i transmisji danych w systemie pomiarowym przedstawiono na Rys. 40. Szczegółowy podział źródeł zmiennych, sposób ich przesyłania oraz miejsca rejestracji pokazano na Rys. 41



Rys. 40 Schemat komunikacji i transmisji danych w systemie pomiarowym.



Rys. 41 Rejestracja danych w systemie zarządzania robotem i eksperymentem.

Przedstawiona konfiguracja stanowiska badawczego, obejmująca środowisko testowe, architekturę komunikacyjną oraz dobór komponentów pomiarowych, stanowi spójny fundament dla realizacji eksperymentów związanych z modelowaniem predykcijnym zużycia energii przez robota mobilnego. Zastosowane rozwiązania zapewniają niezbędną ciągłość akwizycji danych, a ich parametry techniczne umożliwiają prowadzenie analiz w warunkach zbliżonych do rzeczywistych scenariuszy intralogistycznych. Utworzone stanowisko tworzy stabilną bazę dla dalszych etapów badań, obejmujących budowę i walidację modeli predykcyjnych.

6 Opracowanie i walidacja modeli predykcyjnych zużycia energii przez AMR

Rozdział szósty przedstawia opracowanie i walidację autorskich modeli predykcyjnych zużycia energii przez autonomiczne roboty mobilne, stanowiących realizację zasadniczego celu pracy. Zaprezentowano trzy warianty modeli: jednowymiarowy model referencyjny (M1) oparty na regresji wielomianowej, wielowymiarowy model statystyczny (M2) w postaci uogólnionego modelu liniowego oraz model automatyczny (M3) opracowany z wykorzystaniem narzędzia AutoML. Kolejne sekcje obejmują wyniki walidacji, analizę dokładności predykcji oraz ocenę ważności predyktorów. W zakończeniu rozdziału przedstawiono porównanie modeli pod kątem interpretowalności, złożoności i potencjału wdrożeniowego.

Rozdział ten prezentuje autorskie modele predykcyjne zużycia energii autonomicznych robotów mobilnych, których budowa stanowiła część procesu badawczego. Modelowanie to było integralnym elementem projektu eksperymentu przedstawionego na Rys. 33 i częścią ogólnej koncepcji badań zaprezentowanej na Rys. 24. Dobór modeli został przeprowadzony na podstawie założeń określonych w rozdziale 3.3 oraz analizy literatury przedstawionej w rozdziale 2, co umożliwiło wybór metod modelowania najlepiej odpowiadających celowi badawczemu. Etap ten został zrealizowany po opracowaniu planu eksperymentu (rozdział 3.1) oraz po zebraniu danych pomiarowych na stanowisku badawczym opisanym w rozdziale 5.2. Modele te posłużyły do precyzyjnego oszacowania wykonalności zadań transportowych w dynamicznych środowiskach intralogistycznych oraz do wsparcia decyzji dotyczących zarządzania misjami i detekcji zakłóceń w trasach przejazdu. **Poszczególne podejścia, o rosnącym stopniu złożoności, zostały zwalidowane i opublikowane w recenzowanych czasopismach naukowych [184], [185], [186], stanowiących dorobek naukowy autora rozprawy.**

Model M1 został opracowany jako odpowiedź na problem obserwowany w danych systemu BMS: robot wykonujący tę samą misję raportuje zmienne zużycie energii (spadek SoC). Zjawisko to wynika z nieliniowej charakterystyki zależności napięcia obwodu otwartego (OCV) od SoC w ogniwach LiNMC oraz z ograniczeń algorytmów estymacji SoC. Nawet w stabilnym zakresie 20-80% SoC przebieg rozładowania pozostaje nieliniowy (Rys. 13), a błędy aproksymacji mogą prowadzić do rozbieżności w odczytach. Przy założeniu niezmienności parametrów robota i misji, potrzebna jest szybka metoda weryfikacji, czy robot jest w stanie zrealizować zakolejkowane zadania i czy w trakcie przejazdu nie wystąpiły zakłócenia, np. objazdy. Model 1 aproksymuje empiryczną charakterystykę rozładowania funkcją wielomianową dla danej misji. Dzięki temu może być bezpośrednio zaimplementowany w systemie sterowania jako narzędzie predykcji wykonalności zadań i detekcji odchyłeń, a zarazem pełni funkcję punktu odniesienia dla późniejszych, bardziej uniwersalnych modeli.

Modele M2 i M3 mają charakter uniwersalny. W obu przypadkach zbudowano je na wielowymiarowym opisie misji i robota, poprzedzonym selekcją cech o potencjalnym wpływie na zużycie energii, również z myślą o innych platformach AMR. Dzięki temu zarówno zbiór danych, jak i procedura uczenia oraz walidacji są przygotowane do rozszerzenia na nowe misje i kolejne roboty bez zmiany ogólnej struktury rozwiązania. Model M2 wykorzystuje uogólniony model liniowy (GLM), co zapewnia jawną postać równań i pozwala analizować wpływ poszczególnych zmiennych. Model M3 został zbudowany z wykorzystaniem narzędzia AutoML, które automatyzuje proces wyboru i strojenia modeli. Zastosowanie dwóch metod umożliwia ocenę czy wnioski dotyczące wpływu zmiennych wejściowych są niezależne od formalizmu modelu. Równoległa analiza ogranicza ryzyko, że rezultaty będą specyficzne dla jednej techniki, a uzyskane wnioski zyskują silniejsze podstawy metodologiczne. Celem obu modeli jest dostarczenie uniwersalnego narzędzia prognozowania zużycia energii na podstawie parametrów robota, misji i otoczenia, które można wykorzystać do zarządzania operacyjnego flotą, planowania misji, bieżącej oceny wykonalności zadań. Zestawienie GLM i AutoML umożliwia także

porównanie podejścia wymagającego intensywnej pracy eksperckiej z rozwiązaniem, które może być szybsze i tańsze we wdrożeniu, co odpowiada na potrzeby środowisk przemysłowych, w których liczy się czas i dostępność zasobów.

W celu ułatwienia porównania oraz jednoznacznego określenia zakresu i charakteru poszczególnych rozwiązań, poniżej (Tabela 24) zestawiono syntetyczne opisy trzech opracowanych modeli predykcyjnych.

- **Model M1:** „Model predykcyjny zużycia energii przez AMR oparty na jednowymiarowej regresji wielomianowej”.
- **Model M2:** „Model predykcyjny zużycia energii przez AMR oparty na uogólnionym modelu liniowym (GLM) z wieloma zmiennymi wejściowymi”.
- **Model M3:** „Model predykcyjny zużycia energii przez AMR oparty na metodzie automatycznego doboru algorytmów (AutoML)”.

Tabela 24 Główne cechy opracowanych modeli M1-M3

Model	Dane wejściowe	Metoda	Kluczowa właściwość	Scenariusz zastosowania	Cel wdrożenia
M1	SoC początkowy (przy stałych pozostałych parametrach misji i robota)	M1: jednowymiarowa regresja wielomianowa kalibrowana dla pojedynczej misji.	Prostota i niskie wymagania danych; łatwa implementacja	Pojedyncza, powtarzalna misja w stałych warunkach	Opracowanie jawnego modelu bazowego do weryfikacji wykonalności stałej misji i detekcji anomalii energetycznych; stanowi punkt odniesienia dla M2 i M3.
M2	Wektor cech misji, robota i środowiska (dystans, masa ładunku, prędkość, liczba zakrętów, temperatura, itd.).	M2: uogólniony model liniowy (GLM), jawna postać równań.	Interpretowalność współczynników i możliwość testów istotności	Wiele misji jednego robota; przygotowane do rozszerzeń na inne AMR	Opracowanie jawnego, wielowymiarowego modelu predykcyjnego zużycia energii umożliwiającego analizę wpływu czynników misji i parametrów robota oraz prognozowanie zapotrzebowania energetycznego w różnych scenariuszach.
M3	Wektor cech misji, robota i środowiska (dystans, masa ładunku, prędkość, liczba zakrętów, temperatura, itd.).	M3: AutoML, automatyczny dobór algorytmów ML	Automatyzacja procesu budowy - szybkie wdrożenie i skalowanie predykcji w środowisku przemysłowym,	Wiele misji jednego robota; przygotowane do rozszerzeń na inne AMR	Opracowanie modelu predykcyjnego zużycia energii z wykorzystaniem narzędzi AutoML oraz porównanie jego skuteczności i użyteczności z modelem jawnym M2, w kontekście możliwości szybkiego wdrożenia w środowiskach przemysłowych.

6.1 Model predykcyjny zużycia energii przez AMR oparty na jednowymiarowej regresji wielomianowej

Zgodnie z założeniami projektu eksperymentów (rozdział 5.1 - etap 1, Tabela 14) - przeprowadzono pomiary zużycia energii w zakresie 100-10% SoC dla trzech typów misji transportowych:

- **misję referencyjną (140m)**, która stanowiła podstawę do budowy modeli predykcyjnych,
- **misję z przeszkodą (220m)** oraz **misję ze skróconą trasą (100m)**, które pełniły funkcję scenariuszy porównawczych, umożliwiających weryfikację i ocenę działania modeli w warunkach odbiegających od nominalny.

We wszystkich przypadkach robot mobilny przewoził 100% dopuszczalnego obciążenia (100 kg). Misja obejmowała przejazd pomiędzy czterema punktami zlokalizowanymi na terenie hali testowej. Konfigurację środowiska testowego i lokalizację punktów docelowych przedstawiono na Rys. 30a.

Cały proces akwizycji danych został w pełni zautomatyzowany z wykorzystaniem środowiska Node-RED, które pełniło rolę systemu pomiarowego oraz uproszczonego systemu zarządzania flotą (FMS). System nadzorował przebieg misji, w tym ich harmonogramowanie, inicjowanie, kierowanie robota do stacji ładowania oraz rejestrowanie wyników pomiarowych. Procedurę pomiarową przedstawiono na Rys. 30b. Rozpoczynała się ona od pełnego naładowania akumulatora robota do poziomu 100% SoC, po czym robot wykonywał zaprogramowaną misję transportową. Po zakończeniu każdej misji system zapisywał do bazy danych początkowy poziom naładowania akumulatora oraz zużycie energii wskazane przez system BMS. Jeśli poziom SoC był powyżej 10%, robot natychmiast rozpoczynał kolejną misję, aż do momentu spadku poniżej progu 10%, co powodowało automatyczne skierowanie robota do stacji ładowania i zakończenie serii pomiarowej.

Poniżej (Tabela 25) zestawiono liczbę powtórzeń misji zgodnych z projektem eksperymentu wykonanych w ramach pojedynczego cyklu rozładowania akumulatora (100-10% SoC) w każdej z serii pomiarowych. Dane te stanowią podstawę dalszego modelowania matematycznego przedstawionego w niniejszym rozdziale.

Tabela 25 Liczba powtórzeń poszczególnych misji transportowych w ramach pojedynczych serii pomiarowych (rozładowanie akumulatora w zakresie 100-10% SoC).

Nazwa misji	Seria pomiarowa 1	Seria pomiarowa 2	Seria pomiarowa 3
Mir bat 140	63	72	74
Mir bat 220	52	51	-
Mir_bat_100	103	-	-


Tabela 26 przedstawia przykładowy fragment zarejestrowanych pomiarów z realizacji wybranej misji transportowej robota AMR (długość trasy: 140 m, średni czas realizacji: 7 minut, obciążenie: 100 kg), wraz z zapisem początkowego poziomu naładowania akumulatora. Kompletny zestaw danych pomiarowych, obejmujący wszystkie serie i scenariusze misji, stanowi podstawę dalszych analiz modelowych.

*Tabela 26 Przykładowe wyniki pomiarów zużycia energii (SoC) dla jednej misji testowej
Mir_bat_140 (140 m, 7 min, 100 kg)*

ID Pomiaru	Nr pomiaru w serii	Nazwa misji	Seria pomiarowa	Zmierzone zużycie energii [% SoC]	Data	Temperatura akum. [°C]	Początkowe SoC akumulatora [%]	Obciążenie [kg]
775	1	Mir_bat_140	3	2,6	18-01-22 9:20	22,0000	97,4	100
776	2	Mir_bat_140	3	2,2	18-01-22 9:27	21,9375	94,8	100
777	3	Mir_bat_140	3	1,7	18-01-22 9:35	21,9375	92,6	100
778	4	Mir_bat_140	3	1,4	18-01-22 9:42	21,8750	90,9	100
779	5	Mir_bat_140	3	1,4	18-01-22 9:49	21,8750	89,5	100
5780	6	Mir_bat_140	3	1,2	18-01-22 9:56	21,9375	88,1	100
781	7	Mir_bat_140	3	1,4	18-01-22 10:04	21,9375	86,9	100
782	8	Mir_bat_140	3	1,3	18-01-22 10:11	22,0000	85,5	100
783	9	Mir_bat_140	3	1,4	18-01-22 10:18	22,0000	84,2	100

Zgodnie z założeniami planu eksperymentu - etap 1 (Tabela 14) w pomiarach przyjęto wyłącznie jeden czynnik eksperymentalny, którym był początkowy poziom naładowania akumulatora (SoC) przed realizacją misji. Utrzymanie pozostałych parametrów misji oraz warunków środowiskowych na stałym poziomie pozwoliło na jednoznaczne przypisanie obserwowanych zmian zużycia energii wyłącznie wpływowi tego czynnika. Tak przygotowany zbiór danych umożliwia wizualizację wyników w postaci zależności spadku SoC od jego wartości początkowej, co stanowi podstawę do dalszego modelowania matematycznego i konstrukcji modelu predykcyjnego M1.

Na Rys. 42 przedstawiono przebiegi zużycia energii, wyrażonego jako spadek SoC w pojedynczej misji, dla scenariuszy obejmujących: misję podstawową (140 m), misję z przeszkodami (220 m) oraz misję porównawczą o skróconej długości (100 m). Wizualizacja ta umożliwia ocenę charakterystyki energetycznej robota w warunkach referencyjnych oraz weryfikację wpływu zmiany długości trasy na zużycie energii.



Rys. 42 Zużycie energii wyrażone jako spadek SoC [%] w pojedynczej misji w funkcji początkowego poziomu naładowania akumulatora.

Analiza charakterystyki rozładowania akumulatora typu litowo-NMC wykazała istotne nieliniowości w przebiegu spadku SoC w zależności od jego początkowej wartości. Pomimo wykonywania tej samej misji, zużycie energii (wyrażone jako spadek SoC) wykazuje wyraźną niemonotoniczność, oscylującą wokół kilku lokalnych ekstremów. Można wyróżnić trzy charakterystyczne strefy pracy:

1. **<20% SoC** - cechuje się wysoką zmiennością i niestabilnością, co wynika ze wzrostu rezystancji wewnętrznej, zjawisk polaryzacyjnych i ograniczeń napięciowych ogniw, które znacząco wpływają na efektywność dostarczania energii [97], [109], [110],
2. **20-90% SoC** - zakres nominalnej pracy, w którym obserwuje się nieliniowy przebieg rozładowania. Jest to konsekwencją nieliniowej relacji pomiędzy napięciem ogniwa OCV a SoC oraz dynamicznych zmian wewnętrznych parametrów chemicznych i termicznych akumulatora [105], [106]. Zmiany te mogą prowadzić do lokalnych nieliniowości, nawet przy pozornie stałym obciążeniu robota,
3. **>90% SoC** - również wykazuje zwiększoną niestabilność i wyższe zużycie energii, co tłumaczy się zjawiskiem relaksacyjnym oraz zwiększonym napięciem końcowym, które prowadzi do intensywniejszych zjawisk samorozładowania [60], [97].

Takie zachowanie znajduje potwierdzenie w literaturze, gdzie wskazuje się, że zarówno dolne, jak i górne granice SoC są energetycznie niekorzystne i prowadzą do wzrostu strat wewnętrznych. Ponadto, nawet w zakresie 20-90%, przebieg rozładowania nie jest liniowy, a jego kształt może być zależny od stanu akumulator, zmian temperatury oraz obliczeń systemu BMS [105], [106], [107], [110].

W literaturze technicznej oraz zaleceniach producentów akumulatorów powszechnie wskazuje się, że optymalny zakres pracy akumulatorów litowo-jonowych mieści się w przedziale od 20% do 80% poziomu naładowania. Dalsze ograniczenie zakresu pracy stanu naładowania (SOC) poniżej standardowo zalecanego przedziału (20-80%) może dodatkowo przyczynić się do wydłużenia trwałości akumulatora, co opisano w rozdziale 1.4 [107]. Niemniej jednak, w ramach przeprowadzonych badań eksperymentalnych zdecydowano się na analizę szerszego zakresu od 10% do 100% SoC w celu uzyskania pełniejszego obrazu charakterystyki rozładowania ogniwa w kontekście realizacji misji podstawowej o długości 140 metrów.

Dla celów modelowania przyjęto zakres pracy akumulatora 20-90 % SoC. Zakres 20-80 % jest standardowo stosowany w analizach energetycznych robotów mobilnych w celu eliminacji nieliniowych efektów przy skrajnych poziomach naładowania. W niniejszych badaniach rozszerzono go do 90 %, aby zwiększyć liczbę danych pomiarowych, poprawić stabilność estymacji parametrów i lepiej odwzorować rzeczywiste warunki eksploatacji, w których roboty często są doładowywane powyżej 80 %.

Wybór metody modelowania

Celem **Etapu 1** w projekcie eksperymentów było zbudowanie prostego, jednoparametrycznego modelu predykcji zużycia energii. Na tym etapie rozważano różne proste podejścia modelowe, takie jak:


- model liniowy (regresja liniowa),
- model wielomianowy,
- model potęgowy lub logarytmiczny,
- model oparty na funkcji wykładniczej.

Planowano zbudowanie i porównanie kilku wariantów modeli oraz ocenę ich jakości dopasowania do danych empirycznych przy użyciu współczynnika determinacji R^2 . Jednakże analiza wstępna danych, przedstawiona na Rys. 42, ujawniła wyraźnie nieliniowy, krzywoliniowy charakter zależności pomiędzy poziomem naładowania a zużyciem energii. Z tego powodu zrezygnowano z dalszego rozważania modeli liniowych i innych prostych form zależności, które nie byłyby w stanie poprawnie odwzorować

obserwowanego przebiegu. Charakterystyka przedstawiona na rysunku wskazuje na potrzebę zastosowania modelu wielomianowego, co stało się podstawą decyzji o wykorzystaniu w kolejnych etapach pracy jednowymiarowej regresji wielomianowej jako głównej metody modelowania.

Dane przedstawione na rysunku Rys. 42 ilustrują zależność pomiędzy poziomem naładowania akumulatora (SoC) a poborem energii w pojedynczej misji (mierzonej jako spadek SoC w %). Na ich podstawie przeprowadzono aproksymację funkcją wielomianową w celu analitycznego opisu charakterystyki rozładowania akumulatora w trakcie realizacji misji o ustalonym profilu i długości. W tym celu wykorzystano funkcję *polyfit* z biblioteki *NumPy* w języku Python.


Stopień wielomianu dobierano iteracyjnie, opierając się na współczynniku determinacji R^2 , który obliczano dla kolejnych stopni dopasowania. Jako minimalny akceptowalny próg dopasowania przyjęto wartość $R^2=0,9$ (Tabela 14), powyżej której dalsze zwiększanie stopnia wielomianu nie prowadziło do istotnej poprawy jakości odwzorowania, a jedynie zwiększało złożoność modelu matematycznego -Rys. 43.



Rys. 43 Wartość współczynnika determinacji R^2 dla kolejnych stopni wielomianu dopasowanego do funkcji opisującej zużycie energii dla podstawowej misji robota MiR100 (140m 100kg).

Na tym etapie modelowania nie dokonano podziału danych na zbiory uczący i testowy, gdyż celem była aproksymacja znanego zbioru pomiarowego i uzyskanie ciągłej reprezentacji przebiegu rozładowania ogniwa. Takie podejście pozwala na uproszczenie analizy oraz ułatwia integrację modelu z systemami wyższego poziomu, np. planowania misji lub estymacji zużycia energii w czasie rzeczywistym.

Dopasowana krzywa dziewiątego stopnia wielomianu osiągnęła wartość współczynnika determinacji $R^2=0,91$ co świadczy o wysokim poziomie zgodności z danymi eksperymentalnymi. Poniższy rysunek (Rys. 44) przedstawia uzyskaną krzywą dopasowaną do pełnego zbioru danych opisujących zużycie energii (wyrażone jako spadek poziomu SoC) w funkcji poziomu naładowania akumulatora.



Rys. 44 Dopasowanie krzywej do zbioru danych kalibracyjnych: aproksymacja zużycia energii (spadku SoC) w funkcji poziomu naładowania akumulatora.

Na dopasowanej krzywej widoczne są lokalne niedoszacowania wartości zużycia energii w obszarach około 55% oraz 75% SoC, gdzie funkcja aproksymująca przyjmuje wartości niższe niż większość obserwacji empirycznych. Z kolei w obszarach około 35% i 60% SoC występują przeszacowania, wynikające z faktu, że regresja wielomianowa, estymowana metodą najmniejszych kwadratów dąży do minimalizacji błędu uśrednionego, co prowadzi do wygładzania przebiegu i ograniczonej zdolności do odwzorowania wszystkich lokalnych ekstremów obecnych w danych rzeczywistych. Skalę tych rozbieżności wynosi 0,1-0,2 punktu procentowego spadku SoC, co odpowiada błędowi względnemu rzędu kilku-kilkunastu procent względem przewidywanych wartości. Odchylenia te nie wpływają istotnie na użyteczność modelu w dalszych etapach analizy, gdyż zachowuje on poprawną reprezentację globalnego trendu i umożliwia wiarygodne prognozowanie zużycia energii w zastosowaniach operacyjnych.

Postać modelu predykcyjnego utworzonego z wykorzystaniem jednowymiarowej regresji wielomianowej

Zastosowanie regresji wielomianowej umożliwia utworzenie modelu o charakterze jawnym (*ang. white-box model*). Dzięki temu użytkownik ma pełną kontrolę nad strukturą modelu, a jego implementacja w systemach zewnętrznych (np. w środowiskach wysokopoziomowych lub osadzonych) jest stosunkowo prosta i nie wymaga zewnętrznych bibliotek. Postać matematyczna modelu pozwala również na szybką ewaluację wyników i interpretację wpływu zmian poziomu naładowania akumulatora na prognozowane zużycie energii. Jest to szczególnie istotne w zastosowaniach przemysłowych, gdzie wymagane są transparentność działania oraz łatwość walidacji i interpretowalność algorytmów decyzyjnych.

Model predykcyjny zużycia energii przez AMR oparty na jednowymiarowej regresji wielomianowej (M1) został sformułowany jako wielomian dziewiątego stopnia, opisujący charakterystykę rozładowania akumulatora dla zarejestrowanej misji podstawowej. Jego postać analityczną przedstawiono we wzorze poniżej.

$$y(x) = -2.88362741 \times 10^{-13}x^9 + 1.48231619 \times 10^{-8}x^8 - 3.28727589 \times 10^{-8}x^7 + 4.11692849 \times 10^{-6}x^6 - 3.20022662 \times 10^{-4}x^5 + 1.59714909 \times 10^{-2}x^4 - 5.10695739 \times 10^{-1}x^3 + 1.00772980 \times 10^1x^2 - 1.11378154 \times 10^2x + 221.527168295 \times 10^2 \quad (10)$$

Gdzie:

y - procentowe zużycie energii podczas pojedynczej misji „Mir_bat_140”,
x - procentowy poziom naładowania akumulatora na początku misji.

Weryfikacja poprawności działania modelu predycyjnego stanu naładowania (SoC) opartego na jednowymiarowej regresji wielomianowej


Zgodnie z założeniami projektu eksperymentów, **Etap 1 (scenariusze testowe)** - w celu praktycznej oceny użyteczności modelu M1 przeprowadzono jego weryfikację w czterech scenariuszach testowych. Scenariusze te zostały zaprojektowane tak, aby odzwierciedlały zarówno potencjał wykorzystania modelu do wspomagania zarządzania flotą robotów AMR, jak i sytuacje zakłócenia oraz aplikacyjne związane z planowaniem i realizacją misji.

Scenariusz testowy 1 - weryfikacja modelu zużycia energii

W celu eksperymentalnej weryfikacji poprawności opracowanego modelu zużycia energii (M1) przeprowadzono szereg testów z udziałem robota mobilnego MiR100. Celem testów było sprawdzenie, czy rzeczywiste zużycie energii podczas wykonywanych misji jest zgodne z wartościami przewidywanymi przez zaproponowany model matematyczny.

Pierwszy test (Scenariusz 1) przeprowadzono w warunkach referencyjnych. Robot realizował misję podstawową (Mir_bat_140, 140 m, obciążenie 100 kg) po trasie identycznej z trasą kalibracyjną wykorzystaną do budowy modelu. Test polegał na wielokrotnym wykonywaniu misji w pętli w zakresie naładowania akumulatora od 90 % do 20 %, przy całkowitym braku zakłóceń środowiskowych. Pozwoliło to na ocenę zgodności modelu z rzeczywistym zużyciem energii przy założeniu stabilnych warunków operacyjnych.

Ze względu na ograniczoną dokładność dopasowania modelu wielomianowego do danych pomiarowych, w niektórych zakresach poziomu naładowania (SoC) mogą występować odchylenia (Rys. 45), zarówno niedoszacowanie (m.in. w okolicach 50% i 75%), jak i przeszacowanie (w okolicach 65%). W związku z tym, na potrzeby identyfikacji anomalii ustalono akceptowalny próg błędu predykcji równy $\pm 15\%$ względem wartości przewidywanej przez model. Każdy przypadek przekroczenia tego progu uznawany był za potencjalnie nieprawidłowe zużycie energii w danej misji.



Rys. 45 Porównanie rzeczywistego zużycia energii z wartościami przewidywanymi przez model w scenariuszu 1 (ścieżka niezakłócona).

Na wykresie (Rys. 45) przedstawiono funkcję modelu predykcyjnego zużycia energii - M1 (linia niebieska). Model ten opisuje oczekiwane zużycie energii (wyrażone jako spadek poziomu SoC) w zależności od poziomu naładowania akumulatora przed rozpoczęciem misji.


Zielonymi punktami (●) oznaczono misje wykonane przez robota w warunkach testowych, które nie zostały przez system zakwalifikowane jako odstępstwa - tzn. ich zużycie energii mieściło się w akceptowalnym zakresie $\pm 15\%$ względem wartości przewidywanej przez model.

Czerwonymi znacznikami (✗) zaznaczono natomiast przypadki, w których system błędnie uznał misję za zakłócone, mimo że w rzeczywistości były one wykonywane w warunkach prawidłowych - bez przeszkód. Wystąpienie takich fałszywie pozytywnych wykryć związane jest z ograniczoną dokładnością aproksymacji funkcją wielomianową, szczególnie w wybranych zakresach SoC (około 35%, 50%, 65%, 75%), w których wcześniej zidentyfikowano tendencję do przeszacowania lub niedoszacowania zużycia energii przez model.

W scenariuszu 1 wykonano łącznie 58 misji w zakresie naładowania akumulatora od 90% do 20%. Spośród nich 4 misje zostały błędnie sklasyfikowane przez system jako zakłócone.

Scenariusz testowy 2 - wykrycie przeszkody na trasie

W tym scenariuszu na domyślnej trasie robota (140m) umieszczono przeszkodę na okres 4 godzin, co zmusiło robota do autonomicznego zaplanowania objazdu. Skutkiem tego było zwiększenie długości trasy oraz wyższe zużycie energii przypadające na pojedynczą misję, co zostało przedstawione Rys. 46. Celem scenariusza było sprawdzenie czy system predykcji prawidłowo identyfikuje odstępstwa od modelu wynikające z nieplanowanych zmian tras. Za anomalię uznawano każdy przypadek, w którym rzeczywiste zużycie energii przekraczało wartość przewidywaną przez model o więcej niż 15%.



Rys. 46 Zużycie energii w scenariuszu 2 - wpływ celowo wprowadzonej przeszkody na trasie robota

Na wykresie (Rys. 46) przedstawiono zużycie energii (spadek SoC) podczas realizacji misji w scenariuszu 2, w którym wprowadzono celową przeszkodę na domyślnej trasie transportowej robota. W wyniku konieczności ominięcia przeszkody, długość pokonywanej trasy wzrosła z 140 m (misja referencyjna) do około 200 m, co spowodowało zauważalne zwiększenie zużycia energii w tym okresie.

Na wykresie przedstawiono porównanie wartości przewidywanych przez model M1 (linia niebieska) z rzeczywistym zużyciem energii w scenariuszu 2.


- **Zielone punkty (●)** - misje, w których zużycie energii mieściło się w akceptowalnym zakresie $\pm 15\%$ względem predykcji modelu M1 (misje uznane za prawidłowe).
- **Czerwone znaczniki (x)** - misje, w których zużycie energii przekroczyło ustalony próg odchylenia, a więc zostały zaklasyfikowane jako odstępstwa od modelu (potencjalne przeszkody).
- **Czerwony obszar** - przedział, w którym celowo wprowadzono przeszkodę na trasie, wymuszając objazd i wydłużenie drogi robota, co skutkowało wzrostem zużycia energii.

W scenariuszu 2, w zakresie 90-20 % SoC, **zrealizowano łącznie 52 misje**, czyli o 6 mniej niż w scenariuszu 1, co wskazuje na zwiększone zużycie energii spowodowane obecnością przeszkody na trasie. Spośród wszystkich realizacji system błędnie sklasyfikował jedynie 2 misje - w obszarach, w których model M1 wykazywał tendencję do niedoszacowania zużycia energii (zidentyfikowaną wcześniej w scenariuszu 1). **Pozostałe 50 misji zostało poprawnie rozpoznanych: 32 jako niezakłócone oraz 18 jako zakłócone.** Uzyskane wyniki potwierdzają skuteczność modelu M1 w detekcji odchylenia od wartości referencyjnych, takich jak wydłużenie trasy spowodowane przeszkodą.

Scenariusz testowy 3 - system wczesnego powiadamiania o odchyleniach zużycia energii

Scenariusz 3 - integracja modelu M1 z systemem wyższego poziomu i test praktyczny. Celem trzeciego scenariusza było praktyczne wdrożenie modelu M1 do systemu nadzorującego pracę floty AMR i ocena jego użyteczności w automatycznej detekcji nieprawidłowości energetycznych. W ramach tego scenariusza opracowano i zaimplementowano algorytm powiadamiania, który generuje alert po wykryciu określonej liczby kolejnych misji, w których zużycie energii przekroczyło ustalony próg odchylenia względem wartości przewidywanej. Rozwiązanie to ma na celu wsparcie działu utrzymania ruchu poprzez wczesną identyfikację potencjalnych problemów eksploatacyjnych (np. nieplanowanego wydłużenia trasy, dodatkowych oporów ruchu czy usterek).

W tym celu w środowisku Node-RED zaimplementowano autorski system monitorujący, który rejestruje poziom naładowania akumulatora (SoC) na początku oraz na końcu każdej misji. Rzeczywisty spadek SoC jest następnie porównywany z wartością obliczoną na podstawie modelu predykcyjnego M1, odpowiedniego dla danej misji. W przypadku wykrycia istotnego odchylenia (przekraczającego ustalony próg 15%), system generuje powiadomienie w interfejsie aplikacji (dashboard), informujące użytkownika o potencjalnym zakłóceniu. Zasada działania systemu wczesnego ostrzegania („żółtego alarmu”) została zilustrowana na schemacie blokowym (Rys. 47), który przedstawia przepływ danych, logikę porównawczą oraz mechanizm aktywacji alertu. Dodatkowo zaprezentowano pseudokod implementujący proponowany algorytm.



INICJALIZACJA SYSTEMU:

```

PRÓG_ODCHYLENIA ← 15%
LICZBA_POWTÓRZEŃ_DO_ALARMU ← 3
licznik_odchyleń ← 0

```

```

połącz_z_robotem("MiR100_1")
inicjalizuj_bazę_modeli()
wyczyść_stan_misji()

```

PĘTLA GŁÓWNA:

```

while true:
    status ← REST_API.get_status()
    kolejka_misji ← REST_API.get_mission_queue()
    aktywna_misja ← wybierz_pierwszą(kolejka_misji)

    if czy_start_nowej_misji(aktywna_misja):
        SoC_start ← odczytaj_SoC()
        zapisz("nazwa_misji", aktywna_misja.nazwa)
        zapisz("SoC_start", SoC_start)

    if czy_koniec_misji(aktywna_misja):
        SoC_stop ← odczytaj_SoC()
        zapisz("SoC_stop", SoC_stop)

        zużycie_rzeczywiste ← SoC_start - SoC_stop
        zużycie_predykowane ← oblicz_predykację(aktywna_misja, SoC_start)

        odchylenie ← |zużycie_rzeczywiste - zużycie_predykowane| / zużycie_predykowane * 100

        if odchylenie > PRÓG_ODCHYLENIA:
            licznik_odchyleń += 1
        else:
            licznik_odchyleń ← 0


        if licznik_odchyleń ≥ LICZBA_POWTÓRZEŃ_DO_ALARMU:
            wygeneruj_alarm("Żółty", aktywna_misja, odchylenie)
            licznik_odchyleń ← 0

    poczekaj(krótki_interwał)

```

Rys. 47 Schemat działania systemu wczesnego wykrywania anomalii podczas misji zrealizowanego w środowisku Node-RED dla robota MiR100, z wykorzystaniem predykcyjnego modelu zużycia energii


W ramach scenariusza 3 przeprowadzono ponownie pełny cykl rozładowania akumulatora robota MiR100 podczas realizacji misji (90% do 20%) SoC. Celem testu była weryfikacja działania opracowanego systemu predykcijnego wykrywania anomalii zużycia energii, zrealizowanego w środowisku Node-RED. W trakcie realizacji scenariusza 3 (Rys. 48), po wystąpieniu trzech misji charakteryzujących się zużyciem energii przekraczającym o ponad 15% wartość przewidywaną przez model referencyjny, system poprawnie wygenerował żółty alarm. Szybka identyfikacja odstępstwa umożliwiła odpowiednią reakcję techniczną (np. interwencję operatora lub zespołu utrzymania ruchu), co przełożyło się na utrzymanie ciągłości pracy systemu.



Rys. 48 Wykrycie anomalii w scenariuszu 3 - żółty alarm aktywowany po trzech misjach z odchyleniem >15% spowodowanym dodatkową przeszkodą na trasie.

W ramach scenariusza 3 **zrealizowano łącznie 58 misji transportowych**, czyli tyle samo co w scenariuszu 1, pomimo wcześniejszego wystąpienia czterech misji o ponadnormatywnym zużyciu energii. System błędnie sklasyfikował jedynie jedną misję (odchylenie ~35 %), w obszarze, w którym model M1 wykazywał tendencję do niedoszacowania zużycia energii, zidentyfikowaną już w scenariuszu 1. Wizualizację wyników klasyfikacji oraz poziomów zużycia energii przedstawiono na Rys. 48. Poprawne zadziałanie zaproponowanego systemu ostrzegania („żółty alert”) potwierdza skuteczność opracowanego mechanizmu detekcji odchyleń.

Na Rys. 49 przedstawiono porównanie momentu zadziałania alarmu w scenariuszu 3 (żółty alarm) po trzech kolejnych misjach z nadmiernym zużyciem energii i podjęciem działań zaradczych przez operatora eliminujących przeszkodę oraz scenariusza 2, w którym przeszkoda utrzymywała się przez 4 godziny bez reakcji systemu. Dzięki szybszej detekcji i uruchomieniu alarmu w scenariuszu 3 możliwe było wykonanie dodatkowych 6 misji transportowych przed koniecznością naładowania akumulatora, co potwierdza skuteczność zastosowanego modelu predykcijnego do monitorowania poprawności procesu transportu.



Rys. 49 Porównanie scenariuszy 2 i 3 - wpływ działania systemu alarmowego na przebieg cyklu rozładowania akumulatora robota MiR100.


Scenariusz testowy 4 - system weryfikacji wykonalności zakolejkowanych misji

W ramach scenariusza 4 opracowano i przetestowano algorytm umożliwiający automatyczną weryfikację wykonalności wszystkich zakolejkowanych zadań transportowych, przydzielonych do konkretnego robota mobilnego. Celem działania systemu jest ocena, czy na podstawie aktualnego poziomu naładowania akumulatora (SoC), dany robot będzie w stanie zrealizować całość zaplanowanej kolejki misji, bez ryzyka przerwania ich z powodu niedoboru energii.

Dla każdej misji znajdującej się w kolejce pobierany jest przypisany model predykcyjny zużycia energii, a następnie na jego podstawie obliczane jest przewidywane zużycie energii (ΔSoC) wymagane do jej realizacji. Obliczenia prowadzone są iteracyjnie, a zużycie energii sumowane, aż do momentu, w którym dostępny budżet energetyczny zostaje przekroczony. W celu zapewnienia bezpiecznego marginesu działania systemu, uwzględniono dodatkowy warunek: poziom naładowania akumulatora robota nie może spaść poniżej 20 %, co umożliwia mu autonomiczny dojazd do stacji ładowania.

W przypadku wykrycia, że realizacja pełnej kolejki misji nie jest możliwa w obecnym stanie energetycznym, algorytm automatycznie zwraca listę misji, które powinny zostać przekierowane na innego robota lub wykonane po naładowaniu.

Algorytm (Rys. 50) został zaimplementowany w środowisku Node-RED, z wykorzystaniem modułu Python do obliczeń predykcyjnych zużycia energii. Zasada jego działania została przedstawiona poniżej.



INICJALIZACJA SYSTEMU:

```

połącz_z_robotem("Mir100_1")
inicjalizuj_bazę_modeli()
PRÓG_REZERWY ← 20 # [% SoC]

```

PĘTLA_GŁÓWNA:

```

while true:
    # 1. Bieżący stan akumulatora
    SoC_bieżący ← odczytaj_SoC()
    SoC_dostępny ← SoC_bieżący - PRÓG_REZERWY

    # 2. Kolejka misji z REST API
    kolejka ← REST_API.get_mission_queue()
    niewykonalne ← []
    SoC_pozostały ← SoC_dostępny

    # 3. Analiza każdej misji
    for misja in kolejka:
        wzór_modelu ← pobierz_model_predykcyjny(misja.nazwa)
        E_pred ← oblicz_predykcję(wzór_modelu, SoC_pozostały)

        if E_pred ≤ SoC_pozostały:
            SoC_pozostały ← SoC_pozostały - E_pred
        else:
            niewykonalne += [misja.nazwa for m in kolejka[i:]]
            break

    # 4. Raportowanie
    if niewykonalne.is_empty():
        log("Wszystkie misje mogą zostać zrealizowane "
            + "z zachowaniem rezerwy 20%.")
    else:
        wygeneruj_alarm("Czerwony",
            "Przekroczony budżet energetyczny (próg 20%).")
        log("Niewykonalne misje: " + str(niewykonalne))

```

Rys. 50 Implementacja modelu predykcyjnego zużycia energii AMR w systemie prototypowym (Node-RED) do oceny wykonalności misji.

Analiza ograniczeń jednowymiarowego modelu predykcji zużycia energii dla AMR

Przedstawiony w niniejszym rozdziale model predykcyjny zużycia energii przez AMR, oparty na oparty jednowymiarowej regresji wielomianowej, został skutecznie przetestowany w środowisku pracy robota mobilnego MiR100 (hala testowa). Na podstawie przeprowadzonych eksperymentów wykazano, że prosty model M1, oparty na charakterystyce rozładowania akumulatora dla konkretnej misji, pozwala skutecznie identyfikować anomalie energetyczne, pod warunkiem uprzedniej kalibracji modelu dla danej misji.

Pomimo uzyskanej skuteczności, podejście to posiada istotne ograniczenia:

- **Konieczność indywidualnej kalibracji** - model wymaga osobnej kalibracji dla każdej misji, obejmującej pełny zakres roboczy (20-90 % SoC). Proces ten może być czasochłonny i trudny do skalowania w środowisku przemysłowym o dużej liczbie zróżnicowanych zadań transportowych.
- **Brak walidacji międzyplatformowej** - nie przeprowadzono testów z wykorzystaniem innych egzemplarzy robota MiR100 ani innych robotów AMR, co ogranicza możliwość uogólnienia wyników.
- **Pomijanie dodatkowych czynników wpływających na zużycie energii**, takich jak:
 - temperatura otoczenia i temperatura akumulatora,
 - masa ładunku,
 - profil sterowania i dynamika ruchu,
 - stopień zużycia elementów mechanicznych,
 - wiek i stan techniczny akumulatora.

Brak uwzględnienia tych parametrów ogranicza dokładność prognozowania w złożonych i dynamicznych warunkach produkcyjnych.

Z tego względu w kolejnych etapach badań, opisanych w kolejnych rozdziałach skupiono się na rozwoju bardziej zaawansowanego modelu predykcyjnego o charakterze wieloparametrycznym. Celem dalszych prac jest opracowanie uniwersalnego modelu umożliwiającego predykcję zużycia energii dla różnych misji, bez konieczności indywidualnej kalibracji. W dalszym etapie prac zasadniczy nacisk został przeniesiony z aspektów implementacyjnych na rozwój algorytmiczno-modelowy. Wynika to z faktu, że implementacja funkcjonalności systemu wykrywania anomalii, zrealizowana m.in. w środowisku Node-RED nie stanowiła istotnego wyzwania technicznego i potwierdziła wykonalność założeń systemowych. Tym samym, kontynuacja prac została ukierunkowana na pogłębioną analizę oraz rozbudowę warstwy predykcyjnej modelu.

Opisana w tym rozdziale koncepcja stanowi pierwsze podejście badawcze, które zostało zaprezentowane i opublikowane przez autora w pracy [184]. Mimo swoich ograniczeń, podejście to pozwoliło na przetestowanie podstawowych założeń oraz zaprojektowanie fundamentu pod kolejne, bardziej zaawansowane rozwiązania, których opis znajduje się w kolejnych rozdziałach.

6.2 Model predykcyjny zużycia energii przez AMR oparty na jawnym modelu statystycznym uczenia maszynowego z wieloma zmiennymi wejściowymi

Dotychczasowy model predykcyjny stanu naładowania (SoC) - M1, zaprezentowany w rozdziale 6.1, odnosi się do konkretnego przebiegu pojedynczej misji realizowanej przez robota mobilnego. Choć umożliwia on względnie dokładne odwzorowanie zużycia energii dla danego scenariusza operacyjnego, jego główną wadą pozostaje ograniczona możliwość uogólnienia wyników na inne misje, środowiska lub stany robota. W związku z tym każde nowe zadanie logistyczne wymagałoby opracowania odrębnego modelu, co czyniłoby takie podejście niepraktycznym w kontekście rzeczywistych systemów zarządzania flotą robotów mobilnych. Brak elastyczności oraz wysokie koszty czasowe i obliczeniowe związane z generowaniem modeli dla każdej konfiguracji misji stanowią istotne ograniczenie. W świetle rosnącej złożoności zadań intralogistycznych oraz wymagań wobec systemów adaptacyjnych, konieczne jest opracowanie rozwiązania o charakterze uniwersalnym, zdolnego do predykcji SoC na podstawie zestawu zmiennych wejściowych reprezentujących różne typy misji, stany robota oraz warunki środowiskowe.

Na potrzeby modelu M2 wykonano rozszerzoną serię pomiarową, opartą na procedurze opisanej w rozdziale 5.1 (etap 2, Tabela 17). W odróżnieniu od pomiarów dla modelu M1, zarejestrowano większą liczbę parametrów podczas misji (Tabela 16). Badania przeprowadzono dla trzech dystansów przejazdu, przy trzech poziomach obciążenia robota (0%, 50% i 100% nominalnej ładowności) oraz z wykorzystaniem dwóch sztuk akumulatorów trakcyjnych tego samego typu (różny czas eksploatacji).

Zgodnie z założeniami eksperymentu (Tabela 15), planowano wykonanie trzech replikacji pomiarów dla każdej kombinacji akumulatora, dystansu misji i poziomu obciążenia. Ze względu na konieczność równoległego wykorzystania robota AMR w innych badaniach oraz projektach, nie było możliwe pełne zrealizowanie wszystkich serii pomiarowych w przewidzianej liczbie powtórzeń. W konsekwencji dla każdej konfiguracji wykonano minimum dwie replikacje.

Liczbę rzeczywiście zarejestrowanych replikacji oraz łączną liczbę zrealizowanych misji przedstawiono poniżej (Tabela 27). Otrzymany zbiór danych jest **niezrównoważony**, tzn. liczba powtórzeń nie jest identyczna dla wszystkich konfiguracji. **Mimo tego zbiór wiernie odzwierciedla zmienność warunków eksploatacyjnych typowych dla środowisk intralogistycznych i przemysłowych, w których liczba przejazdów dla danych kombinacji obciążenia i dystansu również nie jest stała.**

Tabela 27 Liczba replikacji (oraz łączna liczba misji w nawiasach) wykonanych dla różnych kombinacji obciążenia robota, dystansu przejazdu i użytego akumulatora trakcyjnego

Obciążenie	Akumulator 1 (2 lata działania)			Akumulator 2 (nowy)		
	30m	140m	350m	30m	140m	350m
0 kg	2 (752)	2 (168)	2 (78)	3 (928)	4 (306)	2 (77)
50 kg	2 (712)	4 (278)	2 (78)	2 (460)	3 (235)	3 (111)
100 kg	3 (1048)	3 (217)	3 (102)	4 (1227)	3 (217)	4 (135)

Przykładowe wyniki pomiarów przeprowadzonych podczas misji robota MiR100, obejmujących różne konfiguracje długości trasy, poziomu obciążenia oraz stanu zużycia akumulatora, zestawiono w Tabelach 28-30. Dane te obejmują zarówno wartości misji (takie jak początkowy poziom naładowania akumulatora czy liczba zakrętów), jak i parametry środowiskowe (temperatura otoczenia i akumulatora), kinematyczne (średnie prędkości) oraz zmierzone zużycie energii wyrażone jako spadek SoC [%].

Tabela 28 Przykładowe wyniki pomiarów z misji robota MiR100 o długości trasy ok. 140 m i stałym obciążeniu 0 kg dla 2 letniego akumulatora

ID Pomiaru	Nazwa misji	Data	Temperatura akum. [°C]	Temperatura otoczenia [°C]	v śr. Liniowa [m/s]	v śr. Kątowa [°/s]	Początkowe SoC akumulatora [%]	Liczba zakrętów	obciążenie [kg]	Długość trasy [m]	Czas używania akumul. [lat]	Zmierzone zużycie energii [% SoC]
4760	Mir_bat_140	29.05.2022 05:33	32,3125	20	59,3	0,556103	10,0296	29	0	138,13	2	1,3
4761	Mir_bat_140	29.05.2022 05:40	32,2500	20	58,0	0,560645	9,99505	25	0	137,79	2	1,4
4762	Mir_bat_140	29.05.2022 05:47	32,1250	20	56,6	0,555972	10,5064	27	0	137,91	2	1,5
4763	Mir_bat_140	29.05.2022 05:54	32,0000	20	55,1	0,548508	10,7860	30	0	138,13	2	1,7
4764	Mir_bat_140	29.05.2022 06:00	31,8750	20	53,4	0,553914	9,65884	26	0	136,75	2	1,3

Tabela 29 Przykładowe wyniki pomiarów z misji robota MiR100 o długości trasy ok.30 m i stałym obciążeniu 50 kg dla nowego akumulatora

ID Pomiaru	Nazwa misji	Data	Temperatura akum. [°C]	Temperatura otoczenia [°C]	v śr. Liniowa [m/s]	v śr. Kątowa [°/s]	Początkowe SoC akumulatora [%]	Liczba zakrętów	obciążenie [kg]	Długość trasy [m]	Czas używania akumul. [lat]	Zmierzone zużycie energii [% SoC]
7791	Mir_bat_30	17.06.2022 02:30	33,7500	19	61,8	0,482862	11,0376	9	50	34,64	0	0,2
7792	Mir_bat_30	17.06.2022 02:31	33,7500	19	61,6	0,477029	9,93232	8	50	34,63	0	0,3
7793	Mir_bat_30	17.06.2022 02:32	33,7500	19	61,3	0,504886	10,9653	8	50	34,69	0	0,2
7794	Mir_bat_30	17.06.2022 02:34	33,7500	19	61,1	0,469855	10,5896	8	50	34,91	0	0,3
7795	Mir_bat_30	17.06.2022 02:36	33,6875	19	60,8	0,488512	9,93705	9	50	34,85	0	0,2

Tabela 30 Przykładowe wyniki pomiarów z misji robota MiR100 o długości trasy ok. 350 m i stałym obciążeniu 100 kg dla nowego akumulatora.

ID Pomiaru	Nazwa misji	Data	Temperatura akum. [°C]	Temperatura otoczenia [°C]	v śr. Liniowa [m/s]	v śr. Kątowa [°/s]	Początkowe SoC akumulatora [%]	Liczba zakrętów	obciążenie [kg]	Długość trasy [m]	Czas używania akumul. [lat]	Zmierzone zużycie energii [% SoC]
9015	Mir_bat_350	26.06.2022 11:03	37,7500	20	82,7	0,585525	8,68718	53	100kg	346,50	0	3,5
9016	Mir_bat_350	26.06.2022 11:15	37,4375	20	79,2	0,584059	8,47675	58	100kg	345,80	0	3,9
9017	Mir_bat_350	26.06.2022 11:28	37,1875	21	75,3	0,584275	8,72643	64	100kg	346,40	0	3,5
9018	Mir_bat_350	26.06.2022 11:41	36,8750	21	71,8	0,577577	8,64147	56	100kg	346,40	0	3,0
9019	Mir_bat_350	26.06.2022 11:54	36,6250	21	68,8	0,579948	8,31064	55	100kg	346,10	0	2,8

W trakcie realizacji eksperymentów pomiarowych zarejestrowano większy zbiór parametrów niż ostatecznie wykorzystano w procesie budowy modelu predykcyjnego. Wynika to z faktu, że pomiary prowadzono wyłącznie dla jednego egzemplarza robota MiR100, co oznacza, że część parametrów, mimo że została uwzględniona na etapie planowania badań i analizy przy użyciu diagramu Ishikawy (Rys. 27) nie wykazywała zmienności i nie mogła zostać efektywnie wykorzystana w modelu. Dotyczy to takich parametrów jak: model robota, numer seryjny, typ akumulatora, nazwa misji. Parametry te zostały przewidziane z myślą o przyszłym rozszerzeniu modelu na wiele różnych robotów (np. różnych egzemplarzy tego samego typu, o odmiennym stopniu zużycia lub wariantach konstrukcyjnych). W ramach niniejszych badań były one jednak stałe, dlatego zaklasyfikowano je jako **parametry nieistotne** z punktu widzenia modelowania predykcyjnego.

Należy również zauważyć, że zmienna „temperatura otoczenia” została wykluczona z modelu ze względu na jej niewielką zmienność w trakcie wszystkich pomiarów (w przedziale 19-23 °C). Cecha o tak ograniczonej zmienności nie wnosi istotnej informacji różnicującej do procesu modelowania, a jej wartość predykcyjna pozostaje marginalna. W praktyce metody selekcji cech automatycznie redukują znaczenie bądź całkowicie eliminują zmienne charakteryzujące się brakiem zmienności lub bardzo niską wariancją, ponieważ nie przyczyniają się one do poprawy jakości modelu.

Podział wszystkich zarejestrowanych parametrów na cechy istotne (zmienne) oraz nieistotne (np. stałe) przedstawiono w poniższej tabeli (Tabela 31).

Tabela 31 Parametry, które należy uwzględnić podczas eksperymentów.

Parametry mierzalne (zmienne)	Parametry nieistotne (stałe)
1. Obciążenie robota	1. Nazwa misji
2. Śr. prędkość liniowa	2. Typ akumulatora
3. Śr. prędkość kątowna	3. Model robota
4. Początkowy stan naładowania (SoC)	4. Akcesoria robota
5. Temperatura akumulatora	5. Numer seryjny
6. Czas używania akumulatora	6. Temperatura otoczenia
7. Liczba zakrętów	
8. Długość trasy	

Wybór metody modelowania

Do budowy modelu predykcyjnego zużycia energii w misji zastosowano **uogólniony model liniowy (GLM)**. Uogólnione modele liniowe stanowią elastyczne narzędzie, które może być wykorzystywane również w przypadku danych niezerównoważonych, bez konieczności zachowania jednakowej liczby obserwacji w każdej kombinacji czynników. Ich zastosowanie umożliwia ponadto zachowanie przejrzystości interpretacyjnej oraz analityczne ujęcie relacji pomiędzy wieloma predyktorami a zmienną zależną. Wybór GLM umożliwia jednocześnie uwzględnienie zarówno efektów głównych, jak i interakcji między zmiennymi, przy zachowaniu kontroli nad złożonością modelu. Metoda ta pozwala również na systematyczną selekcję cech istotnych predykcyjnie oraz ocenę stabilności modelu. Istotnym czynnikiem decydującym o wyborze uogólnionego modelu liniowego była jego zgodność z założeniem badawczym, zakładającym opracowanie jawnego, analitycznego wzoru opisującego zużycie energii. GLM spełnia kryteria tzw. modeli „białej skrzynki”, co umożliwia zachowanie wysokiego poziomu objaśnialności wyników. Jest to szczególnie istotne zarówno w kontekście zastosowań przemysłowych, gdzie transparentność modeli stanowi warunek ich akceptowalności

Istotną zaletą uogólnionego modelu liniowego (GLM) jest możliwość definiowania zarówno efektów interakcji, jak i efektów wielomianowych pomiędzy zmiennymi wejściowymi. Efekty interakcji (np. $SoC \times Distance$) pozwalają uchwycić sytuacje, w których wpływ jednej zmiennej (np. dystansu) zależy od wartości innej (np. poziomu naładowania akumulatora). W kontekście modelowania zużycia energii może to oznaczać, że energia zużywana na jednostkę drogi zmienia się wraz z poziomem SoC, co

potwierdzają także obserwacje opisane w modelu M1 i [184], gdzie zauważono nieliniowości zużycia przy tej samej długości trasy. Z kolei efekty wielomianowe (np. SoC^2) umożliwiają modelowanie nieliniowych zależności pomiędzy predyktorami a zmienną zależną, przykładowo wpływ SoC na zużycie energii może być niewielki w średnim zakresie, ale istotnie wzrastać przy wartościach skrajnych.

W celu realizacji założonych celów badawczych wykorzystano zebrane dane oraz oprogramowanie SAS Studio do opracowania modelu predykcyjnego rozładowania akumulatora w oparciu o uogólnioną regresję liniową (GLM). W przeprowadzonych eksperymentach liczba predyktorów (zmiennych niezależnych) wynosiła 7 (zob. Tabela 32).

Tabela 32 Opis zmiennych i ich typów wykorzystanych do budowy modelu predykcyjnego z wykorzystaniem uogólnionego modelu liniowego (GLM).

Etykieta	Opis zmiennej	Typ zmiennej
EnergyCons	Zmierzone zużycie energii	zmienna zależna (wynik)
Payload	Obciążenie robota	zmienna niezależna (predyktor)
AvgLinVelocity	Sr. prędkość liniowa	zmienna niezależna (predyktor)
AvgAngVelocity	Sr. prędkość kątowna	zmienna niezależna (predyktor)
SoC	Początkowy stan naładowania (SoC)	zmienna niezależna (predyktor)
BatteryTemp	Temperatura akumulatora	zmienna niezależna (predyktor)
Turns	Liczba zakrętów	zmienna niezależna (predyktor)
Distance	Długość trasy	zmienna niezależna (predyktor)
BatteryAge	Czas używania akumulatora	parametr eksperymentalny - nieujęty w modelu

Opracowane zostały 2 osobne modele w celu porównania wyników dla dwóch akumulatorów a wymienione zmienne zostały uwzględnione jako pojedyncze efekty w analizowanym modelu GLM. W modelu uwzględniono interakcje pomiędzy parami zmiennych ($n = 2$) oraz efekty wielomianowe do trzeciego rzędu ($k = 3$). Przy takich założeniach model obejmował łącznie 42 efekty (zmienne i ich kombinacje). Do wyboru najbardziej adekwatnego modelu zastosowano następujące algorytmy selekcji efektów:

- selekcję w przód (*forward selection*),
- regresję krokową (*stepwise regression*),
- metodę LASSO (*Least Absolute Shrinkage and Selection Operator*),
- regresję metodą najmniejszych kątów (*Least Angle Regression*, LAR).

W ramach badań eksperymentalnych przeanalizowano również wpływ filtracji danych wejściowych na zmienne **SoC** oraz **EnergyCons**. Przyjęto następujące warunki filtrowania:

- **Filtr 1 (F1): EnergyCons > 0.2**

Celem filtru było wyeliminowanie bardzo krótkich misji, dla których zużycie energii było niższe niż 0,2% pojemności akumulatora. W takich przypadkach pomiary mogły być zniekształcone przez zaokrąglenia stosowane przez wewnętrzny system BMS, co utrudniało interpretację danych. Dodatkowo zaobserwowano, że przebieg rozładowania w tym zakresie odbiegał od trendu opisanego w pracy autora [184] i często miał charakter losowy.

- **Filtr 2 (F2): 20 < SoC < 80**

Zastosowanie filtru 2 wynika z zaleceń producentów robotów oraz wyników badań naukowych dotyczących akumulatorów litowo-jonowych [105], [106], zgodnie z którymi optymalny zakres pracy akumulatora mieści się w przedziale 20-90% poziomu naładowania (SoC). Dodatkowo warto zauważyć, że czas ładowania powyżej 80% SoC znacząco się wydłuża, dlatego w analizowanym zbiorze danych przyjęto zakres SoC ograniczony do przedziału od 20% do 80%.

- **Filtr 3 (F3): $20 < \text{SoC} < 80$ oraz $\text{EnergyCons} > 0.2$**
Połączenie warunków z filtru 1 i 2.

W ramach procesu budowy modelu predykcyjnego przeprowadzono eksperymenty z wykorzystaniem czterech odmiennych metod selekcji cech oraz trzech filtrów wstępnych, co **łącznie pozwoliło na utworzenie 12 wariantów modeli dla każdego akumulatora**. Łączna liczba przeanalizowanych modeli wyniosła zatem 24. Wyniki uzyskane dla poszczególnych konfiguracji, wyrażone za pomocą miary AR-S, zestawiono poniżej (Tabela 33). Do oceny jakości modeli przyjęto skorygowany współczynnik determinacji (Adjusted R-Square, AR-S), który (w odróżnieniu od klasycznego R^2) uwzględnia liczbę predyktorów i karze modele za dodawanie zmiennych niepoprawiających dopasowania. Dzięki temu lepiej sprawdza się przy porównywaniu modeli o różnej złożoności. Uzyskane wyniki potwierdzają skuteczność metody GLM w predykcji zużycia energii. Wartości wskaźnika AR-S były zbliżone do maksymalnej wartości 1, co świadczy o bardzo dobrym dopasowaniu modelu do danych i wysokiej trafności prognoz. **Najlepsze rezultaty uzyskano przy zastosowaniu algorytmu selekcji w przód (*ang. forward selection*) w połączeniu z filtrem 3**. W obu przypadkach (dla nowego i używanego akumulatora) osiągnięto zbliżoną wartość AR-S z dokładnością do 0,006, przewyższającą wartości uzyskane dla pozostałych metod selekcji.

Tabela 33 Wyniki dopasowania modeli GLM dla różnych metod selekcji zmiennych niezależnych i filtrów danych (wartości skorygowanego współczynnika determinacji AR-S)

Wybrany Model	Akumulator 1 (2 lata działania)				Akumulator 2 (nowy)			
	Brak filtra	F1	F2	F3	Brak filtra	F1	F2	F3
Forward	0,9399	0,9466	0,9568	0,9629	0,9489	0,9540	0,9646	0,9694
Stepwise	0,9399	0,9467	0,9568	0,9621	0,9489	0,9541	0,9645	0,9694
LASSO	0,9355	0,9407	0,9514	0,9523	0,9399	0,9461	0,9540	0,9601
LAR	0,9387	0,9407	0,9527	0,9523	0,9469	0,9487	0,9650	0,9693

W Tabeli poniżej (Tabela 34) przedstawiono zmienne niezależne wprowadzane kolejno na etapach działania algorytmu selekcji w przód (*ang. forward selection*) dla obu analizowanych akumulatorów, wraz z odpowiadającą im wartością skorygowanego współczynnika determinacji (AR-S). Należy zauważyć, że pierwsze cztery wprowadzone zmienne (wyróżnione pogrubieniem) są identyczne w przypadku obu akumulatorów. Model oparty wyłącznie na tych czterech predyktorach osiąga wartość AR-S powyżej 0,95 dla każdej z nich. Wartość AR-S na poziomie 0,95, uzyskana przy ograniczonej liczbie zmiennych, jest jedynie nieznacznie niższa od maksymalnych wartości **0,9629** oraz **0,9694**, które osiągnięto w pełnych modelach z zastosowaniem wszystkich zmiennych. Jednocześnie prostszy model jest mniej podatny na przeuczenie i łatwiejszy w interpretacji.

Tabela 34 Przebieg selekcji zmiennych niezależnych metodą forward selection i wartości AR-S dla dwóch akumulatorów.

Krok	Akumulator 1 (2 lata działania)		Akumulator 2 (nowy)	
	Wprowadzony predyktor	AR-S	Wprowadzony predyktor	AR-S
1	Turns	0,9139	Turns	0,9167
2	Distance	0,9196	Distance	0,9202
3	SoC	0,9271	SoC	0,9297
4	SoC * Distance	0,9508	SoC * Distance	0,9591
5	Distance * Distance	0,9521	SoC * SoC	0,9599
6	SoC * SoC	0,9530	BatteryTemp	0,9655
7	AvgAngVelocity	0,9565	Distance * Distance	0,9662
8	SoC * SoC * SoC	0,9573	SoC * Turns	0,9667
9	AvgAngVel * AvgAngVel	0,9613	BatteryTemp * SoC	0,9670
10	SoC * Turns	0,9620	SoC * SoC * SoC	0,9679

11	Payload	0,9624	BatteryTemp * BatteryTemp	0,9681
12	AvgAngVel * Distance	0,9626	BatteryTemp * Distance	0,9689
13	AvgAng * AvgAng * AvgAng	0,9628	Payload	0,9691
14	SoC * Payload	0,9628	Payload * Payload	0,9692
15	Turns * Payload	0,9629	AvgLinVelocity	0,9693
16			AvgLinVel * AvgLinVel	0,9693
17			Turns * Distance	0.9694

W wyniku selekcji zmiennych niezależnych metodą forward selection oraz odnotowania nieznacznego wzrostu wartości wskaźnika AR-S (powyżej 0,95) przy uwzględnieniu czterech głównych predyktorów, zaproponowano redukcję modelu do właśnie tych czterech najbardziej istotnych zmiennych (wyróżnionych w Tabela 35).

Tabela 35 Wartości współczynników regresji dla czterech kluczowych predyktorów w modelu zużycia energii dla akumulatorów o różnym stopniu eksploatacji

Akumulator 1 (2 lata działania)		Akumulator 2 (nowy)	
Predyktor	współczynnik	Predyktor	współczynnik
Turns	-0.027318	Turns	-0.031285
Distance	0.002327	Distance	0.002999
SoC	-0.141574	SoC	-0.136106
SoC * Distance	0.000000246	SoC * Distance	-0.000037981


Analiza wyników modelu GLM

Uzyskane wyniki selekcji zmiennych metodą forward selection przedstawione w Tabela 34 są w dużej mierze zgodne z dostępną literaturą oraz wiedzą ekspercką na temat czynników wpływających na zużycie energii przez autonomiczne roboty mobilne. Szczególnie wyraźnie potwierdzono znaczenie takich parametrów jak liczba zakrętów (Turns), pokonany dystans (Distance), początkowy stan naładowania akumulatora (SoC) oraz jego interakcja z dystansem ($\text{SoC} \times \text{Distance}$) co jest zgodne z wynikami poprzedniego modelu predykcyjnego (M1) stanu naładowania (SoC) opartego na jednowymiarowej regresji wielomianowej.

W literaturze obciążenie (Payload) uznawany jest za istotny czynnik wpływający na zużycie energii robotów mobilnych, zwłaszcza w kontekście pokonywania dystansu i dynamiki ruchu. Jednak w przeprowadzonej analizie jego wpływ okazał się ograniczony - zmienna ta została zaklasyfikowana dopiero na 11. i 13. miejscu w procesie selekcji dla odpowiednio starszego i nowego akumulatora. Jednym z możliwych wyjaśnień jest fakt, że znaczna część całkowitego zużycia energii (ponad 40%) przypada na systemy niezwiązane bezpośrednio z lokomocją, takie jak układy sterowania, sensoryki, przetwarzania danych czy komunikacji, co jest również podkreślane w literaturze przedmiotu [60], [117] jako typowe dla autonomicznych systemów robotycznych pracujących w trybie ciągłym. Dodatkowo, relatywnie niski wpływ obciążenia może być skutkiem specyfiki realizowanych zadań transportowych, obejmujących łagodne trajektorie ruchu, ograniczoną liczbę manewrów oraz niskie opory toczenia wynikające z korzystnych warunków nawierzchni w środowisku testowym. Wskazane jest zatem porównanie tych wyników z rezultatami uzyskanymi przy zastosowaniu alternatywnego modelu predykcyjnego (M3), co pozwoli zweryfikować, czy niski poziom istotności zmiennej obciążenia jest konsekwencją cech danych eksperymentalnych, charakterystyki środowiska pracy robota, czy też przyjętej metody analizy statystycznej. W przeciwieństwie do wyników prezentowanych w literaturze, w niniejszej analizie nie zaobserwowano wyraźnego wpływu temperatury akumulatora [110] ani czasu użytkowania akumulatora [107] na zużycie energii. Brak istotnego wpływu tych zmiennych w analizowanym przypadku może wynikać z ograniczonego zakresu pomiarowego, temperatury

akumulatora mieściły się w przedziale 30-40°C, warunki otoczenia były stabilne (19-23°C), a czas użytkowania akumulatora nie przekraczał trzech lat.

Dla opracowanych modeli predykcyjnych przygotowano również histogramy reszt z dopasowaniem do rozkładu normalnego (Rys. 51), które służą weryfikacji jednego z kluczowych założeń modeli regresyjnych - zgodności rozkładu reszt z rozkładem normalnym. Przedstawione wykresy obrazują rozkład reszt dla wyznaczonych modeli każdego z testowanych akumulatorów. W obu przypadkach rozkłady mają kształt symetryczny i dzwonowaty, typowy dla rozkładu normalnego (Gausa), co należy uznać za korzystne i potwierdzające poprawne dopasowanie modeli. Błędy predykcji są niewielkie i nie wykazują tendencji do systematycznego przeszacowywania ani niedoszacowania. Dodatkowo, dla około 50% obserwacji różnica między przewidywanym a rzeczywistym zużyciem energii nie przekracza 0,1%, natomiast odchylenia większe niż 0,5% stanowią mniej niż 2% wszystkich przypadków. Wskazuje to na wysoką precyzję predykcji uzyskanych modeli w analizowanych warunkach.




Rys. 51 Rozkład reszt dla przewidywanego zużycia energii (EnergyCons) w modelach regresyjnych GLM opracowanych dla akumulatora: a - używanego 2 lata i b. nowego

W ramach oceny jakości dopasowania modeli regresyjnych przeanalizowano również wykresy diagnostyczne obserwacji nietypowych i wpływowych (Rys. 52, ang. *Outlier and Leverage Diagnostics*), służące do identyfikacji danych mogących zaburzać proces estymacji parametrów. Analiza tego typu pozwala wskazać obserwacje charakteryzujące się istotnymi odchyleniami od wartości przewidywanych przez model (wysoka wartość reszty studentyzowanej, *RStudent*) oraz obserwacje o znaczącym wpływie na kształt regresji (wysoka wartość *leverage*). Uwzględnienie tych aspektów umożliwia ocenę czy model nie został nadmiernie ukształtowany przez pojedyncze przypadki odstające, co mogłoby ograniczać jego zdolność uogólniania. Diagnostyka ta stanowi istotne uzupełnienie analizy reszt oraz testowania założeń dotyczących normalności błędów.

W odniesieniu do uzyskanych wykresów dla obu analizowanych akumulatorów można stwierdzić, że zdecydowana większość obserwacji mieści się w obszarze uznawanym za bezpieczny, tj. charakteryzuje się niskimi wartościami dźwigni (*leverage*) oraz resztami w przedziale ± 2 , (oznaczone symbolem $\odot$), co wskazuje na **stabilność i dobre dopasowanie modeli**. Nieliczna grupa punktów została zaklasyfikowana jako wpływowe ($\times$) lub odstające ($+$), przy czym ich liczba i rozmieszczenie nie sugerują istotnych zakłóceń w strukturze danych. Modele wykazują zatem zgodność z danymi empirycznymi i można uznać je za wiarygodne w kontekście warunków testowych - nie ma przesłanek

do filtrowania danych ani konieczności powtarzania eksperymentów. Jednakże, obserwacje oznaczone jako jednocześnie wpływowe i odstające (tzw. punkty krytyczne oznaczone ▲) powinny zostać szczegółowo zidentyfikowane i poddane interpretacji. Ich ewentualne usunięcie lub dalsza analiza mogą stanowić materiał do rozszerzenia badań, szczególnie w kontekście testowania modeli w odmiennych warunkach środowiskowych lub z zastosowaniem innych strategii predykcyjnych.



Rys. 52 Wykres diagnostyczny obserwacji odstających i wpływowych ($RStudent$ vs $Leverage$) dla modeli zużycia energii opracowanych dla akumulatora a - używanego 2 lata i b. nowego

Postać modelu predykcyjnego utworzonego z wykorzystaniem GLM

Z praktycznego punktu widzenia można uznać, że opracowany model predykcyjny dla obu akumulatorów ma zbliżoną postać, co sugeruje, iż dwuletni okres eksploatacji nie wpłynął w istotny sposób na charakterystyki energetyczne akumulatora w kontekście przewidywania zużycia energii. Wskazuje to na stabilność właściwości operacyjnych akumulatorów w analizowanym okresie użytkowania oraz na możliwość stosowania jednolitego modelu predykcyjnego niezależnie od stopnia ich zużycia (2 lata).

Finalny, jawny wzór modelu predykcyjnego został opracowany na podstawie uogólnionego modelu liniowego (GLM), uwzględniającego wielowymiarowy zestaw predyktorów wybranych za pomocą metody selekcji zmiennych typu forward selection. Postać modelu dla pojazdu AMR MiR100 można zapisać jako:

$$\text{EnergyCons} = -0,027318 \cdot \text{Turns} + 0,002327 \cdot \text{Distance} - 0,141574 \cdot \text{SoC} + 0,000000246 \cdot (\text{SoC} \times \text{Distance}) \quad (11)$$

Gdzie:

EnergyCons - prognozowane zużycie energii podczas pojedynczej misji, wyrażone jako procent całkowitej pojemności akumulatora (%).

Turns - liczba wykonanych skrętów przez robota w trakcie misji

Distance - całkowity przebyty dystans podczas misji, wyrażony w metrach,

SoC - stan naładowania akumulatora (State of Charge) na początku misji, wyrażone jako procent całkowitej pojemności akumulatora (%).

Podsumowanie wyników modelu predykcyjnego zużycia energii robota AMR opartego na uogólnionym modelu liniowym (GLM) z wieloma zmiennymi wejściowymi

Opracowany model predykcyjny stanu naładowania (SoC) oparty na uogólnionym modelu liniowym (GLM) stanowi istotny krok w kierunku tworzenia objaśnialnych i skalowalnych narzędzi wspomagających zarządzanie energią w systemach autonomicznych robotów mobilnych. Zastosowanie wielowymiarowej regresji umożliwiło jednocześnie uwzględnienie głównych czynników determinujących zużycie energii, takich jak liczba zakrętów, pokonany dystans, początkowy poziom SoC oraz ich wzajemne interakcje. Kluczową zaletą zastosowanego podejścia jest jego przejrzystość interpretacyjna oraz zgodność z wymaganiami przemysłowymi dotyczącymi modeli typu „biała skrzynka”, co zwiększa ich użyteczność w rzeczywistych systemach decyzyjnych. Wysokie wartości skorygowanego współczynnika determinacji ($AR-S > 0,95$) osiągnięte już przy ograniczonej liczbie predyktorów, a także symetryczny rozkład reszt i brak istotnych obserwacji wpływowych potwierdzają trafność i stabilność opracowanego modelu.

Ważnym elementem skuteczności modelu było hybrydowe podejście do selekcji zmiennych wejściowych, łączące analizę ekspercką, narzędzia przyczynowo skutkowe oraz eksploracyjną analizę danych. Pozwoliło to nie tylko na ustrukturyzowaną identyfikację zmiennych istotnych, ale również na eliminację parametrów stałych lub nieinformatywnych w warunkach eksperymentalnych. Przeprowadzone testy z wykorzystaniem dwóch akumulatorów o różnym stopniu zużycia wykazały, że dwuletnia eksploatacja nie miała istotnego wpływu na dopasowanie modelu. Niemniej, ograniczony wpływ takich zmiennych jak obciążenie czy temperatura Akumulatora może wynikać ze specyfiki warunków testowych wskazane jest zatem dalsze testowanie modelu w środowiskach o wyższej zmienności parametrów operacyjnych. Pomimo tych ograniczeń, uzyskane rezultaty dowodzą, że podejście oparte na GLM z dobrze zaprojektowaną selekcją zmiennych stanowi efektywną i praktyczną metodę predykcji zużycia energii w komercyjnych systemach AMR.

6.3 Model predykcyjny zużycia energii przez AMR zbudowany z wykorzystaniem automatycznego doboru algorytmów (AutoML) z wieloma zmiennymi wejściowymi

Budowa modeli predykcyjnych zużycia energii dla autonomicznych robotów mobilnych stanowi proces złożony, wymagający zaawansowanej wiedzy eksperckiej z zakresu statystyki, uczenia maszynowego oraz analizy danych. Niezależnie od przyjętej klasy podejść, czy są to modele jawne (typu biała skrzynka, czy też modele niejawne (*typu czarna skrzynka*)) proces ten obejmuje szereg wymagających etapów. Do kluczowych należą wstępne przygotowanie i oczyszczenie danych, selekcja istotnych cech wejściowych, wybór architektury modelu oraz wieloetapowa walidacja wyników. Zarówno w przypadku modeli opartych na zrozumiałych relacjach matematycznych, jak i tych wykorzystujących struktury o ograniczonej interpretowalności, niezbędne jest posiadanie wiedzy dziedzinowej, odpowiednich zasobów czasowych oraz mocy obliczeniowych niezbędnych do przeprowadzenia skutecznego procesu uczenia. W warunkach przemysłowych, gdzie kluczowe znaczenie mają szybkość implementacji, elastyczność rozwiązań oraz ograniczone zasoby kadrowe, klasyczne podejście do budowy modeli predykcyjnych staje się czasochłonne, kosztowne i trudne do wdrożenia.

Wybór metody modelowania

W odpowiedzi ograniczenia i trudności w przemysłowym wdrażaniu modelu predykcyjnych coraz częściej stosuje się narzędzia oparte na zautomatyzowanym uczeniu maszynowym (*ang. Automated Machine Learning*, AutoML) - rozdział 2.2, których celem jest maksymalne uproszczenie procesu budowy modeli predykcyjnych. Narzędzia AutoML funkcjonują jako produkty o ograniczonym zakresie ingerencji użytkownika, szczególnie w kontekście wyboru konkretnego algorytmu, architektury modelu czy strategii walidacyjnych. Wybór modeli oparty jest na wcześniej zgromadzonej wiedzy systemowej, wynikającej z analizy tysięcy przypadków uczenia modeli na zróżnicowanych danych wejściowych. Mechanizmy AutoML potrafią dzięki temu automatycznie dopasować algorytm o najlepszych rokowaniach, bazując na rozpoznanych wzorcach danych, które w przeszłości prowadziły do uzyskania najlepszych wyników.

W niniejszej pracy zastosowanie AutoML do budowy trzeciego modelu predykcyjnego (M3) miało charakter wieloaspektowy i służyło realizacji następujących celów badawczych i aplikacyjnych:

1. **Automatyzacja procesu budowy modelu** - zminimalizowanie nakładu pracy eksperckiej poprzez delegowanie doboru algorytmu, selekcji cech oraz strojenia parametrów do systemu AutoML.
2. **Analiza wpływu zmiennych wejściowych** - identyfikacja istotnych zmiennych operacyjnych i środowiskowych wpływających na zużycie energii przez robota mobilnego.
3. **Porównanie podejść modelowania** - przeprowadzenie eksperymentu porównawczego pomiędzy podejściem automatycznym (AutoML) a ręcznie konstruowanym modelem jawnym opartym na regresji liniowej uogólnionej (GLM).
4. **Ocena jakości i dokładności predykcji** - walidacja skuteczności predykcyjnej modelu AutoML w kontekście danych rzeczywistych pochodzących z misji transportowych robota.
5. **Weryfikacja gotowości wdrożeniowej** - ocena, na ile szybko konstruowane modele AutoML są wystarczająco wiarygodne i dokładne, aby mogły zostać zastosowane w komercyjnych systemach zarządzania flotą robotów mobilnych, bez konieczności długotrwałego cyklu wdrożeniowego.

Podejście to umożliwiło zbudowanie modelu predykcyjnego zużycia energii (M3) oraz porównanie jego wyników z modelem M2 (GLM), co pozwoliło na ocenę skuteczności i praktycznej użyteczności obu metod w kontekście wdrożeń przemysłowych.

Na potrzeby budowy modelu M3 wykorzystano ten sam zbiór danych, który został pozyskany w ramach serii pomiarowej dla M2 opisanej w projekcie eksperymentu (rozdziale 5.1, etap 2, Tabela 17). Liczbę rzeczywiście zarejestrowanych replikacji oraz łączną liczbę zrealizowanych misji przedstawiono poniżej (Tabela 36 i Tabela 27). **Otrzymany zbiór danych ma charakter nie zrównoważony, odzwierciedla jednak rzeczywiste warunki eksploatacyjne typowe dla środowisk intralogistycznych i przemysłowych, w których liczba przejazdów dla poszczególnych kombinacji obciążenia i dystansu również nie pozostaje stała.**

Tabela 36 Liczba replikacji (oraz łączna liczba misji w nawiasach) wykonanych dla różnych kombinacji obciążenia robota, dystansu przejazdu i użytego akumulatora trakcyjnego

Obciążenie	Akumulator 1 (2 lata działania)			Akumulator 2 (nowy)		
	30m	140m	350m	30m	140m	350m
0 kg	2 (752)	2 (168)	2 (78)	3 (928)	4 (306)	2 (77)
50 kg	2 (712)	4 (278)	2 (78)	2 (460)	3 (235)	3 (111)
100 kg	3 (1048)	3 (217)	3 (102)	4 (1227)	3 (217)	4 (135)

Przykładowe wyniki pomiarów przeprowadzonych podczas misji robota MiR100, obejmujących różne konfiguracje długości trasy, poziomu obciążenia oraz stanu zużycia akumulatora, zestawiono w Tabelach 28-30.

Do konstrukcji trzeciego modelu predykcyjnego (M3) wykorzystano platformę **Vertex AI AutoML**, dostępną w ramach środowiska **Google Cloud Console**. Obliczenia realizowane są w sposób zdalny na serwerach chmurowych Google, co pozwala na elastyczne wynajęcie dokładnie takiej mocy obliczeniowej, jaka jest w danym momencie wymagana do efektywnej budowy modelu. Takie podejście znacząco skraca czas trenowania i eliminuje konieczność inwestowania w lokalną infrastrukturę obliczeniową, co ma szczególne znaczenie w kontekście szybkiego prototypowania modeli w środowiskach przemysłowych.

Podobnie jak w przypadku modelu **M2**, model **M3** został zbudowany na tym samym zbiorze danych pochodzących z pomiarów uzyskanych w ramach eksperymentów zaplanowanych zgodnie z założeniami projektu badawczego (etap 2).

W procesie tworzenia modelu **M3** w pierwszej kolejności opracowano **modele częściowe (wstępne)** dla akumulatora nr 1 oraz akumulatora nr 2, co umożliwiło porównanie dokładności predykcji i istotności poszczególnych predyktorów z wynikami uzyskanymi dla modelu **M2** w odniesieniu do poszczególnych akumulatorów. Następnie, na podstawie uzyskanych rezultatów i analizy porównawczej, przygotowano **model końcowy M3**, stanowiący uogólnienie wcześniejszych modeli i uwzględniający pełny zbiór danych pomiarowych.

Modele częściowe (wstępne)

Na etapie przygotowania danych dla modelu w środowisku **Vertex AI AutoML** przeprowadzono analizę korelacji potencjalnych predyktorów z wykorzystaniem **współczynnika V Craméra**. W odróżnieniu od współczynnika Pearsona, miara ta umożliwia ocenę zależności zarówno dla zmiennych numerycznych, jak i kategoriowych. Współczynnik V Craméra określa **siłę związku pomiędzy daną cechą (predyktorem) a wynikiem**. Wartości bliskie zera wskazują na brak istotnej korelacji, natomiast wartości zbliżone do jedności świadczą o silnym związku pomiędzy zmiennymi. Należy jednak zauważyć, że wyjątkowo wysokie wartości mogą wskazywać na wyciek informacji, tj. sytuację, w której dana cecha zawiera informacje pochodzące bezpośrednio z wartości zmiennej docelowej. Analiza oparta na współczynniku V Craméra ma charakter jednowymiarowy, każda cecha oceniana jest niezależnie względem zmiennej docelowej, bez uwzględnienia współzależności i nieliniowych relacji pomiędzy predyktorami. Nie można zakładać, iż zależności pomiędzy zmiennymi a wynikiem mają wyłącznie

charakter liniowy (co potwierdziły wyniki modelu M2). Niemniej jednak uzyskane wartości współczynnika stanowią istotną informację, pozwalającą wstępnie ocenić potencjał predykcyjny poszczególnych cech. Narzędzie AutoML nie dokonuje automatycznej eliminacji predyktorów o niskiej wartości informacyjnej, dlatego interpretacja współczynnika V Craméra stanowi istotny etap wspomagający proces selekcji cech. Analiza ta pozwala określić, które zmienne wejściowe wnoszą rzeczywistą wartość predykcyjną do modelu, a które mogą zostać pominięte bez istotnego wpływu na jego jakość.

Współczynnik V Craméra można wyznaczyć wyłącznie w przypadku, gdy dana zmienna przyjmuje co najmniej dwie różne wartości. Z tego względu nie określono wpływu zmiennej opisującej czas użytkowania akumulatora na wynik. Na podstawie uzyskanych wartości współczynnika V Craméra odrzucono zmienne o bardzo niskiej wartości informacyjnej, w tym **temperaturę otoczenia** oraz zmienne o zbyt wysokiej korelacji z celem, takie jak **identyfikator pomiaru** i **identyfikator misji**, które mogły wskazywać na potencjalny wyciek informacji.

Zmienne, które pozostały po selekcji, są zgodne z predyktorami wykorzystanymi w modelu **M2**, wybranymi niezależnie w sposób autorski w rozdziale 4. Wartości współczynnika V Craméra dla wszystkich analizowanych zmiennych w obu zbiorach pomiarowych oraz podział na cechy włączone do modelu i odrzucone przedstawiono poniżej (Tabela 37, Tabela 38).

Tabela 37 Wartości współczynników V Craméra obliczonych dla zbioru potencjalnych predyktorów modelu AutoML dla akumulatora nr 1 (2 lata działania).

Etykieta	Opis zmiennej	Wsp. V Cramera	Typ zmiennej w modelu
MeasEnergyCons	Zmierzone zużycie energii	-	zmienna zależna (wynik)
Payload	Obciążenie robota	0,120	zmienna niezależna (predyktor)
AvgLinVelocity	Śr. prędkość liniowa	0,254	zmienna niezależna (predyktor)
AvgAngVelocity	Śr. prędkość kątowna	0,359	zmienna niezależna (predyktor)
BatterySoC	Pocz. stan naładowania (SoC)	0,568	zmienna niezależna (predyktor)
BatteryTemp	Temperatura akumulatora	0,258	zmienna niezależna (predyktor)
Turns	Liczba zakrętów	0,609	zmienna niezależna (predyktor)
Distance	Długość trasy	0,641	zmienna niezależna (predyktor)
ID	ID pomiaru	0,910	parametr eksperym. - nieujęty w modelu
MissionName	Nazwa misji	0,620	parametr eksperym. - nieujęty w modelu
EnvironmentTemp	Temperatura otoczenia	0,032	parametr eksperym. - nieujęty w modelu
BatteryAge	Czas używania akumulatora	-	parametr eksperym. - nieujęty w modelu

Tabela 38 Wartości współczynników V Craméra obliczonych dla zbioru potencjalnych predyktorów modelu AutoML dla akumulatora nr 2 (nowy).


Etykieta	Opis zmiennej	Wsp. V Cramera	Typ zmiennej w modelu
MeasEnergyCons	Zmierzone zużycie energii	-	zmienna zależna (wynik)
Payload	Obciążenie robota	0,125	zmienna niezależna (predyktor)
AvgLinVelocity	Śr. prędkość liniowa	0,335	zmienna niezależna (predyktor)
AvgAngVelocity	Śr. prędkość kątowna	0,335	zmienna niezależna (predyktor)
BatterySoC	Pocz. stan naładowania (SoC)	0,623	zmienna niezależna (predyktor)
BatteryTemp	Temperatura akumulatora	0,229	zmienna niezależna (predyktor)
Turns	Liczba zakrętów	0,673	zmienna niezależna (predyktor)
Distance	Długość trasy	0,669	zmienna niezależna (predyktor)
ID	ID pomiaru	0,988	parametr eksperym. - nieujęty w modelu
MissionName	Nazwa misji	0,647	parametr eksperym. - nieujęty w modelu
EnvironmentTemp	Temperatura otoczenia	0,042	parametr eksperym. - nieujęty w modelu
BatteryAge	Czas używania akumulatora	-	parametr eksperym. - nieujęty w modelu

Proces trenowania modeli przeprowadzono z wykorzystaniem **siedmiu zmiennych niezależnych** (zob. Tabela 37, Tabela 38) dokładnie na tym samym zbiorze danych jak M2. Liczba dostępnych obserwacji (misji) różniła się w zależności od analizowanego akumulatora:


- **akumulator 1** (użytkowany przez okres dwóch lat) - **3431 misji**,
- **akumulator 2** (nowy) - **3691 misji**.

Dane dla każdego akumulatora podzielono w proporcji **80 % / 10 % / 10 %** na zbiory treningowy, walidacyjny i testowy. Celem optymalizacji była minimalizacja błędu **RMSE**, który pełnił rolę **funkcji celu**. Dla każdego akumulatora opracowano **oddzielny model predykcyjny zużycia energii**, umożliwiający analizę indywidualnych charakterystyk pracy. Proces uczenia ograniczono do **2 godzin**, co stanowi kompromis między dokładnością modelu a kosztami obliczeniowymi, istotny z punktu widzenia zastosowań przemysłowych i szybkiego prototypowania. Zastosowano również mechanizm **wczesnego zatrzymania**, który przerywa trenowanie w przypadku braku dalszej poprawy wartości RMSE, zapobiegając nieefektywnemu wykorzystaniu zasobów obliczeniowych. Po zakończeniu uczenia dla każdego modelu określono **ważność cech**, pozwalającą ocenić wpływ poszczególnych predyktorów na wynik predykcji.

Wybór RMSE jako funkcji celu wynika z charakterystyki problemu w kontekście predykcji zużycia energii przez roboty mobilne, kluczowe jest nie tylko osiągnięcie wysokiej dokładności przeciętnej, lecz przede wszystkim minimalizacja błędów ekstremalnych, które mogą prowadzić do błędnych decyzji operacyjnych, np. zaplanowania zadań przekraczających realny zasięg energetyczny robota. RMSE jako metryka wrażliwa na rozrzut wartości, sprzyja więc konstrukcji modeli bardziej konserwatywnych i odpornych na błędy wysokiego ryzyka, co jest pożądane w aplikacjach czasu rzeczywistego i zastosowaniach przemysłowych. Dodatkowo, RMSE zachowuje tę samą jednostkę miary co wartość predykowana (w tym przypadku: jednostka zużycia energii), co ułatwia interpretację wyniku w kontekście praktycznym oraz umożliwia bezpośrednie porównania z progami decyzyjnymi stosowanymi w systemach zarządzania flotą AMR. Taka właściwość metryki wspiera również ocenę implementacyjną modelu, zarówno w aspekcie diagnostycznym, jak i eksploatacyjnym. Przebieg procesu trenowania modelu z uwzględnieniem minimalizowanej wartości funkcji celu (RMSE) w czasie 2-godzinnego budżetu obliczeniowego przedstawiono poniżej (Rys. 53, Rys. 54).



Rys. 53 Przebieg minimalizowanej wartości funkcji celu (RMSE) w trakcie procesu trenowania modelu predykcyjnego dla akumulatora 1 (2 lata działania).



Rys. 54 Przebieg minimalizowanej wartości funkcji celu (RMSE) w trakcie procesu trenowania modelu predykcyjnego dla akumulatora 2 (nowego).

Analiza wyników wstępnych modeli AutoML


W ramach budowy modelu predykcyjnego zużycia energii AMR (M3) z zastosowaniem narzędzia AutoML opracowano dwa częściowe (wstępne) modele, skonstruowane niezależnie na podstawie danych pochodzących z pomiarów akumulatora nr 1 (po dwóch latach eksploatacji) oraz akumulatora nr 2 (nowego).

Po ich utworzeniu przeprowadzono analizę wpływu zmiennych niezależnych na wynik predykcji z zastosowaniem **metody Shapleya**. Jest to metoda interpretowalności modeli wywodząca się z teorii gier kooperacyjnych, umożliwiającą ilościowe określenie wkładu każdej zmiennej wejściowej w ostateczny wynik predykcji. Metoda ta pozwala ocenić rzeczywiste znaczenie poszczególnych predyktorów nawet w przypadku modeli złożonych i nieliniowych, typowych dla modeli budowanych z wykorzystaniem narzędzi AutoML.

Wyniki analizy przedstawiono poniżej (Rys. 55). Zgodnie z obliczonymi wartościami Shapleya, dominujący wpływ na wynik modelu miały trzy predyktory:

- liczba zakrętów w misji,
- początkowy poziom naładowania akumulatora (SoC),
- długość trasy.

Pozostałe zmienne miały udział nieprzekraczający 15% całkowitego wpływu. Znaczący udział liczby zakrętów można interpretować w kontekście zwiększonego zapotrzebowania energetycznego podczas manewrów skrętu - zarówno planowych (wynikających z przebiegu trasy), jak i wymuszonych (np. w celu ominięcia przeszkody). Manewry te powodują lokalne zmiany kierunku i prędkości, co generuje dodatkowe zużycie energii przez układ napędowy. W efekcie misje realizowane w ograniczonych przestrzeniach, charakteryzujące się dużą liczbą zakrętów i częstymi korektami kursu, prowadzą do istotnie większego zużycia energii, nawet przy relatywnie krótkim dystansie całkowitym. Istotny wpływ na zużycie energii wykazano również dla początkowego poziomu naładowania akumulatora, co potwierdzono także w modelu M1 (rozdział 6.1). Należy natomiast zauważyć, że wpływ masy transportowanego ładunku (payload), pomimo wyraźnego zróżnicowania poziomów obciążenia (0%, 50% i 100%), okazał się relatywnie niewielki.



Rys. 55 Istotność predyktorów w modelu predykcyjnym zużycia energii, wyznaczona metodą wartości Shapleya:
a) akumulator nr 1 (po dwóch latach eksploatacji),
b) akumulator nr 2 (nowy).

Interpretacja wyników metryk regresyjnych

W celu pogłębionej oceny jakości utworzonego modelu predykcyjnego, przeprowadzono analizę jego skuteczności w oparciu o zestaw standardowych metryk regresyjnych wykorzystywanych w dziedzinie uczenia maszynowego. Ocenie poddano dokładność predykcji przy użyciu wskaźników: średniego błędu bezwzględnego (ang. *Mean Absolute Error*, MAE), pierwiastka z błędu średniokwadratowego (ang. *Root Mean Squared Error*, RMSE), logarytmicznego pierwiastka z błędu średniokwadratowego (ang. *Root Mean Squared Logarithmic Error*, RMSLE), współczynnika determinacji (R^2) oraz skorygowanego współczynnika determinacji (AR-S). Wyniki uzyskane dla modelu przedstawiono poniżej (Tabela 39).

Tabela 39 Porównanie metryk regresyjnych modeli predykcji zużycia energii opracowanych w narzędziu AutoML dla akumulatora nr 1 (po dwóch latach eksploatacji) oraz akumulatora nr 2 (nowego).

Miary dopasowania i błędu	Model dla Akumulatora 1 (2 lata działania)	Model dla Akumulatora 2 (nowy)
MAE	0,070	0,068
RMSE	0,111	0,097
RMSLE	0,056	0,063
R^2	0,982	0,975
AR-S	0,982	0,975

MAE określa przeciętną różnicę bezwzględną między wartościami przewidywanymi a rzeczywistymi. W przypadku analizowanych modeli wstępnych **wartość MAE wynosi 0,07 (aku. 1) oraz 0.068 (aku 2)**, przy zakresie zmiennej docelowej 0,0-6,0%, co odpowiada jedynie około 1,2% wartości maksymalnej. Taki niski poziom błędu świadczy o wysokiej dokładności predykcji. Warto podkreślić, że MAE jest odporny na pojedyncze skrajne odchylenia i dobrze odzwierciedla przeciętną jakość prognoz, co czyni go szczególnie przydatnym w kontekście zastosowań praktycznych wymagających stabilnych i powtarzalnych wyników.

RMSE jest szczególnie wrażliwy na większe odchylenia. W analizowanych modelach wstępnych **wartość RMSE wynosi 0,111 (aku. 1) oraz 0.097 (aku 2)**, Uzyskana wartość RMSE w zakresie zmiennej docelowej 0-6% oznacza, że średnie odchylenie prognoz od wartości rzeczywistych wynosi poniżej 2% zakresu. Tak niski poziom błędu wskazuje na bardzo dobrą dokładność modelu predykcyjnego i jego wysoką zdolność do odwzorowania zależności pomiędzy zmiennymi wejściowymi a zużyciem energii. Co istotne, wartość RMSE potwierdza również stabilność modelu, ponieważ nie występują duże odchylenia jednostkowe, które mogłyby świadczyć o przeuczeniu lub wrażliwości na dane odstające.

Uzyskane wartości RMSLE **wynoszące odpowiednio 0,056 (aku. 1) oraz 0,063 (aku 2)**, wskazują na bardzo wysoką dokładność predykcji w obu przypadkach (błąd względny rzędu ok. $e^{0,056}-1 \approx 5,8\%$ oraz $e^{0,063}-1 \approx 6,5\%$, co oznacza, że oba modele charakteryzują się zbliżoną stabilnością i zdolnością uogólniania. Niska wartość RMSLE ($<0,1$) potwierdza, że modele budowane z wykorzystaniem narzędzia AutoML poprawnie odwzorowują relacje w danych.

Wartość współczynnika determinacji **$R^2 = 0,982$ (aku. 1) oraz 0.975 (aku 2)**, potwierdzają bardzo wysoki poziom dopasowania obu modeli do danych empirycznych. Oznacza to, że modele wyjaśniają odpowiednio 98,2% oraz 97,5% zmienności obserwowanego zużycia energii. Tak wysokie wartości R^2 świadczą o skuteczności algorytmów AutoML w uchwyceniu relacji pomiędzy zmiennymi operacyjnymi a zużyciem energii niezależnie od stanu akumulatora. Niewielka różnica pomiędzy modelami wskazuje na ich porównywalną zdolność generalizacji i wysoką stabilność predykcyjną.

Wartość **skorygowanego współczynnika determinacji (AR-S) = 0,982 (aku. 1) oraz 0.975 (aku 2)**, potwierdzają bardzo wysoką jakość dopasowania obu modeli do danych empirycznych. Wartość AR-S, podobnie jak współczynnik determinacji R^2 , opisuje stopień dopasowania modelu, jednak dodatkowo uwzględnia liczbę zastosowanych predyktorów, penalizując modele nadmiernie złożone

Zbieżność wartości R^2 i AR-S wskazuje, że zastosowane modele nie są przeuczone, a liczba wykorzystanych predyktorów jest adekwatna do liczby obserwacji. Tak wysoki poziom dopasowania świadczy o wysokiej zdolności modeli AutoML do odwzorowania zależności pomiędzy zmiennymi operacyjnymi a zużyciem energii zarówno w przypadku akumulatora nowego, jak i eksploatowanego.

Model uogólniony (M3)

Posiadając odrębne zbiory danych pomiarowych dla akumulatora nr 1 oraz akumulatora nr 2, podjęto dodatkową analizę mającą na celu weryfikację wpływu **czasu eksploatacji akumulatora** (okres użytkowania wynoszący dwa lata) na zużycie energii. W tym celu wprowadzono nowy **predyktor opisujący czas użytkowania**, a następnie oceniono jego wpływ na dokładność predykcji oraz istotność statystyczną w kontekście pozostałych zmiennych.


Aby przeprowadzić tę analizę, ponownie opracowano zbiór uczący, łącząc dane pomiarowe z obu akumulatorów w jeden zestaw obejmujący **łącznie 7122 misje pomiarowe**. Dla tak przygotowanego zbioru obliczono współczynnik **V Craméra**, pozwalający na określenie siły zależności pomiędzy nowymi potencjalnymi predyktorami a zmienną objaśnianą (Tabela 40).

Tabela 40 Wartości współczynników V Craméra obliczonych dla zbioru potencjalnych predyktorów modelu AutoML dla scalonego zbioru danych pomiarowych (akumulator 1 i akumulator 2).

Etykieta	Opis zmiennej	Wsp. V Cramera	Typ zmiennej w modelu
MeasEnergyCons	Zmierzone zużycie energii	-	zmienna zależna (wynik)
Payload	Obciążenie robota	0,061	zmienna niezależna (predyktor)
AvgLinVelocity	Śr. prędkość liniowa	0,320	zmienna niezależna (predyktor)
AvgAngVelocity	Śr. prędkość kątowna	0,330	zmienna niezależna (predyktor)
BatterySoC	Pocz. stan naładowania (SoC)	0,566	zmienna niezależna (predyktor)
BatteryTemp	Temperatura akumulatora	0,179	zmienna niezależna (predyktor)
Turns	Liczba zakrętów	0,624	zmienna niezależna (predyktor)
Distance	Długość trasy	0,635	zmienna niezależna (predyktor)
BatteryAge	Czas używania akumulatora	0,005	
ID	ID pomiaru	0,950	parametr eksperym. - nieużyty w modelu
MissionName	Nazwa misji	0,643	parametr eksperym. - nieużyty w modelu
EnvironmentTemp	Temperatura otoczenia	0,008	parametr eksperym. - nieużyty w modelu

Wartość współczynnika **V Craméra** dla nowego potencjalnego predyktora (czas eksploatacji akumulatora) wynosząca **0,005** jest bardzo niska, co wskazuje, że prawdopodobnie nie wywiera istotnego wpływu na zmienną objaśnianą. Należy jednak zauważyć, że współczynnik ten opisuje jedynie zależności liniowe, dlatego predyktor ten mimo niskiej wartości wskaźnika został uwzględniony w kolejnym etapie uczenia modelu, aby umożliwić ocenę jego znaczenia również w relacjach nieliniowych. Podobnie jak w przypadku modeli częściowych, ze zbioru danych usunięto zmienne o charakterze identyfikacyjnym lub nieistotne dla procesu predykcji, tj. **ID misji, nazwę misji oraz temperaturę otoczenia**.

Zbiór danych podzielono w proporcji **80% / 10% / 10%** odpowiednio na zestawy treningowy, walidacyjny i testowy. Ponownie celem optymalizacji było minimalizowanie błędu RMSE, który pełnił funkcję celu podczas procesu uczenia. Czas trenowania ograniczono do **2 godzin**, co stanowiło kompromis pomiędzy dokładnością modelu a kosztami obliczeniowymi. Zastosowano również mechanizm wczesnego zatrzymania, który przerywa proces uczenia w przypadku braku dalszej poprawy wartości RMSE, zapobiegając tym samym nieefektywnemu wykorzystaniu zasobów obliczeniowych (Rys. 56).



Rys. 56 Przebieg minimalizowanej wartości funkcji celu (RMSE) w trakcie procesu trenowania modelu predykcyjnego dla scalonego zbioru danych pomiarowych (akumulator 1 i akumulator 2).

Analiza wyników uogólnionego modelu (M3)


Po zakończeniu procesu trenowania dla każdego modelu określono **ważność predyktorów metodą Shapleya**, umożliwiającą ilościową ocenę wpływu poszczególnych predyktorów na wynik predykcji.

Wyniki analizy przedstawiono na Rys. 57. Zgodnie z obliczonymi wartościami **Shapleya**, dominujący wpływ na wynik modelu wykazały trzy predyktory:

- **liczba zakrętów w misji,**
- **początkowy poziom naładowania akumulatora (SoC),**
- **długość trasy.**

Pozostałe zmienne miały łączny udział nieprzekraczający **11%** całkowitego wpływu. Wśród nich analizowany **dodatkowy predyktor** opisujący **czas użytkowania akumulatora** (nowy i eksploatowany przez 2 lata) wykazał **najniższy udział**, wynoszący **0,76%**. Tak niska wartość może wskazywać, że okres dwóch lat eksploatacji jest zbyt krótki, aby uchwycić istotne zjawiska degradacyjne wpływające na zużycie energii.

W konsekwencji dane z obu serii pomiarowych (dla akumulatora nowego i używanego) mogą zostać wykorzystane do opracowania **wspólnego modelu uogólnionego**, który pozwoli na bardziej kompleksowe odwzorowanie charakterystyki energetycznej akumulatorów niezależnie od ich stopnia zużycia.



Rys. 57 Istotność predyktorów w uogólnionym modelu predykcyjnym zużycia energii M3, wyznaczona metodą wartości Shapleya,

Interpretacja wyników metryk regresyjnych

W celu oceny jakości modelu predykcyjnego przeprowadzono analizę jego skuteczności z wykorzystaniem standardowych metryk regresyjnych stosowanych w uczeniu maszynowym: **MAE**, **RMSE**, **RMSLE** oraz wskaźników dopasowania **R²** i **AR-S**

Dobór tych metryk uzasadniono ich komplementarnością: MAE odzwierciedla średni błąd predykcji, RMSE uwzględnia większe znaczenie dużych odchyleń, RMSLE ogranicza wpływ wartości odstających, natomiast R² i Adjusted R² pozwalają ocenić stopień dopasowania modelu do danych oraz jego złożoność. Taki zestaw zapewnia pełną i obiektywną ocenę skuteczności modelu M3.

Wyniki poszczególnych metryk regresyjnych oraz współczynników dopasowania przedstawiono poniżej (Tabela 41).

Tabela 41 Metryki regresyjne dla uogólnionego modelu predykcyjnego zużycia energii AMR (M3), opracowanego na podstawie scalonego zbioru danych pomiarowych obejmującego akumulator 1 oraz akumulator 2.

Miary dopasowania i błędu	Skumulowane dane
MAE	0,072
RMSE	0,106
RMSLE	0,063
R ²	0,977
AR-S	0,977

Uzyskane wartości metryk regresyjnych dla modelu uogólnionego (tabela 41) są **zbliżone do wyników modeli częściowych**, co potwierdza jego wysoką dokładność i stabilność predykcyjną. Wartości **MAE = 0,072**, **RMSE = 0,106** oraz **RMSLE = 0,063** wskazują na **niskie poziomy błędów bezwzględnych i względnych**, świadczące o dobrej zdolności modelu do odwzorowania zależności między zmiennymi wejściowymi a zużyciem energii.

Wysoki współczynnik determinacji **R² = 0,977** potwierdza bardzo dobre dopasowanie modelu do danych empirycznych. Wartość **skorygowanego współczynnika determinacji (AR-S = 0,977)** jest nieco niższa niż w przypadku modeli częściowych (0,982 i 0,975), co wynika z większej liczby predyktorów oraz zwiększonej różnorodności danych w zbiorze scalonym. Skorygowany współczynnik determinacji uwzględnia liczbę zmiennych wejściowych, dlatego jego nieznaczny spadek jest naturalnym efektem uogólnienia modelu i łączenia danych o zróżnicowanej charakterystyce.

Na tej podstawie można stwierdzić, że opracowany model M3 może zostać przyjęty jako wspólny model predykcyjny zużycia energii robota mobilnego (AMR), odpowiedni dla obu analizowanych akumulatorów.

Postać modelu predykcyjnego utworzonego z wykorzystaniem AutoML

Model utworzony za pomocą narzędzia AutoML stanowi przykład podejścia typu „czarna skrzynka”, co oznacza, że jego wewnętrzna struktura, architektura oraz szczegółowe współczynniki nie są jawne ani dostępne bezpośrednio dla użytkownika, jak ma to miejsce w przypadku klasycznych modeli analitycznych (np. GLM). Gotowy model może być jednak wykorzystany praktycznie. Możliwe jest jego pobranie w postaci **pakietu TensorFlow** i wdrożenie lokalnie (np. w środowisku Python), jak również uruchomienie go jako usługę (*ang. endpoint*), automatycznie hostowaną w chmurze Google Cloud za pośrednictwem platformy Vertex AI. W tym przypadku komunikacja z usługą, na której hostowany jest model predykcyjny, realizowana jest za pośrednictwem interfejsu REST API, natomiast sama predykcja wykonywana jest w chmurze. Takie podejście ułatwia integrację modelu z systemami zewnętrznymi oraz automatyzację procesu przetwarzania danych.

Poniżej przedstawiono przykład zapytania **POST** typu **REST API**, ilustrujący sposób, w jaki model uogólniony (M3) mógłby być wywoływany w środowisku **Google Vertex AI** w celu uzyskania prognozy zużycia energii na podstawie zadanych wartości predyktorów.

POST

`https://europe-central2-aiplatform.googleapis.com/v1/projects/<PROJECT_ID>/locations/europe-central2/endpoints/<ENDPOINT_ID>:predict`

```
{
  "instances": [
    {
      "liczba_zakretow": 28,
      "pocatkowe_soc_akumulatora": 10.02,
      "dlugosc_trasy": 138.5,
      "srednia_predkosc_katowa": 0.555,
      "obciazenie": 0,
      "srednia_predkosc liniowa": 58,3,
      "temperatura_akumulatora": 32,25,
      "czas_uzywania_akumulatora": 2
    }
  ]
}
```

Przykładowa odpowiedź serwisu zawierająca wynik predykcji zużycia energii dla misji o zadanych parametrach może mieć następującą postać:

```
{
  "predictions": [
    {
      "zuzycie_energii": 1.27
    }
  ],
  "deployedModelId": "1234567890123456789",
  "modelDisplayName": "model_predykcji_energii_M3"
}
```

Podsumowanie wyników modelu predykcyjnego zużycia energii przez robota AMR opartego na metodzie automatycznego doboru algorytmów (AutoML)

Opracowany model predykcyjny zużycia energii przez AMR zbudowany z wykorzystaniem narzędzia AutoML stanowi przykład wykorzystania zaawansowanych technik uczenia maszynowego do analizy złożonych, nieliniowych zależności występujących w systemach robotów mobilnych. Dzięki zastosowaniu automatycznej selekcji i optymalizacji algorytmów, model osiągnął bardzo wysokie wskaźniki dopasowania modelu: $R^2 = 0,977$ i $AR-S = 0,977$. Wysoka zgodność wyników z rzeczywistymi wartościami potwierdza wysoką jakość modelu oraz jego zdolność do uogólniania wiedzy w warunkach eksperymentalnych. Model, mimo swojej niejawnej struktury (czarnej skrzynki), został uzupełniony analizą ważności cech za pomocą wartości Shapleya, co pozwoliło na identyfikację kluczowych zmiennych wejściowych. Najistotniejszymi predyktorami okazały się liczba zakrętów w trakcie misji, początkowy poziom SoC oraz pokonany dystans. Zaskakująco niski wpływ masy ładunku (payload) sugeruje, że zużycie energii wynika głównie z dynamiki manewrów oraz charakterystyki trajektorii, a nie z samego ciężaru.

W kontekście zastosowań przemysłowych, istotnym atutem podejścia AutoML jest jego prostota wdrożenia, uzyskana wysoka jakość modelu oraz wysoki stopień automatyzacji procesu budowy modeli predykcyjnych. Narzędzia AutoML, takie jak Vertex AI, umożliwiają szybkie opracowanie i wdrożenie skutecznych modeli bez konieczności posiadania zaawansowanej wiedzy z zakresu statystyki czy

uczenia maszynowego. Całościowy proces, od przygotowania danych po walidację i wdrożenie, może być zrealizowany w znacznie krótszym czasie niż w przypadku klasycznych metod, przy jednoczesnym zachowaniu wysokiej jakości predykcji. Dodatkowo, możliwość bezpośredniego wdrożenia modelu jako usługi sieciowej (np. REST API) oraz eksportu modelu w postaci gotowej do użycia (np. pakiet TensorFlow) znacząco upraszcza integrację z istniejącymi systemami przemysłowymi. Takie podejście nie tylko ogranicza czas i koszty implementacji, ale również zwiększa dostępność zaawansowanych narzędzi analitycznych dla szerszego grona użytkowników, w tym także dla zespołów inżynierskich bez specjalistycznego zaplecza w obszarze data science.

6.4 Porównanie modelu statystycznego (M2) oraz modelu w podejściu AutoML (M3) pod kątem jakości predykcji, interpretowalności wyników, złożoność strukturalnej oraz potencjału wdrożeniowego.

Celem niniejszego podrozdziału jest porównanie dwóch opracowanych modeli predykcyjnych zużycia energii przez robota mobilnego (AMR): modelu statystycznego w postaci uogólnionego modelu liniowego - GLM (M2) oraz modelu zbudowanego z wykorzystaniem narzędzia AutoML (M3). Analizie poddano cztery kluczowe aspekty: jakość predykcji, interpretowalność wyników, złożoność strukturalną oraz potencjał wdrożeniowy. Dodatkowo omówiono odporność modeli na zmienność danych oraz ich przydatność w zastosowaniach naukowych i przemysłowych.

Jakość predykcji

Z punktu widzenia oceny jakości predykcji, oba modele uzyskały wysokie wartości współczynników dopasowania, potwierdzające poprawność przyjętego doboru zmiennych wejściowych. Model statystyczny (M2), oparty na uogólnionym modelu liniowym, osiągnął Skorygowany współczynnik determinacji $AR-S = 0,9508$, co wskazuje na dobre dopasowanie do danych eksperymentalnych. Z kolei model zbudowany z wykorzystaniem narzędzia AutoML (M3) wykazał jeszcze wyższą jakość predykcji $AR-S=0,977$. Należy jednak zauważyć, że poprawa jakości predykcji w M3 została osiągnięta kosztem utraty pełnej interpretowalności, co w kontekście zastosowań naukowych może ograniczać możliwość formułowania wniosków przyczynowych. Wyniki te sugerują, że M2 zapewnia satysfakcjonującą dokładność przy niższej złożoności i pełnej transparentności, natomiast M3 jest bardziej elastyczny i skuteczny w modelowaniu nieliniowości danych, co czyni go bardziej odpowiednim dla zastosowań operacyjnych i adaptacyjnych.

Interpretowalność i możliwość wnioskowania

Z punktu widzenia interpretacji i transparentności, model M2 reprezentuje klasyczne podejście „white-box”, w którym wszystkie współczynniki regresji oraz ich istotność statystyczna są bezpośrednio dostępne i interpretowalne. Umożliwia to analizę wpływu poszczególnych czynników, takich jak dystans, masa ładunku, liczba zakrętów i poziom naładowania akumulatora, na zużycie energii.

W przypadku modelu M3 (AutoML) interpretacja wyników jest ograniczona. Model ten stanowi wynik zautomatyzowanego procesu selekcji i strojenia wielu algorytmów (ensemble), dlatego jego struktura jest znacznie bardziej złożona i nieprzejrzysta. Dla oceny znaczenia predyktorów konieczne było wykorzystanie metod interpretacji post-hoc, takich jak analiza wartości Shapleya, które dostarczają informacji o względnym wpływie zmiennych

Złożoność strukturalna i proces budowy modeli

Model M2 jest strukturalnie prosty - oparty na klasycznej regresji wielowymiarowej z kilkoma zmiennymi niezależnymi. Jego budowa wymaga wiedzy eksperckiej w zakresie doboru zmiennych i walidacji statystycznej, jednak proces jest przejrzysty i w pełni kontrolowany.

Model M3 (AutoML) charakteryzuje się znacznie wyższą złożonością strukturalną. Zastosowana platforma AutoML automatycznie dobiera i stroi wiele algorytmów (m.in. regresję gradientową, drzewa decyzyjne, XGBoost, sieci neuronowe), wybierając konfigurację o najwyższej dokładności. Proces jest automatyczny, co redukuje czas przygotowania modelu, lecz ogranicza kontrolę nad strukturą i trudni replikację wyników w przyszłości.

Potencjał wdrożeniowy

Z punktu widzenia praktycznego wdrożenia w systemach zarządzania flotą robotów mobilnych (FMS), model M3 wykazuje większy potencjał integracyjny i eksploatacyjny. Dzięki architekturze AutoML może być eksportowany bezpośrednio jako usługa REST API lub kontener TensorFlow, co umożliwia jego włączenie w środowiska FMS, MES lub IoT bez konieczności ręcznej implementacji kodu predykcyjnego (np. równania nr. 11).

Takie podejście sprzyja wdrażaniu modelu w systemach o rozproszonej architekturze danych i pozwala na cykliczną aktualizację w chmurze na podstawie nowych obserwacji eksploatacyjnych. Model M3 może być automatycznie ponownie trenowany i automatycznie aktualizowany dla wszystkich robotów mobilnych, co ułatwia jego adaptację do zmian warunków środowiskowych lub degradacji akumulatora, zapewniając tym samym wyższą elastyczność w długoterminowym utrzymaniu systemu predykcyjnego.

Z kolei model M2, mimo mniejszej elastyczności i braku mechanizmów automatycznego uczenia, charakteryzuje się wysoką stabilnością, prostotą implementacji i deterministycznym działaniem. Jego równanie regresyjne może być bezpośrednio zaimplementowane w systemach niskopoziomowych, takich jak Node-RED, system MES, sterowniki PLC lub środowiska Python / C++, bez potrzeby korzystania z zaawansowanych bibliotek uczenia maszynowego. Dzięki temu model M2 stanowi rozwiązanie bardziej przejrzyste, prostsze / szybsze obliczeniowo i łatwiejsze w walidacji, co jest szczególnie istotne w środowiskach przemysłowych, gdzie wymagana jest powtarzalność, deterministyczność i lokalne przetwarzanie danych (np. w zakładach z ograniczonym dostępem do sieci).

Podsumowując, model M3 jest bardziej odpowiedni w kontekście dużych systemów flotowych, w których kluczowe znaczenie mają skalowalność, automatyczna adaptacja, aktualizacja i integracja z chmurą.

Model M2 natomiast lepiej sprawdza się w zastosowaniach lokalnych i deterministycznych, w których liczy się przejrzystość, kontrola nad procesem modelowania oraz minimalne wymagania sprzętowe.

Podsumowanie

W celu syntetycznego zestawienia wyników analizy porównawczej, w tabeli poniżej (Tabela 42) przedstawiono kluczowe różnice pomiędzy modelem statystycznym (M2) a modelem zbudowanym w podejściu AutoML (M3). Zestawienie obejmuje aspekty jakości predykcji, interpretowalności, złożoności strukturalnej, potencjału wdrożeniowego oraz odporności na przeuczenie, stanowiąc podsumowanie najistotniejszych wniosków z przeprowadzonej analizy.

Tabela 42 Zestawienie porównawcze modeli M2 (GLM) i M3 (AutoML) w zakresie jakości predykcji, interpretowalności, złożoności strukturalnej oraz potencjału wdrożeniowego.

Kategoria	Kryterium	Model M2	Model M3	Komentarz
Jakość predykcji	Współczynnik dopasowania AR-S	0,9508 max = 0,9629	0,9770 max = 0,9820	Oba modele wykazują wysoką dokładność predykcji; model M3 osiągnął nieznacznie lepsze dopasowanie do danych empirycznych.
Interpretowalność	Możliwość analizy wpływu zmiennych	wysoka	niska	Model M2 zapewnia większą przejrzystość struktury i interpretację znaczenia poszczególnych predyktorów.
Złożoność strukturalna	Liczba warstw / parametrów / stopień automatyzacji	umiarkowana	wysoka	Model M3 wykorzystuje bardziej złożoną strukturę, co zwiększa jego potencjał obliczeniowy, lecz utrudnia analizę wewnętrzną.
Potencjał wdrożeniowy	Integracja z systemami zewnętrznymi	wysoki	wysoki	Architektura AutoML umożliwia bezpośrednią integrację poprzez API, co sprzyja zastosowaniom w systemach AMR i IoT. Jawny zapis modelu M2 pozwala na łatwe wdrożenie w dowolnym systemie.
Przygotowanie danych	Stopień automatyzacji przetwarzania	Manualne półautomatyczne	automatyczne	AutoML automatyzuje proces selekcji i transformacji cech, redukując ryzyko błędów ludzkich i poprawiając spójność danych wejściowych.
Elastyczność adaptacji	Możliwość aktualizacji modelu w czasie	niska	wysoka	Model M3 może być ponownie trenowany na nowych danych w środowisku AutoML, co umożliwia cykliczną adaptację. Model M2 wymaga ręcznej rekalkulacji współczynników, co ogranicza jego zastosowanie w systemach dynamicznych.
Zarządzanie cyklem życia modelu	Możliwość ponownego trenowania i aktualizacji	ręczna aktualizacja	automatyczna (zależna od środowiska AutoML)	Model M2 wymaga manualnej rekalkulacji współczynników po zmianach danych; Model M3 może być automatycznie ponownie trenowany w trybie cyklicznym.
Replikowalność modelu	Możliwość odtworzenia procesu uczenia	wysoka	niska	Model M2 może być w pełni odtworzony na podstawie równań i parametrów. Model M3 wykorzystuje proces AutoML z losową inicjalizacją i ewolucyjnym doбором hiperparametrów, co utrudnia pełną replikację wyników.
Odporność na przeuczenie	Wpływ na generalizację	kontrolowana ręcznie	kontrolowana automatycznie	Oba modele wykazują porównywalną odporność; w M3 zastosowano mechanizmy wczesnego zatrzymania i regularizacji.
Transparentność procesu modelowania	Dostępność pełnej dokumentacji procesu	wysoka	niska	Model M2 zapewnia większą transparentność i powtarzalność procesu modelowania
Utrzymanie i serwis modelu	Koszt utrzymania i skalowania	niski	umiarkowany / wysoki	Model M2 jest stabilny i nie wymaga stałego nadzoru; Model M3 generuje koszty związane z utrzymaniem infrastruktury AutoML oraz licencjonowaniem środowiska.

Podsumowując, oba modele spełniają wymagania jakościowe i mogą być zastosowane w predykcji zużycia energii przez roboty mobilne, jednak ich użyteczność zależy od kontekstu wdrożenia. Model M2 (GLM) jest deterministyczny i interpretowalny, co czyni go odpowiednim w zastosowaniach

badawczych oraz w systemach, w których wymagane jest pełne zrozumienie mechanizmów wpływu zmiennych. Z kolei model M3 (AutoML) cechuje się wyższą dokładnością predykcji i większym potencjałem wdrożeniowym, jednak kosztem utraty transparentności i zwiększonej zależności od infrastruktury obliczeniowej.

W praktyce przemysłowej najbardziej efektywnym rozwiązaniem może być podejście komplementarne, w którym oba modele pełnią odrębne, lecz uzupełniające się funkcje: model M2 pełni rolę komponentu diagnostyczno-walidacyjnego, pozwalającego na ocenę wpływu czynników fizycznych i środowiskowych, natomiast model M3 stanowi operacyjne narzędzie predycyjne, działające w czasie rzeczywistym w systemie zarządzania flotą robotów. Takie połączenie zapewnia równowagę pomiędzy interpretowalnością a skutecznością predykcji, umożliwiając jednocześnie praktyczne wdrożenie i zachowanie naukowej wiarygodności opracowanego rozwiązania.

6.5 Analiza i ocena wpływu poszczególnych zmiennych wejściowych na dokładność predykcji modeli

Jednym z zadań szczegółowych niniejszej pracy była **analiza i ocena wpływu poszczególnych zmiennych wejściowych na dokładność predykcji modeli zużycia energii**, obejmująca ilościową ocenę ich ważności (zadanie badawcze 9B). W rozdziale 4 zaproponowano trójetapowe hybrydowe podejście do identyfikacji i selekcji predyktorów zużycia energii przez roboty AMR (Rys. 26), stanowiące metodologiczną podstawę dalszych analiz.

W pierwszym etapie przeprowadzono identyfikację teoretyczno-literaturową parametrów potencjalnie wpływających na zużycie energii w robotach mobilnych. Analiza ta obejmowała zarówno modele fizyczne (bilans sił i mocy, sprawności), jak i dane empiryczne opisane w literaturze.


W drugim etapie, wykorzystując analizę przyczynowo skutkową w postaci diagramu Ishikawy (Rys. 27), dokonano systematyzacji oraz redukcji czynników do zbioru parametrów informatywnych, mierzalnych i możliwych do pozyskania w trakcie misji robota AMR. Rezultatem tego etapu był zredukowany diagram czynników (Rys. 29), który stanowił podstawę wyłonienia zestawu predyktorów przyjętych do dalszego modelowania.

Tak określone czynniki potraktowano jako zmienne wejściowe (predyktory) w procesie budowy dwóch niezależnych modeli predykcyjnych:

- **modelu M2**, opartego na uogólnionym modelu liniowym (GLM),
- **modelu M3**, zbudowanego w podejściu automatycznego doboru algorytmów (AutoML).

W rozdziałach 6.2 (M2) oraz 6.3 (M3) oprócz budowy i weryfikacji modeli przeprowadzono ocenę istotności predyktorów w kontekście ich wpływu na dokładność predykcji. Analizę wykonano zarówno dla modeli częściowych (zbudowanych dla pojedynczych akumulatorów *akumulator 1* oraz *akumulator 2*), jak i dla modelu ogólnego opracowanego na bazie danych scalonych.

Dla zrealizowanego czytelności procesu, na Rys. 58 przedstawiono rozszerzony schemat trójetapowego podejścia do identyfikacji i oceny ważności zmiennych wejściowych dla modelu predykcji zużycia energii (opracowany na bazie koncepcji z Rys. 26). W niniejszym podrozdziale dokonano porównania wyników oceny istotności predyktorów uzyskanych w obu podejściach: klasycznym, jawnym (M2) oraz automatycznym (M3).



Rys. 58 Schemat powiązań między etapami identyfikacji predyktorów a procesem budowy i oceny modeli predykcyjnych (M2 - GLM, M3 - AutoML) w ramach trójetapowego podejścia przedstawionego na Rys. 26

W ramach realizacji trzeciego etapu przedstawionego podejścia (rys. 58) przeprowadzono analizę ilościową mającą na celu ocenę wpływu poszczególnych predyktorów na dokładność predykcji oraz porównanie wyników oceny ich istotności uzyskanych w dwóch odmiennych podejściach modelowania - jawnym (M2, GLM) i automatycznym (M3, AutoML).

Dla modelu M2 zastosowano analizę sekwencyjnego przyrostu współczynnika AR-S, umożliwiającą określenie wpływu każdej zmiennej i jej interakcji na poprawę dopasowania modelu. W przypadku modelu M3 wykorzystano analizę wartości Shapleya, pozwalającą na ilościowe oszacowanie znaczenia poszczególnych cech w kontekście ich udziału w końcowym wyniku predykcji. Analizę przeprowadzono zarówno dla modeli częściowych, opracowanych na podstawie danych pochodzących z dwóch akumulatorów o różnym stopniu eksploatacji, jak i dla modelu ogólnego zbudowanego na zbiorze zintegrowanym. Zestawienie wyników oceny istotności predyktorów oraz ich porównanie między modelami przedstawiono poniżej (Tabela 43, Tabela 44)

Tabela 43 Porównanie wpływu predyktorów w modelach M2 (analiza sekwencyjnego wzrostu współczynnika AR-S) i M3 (analiza wartości Shapleya) dla akumulatora nr 1 (po dwóch latach eksploatacji).

Model M2 (GLM)			Model M3 (AutoML)
Zależność zmiennej objaśnianej od wybranych predyktorów - analiza sekwencyjnego wzrostu współczynnika AR-S (akumulator 1, 2-lata)			Istotność predyktorów w modelu predykcyjnym - analiza wartości Shapleya (akumulator 1, 2-lata)
Kolejność wprowadzania predyktorów do modelu	Wprowadzony predyktor	AR-S	
1	Turns	0,9139	
2	Distance	0,9196	
3	SoC	0,9271	
4	SoC * Distance	0,9508	
5	Distance * Distance	0,9521	
6	SoC * SoC	0,9530	
7	AvgAngVelocity	0,9565	
9	SoC * SoC * SoC	0,9573	
10	AvgAngVel * AvgAngVel	0,9613	
11	SoC * Turns	0,9620	
12	Payload	0,9624	
13	AvgAngVel * Distance	0,9626	
14	AvgAng * AvgAng * AvgAng	0,9628	
15	SoC * Payload	0,9628	
16	Turns * Payload	0,9629	

Tabela 44 Porównanie wpływu predyktorów w modelach M2 (analiza sekwencyjnego wzrostu współczynnika AR-S) i M3 (analiza wartości Shapleya) dla akumulatora nr 2 (nowy).

Model M2 (GLM)			Model M3 (AutoML)
Zależność zmiennej objaśnianej od wybranych predyktorów - analiza sekwencyjnego wzrostu współczynnika AR-S (akumulator 2, nowy)			Istotność predyktorów w modelu predykcyjnym - analiza wartości Shapleya (akumulator 2, nowy)
Kolejność wprowadzania predyktorów do modelu	Wprowadzony predyktor	AR-S	
1	Turns	0,9167	
2	Distance	0,9202	
3	SoC	0,9297	
4	SoC * Distance	0,9591	
5	SoC * SoC	0,9599	
6	BatteryTemp	0,9655	
7	Distance * Distance	0,9662	
9	SoC * Turns	0,9667	
10	BatteryTemp * SoC	0,9670	
11	SoC * SoC * SoC	0,9679	
12	BatteryTemp * BatteryTemp	0,9681	
13	BatteryTemp * Distance	0,9689	
14	Payload	0,9691	
15	Payload * Payload	0,9692	
16	AvgLinVelocity	0,9693	
17	AvgLinVel * AvgLinVel	0,9693	

Analizując wyniki przedstawione w Tabeli 43, Tabela 44 oraz rezultaty modelu uogólnionego M3 (Rys. 57), można stwierdzić, że **dla konkretnego robota MiR100, wykorzystanego w badaniach eksperymentalnych, największy wpływ na zużycie energii podczas realizacji misji miały trzy główne predyktory:**

- 1. liczba zakrętów w przebiegu trasy,**
- 2. początkowy stan naładowania akumulatora - wniosek spójny z obserwacjami z modelu M1,**
- 3. długość trasy pokonywanej w danej misji.**

Pozostałe zmienne, takie jak

- średnia prędkość kątowna i liniowa,
- masa ładunku,
- temperatura akumulatora i otoczenia (w zakresie występującym podczas pomiarów)
- czas eksploatacji akumulatora (porównanie: nowy i dwuletni),

wykazywały ograniczony wpływ na wynik predykcji. Zgodnie z analizą wartości Shapleya, sumaryczny udział tych czynników nie przekraczał 15% całkowitego wpływu w modelu M3, co potwierdza ich drugorzędne znaczenie w kontekście predykcji zużycia energii.

7. Podsumowanie i wnioski końcowe

Celem pracy było **opracowanie i weryfikacja modelu predykcyjnego zużycia energii dla komercyjnych autonomicznych robotów mobilnych (AMR) pozwalającego na szacowanie zapotrzebowania energetycznego misji i wsparcie decyzji dotyczących zarządzania flotą w intralogistyce, zwiększając autonomię robota poprzez ocenę wykonalności zakolejkowanych zadań oraz wczesne wykrywanie zakłóceń.**

Motywacja do podjęcia badań wynikała z ograniczeń współczesnych metod zarządzania flotą AMR, w których decyzje operacyjne opierają się głównie na bieżącym poziomie naładowania akumulatora, bez uwzględnienia parametrów misji, dynamiki ruchu i warunków środowiskowych. Przegląd literatury (rozdział 2) wskazał, że zdecydowana większość dotychczasowych badań koncentruje się na prototypowych robotach mobilnych, które zapewniają pełny dostęp do warstwy sterowania oraz poszczególnych komponentów. W przypadku komercyjnych robotów AMR dostęp ten jest istotnie ograniczony, co uniemożliwia budowę modeli predykcyjnych opartych na podejściach fizyczno-strukturalnych, takich jak modele bilansowe, komponentowe czy modele stanowe. Informacje dotyczące zużycia energii są natomiast najczęściej ograniczone do poziomu naładowania akumulatora raportowanego przez system BMS. Jednocześnie w literaturze rzadko podejmowane są próby systematycznej identyfikacji czynników misji, otoczenia oraz cech konstrukcyjnych wpływających na profil energetyczny robota, co utrudnia opracowanie modeli o odpowiednim stopniu uogólnienia.

W rezultacie współczesne systemy flotowe oparte na komercyjnych robotach AMR pozbawione są narzędzi umożliwiających wiarygodne prognozowanie zapotrzebowania energetycznego, weryfikację wykonalności zakolejkowanych misji oraz wczesne wykrywanie anomalii pracy robota. Ogranicza to autonomię operacyjną floty i utrudnia stabilne zarządzanie procesem transportowym.

W świetle tych uwarunkowań opracowanie modelu predykcyjnego działającego w warunkach ograniczonej obserwowalności, z wykorzystaniem danych dostępnych w komercyjnych robotach AMR, stanowiło istotny problem badawczy. Praca odpowiada na tę potrzebę poprzez zaprojektowanie spójnego procesu badawczego obejmującego identyfikację zmiennych, przygotowanie stanowiska pomiarowego, realizację eksperymentów oraz budowę i ocenę modeli predykcyjnych.

7.1 Podsumowanie przebiegu badań

Przebieg badań w rozprawie został ukształtowany zgodnie ze strukturą działań przedstawioną w rozdziale trzecim (Rys. 24). Kolejne rozdziały odzwierciedlają logiczny ciąg prac prowadzących od sformułowania problemu badawczego, przez pozyskanie i analizę danych, aż do budowy i weryfikacji modeli predykcyjnych.

Po przedstawieniu w **rozdziałach 1 i 2** analizy literatury oraz identyfikacji ograniczeń współczesnych metod szacowania zużycia energii przez roboty mobilne, w **rozdziale trzecim** zdefiniowano problem badawczy i zidentyfikowano lukę badawczą (**rozdział 3.1**), którą wypełnia niniejsza rozprawa. Na tej podstawie sformułowano cel główny pracy (**rozdział 3.2**) oraz odpowiadający mu zestaw celów szczegółowych, obejmujących zarówno zagadnienia badawcze, jak i utylitarne (**Tabela 10, Tabela 11**). W rozdziale tym przedstawiono również metodykę badań, opisując logiczną sekwencję działań koniecznych do realizacji celu (**Tabela 12**). Rozdział trzeci pełni zatem funkcję conceptualnego i metodologicznego szkieletu całej rozprawy, na którym oparto dalsze prace.

W rozdziale czwartym przeprowadzono klasyfikację oraz redukcję zmiennych potencjalnie wpływających na zużycie energii przez AMR. Wykorzystano identyfikację teoretyczno-literaturową (Tabela 13), oraz systematyzację jakościową (diagram Ishikawy - Rys. 29), co pozwoliło uporządkować czynniki na związane z misją, otoczeniem i konstrukcją robota. Celem tego etapu było wyodrębnienie potencjalnych predyktorów modelu predykcyjnego, informatywnych a jednocześnie możliwych do pozyskania w robocie MiR100, co stanowiło kluczowy warunek budowy modelu działającego w ograniczonej obserwowalności.

Rozdział piąty obejmuje przygotowanie i realizację eksperymentów. Zbudowano stanowisko pomiarowe umożliwiające równoczesną rejestrację parametrów misji, logów systemowych oraz danych energetycznych robota (Tabela 20, Tabela 23, Rys. 40, Rys. 41). Kluczowym elementem było zapewnienie spójności i synchronizacji danych pozyskiwanych z wielu źródeł. Plan eksperymentów podzielono na dwa etapy (Rys. 33).

- **Etap 1 (Tabela 14)** miał charakter wstępny i służył weryfikacji działania stanowiska, jakości danych oraz powtarzalności pomiarów. Pozwoliło to ograniczyć ryzyko błędów przed przejściem do właściwego eksperymentu.
- **Etap 2 (Tabela 17)** stanowił eksperyment wieloczynnikowy zaplanowany zgodnie z zasadami DoE, obejmujący zróżnicowane dystanse, obciążenia, profile ruchu oraz dwa akumulatory o różnym stopniu zużycia.

Tak zaprojektowany proces umożliwił pozyskanie reprezentatywnego zbioru danych obejmującego szeroki zakres warunków operacyjnych, co było niezbędne do budowy i walidacji modeli predykcyjnych.

W rozdziale szóstym opracowano trzy modele predykcyjne:

1. **model jednowymiarowy M1** - stanowiący punkt odniesienia dla kolejnych badań (równanie 10),
2. **model M2 typu GLM** - umożliwiający jawny opis zależności między predyktorami a wynikiem (równanie 11),
3. **model M3 zbudowany z wykorzystaniem narzędzia AutoML**, które automatyzuje dobór algorytmu, hiperparametrów i transformacji cech, umożliwiając modelowanie nieliniowych zależności przy minimalnej ingerencji eksperta (rozdział 6.3).

Walidacja modeli potwierdziła, że **model M1**, mimo swojej prostoty, jest użyteczny wyłącznie do oceny pojedynczej, powtarzalnej misji, w której jedynym parametrem wejściowym jest początkowy poziom naładowania akumulatora. Modele wielowymiarowe wykazały znacząco wyższą skuteczność predykcji (**M2** AR-S=0,9508, **M3** AR-S=0,977), przy czym M2 zapewniał pełną interpretowalność zależności, natomiast M3 osiągnął najwyższe wartości współczynnika AR-S dzięki automatycznej optymalizacji algorytmów i transformacji cech. Szczegółowe porównanie modeli przedstawiono w Tabela 42.

W dalszej części rozdziału 6 przeprowadzono analizę wpływu zmiennych (predyktorów) na zużycie energii przy użyciu metod selekcji cech (Tabela 34) oraz wartości Shapleya (Rys. 57). Przeprowadzone badania (Rys. 58, Tabela 43, Tabela 44) wykazały, że największe znaczenie dla zużycia energii badanego robota MiR100 mają:

- liczba zakrętów w misji,
- początkowy stan naładowania akumulatora
- długość trasy.

Pozostałe zmienne, takie jak masa ładunku czy prędkość, miały wpływ drugorzędny (<15%) w analizowanym zakresie danych.

Podsumowując, przebieg badań przedstawiony w pracy obejmował: identyfikację i selekcję zmiennych, przygotowanie eksperymentów, pozyskanie danych oraz opracowanie i ocenę modeli predykcyjnych. Kolejne rozdziały tworzą spójny proces, który umożliwił weryfikację przyjętych założeń oraz osiągnięcie celu głównego rozprawy.

7.2 Osiągnięcie celów i realizacja zadań badawczych

Wszystkie cele i zadania określone w rozdziale trzecim (Tabela 10, Tabela 11) zostały zrealizowane, co w pełni dokumentuje mapa rozprawy (Rys. 24) oraz wyniki zaprezentowane w kolejnych rozdziałach.

Zrealizowane zadania badawcze obejmowały m.in.:

- **identyfikację luki badawczej** w zakresie predykcji energetycznej AMR (*rozdział 1,2,3*),
- **analizę i klasyfikację istniejących metod predykcji** zużycia energii w robotach mobilnych oraz identyfikacja ich ograniczeń istotnych z punktu widzenia zastosowań przemysłowych (*Zad 3B, 4B - rozdział 2 Tabela 8, Tabela 9, Rys. 17*),
- **klasyfikację i selekcję czynników wpływających na zużycie energii** (*Zad 5B - rozdział 4, Rys. 29*),
- **opracowanie planu eksperymentów** rejestrujących dane operacyjne i energetyczne z misji AMR (*Zad 6B - Rozdział r, Tabela 14, Tabela 17, Rys. 33*)
- **zaprojektowanie stanowiska pomiarowego** i systemu akwizycji danych (*Zad 1U - rozdział 5, Tabela 20, Tabela 23, Rys. 41*),
- **opracowanie trzech modeli predykcyjnych M1-M3** (*Zad 7B, 8B - rozdział 6 - Równanie 10,11*),
- **analizę wpływu zmiennych na dokładność predykcji** (*Zad 9B - rozdział 6 -Tabela 43, Tabela 44*).

Cel główny pracy, dotyczący opracowania i weryfikacji modelu predykcyjnego zużycia energii dla komercyjnych robotów AMR, został osiągnięty w pełni.

7.3 Weryfikacja celu głównego i oryginalność wyników

Cel główny pracy, obejmujący opracowanie i weryfikację modelu predykcyjnego zużycia energii dla komercyjnych autonomicznych robotów mobilnych, został osiągnięty w pełni. Opracowane modele M1-M3, zbudowane na podstawie danych pomiarowych pozyskanych z robota MiR100, umożliwiły wiarygodną ocenę zapotrzebowania energetycznego misji transportowych oraz identyfikację odchyleń świadczących o potencjalnych nieprawidłowościach pracy systemu. Oryginalność wyników rozprawy przejawia się w kilku istotnych obszarach, obejmujących zarówno metodykę, jak i końcowe rezultaty.

1. Opracowanie pierwszej kompletnej metodyki predykcji zużycia energii dla komercyjnego AMR przy ograniczonej obserwowalności systemu

W literaturze przedmiotu modele zużycia energii budowane są przede wszystkim dla robotów prototypowych, zapewniających pełny dostęp do warstwy sterowania, parametrów komponentów i danych konstrukcyjnych. W przypadku komercyjnych AMR dostęp ten jest znacząco ograniczony, co wielokrotnie podkreślono w analizie literatury (rozdział 2).

W pracy opracowano i zweryfikowano **kompletną metodykę predykcji**, możliwą do zastosowania w rzeczywistym środowisku przemysłowym, obejmującą:

- identyfikację dostępnych zmiennych wpływających na zużycie energii przez AMR,
- selekcję predyktorów możliwych do rejestracji w robocie AMR MiR100,
- integrację danych misji, parametrów środowiskowych i sygnałów diagnostycznych,
- mapowanie czynników według kryteriów mierzalności, zmienności i przyczynowości.

W literaturze brak analogicznych eksperymentów o porównywalnej skali (3 dystanse $\times$ 3 obciążenia $\times$ 2 akumulatory $\times$ pełny zakres SoC $\times$ replikacje) -Tabela 17, nie prezentowano dotąd tak kompletnego procesu pozwalającego na predykcję energetyczną przy tak wąskim zestawie dostępnych danych wejściowych.

2. Systematyczna identyfikacja i redukcja czynników wpływających na zużycie energii AMR

W pracy przeprowadzono pełną, wieloetapową ścieżkę analityczną (Rys. 58), prowadzącą od klasyfikacji czynników energetycznych (m.in. diagram Ishikawy) do wyboru finalnych predyktorów spełniających kryteria mierzalności, przyczynowości, dostępności i zmienności. Proces ten umożliwił selekcję niewielkiego, lecz wysoce informatywnego zestawu zmiennych wejściowych, odpowiednich do modelowania w warunkach ograniczonej obserwowalności systemu MiR100.

Tak przeprowadzona, formalnie ustrukturyzowana redukcja predyktorów nie występuje w literaturze, gdzie typowo prezentowane są jedynie listy czynników lub analizy izolowanych przypadków.

3. Opracowanie trzech modeli predykcyjnych o różnym stopniu złożoności

W pracy przedstawiono trzy modele predykcyjne tworzące uporządkowaną strukturę analityczną:

- **M1** - model podstawowy zależny wyłącznie od początkowego SoC, użyteczny dla pojedynczych misji,
- **M2 (GLM)** - model jawny, pozwalający na predykcję zużycia energii dla misji i interpretację zależności między predyktorami,
- **M3 (AutoML)** - model pozwalający na predykcję zużycia energii dla misji, wykorzystujący automatyczną selekcję cech i algorytmów, uzyskujący najwyższą dokładność (AR-S do 0,982).

Porównanie M2 i M3 (Tabela 42) stanowi istotny element oryginalności - jest to pierwsze ilościowe zestawienie podejść modelu jawnego (white-box) i niejawnego (black-box) w kontekście zużycia energii AMR.

4. Identyfikacja kluczowych predyktorów zużycia energii AMR

Analiza wyników (Tabela 43, Tabela 44, Rys. 57) pozwoliła wyodrębnić trzy dominujące czynniki wpływające na profil energetyczny robota:

- liczbę zakrętów,
- stan naładowania akumulatora (SoC),
- dystans misji.

Jest to unikalna ilościowa weryfikacja relatywnego wpływu tych czynników w warunkach przemysłowych dla komercyjnego AMR MiR100.

5. Wykazanie praktycznej użyteczności modeli i ich implementacji w systemie operacyjnym

Opracowane modele nie mają charakteru wyłącznie teoretycznego. W pracy przedstawiono:

- zastosowanie modeli do oceny wykonalności zakolejkowanych misji (Rys. 50),
- wykorzystanie modeli do identyfikacji potencjalnych przeszkód na trasie AMR (Rys. 47),
- implementację autorskich algorytmów i modeli w autorskim systemie zbudowanym w środowisku **Node-RED**.

W pracy predykcja energetyczna AMR została powiązana z działającym systemem wspierającym decyzje operacyjne.

Powyższe punkty potwierdzają osiągnięcie celu głównego oraz wskazują na oryginalny wkład pracy w obszarze predykcji energetycznej robotów mobilnych. Opracowane podejście obejmuje pełen cykl: od analizy teoretycznej i selekcji predyktorów, poprzez eksperymenty i konstrukcję modeli, aż po ich implementację i weryfikację w środowisku operacyjnym.

7.4 Ograniczenia i zakres ważności wyników

Pomimo uzyskania wysokiej jakości predykcji, zarówno model M2 (GLM), jak i model M3 (AutoML) posiadają ograniczenia wynikające z przyjętej struktury modeli oraz charakteru dostępnych danych. Model M2 jako konstrukcja typu white-box, oferuje wysoką interpretowalność, lecz jego zdolność do odwzorowania nieliniowych zależności jest ograniczona przez formalizm regresji liniowej. Każda zmiana warunków operacyjnych w szczególności dotycząca stanu technicznego akumulatora, nawierzchni czy dynamiki misji wymaga ponownej estymacji parametrów modelu. M2 jest także wrażliwy na jakość selekcji predyktorów; pominięcie istotnych interakcji skutkuje obniżeniem jakości predykcji, co potwierdziła analiza częściowych modeli cech (Tabela 34).

Model M3 uzyskał najwyższą dokładność predykcji, jednak jego struktura ma charakter niejawny i nie pozwala na pełną interpretację zależności przyczynowych. Konieczne było zastosowanie metody Shapleya, która ułatwia analizę wpływu zmiennych, lecz nie zastępuje transparentności typowej dla modeli liniowych. Ponadto, tworzenie modelu M3 wymaga infrastruktury obliczeniowej, a kolejne cykle automatycznej budowy modelu AutoML mogą prowadzić do powstania modeli o odmiennej strukturze, co ogranicza replikowalność i utrudnia implementację w systemach wymagających deterministycznego działania.

Ograniczenia wspólne dla obu modeli wynikają przede wszystkim z charakteru zbioru danych. Modele dobrze odwzorowują misje o strukturze odpowiadającej danym uczącym, lecz ich zachowanie dla misji o innym profilu, np. złożonym układzie zakrętów, inny dystans lub obciążenie robota pozostaje niezaweryfikowane. Modele uczono na danych zapisywanych wyłącznie dla jednego typu robota (MiR100), co oznacza, że ich bezpośrednia przenoszalność na inne platformy AMR może być ograniczona. Należy podkreślić, że metodyka opracowania modeli jest uniwersalna, jednak same modele wymagają ponownego uczenia dla innych konstrukcji. Zakres danych nie pozwolił również na

jednoznaczne określenie wpływu degradacji akumulatora. Wymagana jest szersza baza pomiarowa uwzględniająca różne temperatury otoczenia, odmienne typy baterii, różne platformy AMR, długotrwałą eksploatację oraz zmienność parametrów otoczenia do uzyskania modelu uniwersalnego.

7.5 Określenie potencjału rozszerzenia modeli i kierunki dalszych badań

Uzyskane wyniki potwierdzają, że opracowane modele mogą stanowić fundament rozwiniętego systemu predykcji energetycznej AMR. Jednocześnie zidentyfikowane ograniczenia wskazują obszary dalszych badań, niezbędnych do zwiększenia ich odporności, ogólności i możliwości wdrożeń.

Pierwszy kierunek rozwoju dotyczy **rozszerzenia i uzupełnienia bazy danych**, obejmującego zarówno większą liczbę i różnorodność misji, jak i nowe typy pomiarów, dotychczas niewykorzystywane w modelowaniu energetycznym AMR. W szczególności zasadne jest uwzględnienie **parametrów związanych z oprogramowaniem robota i systemu BMS**, których wersje i konfiguracje mogą wpływać na charakterystykę poboru energii, a nie były dotychczas rejestrowane w badaniach. Równolegle konieczne jest pozyskanie danych z rzeczywistych procesów intralogistycznych oraz długookresowych pomiarów dokumentujących **starzenie akumulatorów**, co umożliwi włączenie do modeli komponentów prognostycznych. Tak uzupełniona baza danych pozwoli na bardziej kompleksową inżynierię cech i identyfikację nowych czynników wpływających na profil energetyczny AMR.

Drugim obszarem rozwoju jest **zwiększenie ogólności modeli poprzez rozszerzenie ich na kolejne platformy AMR**. Opracowana w pracy metodyka ma charakter uniwersalny, jednak same modele zostały wytrenowane wyłącznie na danych z robota MiR100, co ogranicza ich bezpośrednią przenoszalność. Pozyskanie danych z wielu robotów o różnej konstrukcji i parametrach eksploatacyjnych umożliwiłoby budowę **meta-modelu floty**, zdolnego do uogólniania wiedzy i adaptacji do robotów o zbliżonej charakterystyce ruchowej lub działających w odmiennych warunkach środowiskowych.

Kolejnym kierunkiem rozwoju jest przekształcenie modeli w rozwiązania o charakterze **adaptacyjnym**, które potrafią aktualizować się na podstawie nowych danych. Zamiast okresowo trenować modele od początku, można zastosować podejście, w którym model stopniowo „douce się” podczas eksploatacji, wykorzystując dane z kolejnych misji. Jest to zgodne z aktualnymi trendami w uczeniu maszynowym, w których rośnie znaczenie **uczenia ciągłego i modeli strumieniowych**, pozwalających na pracę w środowiskach o stale zmieniającej się charakterystyce. Takie podejście umożliwiłoby reagowanie na zmiany związane z eksploatacją robota — w tym starzenie akumulatora, zmiany wersji oprogramowania, modyfikacje infrastruktury intralogistycznej oraz naturalne różnice w strukturze misji. Adaptacja do tych zmian pozwoliłaby ograniczyć wpływ zjawiska **dryfu koncepcji**, czyli stopniowego rozchodzenia się aktualnych danych od warunków, na których model był pierwotnie trenowany.

Perspektywicznym kierunkiem rozwoju jest **wdrożenie opracowanych modeli do komercyjnych systemów FMS oraz środowisk cyfrowych bliźniaków**, które nadzorują i optymalizują pracę floty AMR. Integracja modeli predykcyjnych z tymi systemami umożliwiłaby dynamiczną ocenę wykonalności misji, planowanie kolejności i czasu ładowania, optymalizację wykorzystania dostępnych robotów oraz ograniczenie liczby sytuacji wymagających interwencji operatora. Modele mogłyby również wspierać decyzje dotyczące wielkości i struktury floty, na przykład poprzez symulację obciążenia energetycznego dla różnych scenariuszy pracy. Istotnym zastosowaniem jest także **utrzymanie predykcyjne AMR**, w którym odchylenia od typowego profilu energetycznego sygnalizują potencjalne problemy techniczne lub degradację komponentów. Połączenie modelu z danymi operacyjnymi w czasie rzeczywistym umożliwiłoby monitorowanie stanu robotów, wczesne wykrywanie anomalii oraz planowanie prac serwisowych według faktycznego zużycia, a nie według sztywnych interwałów.

W kolejnych pracach zasadne jest rozważenie **ujednoczenia sposobu pomiaru energii akumulatorów**, niezależnie od producenta AMR. Obecne systemy BMS obliczają SoC według własnych, często niejawnych algorytmów, co prowadzi do różnic w interpretacji wartości procentowych i utrudnia porównywanie danych pomiędzy robotami. Wprowadzenie **zewnętrznego, jednolitego układu do pomiaru rzeczywistego przepływu ładunku**, opartego na bezpośrednim pomiarze prądu i napięcia, pozwoliłoby uzyskiwać dane w jednostkach fizycznych (Ah, Wh) i eliminować zależność od sposobu liczenia SoC przez poszczególne BMS. Takie rozwiązanie zwiększyłoby porównywalność pomiarów, ułatwiło budowę modeli przenoszalnych między różnymi AMR oraz umożliwiło dokładniejszą analizę degradacji ogniw.

7.6 Wnioski końcowe

Przeprowadzona rozprawa stanowi zweryfikowany empirycznie wkład w rozwój metod predykcji energetycznej dla autonomicznych robotów mobilnych, ukierunkowany na zastosowania w rzeczywistych systemach intralogistycznych. Opracowane modele potwierdziły możliwość wiarygodnego prognozowania zapotrzebowania energetycznego oraz oceny wykonalności misji z wykorzystaniem danych dostępnych w komercyjnych platformach AMR. Wyniki pracy pokazują, że połączenie metod analitycznych i uczenia maszynowego umożliwia rozwiązanie kluczowego problemu braku predykcyjnej informacji energetycznej, ograniczającego autonomię i stabilność pracy komercyjnych flot AMR. Zastosowanie modeli pozwala na wczesną identyfikację odchyłeń energetycznych, co może wspierać zarówno planowanie zadań, jak i predykcyjne utrzymanie ruchu. Uzyskane rezultaty mają znaczenie praktyczne, ponieważ mogą być bezpośrednio włączone do systemów FMS i narzędzi wspierających zarządzanie flotą AMR. Przedstawiona metodyka tworzy podstawę do dalszego rozwoju adaptacyjnych systemów predykcji, które w przyszłości mogą obejmować uczenie online, analizę degradacji akumulatorów oraz integrację z cyfrowymi bliźniakami procesów logistycznych.

8. Spis literatury

- [1] P. P. Groumpos, “A critical historical and scientific overview of all industrial revolutions,” in *IFAC-PapersOnLine*, Elsevier B.V., 2021, pp. 464–471. doi: 10.1016/j.ifacol.2021.10.492.
- [2] T. L. Olsen and B. Tomlin, “Industry 4.0: Opportunities and Challenges for Operations Management,” 2019.
- [3] M. Krstić, S. Tadić, and S. Zečević, “Technological solutions in Logistics 4.0,” *Ekonomika preduzeća*, vol. 69, no. 6–7, pp. 385–401, 2021, doi: 10.5937/ekopre2106385k.
- [4] G. Fragapane, D. Ivanov, M. Peron, F. Sgarbossa, and J. O. Strandhagen, “Increasing flexibility and productivity in Industry 4.0 production networks with autonomous mobile robots and smart intralogistics,” *Ann Oper Res*, vol. 308, no. 1–2, pp. 125–143, Jan. 2022, doi: 10.1007/s10479-020-03526-7.
- [5] M. Dahanayaka and A. Thibbotuwawa, “Intralogistics: making optimized and automated internal logistics and advanced technology attainable,” *Bolgoda Plains*, vol. 1, no. 2, pp. 18–20, Dec. 2022, doi: [https://doi.org/10.31705/BPRM.v2\(1\).2022.3](https://doi.org/10.31705/BPRM.v2(1).2022.3).
- [6] R. deKoster, D. Roy, Y. F. Lim, and S. Kumar, “Managing Autonomous and IoT-driven Intralogistics Operations,” *Prod Oper Manag*, vol. 30, no. 1, pp. 293–294, Jan. 2021, doi: 10.1111/poms.13372.
- [7] S. Winkelhaus and E. H. Grosse, “Logistics 4.0: a systematic review towards a new logistics system,” Jan. 02, 2020, *Taylor and Francis Ltd*. doi: 10.1080/00207543.2019.1612964.
- [8] E. Płaczek and K. Osieczko-Potoczna, “Current State of Knowledge and Research Needs of Intralogistics,” 2024.
- [9] G. Fragapane, R. de Koster, F. Sgarbossa, and J. O. Strandhagen, “Planning and control of autonomous mobile robots for intralogistics: Literature review and research agenda,” Oct. 16, 2021, *Elsevier B.V.* doi: 10.1016/j.ejor.2021.01.019.
- [10] Enoch Oluwademilade Sodiya, Uchenna Joseph Umoga, Olukunle Oladipupo Amoo, and Akoh Atadoga, “AI-driven warehouse automation: A comprehensive review of systems,” *GSC Advanced Research and Reviews*, vol. 18, no. 2, pp. 272–282, Feb. 2024, doi: 10.30574/gscarr.2024.18.2.0063.
- [11] A. A. Tubis and J. Rohman, “Intelligent Warehouse in Industry 4.0—Systematic Literature Review,” Apr. 01, 2023, *MDPI*. doi: 10.3390/s23084105.
- [12] M. Wesselhöft, J. Hinckeldeyn, and J. Kreutzfeldt, “Controlling Fleets of Autonomous Mobile Robots with Reinforcement Learning: A Brief Survey,” *Robotics*, vol. 11, no. 5, Oct. 2022, doi: 10.3390/robotics11050085.
- [13] V. Berenz, F. Tanaka, and K. Suzuki, “Autonomous battery management for mobile robots based on risk and gain assessment,” *Artif Intell Rev*, vol. 37, no. 3, pp. 217–237, 2012, doi: 10.1007/s10462-011-9227-9.
- [14] M. Tomy, B. Lacerda, N. Hawes, and J. L. Wyatt, “Battery charge scheduling in long-life autonomous mobile robots via multi-objective decision making under uncertainty,” *Rob Auton Syst*, vol. 133, Nov. 2020, doi: 10.1016/j.robot.2020.103629.
- [15] “Liczba zgłoszeń patentowych i przyznanych patentów dotyczących technologii związanych z AMR w latach 2000–2025 wg. .lens.org.” Accessed: Jul. 24, 2025. [Online]. Available: .lens.org

- [16] B. Ahmadi, I. Vanany, and R.S. Dewi, "Smart Automated Guided Vehicles and Autonomous Mobile Robots in Warehouse Operations A Bibliometric Analysis," in *Procedia Manufacturing*, Elsevier B.V., 2023, pp. 1577–1586. doi: DOI:10.1109/IEEM58616.2023.10406697.
- [17] Ibrahim Adedeji Adeniran, Christianah Pelumi Efunniyi, Olajide Soji Osundare, and Angela Omozele Abbulimen, "Optimizing logistics and supply chain management through advanced analytics: Insights from industries," *International Journal of Scholarly Research in Engineering and Technology*, vol. 4, no. 1, pp. 052–061, Aug. 2024, doi: 10.56781/ijrsret.2024.4.1.0020.
- [18] J. M. Müller and H. S. Birkel, "Contributions of Industry 4.0 to lean management within the supply chain operations reference model," 2020.
- [19] L. S. Valamede and A. C. S. Akkari, "Lean 4.0: A new holistic approach for the integration of lean manufacturing tools and digital technologies," *International Journal of Mathematical, Engineering and Management Sciences*, vol. 5, no. 5, pp. 854–868, Oct. 2020, doi: 10.33889/IJMEMS.2020.5.5.066.
- [20] M. Vorkapić, S. Ilić, M. Spasenović, M. Vasić, and D. Čočkaló, "Additive technology and 7R methodology in circular economy for wearable sensors production," *Journal of Engineering Management and Competitiveness*, vol. 14, no. 1, pp. 71–78, 2024, doi: 10.5937/jemc2401071v.
- [21] N. Jefroy, M. Azarian, and H. Yu, "Moving from Industry 4.0 to Industry 5.0: What Are the Implications for Smart Logistics?," Jun. 01, 2022, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/logistics6020026.
- [22] C. P. Malagón-Suárez and J. A. Orjuela-Castro, "Challenges and Trends in Logistics 4.0," *Ingenieria (Colombia)*, vol. 28, 2023, doi: 10.14483/23448393.18492.
- [23] D. Kansy, "Technological conditions for Logistics 4.0 development," *Scientific Papers of Silesian University of Technology. Organization and Management Series*, vol. 2023, no. 170, pp. 215–232, 2023, doi: 10.29119/1641-3466.2023.170.13.
- [24] K. Wang, "Logistics 4.0 Solution New Challenges and Opportunities," 2016.
- [25] B. Poskart, G. Iskierka, and K. Krot, "Logistics 4.0-monitoring of transport trolley in the factory through vision systems using the YOLO model based on convolutional neural networks," 2023. doi: https://doi.org/10.1007/978-3-031-44282-7_27.
- [26] O. K. Efthymiou and S. T. Ponis, "Industry 4.0 technologies and their impact in contemporary logistics: A systematic literature review," Nov. 01, 2021, *MDPI*. doi: 10.3390/su132111643.
- [27] R. G. Richey, S. Chowdhury, B. Davis-Sramek, M. Giannakis, and Y. K. Dwivedi, "Artificial intelligence in logistics and supply chain management: A primer and roadmap for research," Oct. 01, 2023, *John Wiley and Sons Inc*. doi: 10.1111/jbl.12364.
- [28] A. Z. Abideen, V. P. K. Sundram, J. Pyeman, A. K. Othman, and S. Sorooshian, "Digital Twin Integrated Reinforced Learning in Supply Chain and Logistics," Dec. 01, 2021, *MDPI*. doi: 10.3390/logistics5040084.
- [29] S. Winkelhaus and E. H. Grosse, "Logistics 4.0: a systematic review towards a new logistics system," Jan. 02, 2020, *Taylor and Francis Ltd*. doi: 10.1080/00207543.2019.1612964.
- [30] K. Furmans, Z. Seibold, and A. Trenkle, "Future Technologies in Intralogistics and Material Handling," in *Lecture Notes in Logistics*, Springer Science and Business Media B.V., 2019, pp. 545–574. doi: 10.1007/978-3-319-92447-2_24.

- [31] S. Dabić - Miletić and K. Raković, "Ranking of Autonomous Alternatives for the Realization of Intralogistics Activities in Sustainable Warehouse Systems using the TOPSIS Method," *Spectrum of Engineering and Management Sciences*, vol. 1, no. 1, pp. 48–57, Aug. 2023, doi: 10.31181/sems1120234m.
- [32] J. Stillig, C. Brenner, and A. Colomb, "Adaptive Intralogistics with Low-Cost AGVs for a Modular Production System," 2023, pp. 118–132. doi: 10.1007/978-3-031-27933-1_12.
- [33] K. Buntak, M. Kovačić, and M. Mutavdžija, "Internet of things and smart warehouses as the future of logistics," *Tehnički glasnik*, vol. 13, no. 3, pp. 248–253, Sep. 2019, doi: 10.31803/tg-20190215200430.
- [34] P. Li, "Machinery and logistics: Development trends and prospects of automated warehouse technology," *Applied and Computational Engineering*, vol. 65, no. 1, pp. 81–88, May 2024, doi: 10.54254/2755-2721/65/20240472.
- [35] A. Raja Santhi and P. Muthuswamy, "Pandemic, War, Natural Calamities, and Sustainability: Industry 4.0 Technologies to Overcome Traditional and Contemporary Supply Chain Challenges," Dec. 01, 2022, *MDPI*. doi: 10.3390/logistics6040081.
- [36] Z. Fatima *et al.*, "Production Plant and Warehouse Automation with IoT and Industry 5.0," Feb. 01, 2022, *MDPI*. doi: 10.3390/app12042053.
- [37] O. Kodym, L. Kubáč, and L. Kavka, "Risks associated with Logistics 4.0 and their minimization using Blockchain," *Open Engineering*, vol. 10, no. 1, pp. 74–85, Jan. 2020, doi: 10.1515/eng-2020-0017.
- [38] P. Stączek, J. Pizoń, W. Danilczuk, and A. Gola, "A digital twin approach for the improvement of an autonomous mobile robots (AMR's) operating environment—A case study," *Sensors*, vol. 21, no. 23, Dec. 2021, doi: 10.3390/s21237830.
- [39] N. Anumbe, C. Saidy, and R. Harik, "A Primer on the Factories of the Future," Aug. 01, 2022, *MDPI*. doi: 10.3390/s22155834.
- [40] J. Pizoń, Ł. Wójcik, A. Gola, Ł. Kański, and I. Nielsen, "Autonomous Mobile Robots in Automotive Remanufacturing: A Case Study for Intra-Logistics Support," *Advances in Science and Technology Research Journal*, vol. 18, no. 1, pp. 213–230, 2024, doi: 10.12913/22998624/177398.
- [41] T. Mikołajczyk *et al.*, "Energy Sources of Mobile Robot Power Systems: A Systematic Review and Comparison of Efficiency," Jul. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app13137547.
- [42] R. Keith and H. M. La, "Review of Autonomous Mobile Robots for the Warehouse Environment," Jun. 2024, [Online]. Available: <http://arxiv.org/abs/2406.08333>
- [43] N. Berti, N. Katiraei, S. Zuin, R. Aldrighetti, A. Persona, and D. Battini, "The Challenges of Driverless Mobile Vehicles in Shared Workspace in the Industry 5.0 Era," *IEEE Access*, vol. 13, pp. 27228–27237, 2025, doi: 10.1109/ACCESS.2025.3539928.
- [44] S. Ferraro, A. Cantini, L. Leoni, and F. De Carlo, "Sustainable Logistics 4.0: A Study on Selecting the Best Technology for Internal Material Handling," *Sustainability (Switzerland)*, vol. 15, no. 9, May 2023, doi: 10.3390/su15097067.
- [45] M. Ghobakhloo, M. Iranmanesh, M. Fathi, A. Rejeb, B. Foroughi, and D. Nikbin, "Beyond Industry 4.0: a systematic review of Industry 5.0 technologies and implications for social,

- environmental and economic sustainability,” *Asia-Pacific Journal of Business Administration*, 2024, doi: 10.1108/APJBA-08-2023-0384.
- [46] T. Sutikno, “The future of artificial intelligence-driven robotics: applications and implications,” *IAES International Journal of Robotics and Automation (IJRA)*, vol. 13, no. 4, pp. 361–372, 2024, doi: 10.11591/ijra.v13i4.pp.
 - [47] A. A. Malik, T. Masood, and A. Brem, “Intelligent humanoids in manufacturing to address worker shortage and skill gaps: Case of Tesla’s Optimus Pre-print Highlights,” 2023. doi: <https://doi.org/10.48550/arXiv.2304.04949>Focustolearnmore.
 - [48] J. Geng *et al.*, “Robot positioning and navigation technology is based on Integration of the Global Navigation Satellite System and real-time kinematics,” in *Journal of Physics: Conference Series*, Institute of Physics, 2023. doi: 10.1088/1742-6596/2467/1/012027.
 - [49] Y. Liu, S. Wang, Y. Xie, T. Xiong, and M. Wu, “A Review of Sensing Technologies for Indoor Autonomous Mobile Robots,” Feb. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/s24041222.
 - [50] M. S. Hernández, “Characterization of AGV Localization System in Industrial Scenarios Using UWB Technology,” *Lenguas Modernas*, no. 62, pp. 183–209, 2023, doi: 10.13039/501100011033.
 - [51] Liang Qiu, Jingchuan Wang, and Weidong Chen, “Heterogeneous AGV Routing Problem Considering Energy Consumption,” 2015. doi: 10.1109/ROBIO.2015.7419049.
 - [52] K. Aliev, E. Traini, M. Asranov, A. Awouda, and P. Chiabert, “Prediction and estimation model of energy demand of the AMR with cobot for the designed path in automated logistics systems,” in *Procedia CIRP*, Elsevier B.V., 2021, pp. 116–121. doi: 10.1016/j.procir.2021.03.036.
 - [53] J. Gödecke and P. Detzner, “A Simulative Approach to AMR Fleet Sizing in Decentralized Multi-Robot Task Allocation,” in *IEEE International Conference on Emerging Technologies and Factory Automation, ETFA*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/ETFA54631.2023.10275717.
 - [54] A. K. Tyagi and S. U. Aswathy, “Autonomous Intelligent Vehicles (AIV): Research statements, open issues, challenges and road for future,” *International Journal of Intelligent Networks*, vol. 2, pp. 83–102, Jan. 2021, doi: 10.1016/j.ijin.2021.07.002.
 - [55] M. Mohammadpour *et al.*, “Energy-Efficient Local Path Planning of a Self-Guided Vehicle by Considering the Load Position,” *IEEE Access*, vol. 10, pp. 112669–112685, 2022, doi: 10.1109/ACCESS.2022.3216601.
 - [56] K. Aloui, A. Guizani, M. Hammadi, M. Haddar, and T. Soriano, “Systematic literature review of collaborative SLAM applied to autonomous mobile robots,” in *2022 IEEE Information Technologies and Smart Industrial Systems, ITSIS 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ITSIS56166.2022.10118378.
 - [57] S. Abdul-Khalil, S. Abdul-Rahman, S. Mutalib, S. I. Kamarudin, and S. S. Kamaruddin, “A review on object detection for autonomous mobile robot,” Sep. 01, 2023, *Institute of Advanced Engineering and Science*. doi: 10.11591/ijai.v12.i3.pp1033-1043.
 - [58] A. K. I. M. Abdalameer, W. A. Alawsi, W. C. Alisawi, and P. A. Vladimirovich, “Development of a Control System for Autonomous Mobile Robots: a Literature Review,” in *5th International Conference on Information Technology, Applied Mathematics and Statistics, ICITAMS 2023*,

- Institute of Electrical and Electronics Engineers Inc., 2023, pp. 96–100. doi: 10.1109/ICITAMS57610.2023.10525367.
- [59] M. Zhang *et al.*, “Universal Trajectory Optimization Framework for Differential Drive Robot Class,” Sep. 2024, [Online]. Available: <http://arxiv.org/abs/2409.07924>
 - [60] M. Wu, C. F. Yeong, E. L. M. Su, W. Holderbaum, and C. Yang, “A review on energy efficiency in autonomous mobile robots,” Nov. 17, 2023, *Emerald Publishing*. doi: 10.1108/RIA-05-2023-0060.
 - [61] S. Yao, G. Chen, L. Pan, J. Ma, J. Ji, and X. Chen, “Multi-Robot Collision Avoidance with Map-based Deep Reinforcement Learning,” in *Proceedings - International Conference on Tools with Artificial Intelligence, ICTAI*, IEEE Computer Society, Nov. 2020, pp. 532–539. doi: 10.1109/ICTAI50040.2020.00088.
 - [62] Z. Razzaq, N. Brahimi, H. Z. U. Rehman, and Z. H. Khan, “Intelligent Control System for Brain-Controlled Mobile Robot Using Self-Learning Neuro-Fuzzy Approach,” *Sensors*, vol. 24, no. 18, p. 5875, Sep. 2024, doi: 10.3390/s24185875.
 - [63] Bartosz Poskart, Grzegorz Iskierka, and Kamil Krot, “Bezprzewodowa wymiana danych w procesach obsługi stanowisk pracy,” *INŻYNIERIA ZARZĄDZANIA CYFRYZACJA PRODUKCJI AKTUALNOŚCI BADAWCZE* 4, 2022, Accessed: Jan. 06, 2025. [Online]. Available: <https://24naukowa.com.pl/inzynieria-zarzadzania-cyfryzacja-produkcji-aktualnosci-badawcze-4,id21562.html>
 - [64] A. Pasparakis, J. De Vries, and R. De Koster, “Assessing the impact of human–robot collaborative order picking systems on warehouse workers,” *Int J Prod Res*, vol. 61, no. 22, pp. 7776–7790, 2023, doi: 10.1080/00207543.2023.2183343.
 - [65] T. Giurgiu, G. Bârsan, I. Virca, and C. Pupăză, “Mecanum Wheeled Platforms for Special Applications,” *International conference KNOWLEDGE-BASED ORGANIZATION*, vol. 28, no. 3, pp. 44–51, Jun. 2022, doi: 10.2478/kbo-2022-0086.
 - [66] M. Kronmueller, A. Fielbaum, and J. Alonso-Mora, “Reducing the Minimal Fleet Size by Delaying Individual Tasks,” *IEEE Transactions on Intelligent Transportation Systems*, vol. 25, no. 9, pp. 11011–11022, 2024, doi: 10.1109/TITS.2024.3368101.
 - [67] E. M. Martinez, P. Ponce, I. Macias, and A. Molina, “Automation pyramid as constructor for a complete digital twin, case study: A didactic manufacturing system,” *Sensors*, vol. 21, no. 14, Jul. 2021, doi: 10.3390/s21144656.
 - [68] W. Quadrini, E. Negri, and L. Fumagalli, “Open interfaces for connecting automated guided vehicles to a fleet management system,” in *Procedia Manufacturing*, Elsevier B.V., 2020, pp. 406–413. doi: 10.1016/j.promfg.2020.02.055.
 - [69] R. M. Gago, M. Galassi, F. Silveira, and G. M. Freitas, “A survey on robot fleet management systems for industrial processes,” in *Proceedings of the 2024 Latin American Robotics Symposium, LARS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/LARS64411.2024.10786445.
 - [70] J. Hažík, M. Dekan, P. Beňo, and F. Duchoň, “Fleet Management System for an Industry Environment,” *Journal of Robotics and Control (JRC)*, vol. 3, no. 6, pp. 779–789, Nov. 2022, doi: 10.18196/jrc.v3i6.16298.

- [71] T. T. Mac, A. Q. Pham, and X.-T. Nguyen, “The Development of Fleet Management System for Mobile Robots Delivering Medicine in Healthcare Environments,” 2024. doi: <https://doi.org/10.12700/aph.21.9.2024.9.5>.
- [72] A. Meseguer Valenzuela and F. Blanes Noguera, “State of the Art in Robot Fleet Management: From Task Allocation to Motion Planning,” in *XLIV Jornadas de Automática: libro de actas: Universidad de Zaragoza, Escuela de Ingeniería y Arquitectura, 6, 7 y 8 de septiembre de 2023, Zaragoza*, Servizo de Publicacións. Universidade da Coruña, 2023, pp. 667–672. doi: 10.17979/spudc.9788497498609.667.
- [73] F. Popolizio, M. Vinetti, A. Combrink, S. F. Roselli, M. Pia Fanti, and M. Fabian, “Online Conflict-Free Scheduling of Fleets of Autonomous Mobile Robots,” in *IEEE International Conference on Automation Science and Engineering*, IEEE Computer Society, 2024, pp. 3063–3068. doi: 10.1109/CASE59546.2024.10711693.
- [74] K. L. Keung, C. K. M. Lee, P. Ji, and K. K. H. Ng, “Cloud-Based Cyber-Physical Robotic Mobile Fulfillment Systems: A Case Study of Collision Avoidance,” *IEEE Access*, vol. 8, pp. 89318–89336, 2020, doi: 10.1109/ACCESS.2020.2992475.
- [75] X. Li, Y. Lin, Z. Du, R. Yin, and C. Wu, “Efficient Multi-Robot Cooperative Transportation Scheduling System,” in *International Conference on Ubiquitous Communication 2024, Ucom 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 449–454. doi: 10.1109/Ucom62433.2024.10695882.
- [76] A. S. Chavan and M. Brocanelli, “Towards High-Quality Battery Life for Autonomous Mobile Robot Fleets,” in *Proceedings - 2022 IEEE International Conference on Autonomic Computing and Self-Organizing Systems, ACSOS 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 61–70. doi: 10.1109/ACSOS55765.2022.00024.
- [77] “MiR Fleet Enterprise Documentation,” 2025. [Online]. Available: www.mobile-industrial-robots.com
- [78] “MIR Fleet - Reference guide,” Mar. 2025. Accessed: Mar. 16, 2025. [Online]. Available: https://www.hmi-mbs.fr/wp-content/uploads/2020/07/notice-mir_fleet_reference_guide_12_en.pdf
- [79] “KUKA Engineering Software KUKA.AMR Fleet 2.11 Operating and Programming Instructions,” 2025. Accessed: Mar. 18, 2025. [Online]. Available: <https://kuka.sharefile.eu/d-se039c1b9b0eb4643a6bca9e211a35e37>
- [80] “KUKA Autonomous Mobile Robots KMP 1500P series Transport Vehicle Operating Instructions,” 2024. Accessed: Mar. 18, 2025. [Online]. Available: <https://kuka.sharefile.eu/d-se039c1b9b0eb4643a6bca9e211a35e37>
- [81] “OMRON - Advanced Robotics Control Language Fleet Manager-Mobile Robots Integration Guide,” 2019. Accessed: Mar. 18, 2025. [Online]. Available: <https://industrial.omron.pl/pl/products/fleet-manager#downloads>
- [82] “OMRON - Fleet Operations Workspace Core User’s Manual,” Mar. 2025. Accessed: Mar. 16, 2025. [Online]. Available: https://files.omron.eu/downloads/latest/manual/en/i635_fleet_operations_workspace_core_-_user_guide_users_manual_en.pdf?v=1
- [83] “Agilox - System Specification,” 2025.
- [84] “AGLILOX Energy Management Specification,” 2025.

- [85] “AGILOX - Mission Management Specification,” 2025.
- [86] “Orbit Boston Dynamics -Documentation,” https://dev.bostondynamics.com/docs/concepts/orbit/about_orbit. Accessed: Jul. 31, 2025. [Online]. Available: https://dev.bostondynamics.com/docs/concepts/orbit/about_orbit
- [87] “Formant - Documentation,” <https://docs.formant.io/docs/getting-started-overview>.
- [88] “InOrbit -Developer Portal”.
- [89] “InOrbit.ai - documentation,” 2025, Accessed: Jul. 31, 2025. [Online]. Available: <https://www.inorbit.ai/>
- [90] “BlueBotics Support Portal.” Accessed: Aug. 18, 2025. [Online]. Available: <https://support.bluebotics.com/support/login>
- [91] J. R. Mollá, “Robotics Middleware Framework - Practical guide to implement OpenRMF in multi-robot environments,” Mar. 2025. Accessed: Mar. 16, 2025. [Online]. Available: https://rua.ua.es/dspace/bitstream/10045/145599/1/Manual_de_uso_de_la_libreria_OpenRMF_para_control_de_siste_Romero_Molla_Joel.pdf
- [92] “OpenRMF Documentation,” <https://openrmf.readthedocs.io/en/latest/>.
- [93] K. Góra, G. Granosik, and B. Cybulski, “Energy Utilization Prediction Techniques for Heterogeneous Mobile Robots: A Review,” Jul. 01, 2024, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/en17133256.
- [94] M. Wesselhöft, J. Hinckeldeyn, and J. Kreutzfeldt, “Controlling Fleets of Autonomous Mobile Robots with Reinforcement Learning: A Brief Survey,” *Robotics*, vol. 11, no. 5, Oct. 2022, doi: 10.3390/robotics11050085.
- [95] A. M. Valenzuela and F. B. Noguera, “Task Allocation in Mobile Robot Fleets: A review,” 2025. [Online]. Available: <https://orcid.org/0000-0002-9234-5377>
- [96] T. M. J. T. Baltussen, M. Goutham, M. Menon, S. G. Garrow, M. Santillo, and S. Stockar, “A Parallel Monte-Carlo Tree Search-Based Metaheuristic For Optimal Fleet Composition Considering Vehicle Routing Using Branch & Bound,” in *IEEE Intelligent Vehicles Symposium, Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/IV55152.2023.10186562.
- [97] D. McNulty, A. Hennessy, M. Li, E. Armstrong, and K. M. Ryan, “A review of Li-ion batteries for autonomous mobile robots: Perspectives and outlook for the future,” Oct. 15, 2022, *Elsevier B.V.* doi: 10.1016/j.jpowsour.2022.231943.
- [98] B. Erdogan, Q. V. Dang, M. Mohammadi, and I. Adan, “MANUFACTURING INTRALOGISTICS CONCEPTS FOR A BATTERY ASSEMBLY LINE,” in *Proceedings - Winter Simulation Conference*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 1645–1656. doi: 10.1109/WSC63780.2024.10838857.
- [99] C. Rema, P. Costa, M. Silva, and E. J. S. Pires, “Task Scheduling with Mobile Robots—A Systematic Literature Review,” *Robotics*, vol. 14, no. 6, p. 75, May 2025, doi: 10.3390/robotics14060075.
- [100] “KMP 1500 The solution for a flexible production process - datasheet,” 2022. Accessed: Mar. 22, 2025. [Online]. Available: <https://www.kuka.com/event/media?itemId=90C5CED8F2884B048A026BD98A4AEB73#:~:text=Battery%20capacity%2052Ah%2F96%20V%20,Charging%20time%202%C2%A0hours>

- [101] T. Mikołajczyk *et al.*, “Energy Sources of Mobile Robot Power Systems: A Systematic Review and Comparison of Efficiency,” Jul. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/app13137547.
- [102] “MiR100-Data sheet MiR100 for automation of in-house transport and logistics solutions Specifications,” 2018. [Online]. Available: <http://mirrobots.com>
- [103] “OMRON AMR (Autonomous Mobile Robot) MD Series - datasheet,” 2024. Accessed: Mar. 22, 2025. [Online]. Available: https://www.ia.omron.com/data_pdf/cat/md_i885-e_2_1_csm1126872.pdf?id=3664#:~:text=Recharge%20Time%2019,Automatic%20or%20manual%20Ambient%20Operating
- [104] “Agilox ONE - datasheet,” 2024. Accessed: Mar. 22, 2025. [Online]. Available: https://www.agilox.net/media/data_sheet_one_a4_en.pdf#:~:text=24%2F7%20operations%20without%20changing%20the,via%20the%20AGILOX%20JSON%20API
- [105] Q. Yu *et al.*, “An open circuit voltage model fusion method for state of charge estimation of lithium-ion batteries,” *Energies (Basel)*, vol. 14, no. 7, Apr. 2021, doi: 10.3390/en14071797.
- [106] S. Karna, P. R. Satpathy, and P. Bhowmik, “Enhanced State of Charge Estimation for Lithiumion Batteries using Polynomial Voltage Approximation,” in *3rd Odisha International Conference on Electrical Power Engineering, Communication and Computing Technology, ODICON 2024*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ODICON62106.2024.10797595.
- [107] B. Xu, A. Oudalov, A. Ulbig, G. Andersson, and D. S. Kirschen, “Modeling of lithium-ion battery degradation for cell life assessment,” *IEEE Trans Smart Grid*, vol. 9, no. 2, pp. 1131–1140, 2018, doi: 10.1109/TSG.2016.2578950.
- [108] A. Ashraf, A. A. Sobaih, and E. Nabil, “Battery Management System Performance Enhancement using Single Sliding Mode Based Charge Equalization Controller,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Dec. 2021. doi: 10.1088/1742-6596/2128/1/012026.
- [109] T. Verstraten, M. S. Hosen, M. Berecibar, and B. Vanderborght, “Selecting Suitable Battery Technologies for Untethered Robot,” Jul. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/en16134904.
- [110] M. Assi and M. Amer, “A Comparative Analysis of Lithium-Ion Batteries Using a Proposed Electrothermal Model Based on Numerical Simulation,” *World Electric Vehicle Journal*, vol. 16, no. 2, Feb. 2025, doi: 10.3390/wevj16020060.
- [111] V. Bobanac, H. Bašićbašić, and H. P. Pandžić, “ONE-WAY VOLTAIC AND ENERGY EFFICIENCY ANALYSIS FOR LITHIUM-ION BATTERIES,” 2022.
- [112] M. U. Anjum, M. Khalid, and U. Manzoor, “Energy Profiling for Wheeled Mobile Robots with LuGre Friction Model in a Realistic Simulation Framework,” in *Proceedings of the IEEE International Conference on Industrial Technology*, Institute of Electrical and Electronics Engineers Inc., 2024. doi: 10.1109/ICIT58233.2024.10540789.
- [113] P. Kumar, I. Bensekrane, and R. Merzouki, “Power Consumption Modeling of Wheeled Mobile Robots With Multiple Driving Modes,” *IEEE Transactions on Industrial Electronics*, vol. 70, no. 10, pp. 10282–10291, Oct. 2023, doi: 10.1109/TIE.2022.3217603.
- [114] S. Fadlo, A. A. Elmahjoub, and N. Rabbah, “Energy performance analysis of a differential wheeled mobile robot with fuzzy logic controller,” in *2021 IEEE International IOT, Electronics*

- and Mechatronics Conference, *IEMTRONICS 2021 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., Apr. 2021. doi: 10.1109/IEMTRONICS52119.2021.9422631.
- [115] K. Góra, M. Kujawinski, D. Wroński, and G. Granosik, “Comparison of energy prediction algorithms for differential and skid-steer drive mobile robots on different ground surfaces,” *Energies (Basel)*, vol. 14, no. 20, Oct. 2021, doi: 10.3390/en14206722.
 - [116] M. Meißner and L. Massalski, “Modeling the electrical power and energy consumption of automated guided vehicles to improve the energy efficiency of production systems,” *International Journal of Advanced Manufacturing Technology*, vol. 110, no. 1–2, pp. 481–498, Sep. 2020, doi: 10.1007/s00170-020-05796-8.
 - [117] V. Mageshkumar, A. Baxi, V. Natarajan, and G. S. Murthy, “Adaptive Energy Optimization for Edge-Enabled Autonomous Mobile Robots,” in *2024 16th International Conference on COMMunication Systems and NETworkS, COMSNETS 2024*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 117–122. doi: 10.1109/COMSNETS59351.2024.10427411.
 - [118] R. Parasuraman, K. Kershaw, P. Pagala, and M. Ferre, “Model Based On-line Energy Prediction System for Semi-Autonomous Mobile Robots,” 2014. Accessed: Apr. 06, 2025. [Online]. Available: <https://ieeexplore.ieee.org/document/7280945>
 - [119] L. Hou, F. Zhou, K. Kim, and L. Zhang, “Practical model for energy consumption analysis of omnidirectional mobile robot,” *Sensors*, vol. 21, no. 5, pp. 1–18, Mar. 2021, doi: 10.3390/s21051800.
 - [120] S. Fadlo, N. Rabbah, and A. A. Elmahjoub, “Energy Modeling for a Differential Guide Mobile Robot Using Simscape,” in *2020 International Symposium on Advanced Electrical and Communication Technologies, ISAECT 2020*, Institute of Electrical and Electronics Engineers Inc., Nov. 2020. doi: 10.1109/ISAECT50560.2020.9523652.
 - [121] G. Gürgöze and İ. Türkoğlu, “A novel energy consumption model for autonomous mobile robot,” *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 30, no. 1, pp. 216–232, 2022, doi: 10.3906/elk-2103-15.
 - [122] R. Niestrój, T. Rogala, and W. Skarka, “An energy consumption model for designing an AGV energy storage system with a PEMFC stack,” *Energies (Basel)*, vol. 13, no. 13, Jul. 2020, doi: 10.3390/en13133435.
 - [123] M. Sperling and K. Furmans, “Energy Requirement Modeling for Automated Guided Vehicles Considering Material Flow and Layout Data,” *Designs (Basel)*, vol. 8, no. 3, Jun. 2024, doi: 10.3390/designs8030048.
 - [124] J. Pentzer, S. Brennan, and K. Reichard, “On-line estimation of power model parameters for skid-steer robots with applications in mission energy use prediction,” *J Field Robot*, vol. 39, no. 6, pp. 763–782, Sep. 2022, doi: 10.1002/rob.22076.
 - [125] Merlin Stampa, Christof Röhrig, Frank Künemund, and Daniel Heß, *Estimation of Energy Consumption on Arbitrary Trajectories of an Omnidirectional Automated Guided Vehicle*. IEEE, 2015. doi: 10.1109/IDAACS.2015.7341429.
 - [126] S. Liu and D. Sun, “Minimizing energy consumption of wheeled mobile robots via optimal motion planning,” *IEEE/ASME Transactions on Mechatronics*, vol. 19, no. 2, pp. 401–411, 2014, doi: 10.1109/TMECH.2013.2241777.

- [127] Oguzhan Guclu and Ahmet Burak Can, "A Comparison of Feature Detectors and Descriptors in RGB-D SLAM Methods," Jul. 2015, Accessed: Feb. 23, 2025. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-319-20801-5_32
- [128] H. Abdelaty, A. Al-Obaidi, M. Mohamed, and H. E. Z. Farag, "Machine learning prediction models for battery-electric bus energy consumption in transit," *Transp Res D Transp Environ*, vol. 96, Jul. 2021, doi: 10.1016/j.trd.2021.102868.
- [129] L. Caballero, Á. Perafan, M. Rinaldy, and W. Percybrooks, "Predicting the energy consumption of a robot in an exploration task using optimized neural networks," *Electronics (Switzerland)*, vol. 10, no. 8, Apr. 2021, doi: 10.3390/electronics10080920.
- [130] M. Visca, R. Powell, Y. Gao, and S. Fallah, "Probabilistic Meta-Conv1D Driving Energy Prediction for Mobile Robots in Unstructured Terrains," *IEEE Access*, vol. 10, pp. 107913–107928, 2022, doi: 10.1109/ACCESS.2022.3209259.
- [131] S. Yanyong, P. Konghuayrob, P. Chaisiri, and S. Kaitwanidvilai, "Energy Prediction of Cleanroom-type Differential Drive Mobile Robot Based on Recurrent Neural Network," *Sensors and Materials*, vol. 35, no. 4, pp. 1497–1508, 2023, doi: 10.18494/SAM4263.
- [132] Z. Li, J. Xin, and N. Li, "End-To-End Autonomous Exploration for Mobile Robots in Unknown Environments through Deep Reinforcement Learning," in *2022 IEEE International Conference on Real-Time Computing and Robotics, RCAR 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 475–480. doi: 10.1109/RCAR54675.2022.9872253.
- [133] M. Zimmermann and F. Ziel, "Efficient mid-term forecasting of hourly electricity load using generalized additive models," *Appl Energy*, vol. 388, Jun. 2025, doi: 10.1016/j.apenergy.2025.125444.
- [134] P. Haji Ali Mohamadi, A. Khorasani, T. Verstraten, and B. Vanderborght, "A Hybrid Parameters Estimation Approach for Power Consumption Modeling of Ground Mobile Robots With Unknown Payload," *J Field Robot*, 2024, doi: 10.1002/rob.22470.
- [135] P. Benecki *et al.*, "Effective Prediction of Energy Consumption in Automated Guided Vehicles with Recurrent and Convolutional Neural Networks," in *Proceedings - 2023 IEEE International Conference on Big Data, BigData 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 5024–5030. doi: 10.1109/BigData59044.2023.10386359.
- [136] A. Gifalli *et al.*, "Forecasting Electricity Consumption Using Function Fitting Artificial Neural Networks and Regression Methods," *Applied System Innovation*, vol. 7, no. 5, Oct. 2024, doi: 10.3390/asi7050100.
- [137] P. Haji Ali Mohamadi, A. Khorasani, T. Verstraten, and B. Vanderborght, "A Hybrid Parameters Estimation Approach for Power Consumption Modeling of Ground Mobile Robots With Unknown Payload," *J Field Robot*, 2024, doi: 10.1002/rob.22470.
- [138] A. S. Prasetya, R. J. Wai, Y. L. Wen, and Y. K. Wang, "Mission-based energy consumption prediction of multirotor uav," *IEEE Access*, vol. 7, pp. 33055–33063, 2019, doi: 10.1109/ACCESS.2019.2903644.
- [139] J. Leng, J. Peng, J. Liu, Y. Zhang, J. Ji, and Y. Zhang, "Profiling Power Consumption in Low-Speed Autonomous Guided Vehicles," *IEEE Robot Autom Lett*, vol. 9, no. 7, pp. 6027–6034, Jul. 2024, doi: 10.1109/LRA.2024.3396051.

- [140] M. A. Atiea, A. M. Shaheen, A. Alassaf, and I. Alsaleh, "Enhanced Solar Power Prediction Models With Integrating Meteorological Data Toward Sustainable Energy Forecasting," *Int J Energy Res*, vol. 2024, no. 1, 2024, doi: 10.1155/er/8022398.
- [141] M. Choudhury and D. Das, "Bootstrapping Lasso in Generalized Linear Models," Apr. 2025, [Online]. Available: <http://arxiv.org/abs/2403.19515>
- [142] T. Ullmann, G. Heinze, L. Hafermann, C. Schilhart-Wallisch, and D. Dunkler, "Evaluating variable selection methods for multivariable regression models: A simulation study protocol," *PLoS One*, vol. 19, no. 8 August, Aug. 2024, doi: 10.1371/journal.pone.0308543.
- [143] G. Wei and M. Yu, "The variable selection methods and algorithms in the multiple linear model," *Commun Stat Theory Methods*, vol. 52, no. 17, pp. 6232–6240, 2023, doi: 10.1080/03610926.2022.2027449.
- [144] E. Nagy and Á. Török, "Comparison of Simulation- and Regression-Based Approaches to Estimating Electric Car Power Consumption," *Applied Sciences (Switzerland)*, vol. 15, no. 2, Jan. 2025, doi: 10.3390/app15020513.
- [145] J. Muraña, J. J. Durillo, and S. Nesmachnow, "UNDERSTANDING ENERGY CONSUMPTION TRENDS IN HIGH PERFORMANCE COMPUTING NODES," in *Proceedings - Winter Simulation Conference*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 2475–2486. doi: 10.1109/WSC63780.2024.10838774.
- [146] S. A. Sarswatula, T. Pugh, and V. Prabhu, "Modeling Energy Consumption Using Machine Learning," *Frontiers in Manufacturing Technology*, vol. 2, Jul. 2022, doi: 10.3389/fmtec.2022.855208.
- [147] B. Han, S. Zhang, L. Qin, X. Wang, Y. Liu, and Z. Li, "Comparison of Support Vector Machine, Gaussian Process Regression and Decision Tree Models for Energy Consumption Prediction of Campus Buildings," in *2022 8th International Conference on Hydraulic and Civil Engineering: Deep Space Intelligent Development and Utilization Forum, ICHCE 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 689–693. doi: 10.1109/ICHCE57331.2022.10042664.
- [148] E. Pintelas, I. E. Livieris, and P. Pintelas, "A Grey-Box ensemble model exploiting Black-Box accuracy and White-Box intrinsic interpretability," *Algorithms*, vol. 13, no. 1, Jan. 2020, doi: 10.3390/a13010017.
- [149] Y. Dang, J. Yao, and R. Zheng, "Multi-objective Optimization of Residential Energy Consumption Based on Machine Learning," in *2023 International Conference on Image Processing, Computer Vision and Machine Learning, ICICML 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 872–875. doi: 10.1109/ICICML60161.2023.10424813.
- [150] W. Cai, X. He, Y. Wu, J. Zhang, Y. Ran, and L. Li, "Research on energy consumption prediction model based on big data platform and random forest algorithm," in *Proceedings - 2022 International Conference on Data Analytics, Computing and Artificial Intelligence, ICDACAI 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 384–388. doi: 10.1109/ICDACAI57211.2022.00082.
- [151] H. A. Salman, A. Kalakech, and A. Steiti, "Random Forest Algorithm Overview," *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/bjml/2024/007.
- [152] P. Benecki, D. Kostrzewa, P. Grzesik, B. Shubyn, and D. Mrozek, "Forecasting of Energy Consumption for Anomaly Detection in Automated Guided Vehicles: Models and Feature Selection," in *Conference Proceedings - IEEE International Conference on Systems, Man and*

- Cybernetics*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 2073–2079. doi: 10.1109/SMC53654.2022.9945146.
- [153] M. Eder and G. Steinbauer-Wagner, “Predicting Energy Consumption and Traversal Time of Ground Robots for Outdoor Navigation on Multiple Types of Terrain,” Aug. 2023, [Online]. Available: <http://arxiv.org/abs/2308.15978>
 - [154] M. Wei and V. Isler, “Predicting Energy Consumption of Ground Robots On Uneven Terrains,” 2022. doi: <https://doi.org/10.48550/arXiv.2212.06393>.
 - [155] M. Medykovskyy, R. Cupek, O. Pavliuk, and M. Mishchuk, “An approach towards AGV battery cell voltage prediction using DL and data pre-processing,” in *International Scientific and Technical Conference on Computer Sciences and Information Technologies*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/CSIT61576.2023.10324170.
 - [156] Y. Zhong, C. Yang, X. Su, B. Li, X. Huang, and Y. Shuai, “Review on Research of Automated Machine Learning,” in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Dec. 2023, pp. 526–532. doi: 10.1145/3638584.3638678.
 - [157] L. Quaranta, K. Azevedo, F. Calefato, and M. Kalinowski, “A multivocal literature review on the benefits and limitations of industry-leading AutoML tools,” Feb. 01, 2025, *Elsevier B.V.* doi: 10.1016/j.infsof.2024.107608.
 - [158] A. M. Del Valle, R. G. Mantovani, and R. Cerri, “A systematic literature review on AutoML for multi-target learning tasks,” *Artif Intell Rev*, vol. 56, pp. 2013–2052, Nov. 2023, doi: 10.1007/s10462-023-10569-2.
 - [159] K. Witvoet, S. Saad, C. Vidal, R. Ahmed, and A. Emadi, “Electric Vehicle’s Range and State of Charge Estimations using AutoML,” in *2023 IEEE Transportation Electrification Conference and Expo, ITEC 2023*, Institute of Electrical and Electronics Engineers Inc., 2023. doi: 10.1109/ITEC55900.2023.10186953.
 - [160] N. Alkhulaifi, A. L. Bowler, D. Pekaslan, I. Triguero, and N. J. Watson, “Exploring Automated Feature Engineering for Energy Consumption Forecasting with AutoML,” in *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, Institute of Electrical and Electronics Engineers Inc., 2024, pp. 2993–2998. doi: 10.1109/SMC54092.2024.10831959.
 - [161] G. Sakayori and G. Ishigami, “Energy-aware trajectory planning for planetary rovers,” *Advanced Robotics*, vol. 35, no. 21–22, pp. 1302–1316, 2021, doi: 10.1080/01691864.2021.1959396.
 - [162] Y.-W. Huang, C. Prehofer, W. Lindskog, R. Puts, P. Mosca, and G. Kauermann, “Predictive Energy Management for Battery Electric Vehicles with Hybrid Models,” May 2024, doi: 10.1007/978-3-031-30855-0_13.
 - [163] Q. Zhu, Y. Huang, C. F. Lee, P. Liu, J. Zhang, and T. Wik, “Predicting Electric Vehicle Energy Consumption from Field Data Using Machine Learning,” *IEEE Transactions on Transportation Electrification*, 2024, doi: 10.1109/TTE.2024.3416532.
 - [164] H. Mediouni, A. Ezzouhri, Z. Charouh, K. El Harouri, S. El Hani, and M. Ghogho, “Energy Consumption Prediction and Analysis for Electric Vehicles: A Hybrid Approach,” *Energies (Basel)*, vol. 15, no. 17, Sep. 2022, doi: 10.3390/en15176490.
 - [165] J. Liu, P. Borja, and C. Della Santina, “Physics-Informed Neural Networks to Model and Control Robots: A Theoretical and Experimental Investigation,” *Advanced Intelligent Systems*, vol. 6, no. 5, May 2024, doi: 10.1002/aisy.202300385.

- [166] Z. Yan, H. Ji, and Q. Chang, “Energy Consumption Minimization of Quadraped Robot Based on Reinforcement Learning of DDPG Algorithm,” *Actuators*, vol. 13, no. 1, Jan. 2024, doi: 10.3390/act13010018.
- [167] J. Heredia, K. Zielinski, C. Schlette, and M. B. Kjargaard, “Empowering Cobots with Energy Models: Real Augmented Digital Twin Cobot with Accurate Energy Consumption Model,” in *IEEE International Workshop on Robot and Human Communication, RO-MAN*, IEEE Computer Society, 2023, pp. 1353–1359. doi: 10.1109/RO-MAN57019.2023.10309614.
- [168] J. Xu, J. Han, H. Zhu, and Q. Zheng, “Study on the Prediction of Consumer Electricity Consumption Based on Hybrid Model,” in *5th IEEE Conference on Energy Internet and Energy System Integration: Energy Internet for Carbon Neutrality, EI2 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 3340–3346. doi: 10.1109/EI252483.2021.9713206.
- [169] M. Sakib, T. Siddiqui, S. Mustajab, R. M. Alotaibi, N. M. Alshareef, and M. Z. Khan, “An ensemble deep learning framework for energy demand forecasting using genetic algorithm-based feature selection,” *PLoS One*, vol. 20, no. 1, Jan. 2025, doi: 10.1371/journal.pone.0310465.
- [170] P. Petersen, T. Rudolf, and E. Sax, “A Data-driven Energy Estimation based on the Mixture of Experts Method for Battery Electric Vehicles,” in *International Conference on Vehicle Technology and Intelligent Transport Systems, VEHITS - Proceedings*, Science and Technology Publications, Lda, 2022, pp. 384–390. doi: 10.5220/0011081000003191.
- [171] Mirosław Krajewski, “O METODOLOGII NAUK I ZASADACH PISARSTWA NAUKOWEGO,” 2020.
- [172] Dr. Sanjeevreddy K. Hudgikar, “Research methods for engineers,” 2021.
- [173] M. Kuhn and K. Johnson, “Applied Predictive Modeling,” 2016.
- [174] JOHN W. CRESWELL, “Design Qualitative, Quantitative, and Mixed Methods Approaches,” 2014.
- [175] Forrest Shull Janice Singer Dag I.K. Sjøberg (Eds), “Guide to Advanced Empirical Software Engineering,” 2008.
- [176] U. Department of Computer Science University of Durham Durham, “Guidelines for performing Systematic Literature Reviews in Software Engineering,” 2007.
- [177] L. Liu, R. Zhong, A. Willcock, N. Fisher, and W. Shi, “An Open Approach to Energy-Efficient Autonomous Mobile Robots,” in *Proceedings - IEEE International Conference on Robotics and Automation*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 11569–11575. doi: 10.1109/ICRA48891.2023.10161110.
- [178] J. Y. . Wong, *Theory of ground vehicles*. John Wiley, 2001.
- [179] M. Ehsani, S. Longo, Y. Gao, and K. Ebrahimi, “Modern Electric, Hybrid Electric, and Fuel Cell Vehicles - THIRD EDITION,” 2018. [Online]. Available: <http://taylorandfrancis.com>
- [180] D. C. . Montgomery, *Design and Analysis of Experiments, EMEA Edition, 9th Edition*. John Wiley & Sons, Inc., 2020. Accessed: Aug. 25, 2025. [Online]. Available: <https://www.wiley.com/en-ie/Design+and+Analysis+of+Experiments%2C+EMEA+Edition%2C+9th+Edition-p-9781119638421>
- [181] Douglas C. Montgomery and George C. Runger, “Applied Statistics and Probability for Engineering,” 2014.

- [182] A. Schommer, D. D. Sciortino, D. Morrey, and G. Collier, “Experimental investigation of power available in lithium-ion batteries,” *J Power Sources*, vol. 618, Oct. 2024, doi: 10.1016/j.jpowsour.2024.235168.
- [183] K. Furmans, Z. Seibold, and A. Trenkle, “Future Technologies in Intralogistics and Material Handling,” in *Lecture Notes in Logistics*, Springer Science and Business Media B.V., 2019, pp. 545–574. doi: 10.1007/978-3-319-92447-2_24.
- [184] K. Krot, G. Iskierka, B. Poskart, and A. Gola, “Predictive Monitoring System for Autonomous Mobile Robots Battery Management using the Industrial Internet of Things Technology,” *Materials*, vol. 14, 2021, doi: 10.3390/xxxxx.
- [185] B. Poskart, G. Iskierka, K. Krot, R. Burduk, P. Gwizdal, and A. Gola, “Multi-Parameter Predictive Model of Mobile Robot’s Battery Discharge for Intelligent Mission Planning in Multi-Robot Systems,” *Sensors*, vol. 22, no. 24, Dec. 2022, doi: 10.3390/s22249861.
- [186] B. Poskart, G. Iskierka, K. Krot, B. Telesiński, and J. Husár, “Forecasting the Feasibility of Autonomous Mobile Robots Performing Tasks Using AutoML,” 2024, pp. 409–419. doi: 10.1007/978-3-031-62684-5_36.